

UNIVERZITA PARDUBICE

DOPRAVNÍ FAKULTA JANA PERNERA

**DETEKCE SILNIČNÍCH VOZIDEL
V OBRAZE**

DIZERTAČNÍ PRÁCE

2008

Ing. Martin Dobrovolný

UNIVERZITA PARDUBICE
DOPRAVNÍ FAKULTA JANA PERNERA

KATEDRA ELEKTROTECHNIKY, ELEKTRONIKY
A ZABEZPEČOVACÍ TECHNIKY V DOPRAVĚ

DETEKCE SILNIČNÍCH VOZIDEL
V OBRAZE

DIZERTAČNÍ PRÁCE

AUTOR: Ing. Martin Dobrovolný

ŠKOLITEL: Doc. Ing. Simeon Karamazov, Dr.

2008

UNIVERSITY OF PARDUBICE
JAN PERNER TRANSPORT FACULTY

**DEPARTMENT OF ELECTRICAL AND ELECTRONIC
ENGINEERING AND SIGNALLING IN TRANSPORT**

**ON-ROAD VEHICLE DETECTION
BASED ON IMAGE PROCESSING**

THESIS

AUTHOR: Ing. Martin Dobrovolný

SUPERVISOR: Doc. Ing. Simeon Karamazov, Dr.

2008

ZADÁNÍ ZE STAGU

ZADÁNÍ ZE STAGU

Poděkování

Na tomto místě bych chtěl vyjádřit poděkování svému školiteli, panu Doc. Ing. Simeonu Karamazovovi, Dr., za jeho vedení během mého postgraduálního studia. Také bych chtěl velmi rád poděkovat panu Prof. Ing. Pavlu Bezouškovi, CSc. za jeho rady, cenné podněty a připomínky, které mi často pomáhaly během studia i při zpracování této práce.

V neposlední řadě patří můj dík všem pracovníkům v mém okolí a také mým rodičům, kteří mi vytvořili vhodné podmínky pro napsání této dizertační práce.

V Pardubicích dne 28. března 2008

Ing. Martin Dobrovolný

Souhrn

Práce se zabývá technikami nízkourovňové segmentace obrazu a technikami detekce objektů v obraze využitelnými v systémech automatického vedení vozidel, tedy systémů tvořících podskupinu široké oblasti nazývané dnes inteligentní dopravní systémy. Popisované metody využívají obrazu snímaného kamerou umístěnou v přední části vozidla, jež sleduje dopravní situaci před vozidlem. V práci je představeno několik původních metod zpracování obrazu, jejichž cílem je detekce obrysů vozidel, pohybujících se před vozidlem a vozidel míjejících toto vozidlo. Vytvořené metody tvoří základ kamerových systémů detekce vozidel. Takto získané informace o výskytu ostatních vozidel v obraze mohou být ve spolupráci s nadstavbovými systémy sledování pohybu objektů a ve fúzi s dalšími např. radarovými systémy využity v systémech ACC (Adaptive Cruise Control - systémy autonomního vedení vozidla).

Klíčová slova:

Zpracování obrazu, ACC systémy, segmentace shlukováním K-means, Houghova transformace, detekce symetrie, kumulativní metoda, algoritmy 2D korelace a SAD.

Summary

This thesis deals with low-level image segmentation methods and with object detection methods in picture, convenient for exploitation in automatic cruise control systems belonging to the so called Intelligent Transport Systems. The described methods exploit the output of a video camera, situated at the vehicle and scanning the situation in front of it. In the thesis several new methods of image processing are introduced for vehicle contour detection, moving in front of, or passing the camera equipped vehicle. These methods could form a base for further development of camera systems for vehicle detection. The acquired information on vehicle occurrence in the picture could be then used in accordance with further (for inst. radar) sensors in a higher control system as an ACC (Adaptive Cruise Control) system.

Keywords:

Image processing, ACC systems, K-means clustering, The Hough transform, The symmetry detection, The cumulative method, 2D correlation, 2D SAD algorithm.

Obsah

1 ÚVOD.....	3
2 CÍLE PRÁCE.....	5
3 STRUKTURA PRÁCE.....	6
4 INTELIGENTNÍ DOPRAVNÍ SYSTÉMY.....	7
4.1 Architektura Inteligentních dopravních systémů.....	8
4.2 Obrazová část palubních systémů vedení vozidla.....	10
5 OBRAZOVÁ ČÁST ACC SYSTÉMŮ – SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY.....	11
6 PŘÍPRAVA VSTUPNÍCH DAT.....	14
6.1 Typ použitého snímacího zařízení.....	16
6.1.1 Parametry snímacího zařízení.....	17
6.1.2 Použité nástroje.....	18
6.2 Předzpracování vstupních dat.....	20
7 ZPRACOVÁNÍ OBRAZU.....	26
7.1 Detekce vozovky.....	27
7.1.1 Detekce pomocí histogramu jasové složky.....	27
7.1.2 Detekce v barevném modelu HSV.....	31
7.1.3 Segmentace shlukováním.....	36
7.1.4 Algoritmus K-means (MacQueenova metoda).....	41
7.1.5 Víceparametrické shlukování K-means.....	49
7.2 Detekce vozidel.....	60
7.2.1 Odhad polohy vozidel na základě vlastností masky vozovky.....	60

7.2.2	Detekce objektů porovnáním se vzory.....	63
7.2.3	Detekce vozidel s využitím Houghovy transformace.....	69
	Aplikace Houghovy transformace v segmentaci obrazu.....	72
	Detekce vozidel s využitím symetrie objektů.....	77
7.2.4	Aplikace detekce symetrických objektů v oblasti detekce vozidel.....	79
7.2.5	Kumulativní metoda vyhledávání obrysů vozidel.....	90
8	ZÁVĚR.....	101
9	SEZNAM LITERATURY.....	103
	Vybrané publikace autora:.....	109
10	SEZNAM ZKRATEK A SYMBOLŮ.....	110
11	SEZNAM ILUSTRACÍ.....	113

1 Úvod

Jednou z motivací k napsání této práce byl neutěšený stav na pozemních komunikacích. Doprava, zejména silniční čelí v dnešní době negativnímu trendu značného nárůstu nehodovosti. Tento fakt souvisí se vzrůstající hustotou dopravy i se zvyšujícími se rychlostmi vozidel. Rozbory dopravních nehod vypovídají o tom, že ztráta kontroly řidiče nad vozidlem v době bezprostředně předcházející nehodě, hraje klíčovou roli v následcích dopravních nehod. Významným aktivním prvkem, který v budoucnu značnou měrou přispěje ke zvýšení bezpečnosti provozu na komunikacích a snížení následků dopravních nehod, budou inteligentní systémy podpory řízení. Tyto systémy již dnes vykonávají řadu důležitých podpůrných funkcí a zvyšují nejen bezpečnost, ale i komfort cestování. Svě provozní informace přitom tyto systémy získávají mnoha způsoby. V současnosti převažují systémy získávající informace zejména z radarových snímačů, případně z dalších čidel nesených vozidlem, sledujících dění v okolí vozidla.

Jednou z nejzajímavějších částí těchto systémů jsou však systémy snímání dopravní situace před vozidlem a v okolí vozidla prostřednictvím kamerových snímačů, vyhodnocujících objekty nacházející se v dopravní scéně. Tyto systémy sbírají data o bezprostředním dění v okolí vozidla a ve spojení s dalšími systémy mohou upozorňovat řidiče na hrozící nebezpečí, či dokonce samy aktivně zasahovat do řízení vozidla. Systémy zpracování obrazové informace mají značnou perspektivu v oblasti bezpečnostních systémů a mohou poskytovat velké množství přesných informací. Jedná se však o nejsložitější systémy získávání informací s vysokým stupněm inherentní inteligence a tomu odpovídá i jejich doposud nízké zastoupení v oblasti elektroniky vozidel.

Tato práce vychází z přehledu současného stavu v oblasti inteligentních dopravních systémů, využívajících obrazových systému sledování vozidel. V práci je navrženo několik konkrétních nízkourovňových algoritmů detekce vozovky, vozidel a pozadí, tedy základních prvků tvořících celkovou dopravní scénu. Zvláštní pozornost je věnována zejména detekci obrysů vozidel, pohybujících se proměnnými rychlostmi. Tato problematika je obzvláště ztížena nestacionárním charakterem pozadí dopravní scény s velmi proměnnými parametry, které značně komplikují aplikaci klasických postupů obrazové detekce objektů.

Práce se opírá o nové poznatky v oblasti rozpoznávání obrazu a aplikuje je do dopravní oblasti. Problematika rozpoznávání vozidel pomocí zpracování obrazu patří v současné době k nejdynamičtěji se rozvíjejícím částem automobilových bezpečnostních

systemů a je jí věnována zvýšená pozornost všemi předními firmami zabývajícími se dopravní technikou i předními světovými univerzitami.

2 Cíle práce

V současné době jsou systémy schopné spolehlivé detekce pohybujících se vozidel v dopravní scéně stále ještě ve fázi vývoje a jejich spolehlivost zdaleka neumožňuje jejich masovou aplikaci ve vozidlech. Přední světový výrobci a vývojové týmy univerzit intenzivně řeší zejména problematiku přesného a jednoznačného vyhodnocení a klasifikace jednotlivých objektů a jejich identifikaci v komplexní dopravní scéně. Přestože již existuje řada postupů nízkourovňové detekce vozidel, zůstává ještě stále značný prostor v oblasti návrhu alternativních a z hlediska rychlosti optimalizovaných postupů.

Vývoj nízkourovňových segmentačních postupů je také primární podmínkou, nutnou pro možnost úspěšného vývoje nadstavbových sledovacích a klasifikačních postupů vyšších úrovní. Vzhledem k tomu, že tato problematika nebyla dosud na naší univerzitě řešena, zaměřuje se tato práce právě na oblast segmentačních postupů.

Cílem dizertační práce je tedy návrh skupiny algoritmů nízkourovňové detekce objektů v obraze, u systémů využívajících snímání dopravní situace před vozidlem kamerou. Práce se zaměřuje zejména na tyto body:

- analýza současného stavu řešené problematiky
- výchozí rozbor použitelných postupů obrazové detekce v dopravní oblasti
- shromáždění souboru vstupních obrazových dat, jejich předzpracování a vhodné rozčlenění
- návrh algoritmů detekce základních prvků tvořících scénu, jako jsou vozovka, či pozadí s objekty s využitím statistických metod
- vlastní detekce vozidel
- algoritmy zpřesnění tvaru a pozice vozidel
- rozbor vlastností uvedených metod

Výsledkem práce by měl být modelový návrh algoritmů, umožňujících detekci vozidel v obraze a rozbor vlastností těchto metod. Navržené metody budou vyvíjeny a ověřovány především v programovém prostředí *MATLAB* pod operačním systémem *Microsoft Windows*.

Vyvinuté metody by měly tvořit základní soubor nízkourovňových algoritmů, využitelných v systému detekce vozidel, na nějž bude možné navázat dalším výzkumem zejména v oblasti vyhodnocování polohy vozidel v reálné dopravní scéně.

3 Struktura práce

V první části práce je analyzován současný stav řešené problematiky. Jsou zde rozebrány v současné době používané dopravní inteligentní systémy sledující dopravní situaci v okolí vozidla se zaměřením na systémy využívající obrazového snímání. Podrobnější popis je věnován zejména používaným technikám zpracování obrazu a jejich výsledkům. V této části práce je dále rozebrán současný stav řešené problematiky v komerční i univerzitní sféře.

V kapitole nazvané Příprava vstupních dat je popsán způsob získání obrazových dat, jež byla použita při vývoji jednotlivých algoritmů a jejich rozřídění do jednotlivých skupin reprezentujících dopravní situace. Je zde popsán i původní vyvinutý software, umožňující rozřídění, hromadné přejmenovávání a kompresi jednotlivých snímků pro možnost zpracování v programovém prostředí *MATLAB*.

V kapitole Zpracování obrazu jsou v první části popsány jednotlivé metody barevné i jasové segmentace obrazu a metody získávání masek reprezentujících jednotlivé části scény s využitím statistického přístupu. Dále jsou v následujících kapitolách popsány jednotlivé metody, umožňující extrakci obrysů vozidel, či středů vozidel pohybujících se před vozidlem se snímací kamerou. Zvláštní pozornost je věnována možnostem využití charakteristických vlastností vozidel, jako je symetrie, předpokládaný tvar obrysů, či odezva stínu vozidla v průběhu masky reprezentující vozovku pod vozidlem.

V závěru každé z kapitol jsou diskutovány dosažené výsledky navržených metod a jejich vlastnosti.

4 Inteligentní dopravní systémy

Analýzy příčin dopravních nehod vypovídají o tom, že ztráta kontroly řidiče nad vozidlem v době bezprostředně předcházející nehodě, hraje klíčovou roli v následcích těchto nehod. Prvkem, který v budoucnu značnou měrou přispěje ke zvýšení bezpečnosti provozu na komunikacích a snížení následků dopravních nehod, budou inteligentní systémy podpory řízení - **IDS**¹. Tyto systémy již dnes vykonávají řadu důležitých podpůrných funkcí a zvyšují nejen bezpečnost, ale i komfort cestování. Jedná se například o systémy brzdění, včasného varování před překážkami na vozovce, předávání informací z vozidla na vozidlo, centrální distribuce informací a mnohé další. Tyto systémy dále mohou zvýšit vhodným způsobem propustnost stávajících komunikací vhodným řízením kolon vozidel a ve spojení s dalšími nadřízenými systémy mohou například upozorňovat řidiče na nejvhodnější trasu. Primární úlohou bezpečnostní části těchto systémů je však poskytnutí většího množství času na přípravu bezpečnostních prvků před vlastní havárií, či nejlépe zamezení krizové situace vedoucí k havárii vozidla.

Sekundární, avšak do budoucnosti jistě perspektivní rolí těchto systémů jsou vlastnosti umožňující autonomní vedení vozidla po komunikacích. Tyto systémy jsou souhrnně nazývány **ACC**² – systémy autonomního, či adaptivního vedení vozidla a s využitím fúze všech dostupných technologií tvoří část *IDS* systémů integrovaných ve vozidlech.

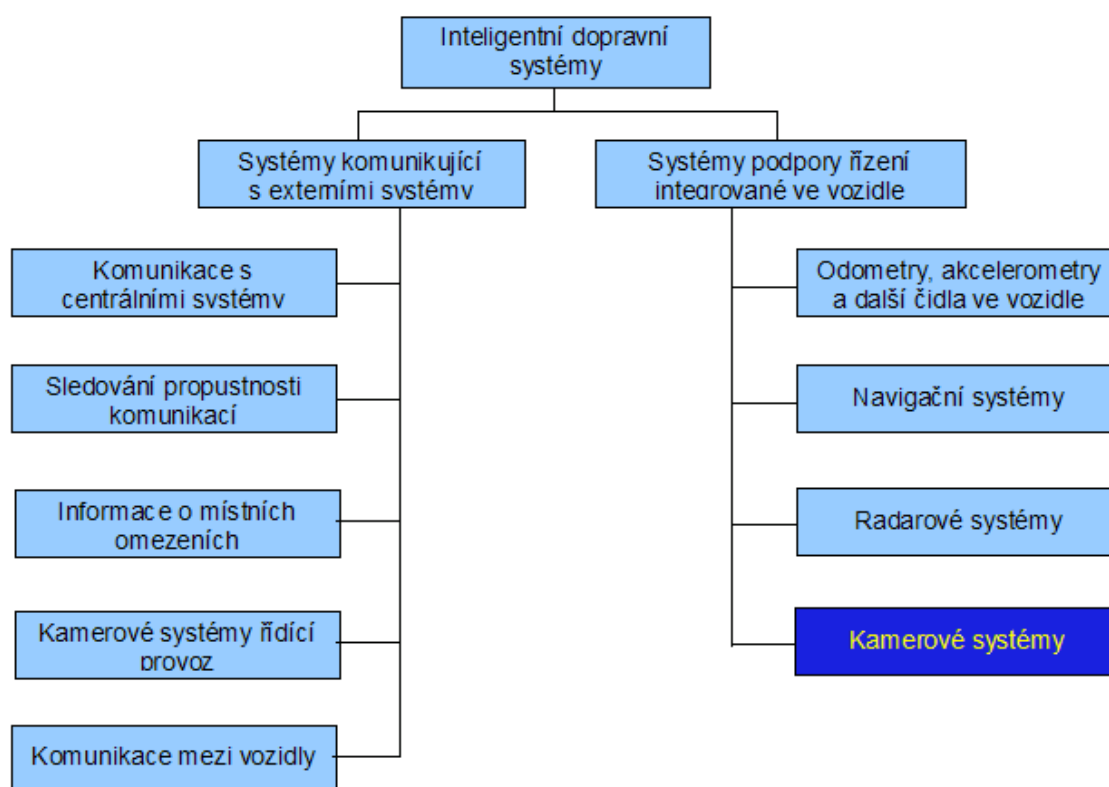
¹ ITS/IDS - Intelligent Transport Systems, inteligentní dopravní systémy

² ACC - Adaptive Cruise Control, systémy adaptivního vedení vozidla

4.1 Architektura Inteligentních dopravních systémů

Inteligentní dopravní systémy (IDS) jsou tvořeny mnoha relativně samostatnými částmi. Tyto subsystémy byly dosud používány odděleně a teprve v posledních letech se objevují komplexní systémy tvořené fúzí těchto částí [13]. Inteligentní dopravní systémy je možné rozdělit na dvě významné části podle dislokace jejich dominantních funkcí (Obr. 1):

- **externí systémy** – zajišťující především komunikaci vozidel mezi sebou či komunikaci vozidla s centrálními stacionárními zdroji informací (navigace vozidel, informace o stavu trasy, jako je např. propustnost komunikace, či výskyt momentálních překážek. Tyto systémy také mohou zajišťovat předávání informací mezi jednotlivými vozidly)
- **interní systémy** – zaměřené na vyhodnocování dopravní situace v bezprostředním okolí vozidla a sloužící primárně pro vyhodnocení a případně i zabránění nebezpečným situacím. Tyto systémy jsou obecně řazeny mezi palubní elektronické systémy a jsou nazývány *IDA*³ (inteligentní asistenti řízení)



Obr. 1: Architektura Inteligentních dopravních systémů

³ IDA - Intelligent Driver Assistant, inteligentní asistenti řízení

V současnosti používané prvky pasivní bezpečnosti automobilu mají na zajištění ochrany cestujících v případě nárazu vozidla řádově desítky milisekund. Jejich činnost je zahájena teprve při překročení prahové hodnoty tíhového zrychlení, zatímco u významného podílu dopravních nehod uplynou i sekundy od vzniku kritické situace než dojde k vlastnímu nárazu. Těto časové prodlevy lze využít k maximální přípravě ochranných funkcí vozidla, doplněných o další bezpečnostní opatření. Právě tato funkce je dominantní úlohou moderních interních palubních systémů. Asistenční systémy tohoto typu jsou často nazývány protisrážkovými systémy (*Pre-State* či *Pre-Crash*) a vycházejí z včasného rozpoznání nebezpečné kolizní situace na základě informací z celé řady čidel. Podle povahy avizovaného nebezpečí se pak mohou například v předstihu aktivovat ochranné bezpečnostní systémy (např. předpínače bezpečnostních pásů, ochranné oblouky, či brzdový systém. Sedadla se mohou formovat do optimální bezpečnější polohy v níž jsou bezpečnostní pásy a airbagy neúčinnější a nejlépe zvládají směr a sílu očekávaného nárazu a mnohé další).

Palubní systémy získávají většinu informací o bezprostředním okolí vozidla v současné době zejména třemi základními způsoby:

- z radarových systémů umístěných v přední, či zadní části vozidla
- ze snímačů zrychlení, snímačů ABS, odometrů a dalších čidel ve vozidle
- a nově také z kamerových systémů, sledujících dění v okolí vozidla

Zatímco technologie radarových systémů či systémů využívajících pasivních snímačů je již poměrně zvládnutá a konečné produkty lze najít ve formě příplatkové výbavy vozidel mnoha automobilek, technologie kamerových systémů je zatím zejména pro nároky na složitost vyhodnocovacích algoritmů stále ve stádiu vývoje.

Tato práce se zaměřuje na jednu z nejzajímavějších částí těchto systémů, kterou jsou právě systémy snímání dopravní situace před vozidlem a v okolí vozidla prostřednictvím kamerových systémů a na vyhodnocování objektů nacházejících se v dopravní scéně. Pro spolehlivou a efektivní funkci těchto systémů je nutné zabezpečit získávání a vyhodnocování značného množství informací o bezprostředním okolí vozidla v reálném čase. Jen tak mohou tyto systémy ve spojení s dalšími vyššími celky spolehlivě upozorňovat řidiče na hrozící nebezpečí, či dokonce samy aktivně zasahovat do řízení vozidla. Systémy zpracovávající obrazovou informaci mají značnou perspektivu v této oblasti a mohou poskytovat velké množství přesných informací. Jedná se však o nejsložitější systémy získávání informací, vyžadující značně sofistikované algoritmy vyhodnocování, pro správné porozumění obsahu snímané obrazové informace.

4.2 Obrazová část palubních systémů vedení vozidla

Palubní systémy zpracovávající obrazovou informaci poskytují velké množství informací. Tyto informace mohou být využity v celé řadě oblastí. V současné době se jedná zejména o systémy:

- inteligentního vedení vozidla (ACC – Adaptive Cruise Control)
- detekce překážek náhle se vyskytujících v trase vozidla
- systémy automatického dodržování bezpečné vzdálenosti mezi vozidly
- distribuovaného řízení kolon vozidel
- systémy *stop&go* – systémy regulující pojezd a zastavování vozidel v hustém městském provozu
- systémy detekce svislého a vodorovného dopravního značení
- systémy detekce optických dopravních návěstí

Z tohoto přehledu, který jistě není zdaleka úplný je vidět široké spektrum možností uplatnění kamerových systémů a s tím spjatých problémů. Podstatou funkce všech výše zmíněných systémů je však správné porozumění snímané obrazové informaci, reprezentující dopravní scénu. Pro každý z výše uvedených systémů jsou rozhodující odlišné subjekty vyskytující se v obraze. Jednou ze společných vlastností téměř všech výše zmíněných systémů je však spolehlivá detekce jízdní trasy vozidla, okolních vozidel, překážek a dalších částí tvořících komplexní dopravní situaci.

Následující část práce se věnuje specializovanému, avšak velmi důležitému problému detekce vozidel, vyskytujících se před vozidlem nesoucím snímací zařízení. Úspěšné vyřešení problému detekce vozidel je jedním ze vstupních předpokladů vybudování rozsáhlého a komplexního systému autonomního vedení vozidla, kombinujícího v sobě bezpečnostní i komfortní prvky. Pokud se podaří úspěšně detekovat vozidla, jízdní trasu a ostatní překážky v trase vozidla je možné například ve fúzi s radarovými systémy jež jsou v našem týmu také řešeny, vytvořit skutečně komplexní systém.

Složitost problematiky však přesahuje bariéry jednoho oboru a svou komplexností zasahuje do mnoha zcela odlišných vědních disciplín. Proto věřím, že na práci naváží další výzkumné projekty, s jejichž pomocí se nakonec podaří vybudovat skutečně komplexní systém autonomního vedení vozidla.

5 Obrazová část ACC systémů – současný stav řešení problematiky

Jak již bylo uvedeno výše, jednou z nejkomplicovanějších částí systémů podpory řízení je část založená na zpracování obrazové informace. Proto je tato problematika v současné době intenzivně řešena na řadě vědeckých pracovišť a je i silně podporována předními světovými výrobci automobilové elektroniky. Pomocí vhodně umístěných kamer uvnitř vozidla i mimo vozidlo je možné predikovat situaci nastávající před vozidlem a upozorňovat tak řidiče například na překážky, či na dodržování vhodného odstupu. Tyto systémy tak přispívají nejen k vyšší bezpečnosti, ale také ke zvýšení komfortu a plynulosti dopravy.

Palubní systémy s kamerami zabudovanými uvnitř vozidla představují v podstatě inteligentní spolujezdce v automobilu - sledují řidiče, automobil, oblast před a za vozidlem, navigují a informují řidiče o výskytu kritických situací. Tento pohled přináší mnoho oblastí aplikace takovýchto systémů. V současné době jsou například řešeny systémy automatického dodržování vhodného odstupu za následujícím vozidlem [37], jež byly doposud realizovány především radarovými senzory. V rámci projektu *IVHS* (Intelligent Vehicles Highway System) jsou v USA v současné době řešeny systémy upozorňující řidiče (zejména dálkové nákladní dopravy) na vyjetí ze svého pruhu na dálnici [13], Protisrážkové systémy [25], systémy detekce přechodů pro chodce [21], systémy detekce křižovatek podle vodících čar [35], či detekce dopravních značek [16], semaforů a mnohé další aplikace obrazového rozpoznávání dopravní scény.

V této oblasti je v současné době řešeno velké množství dílčích problémů. Zásadním problémem je nestacionarita pozadí, tvořícího dopravní scénu. Problematika detekce vozidel na nestacionárním pozadí je řešena např. v. [10]. Typickým řešením používaným v oblasti obrazů s nestacionárním pozadím je detekce pomocí optického toku [11], [12] s předpokladem nízkého optického toku v oblasti objektů oproti optickému toku pozadí. V projektu [10] je řešena detekce vozidel externí otáčející se kamerou, která sleduje parkovací plochu s dobře popsatelnou funkcí pohybu pozadí. Bohužel v případě systémů detekce vozidel snímači umístěnými ve vozidle nevede tento způsob, vzhledem k axonometrickému zkreslení, k uspokojivým výsledkům. U obrazu snímaném z pohybuujícího se vozidla se optický tok lineárně snižuje směrem do axonometrického středu obrazu. Objekty v oblasti blízké středu obrazu (ve velké vzdálenosti) jsou tak obklopeny oblastí s takřka nulovým

optickým tokem. Také optický tok oblastí nad horizontem obrazu je z principu poměru vzdáleností velmi nízký. Tyto skutečnosti téměř vylučují použití metod optického toku na celou dopravní scénu a detekce optického toku je tak vhodná pouze pro blízkou oblast. V kapitole [7.2.7](#) je tento postup využit například pro zpřesnění obrysů vozidla.

Stěžejním předpokladem úspěšné detekce vozidel je přesné určení tvaru a průběhu vozovky. Objekty nacházející se mimo oblast vozovky je možné z detekce vozidel vyloučit. Naopak při znalosti průběhu vozovky je možné určit předpokládaná místa vstupu vozidel do záběru snímací kamery. Zejména z těchto důvodů je detekci jízdní trasy věnováno značné úsilí. Převážná většina publikací se věnuje detekci a predikci dálničních úseků, pro něž jsou především vyvíjeny systémy autonomního vedení vozidla. Složitost běžných komunikací (zejména v intravilánu) zatím značně ztěžuje vytvoření spolehlivého modelu průběhu okrajů vozovky [43], [14], [15]. K detekci vozovky je přistupováno mnoha způsoby. Používány jsou nejjednodušší metody prahování, či hranové detekce [5]. Tyto metody se však často vyznačují značnou nadsegmentací. Pro snížení nadsegmentace je prováděna detekce v odlišných barevných modelech, například v *HSV* modelu [5]. Z použití vhodných barevných modelů profitují zejména aplikace pro detekci jízdní trasy v terénu [17], či ve speciálních podmínkách, jako je například sledování trasy po předchozím vozidle ve sněhu [18]. Tyto problémy jsou společné i aplikacím autonomního pohybu robotů v terénu [19], [20].

S detekcí jízdní trasy na pozemních komunikacích souvisejí i další úkoly rozpoznávání, jako je detekce vodorovného značení [21], či detekce přechodů pro chodce a dalších útvarů [22]. V pracích [34] a [36] je řešena detekce vodících bílých čar na krajnici a čar oddělujících jednotlivé jízdní pruhy. Detekce vodících čar umožňuje jednak vedení vozidla a dále je základem pro rozčlenění perspektivních překážek před vozidlem na víceproudých vozovkách. Tento problém je v současnost řešen nejčastěji pomocí specializovaných infra snímačů na okrajích vozidla, detekujících vodící čáry. Tyto metody byly úspěšně odzkoušeny na kvalitních rychlostních komunikacích s dokonalým značením v západní Evropě a v USA. Bohužel metody selhávají na vozovkách bez kvalitně vyznačených vodících čar, což je zejména problém komunikací nižších tříd. Aplikace obrazových snímačů zřejmě umožní využití i v případě nespojitého značení na méně kvalitně značených komunikacích.

Ukazuje se, že pro detekci jízdní trasy je nutné volit sofistikovanější postupy segmentace založené např. na metodách barevné segmentace [23], či metodách shlukování [24].

Algoritmy detekce vozidel využívají celé řady postupů extrakce charakteristických rysů vozidel. V současné době je detekce prováděna nejčastěji oddělenou separací

vertikálních a horizontálních hran vozidla [25], [26], což je velmi rychlý postup. Jeho značnou nevýhodou je však nutnost potlačovat značnou nadsegmentaci a dále komplikovaný výpočet segmentačních prahů pro rychle se měnící prostředí. Postupy založené na hranové detekci dále vyžadují značně složité modely tvarů vozidel pro následnou klasifikaci objektů [26], [27].

Někteří autoři si všímají charakteristické, avšak obtížně popsatelné vlastnosti vozidel, již je produkce různě situovaných stínů na vozovce [28], [29]. Snaha o detekci jejich zdrojů však naráží na složitost predikčního modelu popisujícího vztah mezi zdrojem stínu, zdrojem osvětlení scény a vrženým stínem. Také popis kontur stínů je velmi složitý. Z těchto důvodů jsou práce detekující stíny vozidel zaměřeny zejména na systémy se statickými snímači.

Další skupina prací se snaží detekovat vozidla nalezením shody charakteristických částí vozidel se skupinou vzorů v různém měřítku a v různém natočení [31], [32]. Pro správnou funkci těchto algoritmů je nutné řešit správný výběr vzorů a jejich modifikace. Vyhledávání pak probíhá nejčastěji výpočtem korelace. Volba počáteční skupiny vzorů v těchto případech ovlivňuje nejen spolehlivost, ale i rychlost porovnání. Příliš rozsáhlý výběr vzorů snižuje rychlost výpočtů pod akceptovatelnou hranici [33].

Detekce vozidel (ať již jedoucích souhlasně, či v opačném směru) je tedy nosnou částí většiny systémů autonomního vedení vozidla. Správné rozpoznání okolních vozidel je nutnou podmínkou budování dalších nadstavbových částí těchto systémů. Zdá se, že zatím zůstávají v této oblasti nevyužity některé segmentační postupy využívané v jiných oblastech aplikace zpracování obrazu.

Práce vychází ze současných poznatků segmentace vozidel a snaží se aplikovat segmentační postupy využívané v jiných oblastech zpracování obrazu jako jsou například detekce symetrie objektů, či detekce s využitím některých druhů integrálních transformací, nebo sofistikovaných metod shlukování do oblasti detekce vozidel.

6 Příprava vstupních dat

Nutnou podmínkou pro vývoj systému sledování vozidel bylo shromáždění a předzpracování dostatečného množství dat, reprezentujících dopravní situace v běžném provozu. Během první fáze projektu byl proto vytvořen systém pro snímání dat z reálné dopravní situace. Podstatnou se v této fázi ukázala volba vhodné snímací kamery a její umístění ve vozidle. Volba pozice a uchycení snímací kamery může do značné míry negativně i pozitivně ovlivnit parametry pořízených dat. Nevhodné umístění ve vnější části vozidla má za následek zvýšené ovlivňování snímací soustavy vnějšími vlivy (děšť, prach...), které se projeví zvýšením šumu ve snímaných datech. Výhodou takového umístění (zejména umístění na přední části vozidla) je snímání s nulovou elevací, což snižuje prostorové zkreslení v obraze (Obr. 2), [37].



Obr. 2: Příklad komplexní dopravní situace snímané s malou elevací

Při experimentálním ověření se ukázalo, že umístění kamery do přední části vozidla vyžaduje značné mechanické úpravy vozidla, což naráží na finanční a zejména legislativní problémy. Kamera by také musela být v provedení určeném pro trvalé externí použití. Při umístění snímací kamery na vozidle bylo také nutné řešit problematiku uchycení kamery a s tím související vibrace celého snímacího zařízení. Z těchto důvodů jsem volil umístění vhodné digitální kamery v interiéru osobního vozidla (Obr. 3) podobně jako v [43], [14], či [5].



Obr. 3: Umístění snímací kamery v měřícím vozidle, [25]

Jako nejvhodnější pozici jsem pro monokulární systém posléze vybral střed vozidla, v oblasti za čelním sklem na palubní desce vozidla. Toto řešení má výhodu v možnosti operativnějších zásahů do ovládání kamery či případného spolupracujícího zařízení. Toto umístění také umožňuje použití standardní typů kamer a zajišťuje dobrou viditelnost i při zhoršených podmínkách viditelnosti díky stěračům čelního skla.

Při uchycení bylo nutno vyřešit problémy způsobované vibracemi vozidla. Z těchto důvodů byla použita kamera disponující funkcí potlačení vibrací obrazu. Několikrát bylo také upraveno uchycení kamery k palubní desce vozidla. Tyto kroky vedly k celkovému zlepšení kvality obrazu na přijatelnou úroveň. Dalšího zlepšení by bylo možné případně dosáhnout předúpravou obrazových dat některým z algoritmů stabilizace obrazu [38], [39].

6.1 Typ použitého snímacího zařízení

Použitý typ kamery a optické soustavy rozhoduje o přesnosti, s jakou budou pořízena data, tedy o kvalitě vstupních dat a jejich vhodnosti pro další zpracování. Mezi nejdůležitější parametry patří rozlišení a pozorovací úhel. Například při použití snímací kamery s rozlišením 320 obrazových bodů horizontálně a pozorovacím úhlu 90°, reprezentuje ve vzdálenosti 50m před vozidlem jeden obrazový bod 0,31m. Automobil o šířce 1,8m bude v horizontálním směru reprezentován pouze necelými 6 obrazovými body. U složitějších segmentačních algoritmů to již bude znamenat omezení. Řešením je použití kamer s vyšší rozlišovací schopností, či kamer s nižším pozorovacím úhlem. V [13] je použito více kamer, z nichž některé sledují oblast těsně před vozidlem do vzdáleností cca. 20m a další jsou zaměřeny s nižším úhlem záběru do vzdálené oblasti. Vzhledem k tomu, že se primárně zaměřím na vyvinutí algoritmů detekce obrysů vozidel jedoucích v souhlasném směru, není předpoklad, že by výše popsané problémy s rozlišením ve vzdálenějších oblastech byly omezením. Nižší rozlišení ve vzdálenějších oblastech se pouze projeví jako zpoždění detekce vozidel přibližujících se v opačném směru.

V případě jedné kamery dále mohou vznikat problémy s fixním zaostřením na určitou vzdálenost. V tomto je nejvhodnější použít kameru s automatickým zaostřováním, případně s fixním zaostřením, například 2 m - ∞ .



Obr. 4: Snímací kamera použitá pro snímání vstupních dat

V projektu jsem použil snímací kameru SONY typ TRV130E (Obr. 4), pro některé své charakteristické vlastnosti. Základní rozlišení, ve kterém jsou produkována obrazová data je 720 x 576 obrazových bodů ve formátu RGB při použití 8bitových AD převodníků. Kamera je dále vybavena automatickým ostřením obrazu a systémem automatického vyrovnávání citlivosti.

Pro účely analýzy a dalšího zpracování obrazových dat byla snímaná data v kameře ukládána ve formě digitálního záznamu na mg. pásek. Obraz byl posléze převeden na video soubory ve formátu *avi*⁴ za použití bezztrátového kompresního kodeku *miroDV2avi*.

Tento postup umožnil pozdější analýzu nasnímaných dat, bez nutnosti opakovaných měření v terénu. Celkově bylo pořízeno více, než 20GB obrazových dat čítajících více než 100tis. snímků.

6.1.1 Parametry snímacího zařízení

Přesnost vyhodnocení dopravní situace má úzkou souvislost s obnovovací frekvencí snímaného obrazu. V případě, že by bylo požadováno určování polohy statických objektů (například při použití stereoskopického snímání), je minimální nepřesnost v určení polohy závislá na rychlosti vozidla a rychlosti zpracování obrazové informace. Většina současných publikovaných modelů pracuje s rychlostmi vyhodnocování nižšími než 5 snímků/s (*fps*). Při rychlostech nad 100 km/h již vozidlo ujede větší dráhu, než je délka jednoho vozidla. V Tab. 1 jsou červeně označeny nevyhovující kombinace rychlostí vozidla a rychlosti zpracování (nepřesnost > 3m). V případě určování polohy vozidel jedoucích proti vlastnímu vozidlu závisí vzdálenosti dále na rychlosti těchto vozidel.

Rychlost vozidla	Frekvence vyhodnocování				
	1 fps	2,5 fps	10 fps	25 fps	30fps
		**		PAL	NTSC
5 km/h*	1,4 m	0,6m	0,14m	0,06m	0,05m
30 km/h	8,3m	3,3m	0,83m	0,33m	0,28m
60 km/h	16,6m	6,6m	1,7m	0,67m	0,56m
100 km/h	27,8m	11,1m	2,8m	1,11m	0,93m
120 km/h	33,3m	13,3m	3,3m	1,33m	1,11m

Tab. 1: Vliv obnovovací frekvence obrazu a relativní rychlosti na dosažitelnou přesnost (nedostatečně označeny červeně)

* typická průměrná rychlost pro Stop&go systémy

** běžné rychlosti snímků/s (*fps*) dosahované současnými modely

V projektu jsem použil snímání vstupních dat s frekvencí 50 pulsů/s, což umožňuje dosáhnout při rychlosti 100 km/h prostorového odstupu mezi snímky zhruba 1 m.

⁴ *avi* - Audio Video Interleave

Při vývoji byla zpracovávána data zaznamenaná v průběhu měření, což mimo jiné umožnilo volit proměnnou snímkovou rychlost v závislosti na složitosti algoritmů a době jejich trvání.

Zvolená kamera dále umožňuje snímat obraz v barevném, či černobílém režimu, přičemž v černobílém režimu je citlivost snímacího prvku vyšší. V tomto režimu by bylo také možné realizovat přisvětlování dopravní scény zdrojem infračerveného záření. V první fázi projektu však byla data snímána barevně, což umožnilo aplikovat metody barevné segmentace.

Připojení snímací kamery k počítači bylo realizováno pomocí rozhraní *IEEE 1394 (FireWire)*. Ke komunikaci videokamery s programovým kompletem *MATLAB* byly využity nástroje *Image Acquisition toolbox*.

6.1.2 Použité nástroje

V průběhu práce jsem využil postupně několik nástrojů. Pro zpracování nasnímaných dat jsem v integrovaném programovém prostředí *Borland DELPHI* vyvinul program pro automatizovaný převod jednotlivých snímků z videoformátu *avi* komprimovaného kodekem *miroDV2avi* do formátu jednotlivých snímků s volitelným stupněm komprese. Důvodem byla neschopnost programového prostředí *MATLAB* a nadstavbového software *SIMULINK* (dále jen *MATLAB*) vyčítat jednotlivé snímky z komprimovaných videosouborů. Tato možnost se objevila až s příchodem *MATLABu* verze 7.0.

Pro implementaci algoritmů počítačového vidění jsem dále využil programového prostředí *MATLAB* ve verzi 7.0, včetně těchto doplňkových modulů:

- *Image Processing Toolbox*
- *Image Acquisition Toolbox*
- *Video and Image Processing Blockset*

Výhodou použití zmíněných modulů byla možnost používat v algoritmech počítačového vidění rychlé předkompilované funkce algoritmů techniky zpracování obrazu. Modul *Image Acquisition Toolbox* navíc umožnil propojit programové prostředí *MATLAB* s rozličnými typy kamer komunikujících prostřednictvím rozhraní *IEEE 1394* a *USB*.

Programové prostředí *MATLAB* se ukázalo pro analýzu obrazu velmi vhodné svým maticově orientovaným přístupem. Ve spojení s maticově orientovanými algoritmy zpracování obrazu tak bylo možné dosáhnout značné rychlosti zpracování dvourozměrných obrazových dat.

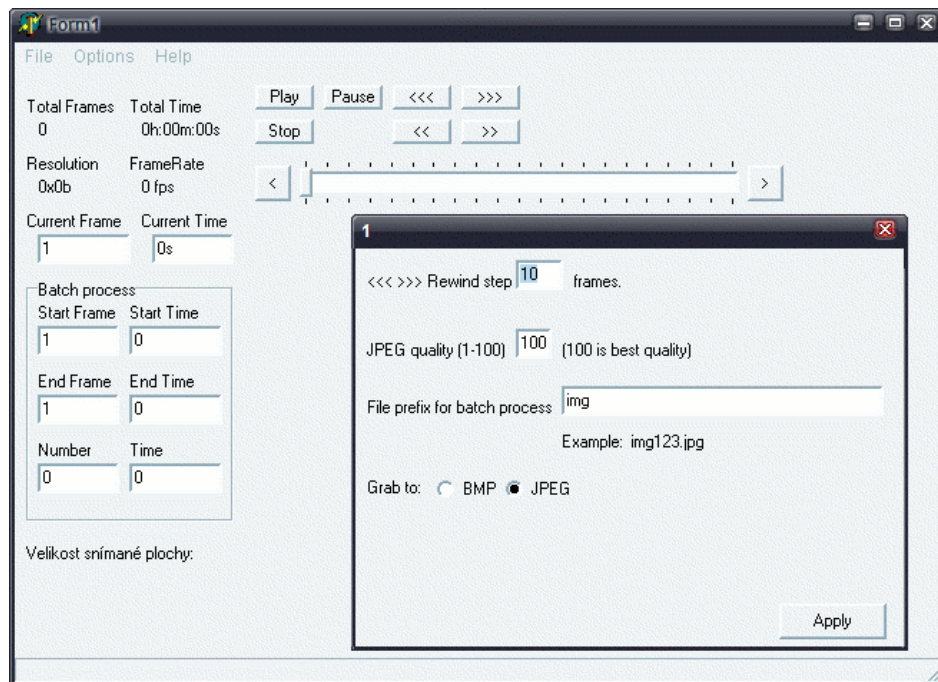
Během práce jsem s výhodou využil i dalších nástrojů, například vynikajícího integrovaného prostředí *VirtualDUB* vyvíjeného pod licencí *GNU*. Tento nástroj sloužil zejména ke stříhu videodat, odstranění prokládání a k aplikaci filtrů.

Pro manipulaci se vstupními daty jsem vyvinul některé další nástroje, které budou krátce představeny v následující kapitole.

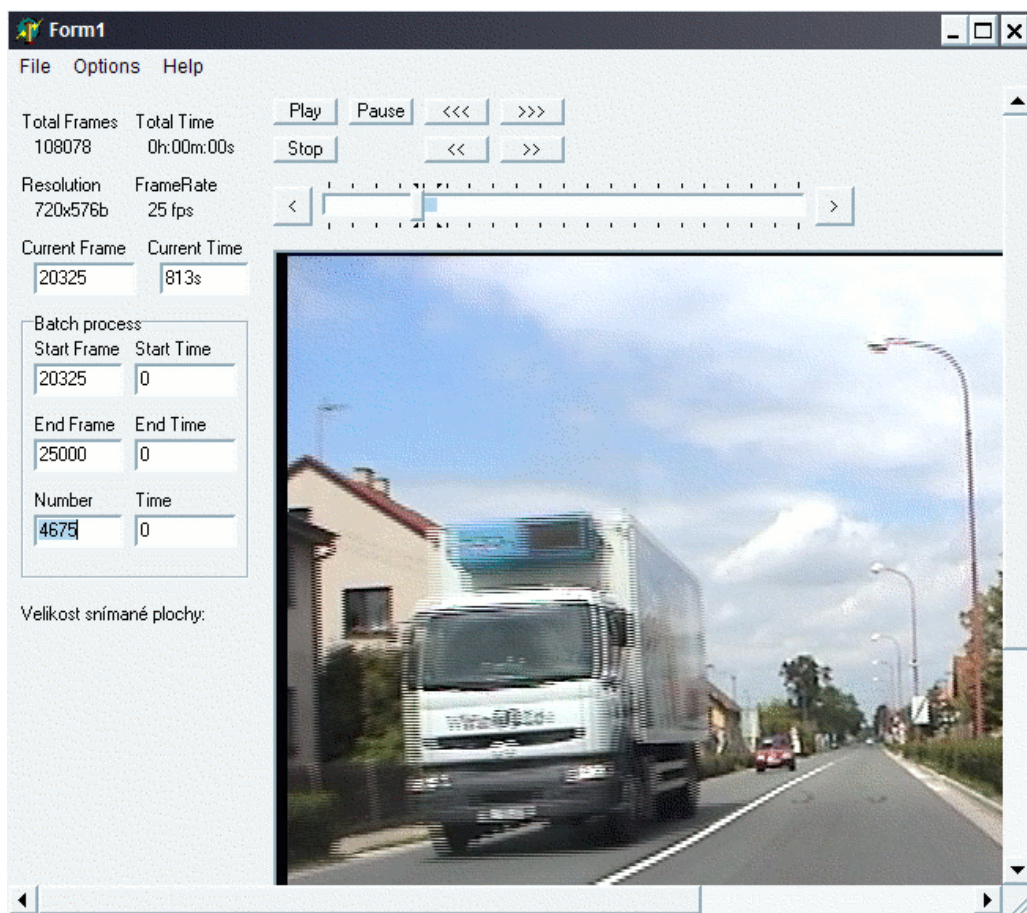
6.2 Předzpracování vstupních dat

Nasnímaná data reprezentující reálné dopravní situace jsem podrobil předzpracování, s cílem snížit výpočetní náročnost detekčních algoritmů a zvýšit pravděpodobnost detekce objektů. Techniky předzpracování dat byly realizovány pro některé části nasnímaných dat společně, pro urychlení práce s jednotlivými úseky dat. Některé algoritmy ale provádějí dále popsané postupy i samostatně, z důvodu současného přístupu k datům v neupravené podobě.

Při pořizování zdrojových dat jsem nashromáždil přes 20 GB obrazových dat s televizním rozlišením 720 x 576 obrazových bodů. Pro vlastní vývoj systému v prostředí *MATLAB* bylo nutné všechna data předpřipavit. Obrazový materiál byl při přenosu ze snímací kamery komprimován obrazovým kodekem *miroDV2avi*. Vzniklo tak několik větších datových souborů se záznamy jízd. Tyto záznamy byly rozříděny podle obsahu reprezentované dopravní scény (sledování jednoho vozidla, více vozidel, otevřené prostranství, městská zástavba, situace na křižovatkách...). Bohužel programové prostředí *MATLAB* až do verze 6 neumožňovalo přímý přístup k jednotlivým snímkům v komprimovaném videu. Proto jsem vyvinul program *avi2jpg* (Obr. 5, Obr. 6) umožňující automatizovaný převod vybraného segmentu videozáznamů do snímků komprimovaných diskretní kosinovou transformací (*JPEG*). Tyto snímky již bylo možné bez větších problémů načítat do proměnných v prostředí *MATLAB*.




Obr. 5: „avi2jpg“ – program pro automatizovaný převod video sekvencí do jednotlivých bmp / jpeg snímků



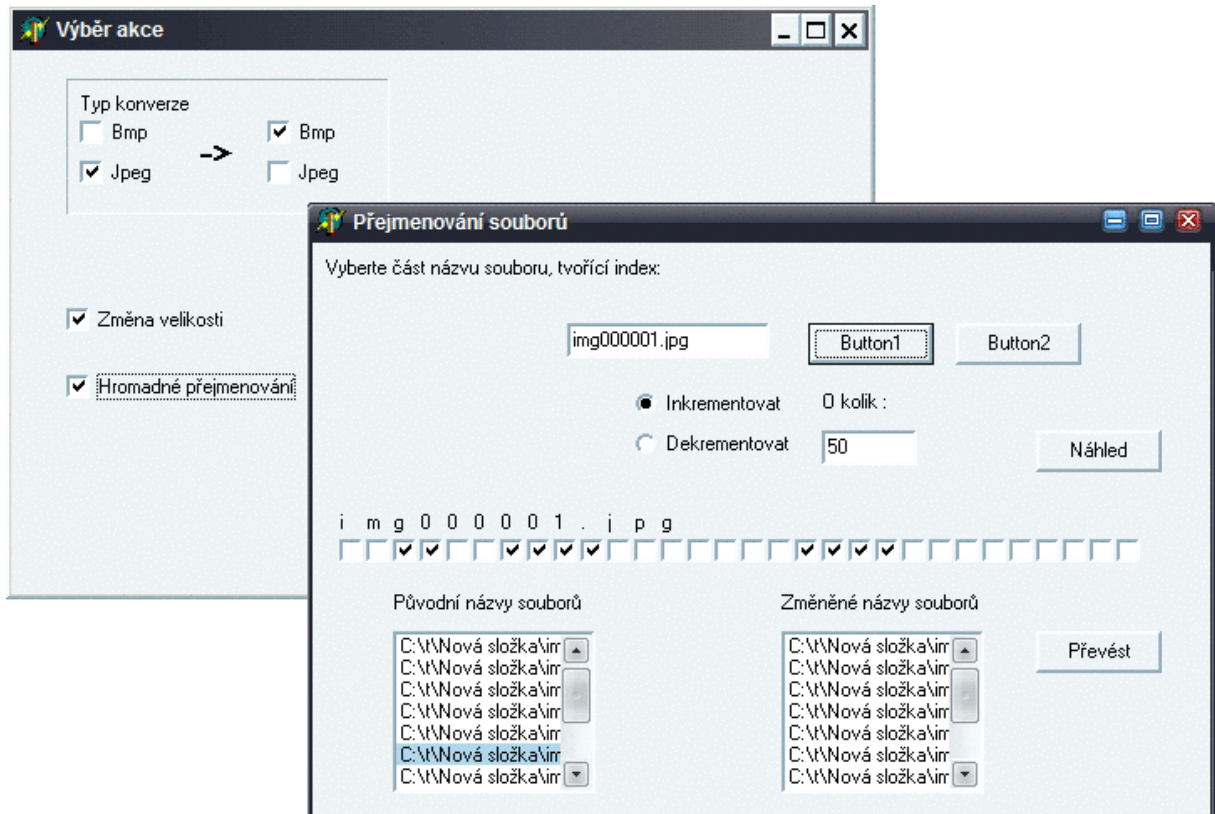
Obr. 6: „avi2jpg“ – výběr video sekvence pro převod do jpeg snímků

Pro snazší manipulaci s velkým množstvím malých souborů (scéna v délce 3 min je tvořena téměř 5 tisíci soubory) jsem dále vyvinul další program *bmp2jpg* (Obr. 7) pro automatizované převody snímků do a z komprimované podoby, hromadné přejmenovávání, změny úrovně ztrátové komprese a posuny offsetů jmen souborů (Obr. 8).

Pomocí těchto nástrojů již bylo možné připravit a v průběhu vývoje měnit skupiny snímků, reprezentujících právě analyzovanou část dopravní situace.



Obr. 7: „bmp2jpg“ - výběr sekvence snímků



Obr. 8: „bmp2jpg“ - možnosti změn v rámci jména souboru

Takto načtené snímky byly podrobovány některým dalším operacím, které jsou společné téměř všem modulům:

- datový formát *UINT8* je převeden do nativního formátu *MATLABu double*, což vede ke značnému urychlení výpočtů
- ze snímků je ořezána nepotřebná informace (část karoserie vozidla)
- na videodatech jsou provedeny *deinterlace*⁵ techniky
- snímky jsou transformovány do rozlišení 256 x 256 obrazových bodů (zejména z důvodů urychlení výpočtů algoritmů *FFT*⁶), Toto rozlišení je kompromisem mezi náročností zpracování (je třeba zpracovávat 3 x 256² obrazových bodů v případě barevné segmentace) a ztrátou informace obsažené v obraze
- u snímků je ekvalizován průběh jasové složky

S příchodem prostředí *MATLAB 7* a zejména *Image Acquisition toolboxu*, bylo možné (pouze v prostředí operačního systému *Windows*) vyčítat jednotlivé snímky pomocí funkce *aviread* přímo z komprimovaného videa (za předpokladu správně nainstalovaných dekompresních kodeků). Funkce umožňuje vyčtení jednoho snímku, či celé skupiny snímků. Bohužel, samotné vyčtení snímků trvá přibližně 1s⁷. Tento čas se nevhodně projevuje ve všech prezentovaných algoritmech, které tak nemohou pracovat v reálném čase. Jedním z řešení je načtení snímků do paměti před jejich zpracováním. *MATLAB* však ukládá snímky v proměnných v nekomprimované podobě a to způsobuje problémy s velikostí požadované paměti. Proto je při výpočtech použit první model, který ač je pomalejší, umožňuje flexibilní přístup k vybraným snímkům.

Datové soubory vytvořené profesionálním kodekem *miroDV2avi* obsahovaly původní data získaná z digitální kamery. Jejich značnou nevýhodou však byla velikost dosahující 20 GB. Tato velikost ztěžovala manipulaci a komplikovala načítání jednotlivých snímků do prostředí *MATLAB*.

Pro zjednodušení manipulace se vstupními daty jsem obrazové soubory převedl do formy obrazových videodat komprimovaných ztrátovým kompresním kodekem s jádrem využívajícím diskrétní kosinovou transformaci. Vhodnou volbou kvantovacích koeficientů jsem dosáhl akceptovatelné degradace obrazu při výrazném snížení velikosti vstupních dat.

⁵ *deinterlace techniky* – techniky odstranění efektů vzniklých prokládáním obrazových pálsnímků

⁶ *FFT* – rychlá diskrétní Fourierova transformace

⁷ tento čas je způsoben nutností vyhledání předchozího I snímku a dopočítání *P* a *B* snímku v toku komprimovaných snímků [40]

Obrazová data ze snímací kamery byla ve formátu 50 pulsů s^{-1} . Při převodu bylo tedy řešeno také odstranění artefaktů vzniklých prokládáním pulsů. Na Obr. 9 je zobrazena reálná dopravní scéna s vozidlem pohybujícím se proti vozidlu se snímací kamerou. Tento příklad dokumentuje problém vznikající sloučením pulsů sejmутých v různých časech. Efekt je zvláště patrný u vozidel pohybujících se proti vozidlu se snímací kamerou. Problém je řešitelný několika způsoby. Nejčastějším řešením, používaným ve filmové technice je sloučení jednotlivých pulsů pomocí vhodného filtru (Obr. 10). Tyto postupy však využívají nedokonalosti lidského zraku a ve své podstatě vždy vedou k lokální degradaci obrazu, která je nejvíce patrná u rychle se pohybujících objektů.



Obr. 9: Efekt prokládání pulsů na rychle se pohybujícím objektu



Obr. 10: Nevhodné potlačení efektu prokládání (mediánový filtr)

Pro techniky detekce objektů v obraze tato degradace, která je nejčastěji ve formě lokálního rozmazání kontur objektu, představuje zásadní problém a vede ke snížení účinnosti segmentačních metod (zejména metod hledání hran v obraze). Z těchto důvodů byla volena metoda vynechání lichého pulsů. Tento postup sice vede k polovičnímu snížení vertikální informace obsažené v obraze, ale pozitivem je zachování maximální ostrosti obrazu (Obr. 11). Dalším pozitivem je, že tento postup neovlivňuje žádným dalším způsobem, například vyhlazovacími filtry, informaci obsaženou v obraze.



Obr. 11: Výsledný obraz (lichý pulsů)

Data získaná snímací kamerou také obsahovala v části záběru přídržné zařízení kamery a část vozidla. Tyto nepodstatné informace byly z obrazu vyjmuty.

Takto získaný obraz s rozlišením 720 x 288 obrazových bodů je následně ve většině modulů převáděn do rozlišení 256 x 256 obrazových bodů. Vzhledem k neracionálnímu poměru velikostí vstupních a výstupních obrazů je po převodu prováděna bilineární interpolace mezilehlých obrazových bodů.

Takto připravená data již slouží pro analýzu a vývoj jednotlivých detekčních metod.

7 Zpracování obrazu

Při zpracování obrazu v oblasti ACC systémů jsou obvykle prováděny segmentační postupy s cílem extrakce objektů, jimiž jsou obrysy automobilů a překážek. Tento projekt se zaměřuje zejména na detekci vozidel v dopravní scéně. Na segmentaci je možné nahlížet v podstatě třemi pohledy: Hledání regionů, kdy přiřazujeme obrazový bod části objektu či regionu. Hledání hranic oddělujících jednotlivé regiony a hledání hran v obraze, tedy hledání hraničních obrazových bodů a jejich spojování do hranic oddělujících jednotlivé regiony. Průnik všech těchto pohledů na segmentaci obrazu je v dalších částech práce využíván.

V následujících částech práce jsou popsány segmentační postupy mající za cíl extrakci některých základních prvků (vozovka, pozadí...) a zejména vozidel v obraze.

První část je věnována extrakci vozovky, pozadí a segmentu oblohy z obrazu. Klasické postupy využívající například adaptivní prahování, konvoluci obrazu s gradientními operátory, či záplavových algoritmů neprodukují dostatečně zřetelné hranice na rozhraní těchto skupin obrazu, nebo produkují velké množství hran uvnitř těchto skupin. Obrazové body tvořící jednotlivé skupiny mají však některé příbuzné vlastnosti a to v prostorové i v jasových hodnotách. Tyto výchozí předpoklady mne vedly k vývoji postupu založeného na metodách shlukování, vedoucích k separaci jednotlivých skupin. Produktem separačního postupu jsou masky, překrývající jednotlivé části obrazu.

Při experimentálním porovnávání výsledků dosažených v extrakci vozovky se projevila velmi zajímavá vlastnost způsobená přítomností vozidel na vozovce. Vozidla na vozovce ovlivňují specificky průběh masky vozovky pod každým z vozidel. Využití této vlastnosti je prezentováno v kapitole [7.2.1](#).

V dalších kapitolách jsou představeny algoritmy detekce vozidel. Tyto postupy jsou založeny na apriorní znalosti některých vlastností vozidel. Pozornost je věnována především hledání:

- specifického průběhu okrajů tvořících průmět vozidla
- vertikální a horizontální symetrii průmětu vozidla
- aplikaci *Houghovy* transformace na vyhledání bodů tvořících okraj vozidla
- využití *kumulativní metody* pro zpřesnění velikosti průmětu vozidla

7.1 Detekce vozovky

Detekci vozidel v jednotlivých snímcích je možné provádět separátně, bez apriorní znalosti o dalších objektech tvořících snímanou dopravní situaci. K podstatnému zjednodušení však dojde, pokud se nám podaří separovat některé z významných objektů tvořících scénu a pokud využijeme některých dodatečných informací o předpokládaném umístění objektů v obraze. Jednou z nejdůležitějších částí, která je také jednou ze vstupních informací pro následující výpočetní moduly je detekce vozovky. Informace o pozici vozovky v obraze je důležitá pro posouzení validity zdetekovaných vozidel v obraze.

Dopravní situaci (Obr. 12) je možné rozdělit na tři významné části: vozovku, oblohu a pozadí, ve kterém je možné provádět další separaci objektů (vozidla, domy, překážky...).

7.1.1 Detekce pomocí histogramu jasové složky

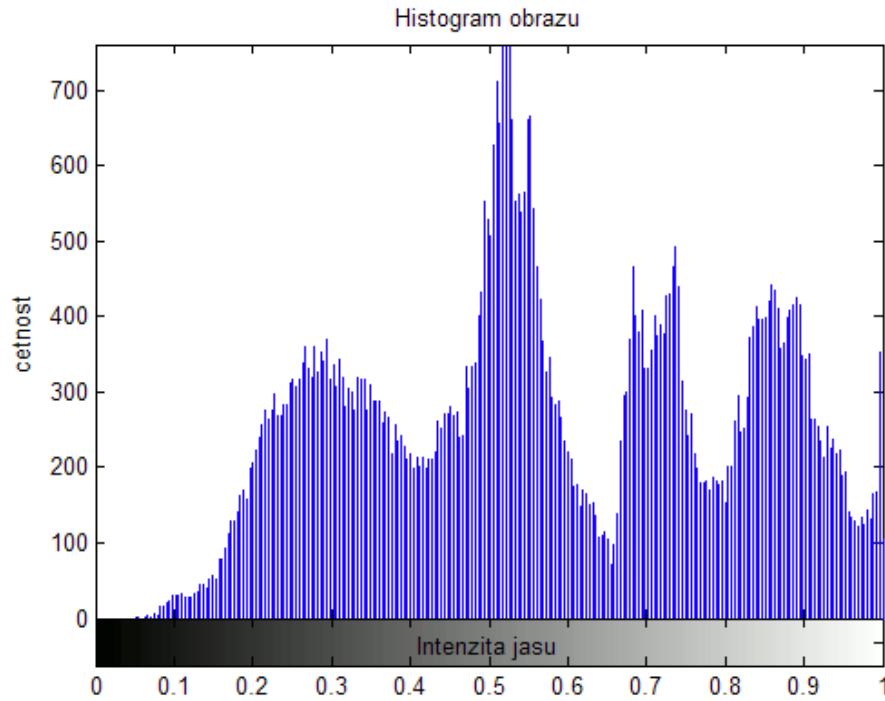
Pro detekci vozovky je možné využít některé její charakteristické vlastnosti, jako například průběh rozložení intenzit obrazových bodů.



Obr. 12: Dopravní situace

Po zobrazení rozložení intenzit (Obr. 13) vstupního obrazu Obr. 12, můžeme předpokládat normální rozdělení intenzit jasu obrazových bodů (7.1.1) [1], [16].

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (7.1.1)$$



Obr. 13: Histogram předchozího obrázku (jasová složka)

Můžeme-li odhadnout oblast, kde se s největší pravděpodobností vyskytuje část vozovky, je možné této informaci využít. Při výpočtu vycházíme z předpokladu, že část vozovky se zcela jistě nachází v dolní části snímaného obrazu. V této části je možné vybrat homogenní segment vozovky (Obr. 12) a vypočítat základní popisné statistické charakteristiky, střední hodnotu μ náhodného výběru a směrodatnou odchylku σ .


$$\mu = \frac{1}{N} \sum_{x=1}^{x=N} f(x) \quad (7.1.2)$$

$$\sigma = \left(\frac{1}{n-1} \sum_{x=1}^N (f(x) - \mu)^2 \right)^{1/2} \quad (7.1.3)$$

kde N je velikost zvolené oblasti.

Při znalosti těchto charakteristik je poté možné vyseparovat část dat v histogramu odpovídající těmto charakteristikám (Obr. 14, Obr. 15).

$$\xi = \langle \mu - k \cdot \sigma ; \mu + k \cdot \sigma \rangle \quad (7.1.4)$$

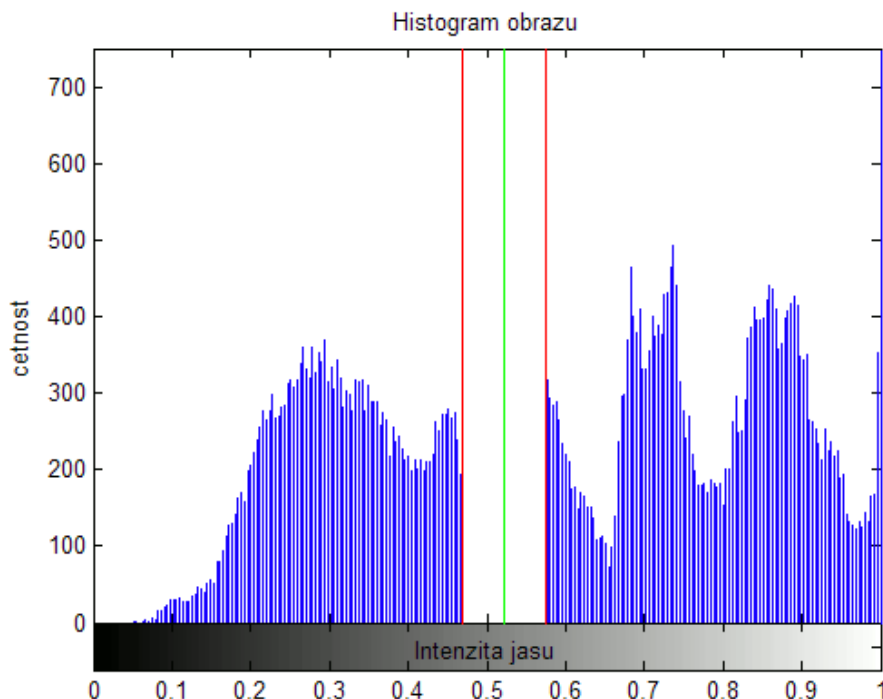


Obr. 14: Upravený histogram pro parametry μ a σ_1



Obr. 15: Výsledek vyříznutí bodů reprezentujících vozovku (žlutá b.) pro μ a σ_1

Tato metoda však obecně nevede k dostatečně uspokojivým výsledkům z několika důvodů. Předpoklad normálního rozdělení intenzit jasu obrazových bodů není zcela správný. Do rozdělení intenzit jasu obrazových bodů v obraze vstupují další aspekty, jako je zatížení šumem snímacích prvků, který se svým charakterem blíží bílému šumu. Povrch vozovky je také značně nehomogenní (osvětlení a zastínění vozovky) a pokryt texturami různého tvaru. Výsledkem je pouze přiblížení k ideálnímu průběhu charakteristiky normálního rozdělení. Zvýšíme-li rozptyl (tedy σ), zvýší se počet obrazových bodů správně přiřazených do oblasti vozovky, ale naroste také počet bodů se shodnou intenzitou jasu, které se nacházejí mimo oblast vozovky (Obr. 16, Obr. 17).



Obr. 16: Upravený histogram pro parametry μ a $\sigma_2 = 3\sigma_1$



Obr. 17: Vybraná část vozovky při μ a $\sigma_2 = 3\sigma_1$

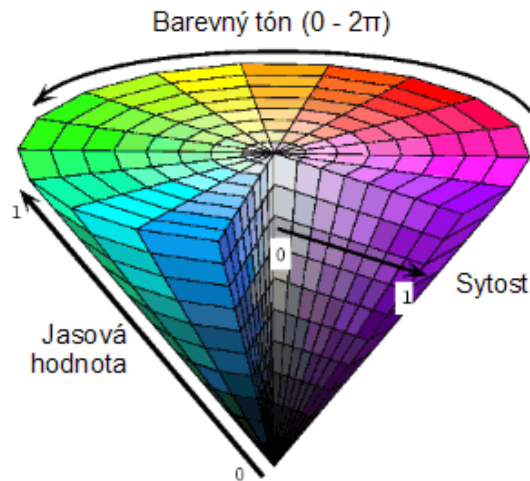
Pokud na takovéto řešení naváží další vhodné techniky, jako je například morfologické otevření obrazu, či konvoluce s vhodným dolnofrekvenčním filtrem, je možné zvýšit úspěšnost detekce. Perspektivnější cestou je však například změna použitého barevného modelu.

7.1.2 Detekce v barevném modelu HSV

Se stejným postupem popsaným v předchozí kapitole lze dosáhnout podstatně lepších výsledků v případě volby vhodnějšího barevného modelu. V předchozí kapitole byla popsána segmentace v jasové složce sestavené z jednotlivých složek *RGB* modelu. Nevýhodou tohoto postupu je vysoká citlivost na změny jasu, projevující se značným rozptylem kolem hodnot střední hodnoty μ , což je pro detekci spojitých útvarů nežádoucí a dále značná korelace mezi jednotlivými barevnými složkami a celkovou jasovou složkou. Tento efekt se projevuje velmi zřetelně například u vozovek s proměnným stupněm osvětlení, nebo na nekvalitních komunikacích se složitou texturou povrchu.

Při volbě vhodného modelu je však možné podstatně zvýšit úspěšnost výše popsaných postupů. Vhodným modelem v tomto případě bude takový model, který v některé ze svých složek bude vykazovat menší citlivost na změny jasových hodnot, bude však citlivý na další informace obsažené v obraze, jako je například informace o barvách obrazových bodů. Velmi

často používaným modelem, vyhovujícím výše zmíněným kritériím, je barevný model HSV^* , vyčleňující zvlášť informaci o jasů obrazového bodu a složky popisující barevnou informaci. V tomto barevném modelu reprezentují jednotlivé složky: H - barevný tón, S - sytost barvy a V - jasovou úroveň (Obr. 18).



Obr. 18: Geometrická reprezentace HSV modelu

Barevný tón reprezentuje základní spektrální barvu a spolu se sytostí, udávající přimíšení bílé barvy reprezentují barvu obrazového bodu.

Převod mezi prostory RGB a HSV byl realizován transformacemi:

$$MAX = \text{maximum}\{R, G, B\} \quad MIN = \text{minimum}\{R, G, B\} \quad (7.1.5)$$


$$H = \begin{cases} \left(0 + \frac{G-B}{MAX-MIN}\right) \times 60 & \text{if } R=MAX \\ \left(2 + \frac{B-R}{MAX-MIN}\right) \times 60 & \text{if } G=MAX \\ \left(4 + \frac{R-G}{MAX-MIN}\right) \times 60 & \text{if } B=MAX \end{cases} \quad (7.1.6)$$

$$S = \frac{MAX - MIN}{MAX} \quad (7.1.7)$$

$$V = MAX \quad (7.1.8)$$

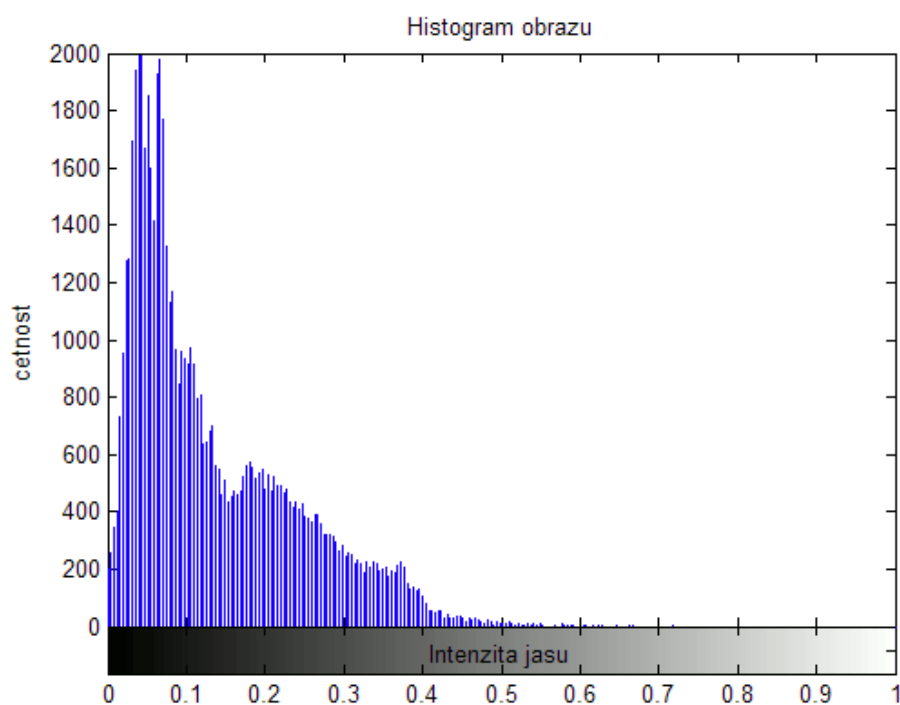
* Hue, Saturation, Brightness – barevný tón, sytost barvy, hodnota jasu

Budou li prováděny následující segmentační postupy pouze v rozsahu složek H nebo S , bude segmentace prováděna v úrovni konstantní hodnoty jasu. Transformací je tedy možné dosáhnout snížení citlivosti segmentačních metod na lokální průběh jasové funkce v obraze.




Obr. 19: Separace složek původního obrázku v HSV modelu (zleva: V , H , S)

Příklad složek obrazu transformovaného do HSV modelu je zobrazen na Obr. 19. Na Obr. 19c je zřetelná snížená citlivost S složky HSV obrazu na lokální změny jasu (jasová informace je potlačena). Na Obr. 20 je pak zobrazen histogram S složky obrazu. Aplikujeme li na S složku obrazu výše zmíněný postup segmentace dosáhneme podstatně lepších výsledků (Obr. 21, Obr. 22 - porovnejte s Obr. 15).



Obr. 20: Histogram S složky obrázku v HSV modelu

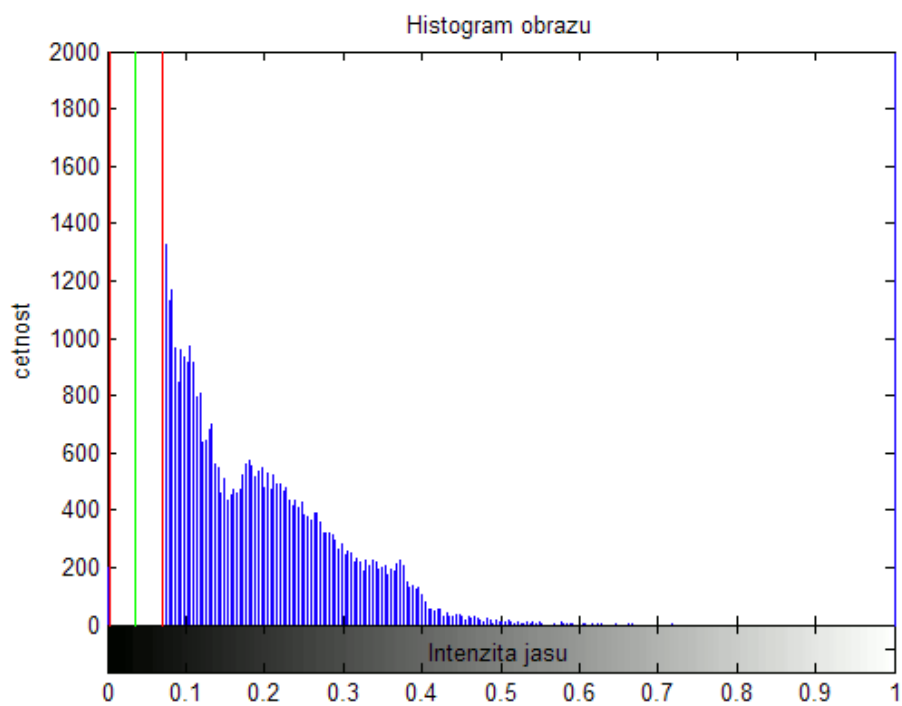


Obr. 21: Upravený histogram S složky obrázku v HSV modelu pro parametry μ a σ_1



Obr. 22: Výsledek separace bodů reprezentujících vozovku (žlutá b.) pro μ a σ_1 při použití HSV modelu

Přirozeně i v tomto případě je možné zvýšit počet bodů připadajících do oblasti vozovky zvýšením hodnoty rozptylu (Obr. 23, Obr. 24). Výsledkem je téměř homogenní maska vyznačující oblast vozovky (porovnejte s Obr. 17).



Obr. 23: Upravený histogram S složky obrázku v HSV modelu pro parametry μ a $\sigma_2 = 3\sigma_1$



Obr. 24: Výsledek separace bodů reprezentujících vozovku (žlutá barva) pro μ a $\sigma_2 = 3\sigma_1$ při použití HSV modelu

Výše popsaný postup barevné segmentace již celkem dobře klasifikuje obrazové body spadající do oblasti vozovky a to i v případě, kdy je povrch vozovky značně nehomogenní v jasové složce. Algoritmus však produkuje také velké množství obrazových bodů mimo oblast vozovky.

Výskyt bodů spadajících mimo oblast vozovky je možné potlačit pomocí vhodných nastavbových postupů aplikovaných na výše uvedený algoritmus, zejména známe-li alespoň část obrazu, ve které se vyskytuje vozovka (předpoklad z počátku kapitoly). Takovéto nastavbové postupy sice vedou k minimalizaci počtu chybně zařazených bodů, ale za cenu zvýšené výpočetní náročnosti. Přitom společnou vlastností všech těchto postupů je využití dalších typů informací obsažených v obraze.


V další kapitole bude podrobně diskutován systém provádějící segmentaci nejen na základě hodnoty jasu, či barevnosti obrazových bodů, ale i jejich prostorového umístění v obraze.

7.1.3 Segmentace shlukováním

Sjednocujícím prvkem výše popisovaných oblíbených segmentačních metod je snaha o segmentaci obrazu na základě informace obsažené v jasové, případně barevné složce obrazu a to na základě fixních hodnot prahů, vypočtených ze statistických vlastností úzkého výběru dat. Tyto metody neuvažují při výpočtu informaci obsaženou například v prostorových

souřadnicích obrazového bodu, či další informace obsažené v barvě obrazu. Jedná se tedy o segmentační postupy prováděné v dvourozměrném prostoru (histogram) na základě znalostí získaných popisnými statistickými veličinami. Pro účely segmentace však zůstávají další typy informací obsažené v obraze nevyužity. Segmentace je však rychlá a jednoduše implementovatelná.

Připojíme-li k informaci o jasové složce obrazového bodu informaci o pozici, přesouvá se problém shlukování obecně do třírozměrného prostoru. Pokud budeme uvažovat dále informaci o barvě, posouvá se problém segmentace obecně ke čtyř, či více dimenzionálnímu prostoru (v závislosti na vyjádření barevné, či dalších informací). Představu segmentačního problému v třírozměrném vyjádření obrazu můžeme vidět na Obr. 25⁸, v němž je ve třírozměrném grafu zobrazen obraz dopravní scény z Obr. 12.

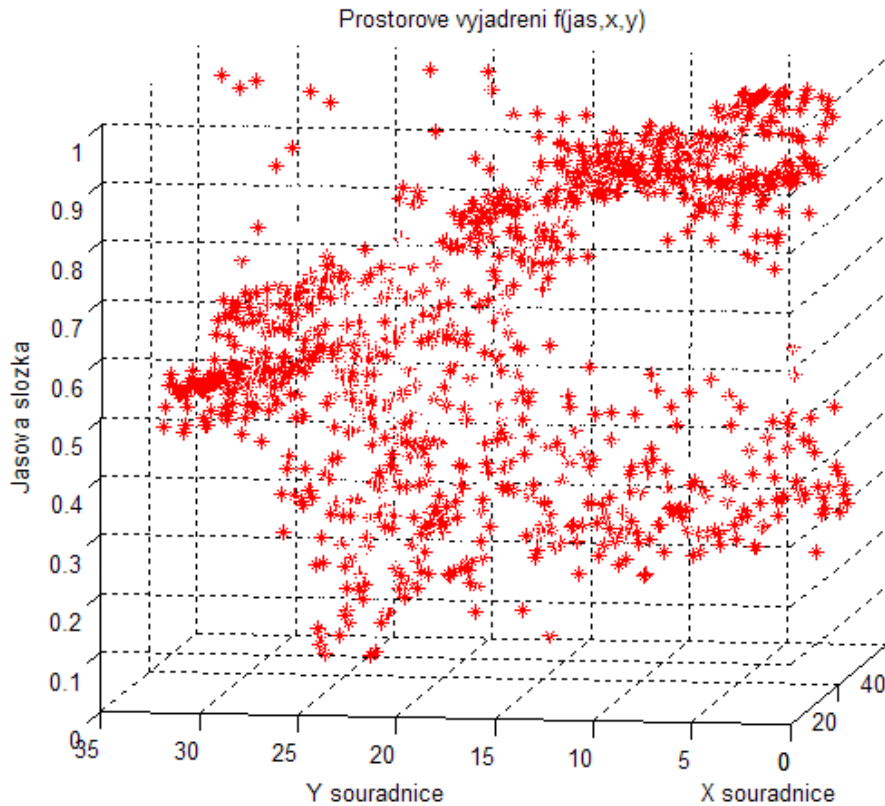


Obr. 25: Třírozměrné vyjádření intenzity obrazových bodů obrazu

V závislosti na složitosti scény se v Obr. 25 (a v pootočeném Obr. 26) vyskytuje jeden či více *shluků* obrazových bodů, odpovídajících blokům obrazu tvořících scénu. Počet *shluků*,

⁸ obraz byl pro přehlednost transformován do velikosti 32x32 obrazových bodů

jejich orientace, velikost a další vlastnosti jsou také silně závislé na použité *shlukovací strategii* a *shlukovacím kritériu*.



Obr. 26: Třírozměrné vyjádření intenzity obrazových bodů obrazu - obraz otočen o cca 60° doprava pro lepší zviditelnění shluků obrazových bodů

Při volbě *shlukovací strategie* jsem uvažoval obecně množinu O obsahující n obrazových bodů (s popisnými vlastnostmi) pro možnost segmentace dle různého počtu vlastností obrazových bodů. Cílem bylo rozložit tuto množinu do souboru disjunktních neprázdných podmnožin $\Omega = \{C_1, C_2, \dots, C_n\}$, které dohromady tvoří zdrojovou množinu O . Pro $i \neq j$ tedy: $C_i \cap C_j = \emptyset$ a $C_1 \cup C_2 \cup C_3 \dots \cup C_n = O$. Každá podmnožina C_i se nazývá *komponentou rozkladu*. *Shlukování* je tedy rozklad množiny O . Komponenty tohoto rozkladu se nazývají *shluky* [24].

Shlukovací metody můžeme rozdělit podle cílů, k nimž směřují, na *hierarchické* a *nehierarchické*.

Hierarchické shlukování je systém navzájem různých neprázdných podmnožin množiny O , v němž průnikem každých dvou podmnožin je buď jedna z nich, nebo prázdná množina a v němž existuje alespoň jedna dvojice podmnožin, jejichž průnikem je jedna

z nich. V případě segmentace obrazových dat je tedy nutné řešit neprázdné průniky množin $C_i \cap C_j$.

Naproti tomu *nehierarchické shlukování* je systém navzájem různých neprázdných podmnožin množiny O , v němž průnikem každých dvou podmnožin není žádná z nich.

Pro rychlou segmentaci obrazových dat pro účely navazující detekce byly zajímavé zejména metody vedoucí k disjunktnímu rozkladu množiny O .

Objekty určenými ke klasifikaci jsou obrazové body. Objekt je v tomto případě popsán pomocí vektoru s konečným počtem p předem stanovených charakteristik – *znaků*. Tyto charakteristiky představují hodnoty vlastností objektů (jas, souřadnice_x, souřadnice_y, bar_inf_1, bar_inf_2...). Objektem pro shlukovou analýzu je obecně tedy p -rozměrný vektor čísel. V případě n objektů $Obj = \{o_1, \dots, o_p\}$, z nichž každý je popsán p znaky je h -tý objekt $o_h = \{z_{h1}, \dots, z_{hm}\}$. Znaky objektů mohou obecně nabývat několika typů (kvantitativní, kvalitativní, binární...). Pro účely segmentace obrazových bodů jsem však uvažoval kvantitativní charakteristiky.

Kvantitativní znaky objektů (obrazových bodů) jsou v různých jednotkách (prostorové souřadnice, hodnoty jasu...). Každý znak patří do konečné, spočetné množiny U_i z intervalu $\langle a, b \rangle$, kde $U_i \in \mathbf{R}^m$. To může způsobovat, že se určité znaky jeví jako dominující a jiné znaky jen málo ovlivňují průběh shlukování. Před vlastním procesem shlukování jsem tedy výhodně data upravil tak, aby byly všechny znaky souměřitelné $U_1, U_2, \dots, U_i \in \mathbf{R}_{\langle a_1, b_1 \rangle}^m$. Jedním ze způsobů, jak toho docílit, je *standardizace a normalizace dat*:

Nechť je dána matice dat $Z = (z_{ij})$ typu $n \times p$, jejíž řádky jsou p -rozměrné vektory čísel charakterizující n objektů. Standardizaci dat provedeme ve dvou krocích:

1. Vypočteme střední hodnotu μ_j j -tého znaku z_j (7.1.9) a směrodatnou odchylku σ_j (7.1.10) pro $j = 1, 2, \dots, p$ podle:

$$\mu_j = \frac{1}{n} \sum_{i=1}^n z_{ij} \quad (7.1.9)$$

$$\sigma_j = \sqrt{\frac{1}{n} \sum_{i=1}^n (z_{ij} - \mu_j)^2} \quad (7.1.10)$$

2. Původní hodnoty z_{ij} j -tého znaku i -tého objektu přepočteme na tzv. standardizované hodnoty:

$$x_{ij} = \frac{z_{ij} - \mu_j}{\sigma_j} \quad (7.1.11)$$

Takto získané hodnoty znaků již mají střední hodnotu $\mu=0$ a rozptyl roven I .

3. Jednotlivé p -složky znaků z_{ij} mají proměnnou normu. Všechny parametry byly proto normovány na rozsah $\langle 0, 1 \rangle$ (v *uint8* formátu $\langle 0, 255 \rangle$).

Pro vlastní segmentaci objektů reprezentovaných znaky z_{ij} je důležité stanovit *měřítko podobnosti* (resp. *nepodobnosti*), dvou objektů o_i a o_j . *Měřítko podobnosti* určuje zařazení objektu o_j do podmnožiny C_i , a je reprezentováno *funkcí podobnosti* [24]. *Funkce podobnosti* přiřazuje každým dvěma objektům o_i, o_j číslo II – *měřítko podobnosti*:

$$II(o_i, o_j) \geq 0$$

$$II(o_i, o_j) = II(o_j, o_i)$$

Problém *funkce podobnosti* je stanovení hodnoty funkce II pro objekty o_i a o_j s vysokou podobností, v limitním případě pro shodné objekty o_i a o_i . V takovém případě je nutné stanovit hodnotu funkce II reprezentující maximální podobnost, což může být problematické. Proto jsem ve výpočtech použil *funkci nepodobnosti* objektů N , pro kterou platí:

$$N(o_i, o_j) = 0 \iff o_i = o_j$$

$$N(o_i, o_j) \geq 0$$

$$N(o_i, o_j) = N(o_j, o_i)$$

Způsobů aplikačního vyjádření *funkce nepodobnosti* existuje velké množství. Pro účely segmentace obrazových dat jsem v projektu vybral metriku vycházející z geometrického modelu dat, reprezentovanou eukleidovskou vzdáleností v p -rozměrném prostoru E_p . Pro dva body (r, s) je definována eukleidovská vzdálenost v p -rozměrném eukleidovském prostoru E_p :

$$\lambda(r, s) = \sqrt{\sum_{i=1}^p (x_{ri} - x_{si})^2} \quad (7.1.12)$$

použitelných metrik pro určení nepodobnosti existuje celá řada a některé (např. SAD^9) budou diskutovány v dalších kapitolách.

Před započítáním segmentace je velmi důležitá volba počátečního rozkladu matice O . Stanovení optimálního počátečního rozkladu na k -shluků při počátku rozkladu může být následováno buď zachováním stejného počtu shluků nebo změnou počtu v průběhu výpočtu v závislosti na řídicích proměnných algoritmu [24]. Po experimentálním vyhodnocení pořízených dat se ukázala jako nejvhodnější volba stanovení tří, nebo čtyř shluků obrazových

⁹ Suma absolutních diferencí, kapitola: [8.2.7 Kumulativní metoda vyhledávání obrysů vozidel](#)

bodů v závislosti na stupni prostoru R^n , reprezentujících vozovku, pozadí¹⁰ (včetně objektů vozidel) a oblohu. V projektu jsem tedy využil algoritmus zachovávající počet shluků v průběhu výpočtu (*k-means*). V případě použití algoritmu zachovávajícího neměnný počet shluků je obzvláště důležitá vhodná volba počáteční rozkladu množiny O a volba iniciačních vektorů μ_j , tedy stanovení typických vzorových objektů (v eukleidovském prostoru typických bodů, kolem nichž se dá předpokládat vytvoření shluků). Počáteční rozklad pak může být z počátečních údajů odvozen mnoha způsoby:

- náhodným výběrem prvních k -bodů z libovolně uspořádané množiny bodů - velké riziko ukončení algoritmu v lokálním extrému, velké riziko výběru inicializačních bodů v rámci jednoho shluku
- generováním k umělých bodů, jejichž každá souřadnice je náhodné číslo z příslušného variačního intervalu – vyšší implementační složitost, připouští určitou míru počáteční nepřesnosti v odhadu počátku shluku
- výběrem bodů v závislosti na využití některých dalších informací o množině O (apriorní znalosti o segmentované scéně, předpokládané rozložení objektů v obraze viz dále)

Snahou je však docílit vhodné volby rozkladu O tak, aby se minimalizoval počet iteračních kroků výpočtu, případně se eliminovala další rizika vyplývající ze zvolené metody (ukončení algoritmu v lokálním extrému, nevhodná volba μ_j znamenající chybný rozklad).

7.1.4 Algoritmus K-means (MacQueenova metoda)

Pro segmentaci shlukováním jsem zvolil algoritmus *k-means*. Algoritmus *K-means* obecně hledá pro množinu vstupních dat $X = \{x_1, \dots, x_n\}$ vektory μ_1, \dots, μ_k ($k < n$) takové, které nejlépe vyhovují podmínce minimální střední kvadratické odchylky bodů množiny X od vektorů μ_1, \dots, μ_k podle měřítka nejmenší eukleidovské vzdálenosti (7.1.12) a rozděluje je do předem daného počtu shluků (tříd) k . Vstupem algoritmu je množina dat x_1, x_2, \dots, x_l a číslo k udávající počet vektorů $\mu_j, j=1\dots k$. Na začátku se inicializují vektory $\mu_j, j=1\dots k$ podle znalosti zpracovávaných dat.

Po inicializaci se začnou iterativně opakovat následující dva kroky:

¹⁰ v případě segmentace dle souřadnic bylo pozadí reprezentováno dvěma μ_j ($k=4$) – viz dále

1. Klasifikace: Všechna data x_i , $i=1\dots l$, se klasifikují do tříd určených vektory μ_j , $j=1\dots k$ podle minima eukleidovské vzdálenosti. Tedy vzor x_i je přiřazen do třídy C_i podle $y_i = \operatorname{argmin} \|x_i - y_j\|$.
2. Přepočítání vektorů μ_j : Vypočítají se nové hodnoty vektorů μ_j jako střední hodnoty dat x_i , které byly klasifikovány do třídy určené příslušným vektorem μ_j . Tedy nová hodnota μ_j se vypočítá podle vztahu:

$$\mu_j = \frac{1}{l_j} \sum_{i=1, y_i=1}^l (x_i) \quad (7.1.13)$$

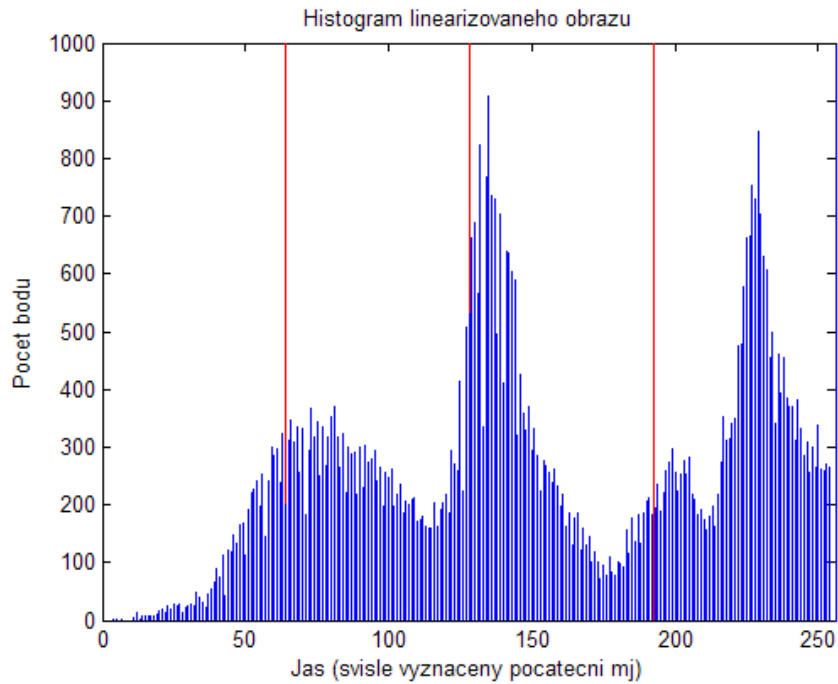
kde l_j je počet vzorů x_i klasifikovaných v druhém kroku do třídy určené μ_j .

Kroky 1 a 2 je možné provádět tak dlouho, než dojde ke stabilní konfiguraci rozkladu na výsledné shluky. Druhou (použitou) možností je ukončení výpočtu až po zpracování všech vektorů x_i vstupní množiny O .

Segmentace byla nejprve prováděna v prostoru R^3 (prostorové souřadnice, jas), ale pro vlastní segmentaci byla využívána pouze jasová informace pro možnost porovnání s výsledky předchozích algoritmů. Algoritmus *k-means* byl tedy v podstatě aplikován na histogram obrazu. Vzhledem k tomu, že jsem neměl na počátku k dispozici modul *Statistics-toolbox* pro prostředí *MATLAB*, vyvinul jsem vlastní rychlý algoritmus segmentace *k-means*, využívající transformace obrazu z prostoru R^3 do prostoru R^1 (linearizace obrazu) a rychlé implementace funkce výpočtu histogramu. Tato transformace sice vede ke ztrátě prostorové informace, ta ale není v segmentaci využita. Informace o jasových hodnotách obrazových bodů zůstává zachována a shlukování je prováděno na ní. Při analýze velkého počtu vstupních snímků byl zjištěn charakteristický průběh histogramu obrazu (Obr. 27), obsahující tři výrazné vrcholy reprezentující velké plochy obrazových bodů s příbuznými vlastnostmi: *povrch vozovky*, *oblohu* a *pozadí* (včetně hledaných objektů na vozovce). Pro inicializaci počátečních vektorů μ_j bylo zvoleno rovnoměrné rozdělení iniciačního vektoru μ_j v rozsahu jasové složky:

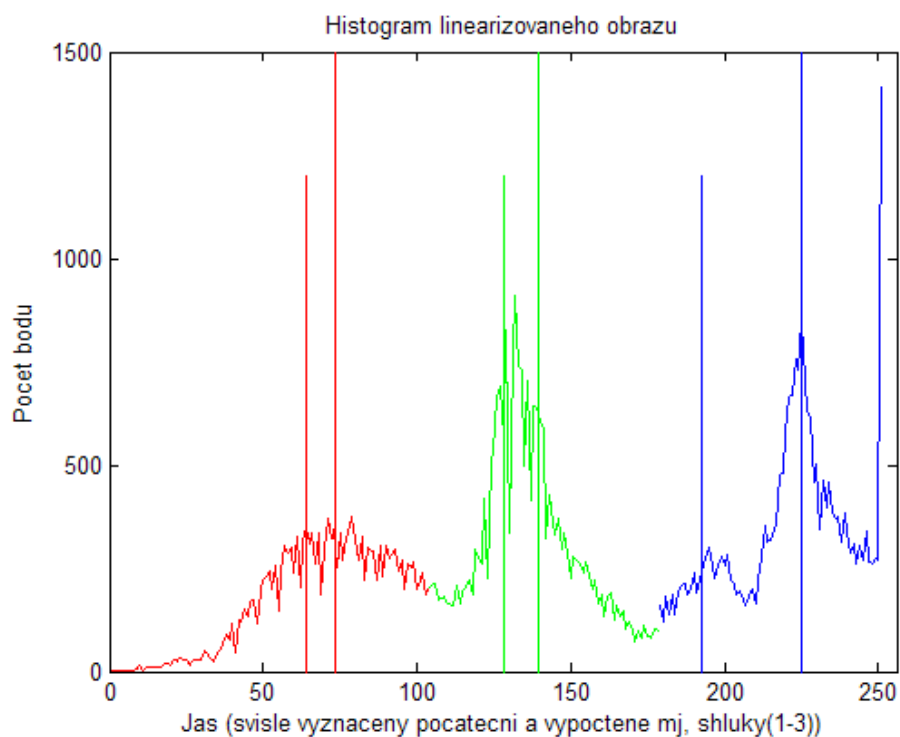
$$\mu_j = \frac{(1:k) \cdot I_{max}}{k+1} \quad (7.1.14)$$

Na Obr. 27 je zobrazen histogram Obr. 12 s vyznačenými iniciačními vektory μ_j . Podle vzorce (7.1.14) je tedy algoritmus schopen automatické iniciace počátečního μ_j v závislosti na požadovaném počtu výsledných shluků (parametr k). Vzhledem k disjunktímu rozkladu množiny vstupních dat O (každý objekt x_i je zařazen pouze do jedné podmnožiny C_i) je algoritmus značně necitlivý i na velmi nevhodné rozmístění iniciačních μ_j .




Obr. 27: Histogram linearizovaného obrazu s vyznačenými iniciačními μ_j (červené svislé čáry) při parametru $k=3$

Výpočet probíhal podle výše popsaného iteračního postupu. Jednotlivé objekty x_1, x_2, \dots, x_i byly přiřazovány podle kritéria (7.1.12) ke shlukům C_i definovaným μ_j . V průběhu výpočtu byly pozice μ_j aktualizovány. Výsledkem algoritmu je rozdělení množiny O vstupních objektů na k shluků a nově vypočtené hodnoty μ_j (Obr. 28).



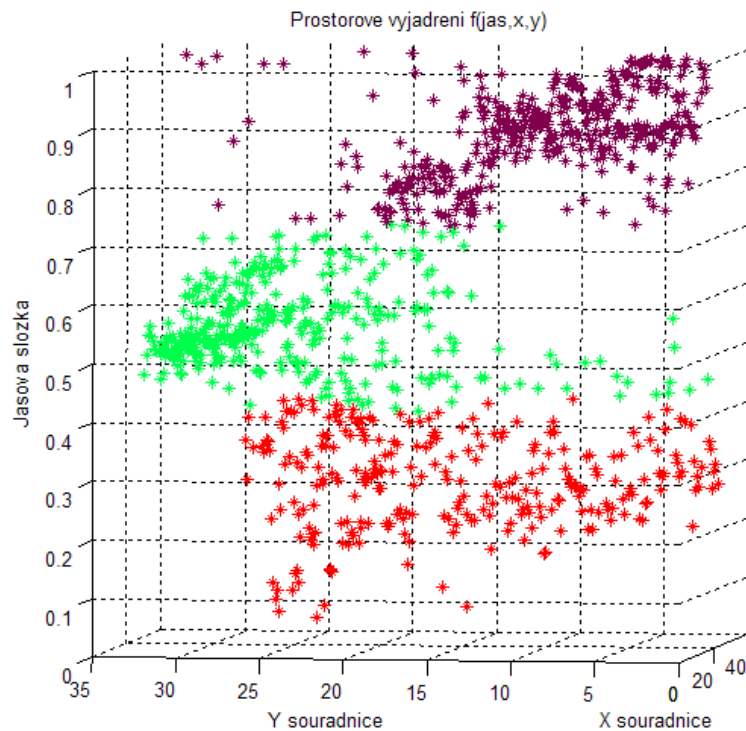
Obr. 28: Histogram (pro větší přehlednost zobrazen spojitě) s vypočtenými shluky jasových hodnot a konečnými hodnotami μ_j (větší svislé čáry)

Po zpětné transformaci $R^l \rightarrow R^3$ je možné zobrazit vyjádření shluků obrazových bodů ve formě třírozměrného grafu (Obr. 29, Obr. 30). V grafu je patrné horizontální oddělení shluků obrazových bodů.



Obr. 29: Výsledek shlukování obrazu v prostoru R^1 (segmentace podle jasů)

(všechny 3D grafy jsou zobrazeny v podvzorkování $256 \times 256 \rightarrow 32 \times 32$ pro větší přehlednost)




Obr. 30: Výsledek shlukování obrazu v prostoru R^1 (segmentace podle jasů) - obraz otočen o cca 60° doprava pro lepší zviditelnění shluků obrazových bodů

Jednotlivé shluky obrazových bodů reprezentují k segmentovaným částí obrazu. Vzhledem k segmentaci podle úrovně jasu jsou segmentované části obrazu reprezentovány částečně nespojitými oblastmi (Obr. 31a). Tyto části je možné separovat a dalšími úpravami snížit počet nespojitostí. Cílem je vytvořit spojitou masku nad zvoleným objektem. Na Obr. 31 je zobrazen postup úprav (příklad pro masku vozovky).

Z masky vozovky (Obr. 31b) jsem nejprve pomocí *Sobelova hranového operátoru* získal průběh okrajů (Obr. 31c). Je vidět, že maska vozovky netvoří jeden celistvý útvar, ale vlivem nadsegmentace v obraze vznikají hrany i kolem objektů mimo vozovku. Takto vzniklý okraj je také necelistvý a neumožňuje vyplnění uzavřené oblasti.

Pro potlačení výskytu těchto drobných objektů v obraze a uzavření hranice jsem zvolil metodu eliminace pomocí operace *erose* následované operací *dilatace*, tedy *morfologického otevření* obrazu. Výhodou *morfologického otevření* obrazu je odstranění malých objektů, zatímco tvar a velikost velkých objektů zůstávají zachovány.



Obr. 31: Postup úpravy masky vozovky

Morfologické operace jsou definovány pro dvě vzájemně interagující množiny A a B v prostoru celých čísel Z^2 se složkami $a=(a1, a2)$ a $b=(b1, b2)$. Mezi základní morfologické operace patří *eroze*, *dilatace*, *otevření* a *uzavření* obrazu.

Operace *dilatace* je definována [2]:

$$A \oplus B = \{ x: (B')_x \cap A = \emptyset \} \quad (7.1.15)$$

kde \emptyset je prázdná množina a $(B')_x$ reprezentuje množinu B zrcadlenou okolo počátku a posunutou o x :

$$B' = \{ x: x = -b, \text{ pro } b \in B \} \quad (7.1.16)$$

Množina A je vstupní množinou obrazových bodů (obrazem), zatímco množina B reprezentuje *strukturální element* ovlivňující množinu A . Výsledkem je přidání obrazových bodů. Struktura a počet přidávaných bodů je dána tvarem a velikostí *strukturálního elementu* B . Na Obr. 31d je zobrazena hranice vzniklá z původní hranice aplikací *morfologické dilatace* s diskovým *strukturálním elementem* o poloměru pěti obrazových bodů. Takto vzniklá hranice je již celistvá a umožňuje vyplnění svého středu (Obr. 31e).

Operace *eroze* je definována [2]:

$$A \ominus B = \{ x: x \in (B)_x \subseteq A \} \quad (7.1.17)$$

kde $(B)_x$ značí posun množiny B o vzdálenost x :

$$(B)_x = \{ c: c = b + x, \text{ pro } b \in B \} \quad (7.1.18)$$

Množina A je vstupní množinou obrazových bodů (obrazem), zatímco množina B reprezentuje *strukturální element* ovlivňující množinu A . Výsledkem je odebrání obrazových bodů.

Operace *eroze a dilatace* jsou duální operace, avšak nejsou navzájem inverzní [8], [2]. Této skutečnosti je s výhodou využíváno v následujících částech k odstranění drobných elementů v obraze.

Operace *morfologického otevření* obrazu je definována jako operace *eroze* množiny A následovanou operací *dilatace* množiny A shodným strukturálním elementem B :

$$A \circ B = \{(A \ominus B) \oplus B\} \quad (7.1.19)$$

a vede k odstranění drobných objektů, přerušení úzkých spojení hran mezi objekty a odstraňuje úzké výčnělky objektů v obraze [8].

Naopak operace *morfologického uzavření* obrazu je definována jako operace *dilatace* množiny A následovanou operací *eroze* množiny A shodným strukturálním elementem B :

$$A \bullet B = \{(A \oplus B) \ominus B\} \quad (7.1.20)$$


a způsobuje slučování přerušených hranic, odstraňuje malé otvory a trhliny v objektech [8].

Pomocí *morfologického otevření obrazu* je v obrazu masky snížen počet bodů mimo oblast vyplnění (Obr. 31f). Tento postup jsem volil především pro velkou rychlost výpočtu oblastí.

Pokud aplikujeme uvedený postup na všechny¹¹ množiny $C_1..C_k$, získáme postupně ucelené masky překrývající oblasti vozovky, pozadí (včetně dalších významných objektů) a oblohy (Obr. 33), případně další v závislosti na požadovaném počtu shluků k .

Výstupem výše popsaného algoritmu jsou vektory μ_j určující centra shluků a dále maska (Obr. 32), obsahující masky k částí obrazu (množin C_1 až C_k) s indexy 1.. k . Protože v průběhu výpočtu nebyly uvažovány prostorové souřadnice obrazových bodů není možné přiřazení indexů predikovat. Proto po algoritmu následuje detekce ve dvou oblastech obrazu (v horní a v dolní části) obrazu, kde jsou definovány výběrové bloky, v nichž je vypočtena převládající hodnota masky. Takto získáme index masky vozovky a oblohy. Hodna indexu masky pozadí je vypočtena doplňkem k parametru k . Takto je v algoritmu vždy jednoznačně určena hodnota indexu *masky vozovky, oblohy a pozadí*, bez ohledu na pořadí přiřazení v *k-means*.

Obraz s aplikovanou maskou



Obr. 32: Výstup algoritmu *k-means*: maska (s indexy 1.. k , $k=3$), segmentace v jasové oblasti

¹¹ Poslední masku lze jednoduše získat doplňkem $O - \sum C_i$

Segmentovaný obraz (Obloha = žlutá maska)




Vozovka = zelená maska, pozadí=bez masky

Obr. 33: Obraz s grafickým vyjádřením masek obrazu ($k=3$) segmentace shlukováním (k -means) v jasové oblasti

Na Obr. 33 je zobrazen výstup segmentace ve formě k masek aplikovaných na původní obraz (pro přehlednost zobrazen barevný obraz). Obrazové masky pokrývají obrazové body příslušející shodným shlukovým množinám C_i . Při porovnání s Obr. 17 či Obr. 24 je jasně patrný posun v kvalitě segmentace. Maska nad vozovkou i nad oblohou je již téměř spojitá, jasně ohraničující dané oblasti a pomocí aplikace morfologického otevření obrazu je dosaženo jednoznačné detekce vozovky, oblohy a pozadí určených spojitou maskou. Takto definovaný postup již dává vynikající výsledky při nízkých nárocích na výpočetní čas a výstup je možno použít v dalších částech detekce vozidel.

7.1.5 Víceparametrické shlukování K-means

V kapitole [7.1.4](#) popsany algoritmus odděluje jednotlivé shluky na úrovni hladin jasu (Obr. 30). Výhodou shlukovacího algoritmu je však možnost jednoduchého navýšení počtu parametrů p objektů o_i vstupujících do procesu shlukování. Je tak možné například velmi snadno aplikovat proces barevné segmentace. Při rozšíření vstupních parametrů do prostoru R^3 (hodnoty barev modelu RGB/HSV) je možné pozorovat drobné přeskupení obrazových bodů na okrajích shluků (Obr. 34 - rozhraní mezi stromy a oblohou, porovnejte s Obr. 32).

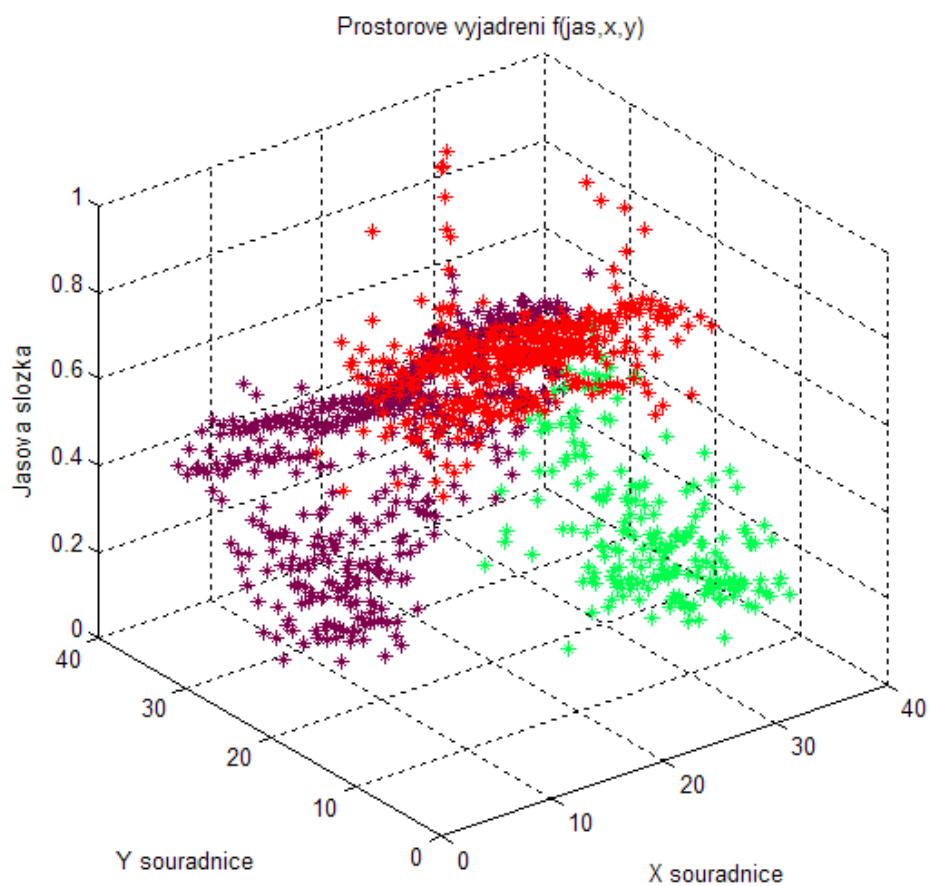


Obr. 34: Výstup algoritmu *k-means*: maska (s indexy 1.. k , $k=3$), segmentace v R^3 (barvy RGB)

Popsané rozšíření přináší dodatečné zkvalitnění detekce, ale prodlužuje počet iteračních kroků nutných pro separaci shluků.

Parametry p vstupních objektů o_i je možné rozšířit i o prostorové souřadnice. V takovém případě je však nutné znovu určit iniciační vektory μ_j a zahrnout do nich vhodným způsobem prostorové souřadnice obrazových bodů. Pro horní část obrazu a pro vozovku jsou výchozí μ_j totožné. Pro střední část obrazu je však díky axonometrickému zobrazení dopravní scény obtížnější μ_j určit. Pozadí (objekt mezi oblohou a vozovkou) v obraze rozděleno téměř symetricky podle vertikální osy obrazu na dvě části. V závislosti na složitosti dopravní scény se toto rozdělení projevuje více či méně¹². Na Obr. 35 je zobrazen případ, kdy je voleno $k = 3$ shluky s iniciačním vektorem μ_j pro skupinu pozadí z pravé části obrazu.


¹² Pro dokumentaci tohoto jevu byl vybrán Obr. 12, na němž shlukování s prostorovými souřadnicemi vede k nadsegmentaci



Obr. 35: Výsledek shlukování obrazu v prostoru R^5 (segmentace podle barev, prostorových souřadnic), pro $k = 3$ shluků

Z Obr. 35 je vidět, že ze skupiny bodů kolem výchozího μ_j z pravé části obrazu byl správně vytvořen shluk (zeleně označené body), obrazové body z pravé části obrazu však byly nesprávně zahrnuty do shluku obrazových bodů příslušejících vozovce (Obr. 36).


Obráz s aplikovanou maskou



Obr. 36: Výstup algoritmu k -means: maska (s indexy 1.. k , $k=3$), segmentace v R^5 (barva, prostor. souřadnice)

I v takovémto případě vede výše popsaný algoritmus morfologického otevření obrazu k tvorbě spojitě masky nad plochou vozovky a to díky značení na okraji vozovky (Obr. 37). Detekce je však v tomto případě značně nespolehlivá.

Maska vozovky




Obloha = žlutá maska, Vozovka = zelená maska



pozadí=bez masky Predikce = modré cary

Obr. 37: Maska vozovky po morfologickém otevření. Obraz s grafickým vyjádřením masek obrazu ($k=3$), segmentace v R^5 (barva, prostor. souřadnice)

Řešením výše popsaného problému s nesymetrickou tvorbou shluku, v obraze dopravní scény, je volba $k = 4$ shluků a dvou μ_j inicializujícím tvorbou shluků pozadí.



Obr. 38: Výsledek shlukování obrazu v prostoru R^5 (segmentace podle RGB, prostorových souřadnic), pro $k = 4$ shluků

Na Obr. 38 je zobrazena situace pro shlukování do čtyř disjunktních shluků. Vzhledem k tomu, že parametry prostorových souřadnic jsou srovnatelné s parametry hodnot barev (standardizace dle (7.1.11)), došlo ve shluku bodů tvořících pozadí v levé části obrazů ke sloučení s částí bodů tvořících oblast vozovky. Přřazené obrazové body splňují kritérium (7.1.12) v prostorové vzdálenosti s nižší hodnotou nepodobnosti než v prostoru barev. Výsledkem je tedy nesprávná segmentace vozovky a pozadí¹³ (Obr. 39).

Za povšimnutí však stojí téměř dokonalá separace jednotlivých množin C_i (na Obr. 39a zejména rozhraní mezi maskou oblohy a pozadí – porovnejte s rozhraními na Obr. 34)

¹³ dvě masky pozadí jsou ve výstupech programu pro názornost znovu sloučeny v jednu (v obraze žlutá barva)



Obr. 39: Maska vozovky. Obraz s grafickým vyjádřením masek obrazu ($k=4$), segmentace v R^5 (barva, prostor. souřadnice)

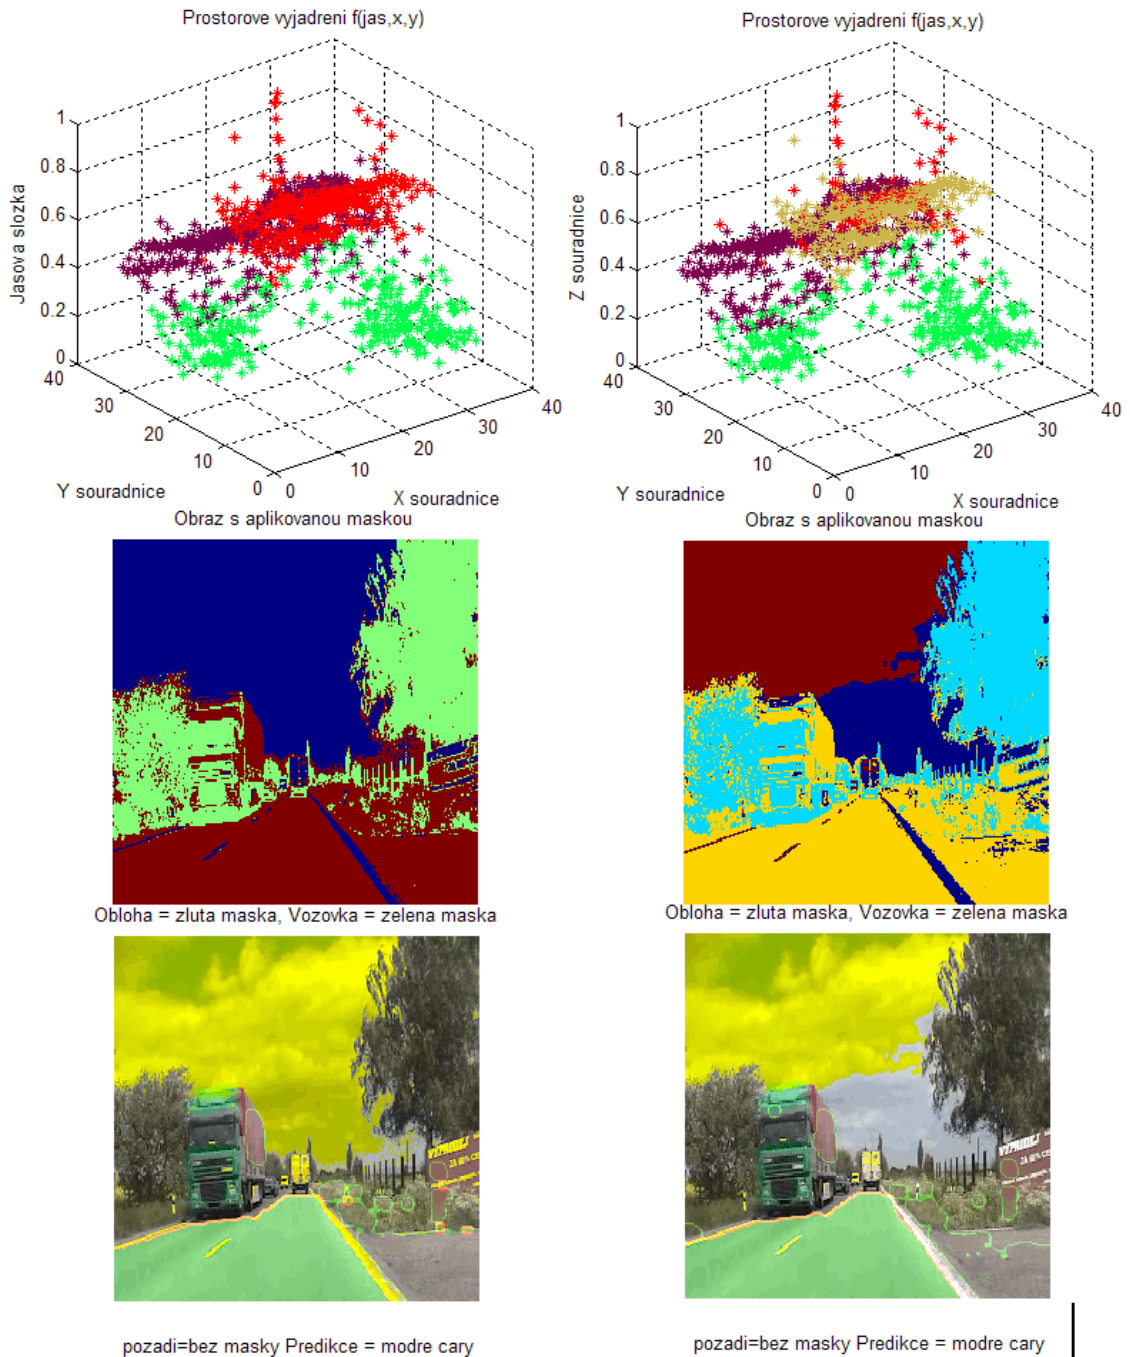
Jedním z možných řešení je posílení vlivu parametrů p reprezentujících barevnou informaci a naopak ztlumení vlivu parametrů prostorových souřadnic.

Toho lze dosáhnout ovlivněním měřítka funkce nepodobnosti (7.1.12) rozdílně pro jednotlivé parametry p , nebo jednodušeji úpravou vstupních parametrů. Transformujeme-li např. rozsah parametru p_i z $\langle a_1, b_1 \rangle$ do $\langle a_1, b_2 \rangle$ kde $b_2 > b_1$, dojde u příslušného parametru také k nárůstu meziobjektové vzdálenosti a tím k nárůstu hodnot funkce měřítka (eukleidovská vzdálenost). Tak dojde ke zvýraznění daného parametru p_i oproti ostatním, tedy k vyšší citlivosti algoritmu na tento parametr.

Na Obr. 40 je zobrazena situace potlačení vlivu parametrů koeficientů prostorových souřadnic oproti parametrům koeficientům jasových (barevných) složek o 33%. Na obrázku v levé části je zobrazena segmentace do $k=3$ shluků¹⁴, v pravé části pak $k=4$ shluků. V obou případech došlo ke správnému spojení obrazových bodů tvořících pozadí (zelená barva) do jednoho shluku (převážilo měřítko hodnot barevných úrovní). Vzhledem k tomu, že předpokládám pouze tři významné objekty tvořící scénu (vozovka, pozadí, obloha) a s přihlédnutím k významnému potlačení vlivu koeficientů prostorových souřadnic, vede segmentace do $k=4$ shluků nutně k nevhodné nadsegmentaci obrazu, což se projevuje vznikem dvou shluků v oblasti objektů tvořících oblohu (Obr. 40 - v pravé části). Segmentace do čtyř shluků také zvyšuje počet iteračních cyklů výpočtu a prodlužuje tak dobu výpočtu.

¹⁴ iniciační μ_j vektor pozadí v pravé části obrazu shodně s předchozími příklady

Navržený postup je velmi robustní a poskytuje vynikající výsledky. Jeho hlavní výhodou je tvorba masek bez většího počtu nespojitých oblastí. Dalším přínosem je zahrnutí prostorových souřadnic, což vede ke správnějšímu přeskupení obrazových bodů zejména na rozhraní jednotlivých podmnožin shluků C_i .




Obr. 40: Výsledky shlukování K -means při $p_{barev}/p_{souř}=0.66$ v R^5 (barva, prostor. souřadnice), Levý sloupec: $k=3$ shluky, pravý sloupec $k=4$ shluky

Obloha = žlutá maska, Vozovka = zelená maska



Obraz s aplikovanou maskou




pozadí=bez masky Predikce = modré čary

Obloha = žlutá maska, Vozovka = zelená maska




Obraz s aplikovanou maskou




pozadí=bez masky Predikce = modré čary

Obloha = žlutá maska, Vozovka = zelená maska



Obraz s aplikovanou maskou



pozadí=bez masky Predikce = modré čary

Obr. 41: Příklad obrázků po aplikaci segmentace shlukováním v prostoru R^3 (tři barvy, souřadnice - se sníženým vlivem), pro $k=3$

Transformací jednotlivých parametrů p objektu o_i vstupujících do procesu shlukování se podařilo vhodně snížit citlivost algoritmu na prostorové rozložení obrazových bodů v dopravní scéně a naopak zvýšit citlivost v prostoru barev. Na Obr. 41 je zachyceno několik případů snímků, reprezentujících reálné dopravní situace na které byly aplikovány výše zmíněné postupy. Na snímcích jsou vyznačeny masky vozovky (zelená barva), obrysy vozovky (červená barva) a oblohy (žlutá maska). Výsledky je možné porovnat s klasickými segmentačními postupy, uvedenými např. na Obr. 17, či Obr. 24, či s postupy využívající hranové operátory.

Obloha = žluta maska, Vozovka = zelena maska Obloha = žluta maska, Vozovka = zelena maska



pozadi=bez masky Predikce = modre cary

pozadi=bez masky Predikce = modre cary

Obloha = žluta maska, Vozovka = zelena maska Obloha = žluta maska, Vozovka = zelena maska

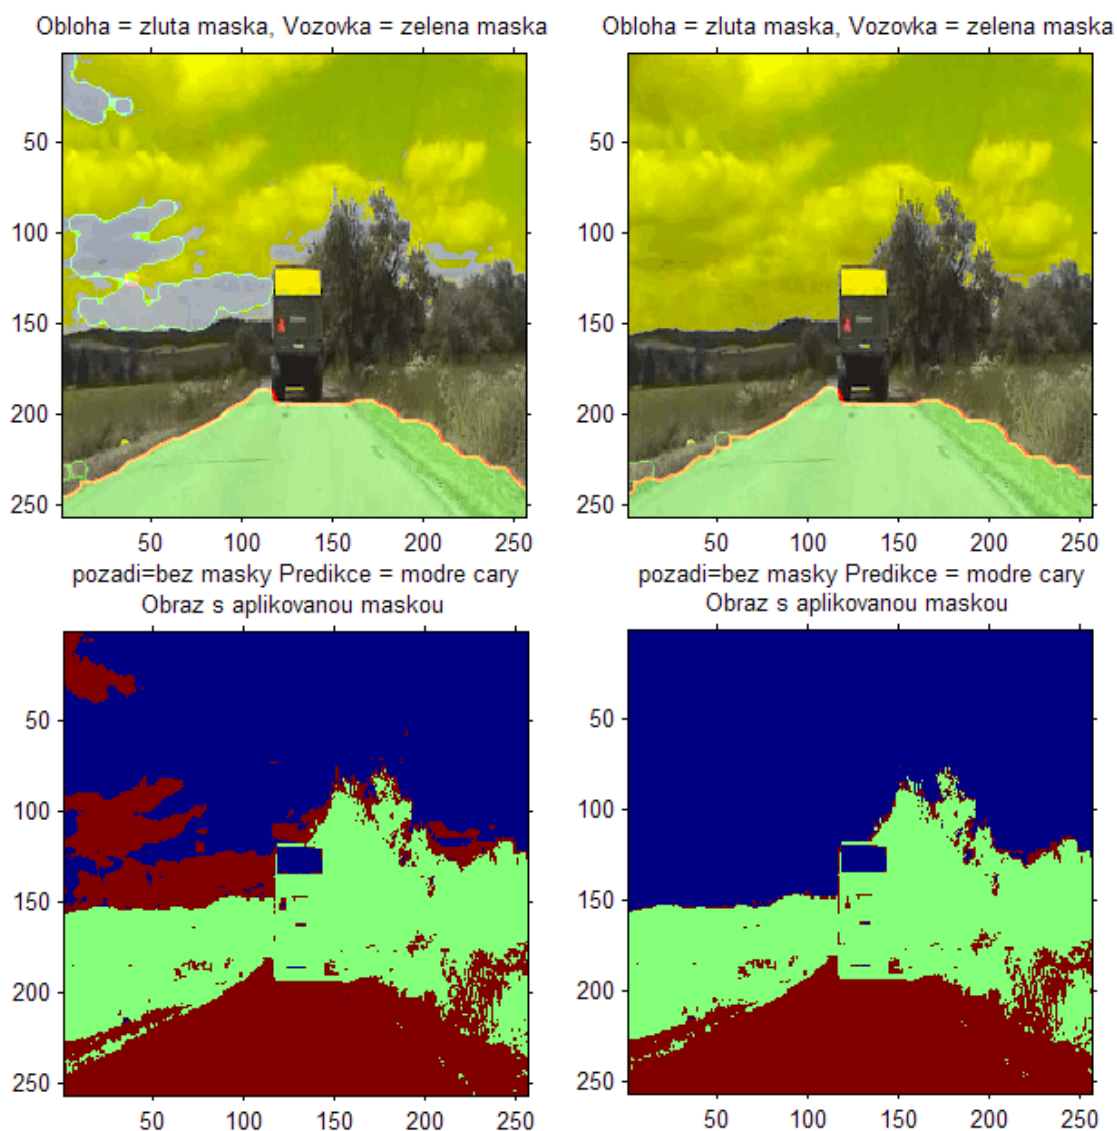


pozadi=bez masky Predikce = modre cary

pozadi=bez masky Predikce = modre cary

Obr. 42: Příklady obrazů po aplikaci segmentace shlukováním v prostoru R^3 (barvy), pro $k=3$

Na Obr. 42 je zobrazeno několik dalších dokumentačních příkladů obrazů segmentovaných pouze v prostoru barev. Výhodou zvolené metody je disjunkttní rozklad obrazové množiny, což značně ulehčuje aplikaci dalších segmentačních algoritmů a také konvergence vedoucí vždy k řešení (s větší či menší přesností). Nevýhodou tohoto postupu je ale značné množství zpracovávané informace, narůstající kvadraticky s rozlišením obrazu a proměnný počet iterací vedoucích k řešení.



Obr. 43: Porovnání výsledků segmentace shlukováním K -means aplikovaným pouze na jasovou složku (obrázky vlevo) a v prostoru R^5 (tři barvy, souřadnice - se sníženým vlivem), pro $k=3$

Na Obr. 43 je zobrazeno porovnání výsledků segmentace dosažených dvěma výše popsanými postupy. Zatímco na segmentaci pouze v jasové složce bylo třeba 13 iteračních kroků s celkovou délkou výpočtu 0,73 s, na výpočet v R^5 (tedy v barvách a prostorových souřadnicích s potlačeným vlivem) bylo třeba 11 iteračních kroků s celkovou délkou 1.68 s. Je to způsobeno rozdílným množstvím zpracovávaných dat. Zatím co v prvním případě bylo zpracovááno pouze zhruba 256 jasových úrovní ve 13 cyklech, ve druhém případě bylo nutné zpracovávat 65536 objektů, každý s 5 parametry. V závislosti na složitosti scény se mění počet iteračních kroků vedoucích k řešení. Algoritmu shlukování v R^5 však dosahuje podstatně lepších výsledků, zejména na rozhraních množin. Pro časově kritické aplikace je tak výhodnější použití metody shlukování v oblasti jasu, případně v oblasti parametrů barev, vedoucí k podobným výsledkům, avšak v kratším čase¹⁵. Značného urychlení výpočtů za cenu snížené přesnosti je možné dosáhnout aplikací výše uvedených postupů na podvzorkovaný obraz.

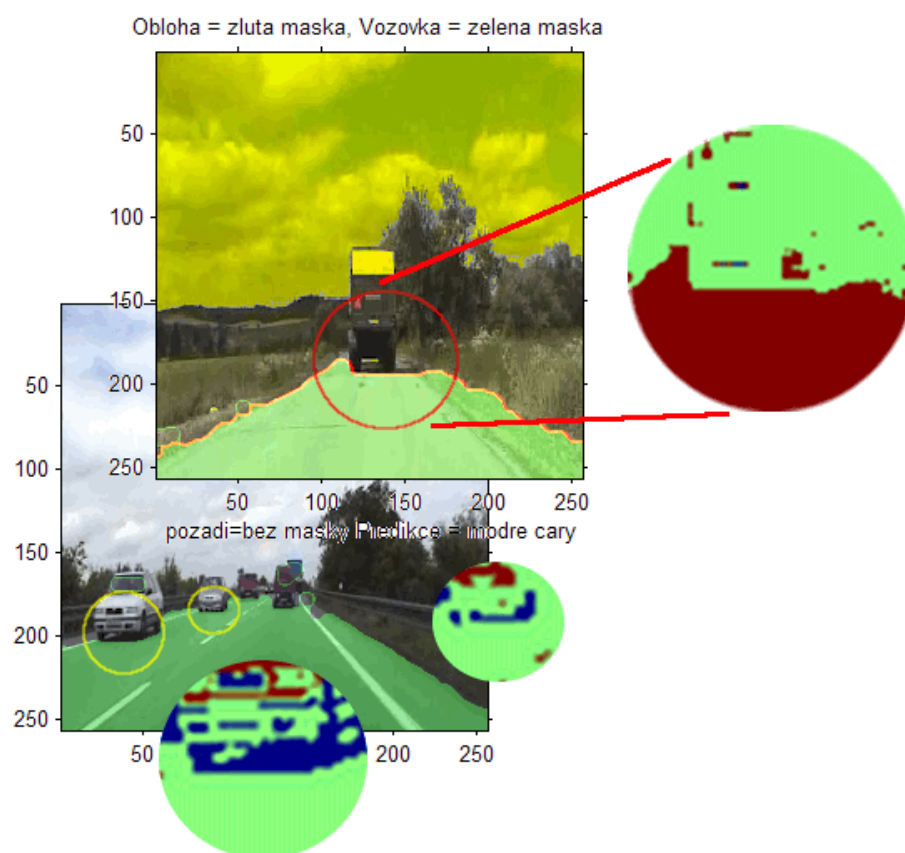
¹⁵ Rozdílnost dosahovaných časů je značně závislá na způsobu implementace některých algoritmů výpočtu histogramu a *K-means*. Na jiných platformách, než v prostředí *MATLAB* bude rozdíl v časech zřejmě vyšší.

7.2 Detekce vozidel

Následující část práce se věnuje detekci vozidel v obraze. Představené metody tvoří soubor několika nízkoúrovňových metod, tvořících základ pro další nadstavbové algoritmy sledování polohy vozidel. Představené metody využívají statické snímky získané ze souboru vstupních dat. Podle požadavků na rychlost zpracování mohou být tyto metody využívány vyššími systémy jednotlivě, či v kombinaci periodicky, či pouze pro zpřesnění polohy. Metoda *kumulativního* vyhledávání obrysů vozidel využívá ze vstupních dat první určující snímek se vstupními souřadnicemi a dále skupinu několika následujících snímků s pohybujícím se vozidlem.

7.2.1 Odhad polohy vozidel na základě vlastností masky vozovky


Detekční postupy popisované v předchozích částech produkují masku vozovky vyznačující se některými specifickými vlastnostmi v místech výskytu vozidel. Těchto vlastností je možné použít pro zvýšení pravděpodobnosti detekce cíle, jak bude popsáno v následujících kapitolách.



Obr. 44: Deformace okraje masky v místě výskytu objektů

Při analýze výstupů detekčních postupů produkujících masku vozovky se projevila odezva na výskyt vozidla, promítající se do tvaru masky vozovky v místě pod vozidlem. Na Obr. 44 jsou zobrazeny příklady dvou dopravních scén s různým počtem vozidel v několika vzdálenostech od snímací kamery. V detailech snímků je zvýrazněno charakteristické zakřivení masky pod vozidly. Nezávisle na úhlu okraje masky vozovky je pod každým vozidlem normála okraje masky skloněna pod úhlem zhruba $90^{\circ 16}$ v závislosti na rotaci objektu oproti vodorovné ose. Tohoto faktu je možné využít k separaci těchto částí z masky.

V první části separačního postupu je maska vozovky (Obr. 45a) pomocí *morfologického otevření* s diskovým *strukturálním elementem* o velikosti pěti obrazových bodů zbavena nevhodně detekovaných částí narušujících celistvost masky (Obr. 45b).



Obr. 45: Separace segmentů okraje masky vozovky pod vozidly

¹⁶ měřeno vůči vodorovné ose

Na masku je poté aplikován *Prewittův hranový operátor* pro získání okraje masky. Hranová detekce je prováděna ve svislém i vodorovném směru pro pozdější možnost vyhledávání složitěji tvarovaných segmentů a pro zachování spojitého průběhu hrany.

Poslední část segmentace je založena na separaci úseků vyhovujících zadanému kritériu. K separaci by bylo možné použít více postupů. Jako nejjednodušší, nejrychlejší a při tom dostatečně spolehlivý se ukázal postup morfologického otevření se strukturálním elementem v podobě *horizontálně orientované přímky* o rozměrech 1 x 9 obrazových bodů¹⁷. Díky vlastnostem morfologického otevření je tak při vhodné volbě délky strukturálního elementu dosaženo spolehlivé separace vodorovných segmentů hrany masky (Obr. 45d).

Takto získané segmenty je možné promítnout do původního obrazu (Obr. 46) a využít je pro případné ohodnocení pravděpodobnosti detekce objektů v dalších detekčních algoritmech.



Obr. 46: Detekované segmenty hrany masky vozovky promítnuté do zdrojových obrazů

Velkou výhodou uvedeného postupu je rychlost a spolehlivost detekce. Téměř všechna vozidla jsou tímto postupem zachycena, což umožňuje porovnat výsledky dosažené dále uvedenými postupy. Na Obr. 46b je vidět, že jsou zpracovány i ty segmenty, které je možné reprezentovat postupně přesazenými několika úseky. Dojde tak k zachycení i těch částí hranice, jež jsou skloněny o nepatrný úhel oproti vodorovné poloze.

¹⁷ Při rozlišení obrazu 256 x 256 bodů

Nevýhodou tohoto jednoduchého algoritmu je ale produkce segmentů i v místech kde se nachází vodorovná část hrany i bez přítomnosti vozidla. Uvedený postup tedy nelze použít samostatně bez dalších nadstavbových vyhodnocovacích částí.

Tento postup bude využíván pro validaci výsledků u dalších segmentačních postupů.

7.2.2 Detekce objektů porovnáváním se vzory

Velmi často používanou metodou pro vyhledání objektů v obraze je porovnávání vhodné masky, či více masek získaných ze souboru vzorových dat s obrazem. V následující části je popsán jednoduchý způsob vyhledávání vozidel pomocí hledání jejich obrysů.

Vstupní obraz (Obr. 47), reprezentující dopravní scénu obsahuje velmi mnoho drobných a z hlediska hledání objektů nevýznamných útvarů. K jejich potlačení je využita metoda *morfologického otevření obrazu* pomocí vhodně definovaného strukturálního elementu. Podobného efektu by bylo možné dosáhnout vhodnou dolnofrekvenční propustí, došlo by však k rozmazání hran v obraze.

Výhodou *morfologického otevření obrazu* je odstranění malých objektů, zatímco tvar a velikost velkých objektů zůstávají zachovány [2]. Efektem této operace je tedy eliminace malých a nevýznamných objektů (Obr. 48), které díky své velikosti nemohou reprezentovat vozidla.

Při analýze struktury vstupního obrazu obsahujícího vozidla a další objekty na vozovce, se ukázalo jako nejvýhodnější aplikovat v operaci *morfologického otevření obrazu* čtvercový *strukturální element* s velikostí 15 obrazových bodů¹⁸. Výsledkem těchto operací je obraz s jasně viditelnými dominantními objekty (pozadí, vozovka, obloha, vozidla) a s potlačeným výskytem nezajímavých objektů. Na Obr. 48 je tento jev viditelný v porovnání s Obr. 47 na svislém dopravním značení.

¹⁸ Při velikosti vstupního obrazu 256x256obrazových bodů.




Obr. 47: Vstupní obraz



Obr. 48: Obraz po morfologickém otevření

Takto je v obraze potlačen výskyt objektů menších než zadané kritérium. Na upravený obraz je dále aplikován *Robertsův hranový operátor* v obou směrech pro nalezení svislých a vodorovných hran [1]. Výsledkem jsou nalezené správné a mnoho parazitních hran (Obr. 49).



Obr. 49: Obraz po aplikaci Robertsova hranového operátoru s jasně patrnými obrysy hledaného objektu.

Úkolem následující části je nalezené hrany klasifikovat podle příslušnosti k hledaným objektům. Tento úkol je řešen mnoha způsoby, např. pomocí *Houghovy transformace* [1]. Vzhledem k apriorním znalostem některých vlastností hledaného objektu, je však možné použít i dále uvedený postup: V dopravní scéně jsou hledány objekty s přibližně čtvercovým, či obdélníkovým průmětem obrysu vozidla. Pro vlastní detekci jsem použil myšlenky vyhledání rohů těchto objektů a jejich vzájemné vhodné propojení, či sdružení do skupiny tvořící obrys vozidla.

K vyhledání rohů nejsou použity klasické postupy, ale rohy objektů jsou vyhledány pomocí algoritmu dvourozměrné *FFT*. Pro zpřesnění pozice nalezených hran probíhá konvoluce vstupního obrazu s jádrem o velikosti 11×11 bodů reprezentujícím roh (či jakýkoli jiný hledaný průběh) obrysu vozidla ve čtyřech stupních (Obr. 50). Cílem je nalezení všech rohů tvořících obrys vozidla v polohách 0° , 90° , 180° a 270° . V oblasti výskytu rohu dosahuje výsledek konvoluce s jádrem maxima a v obraze se objeví bod s vysokou intenzitou (Obr. 51). V okolí bodu intenzita jasu obrazových bodů prudce klesá a odstup oproti bodům pozadí je značný. Výhodou tohoto postupu je nalezení i takových útvarů, které odpovídají masce pouze přibližně, či masce rotované o malý úhel.

```

rohLH=[ 0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 1 1 1 1 1 1 1;
        0 0 0 0 1 0 0 0 0 0 0;
        0 0 0 0 1 0 0 0 0 0 0;
        0 0 0 0 1 0 0 0 0 0 0;
        0 0 0 0 1 0 0 0 0 0 0;
        0 0 0 0 1 0 0 0 0 0 0;];

rohPH=[ 0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;
        1 1 1 1 1 1 1 1 0 0 0;
        0 0 0 0 0 0 1 0 0 0 0;
        0 0 0 0 0 0 1 0 0 0 0;
        0 0 0 0 0 0 1 0 0 0 0;
        0 0 0 0 0 0 1 0 0 0 0;
        0 0 0 0 0 0 1 0 0 0 0;];

rohLD=[ 0 0 0 0 1 0 0 0 0 0 0;
        0 0 0 0 1 0 0 0 0 0 0;
        0 0 0 0 1 0 0 0 0 0 0;
        0 0 0 0 1 0 0 0 0 0 0;
        0 0 0 0 1 0 0 0 0 0 0;
        0 0 0 0 1 0 0 0 0 0 0;
        0 0 0 0 1 0 0 0 0 0 0;
        0 0 0 0 1 1 1 1 1 1 1;
        0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;];

rohPD=[ 0 0 0 0 0 0 1 0 0 0 0;
        0 0 0 0 0 0 1 0 0 0 0;
        0 0 0 0 0 0 1 0 0 0 0;
        0 0 0 0 0 0 1 0 0 0 0;
        0 0 0 0 0 0 1 0 0 0 0;
        0 0 0 0 0 0 1 0 0 0 0;
        0 0 0 0 0 0 1 0 0 0 0;
        1 1 1 1 1 1 1 1 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;
        0 0 0 0 0 0 0 0 0 0 0;];

```

Obr. 50: Příklad konvolučních jader pro vyhledání rohů obrysu objektu



Obr. 51: Příklad výsledku konvoluce jádra masky levého horního rohu se vstupním obrazem (detail maxima)

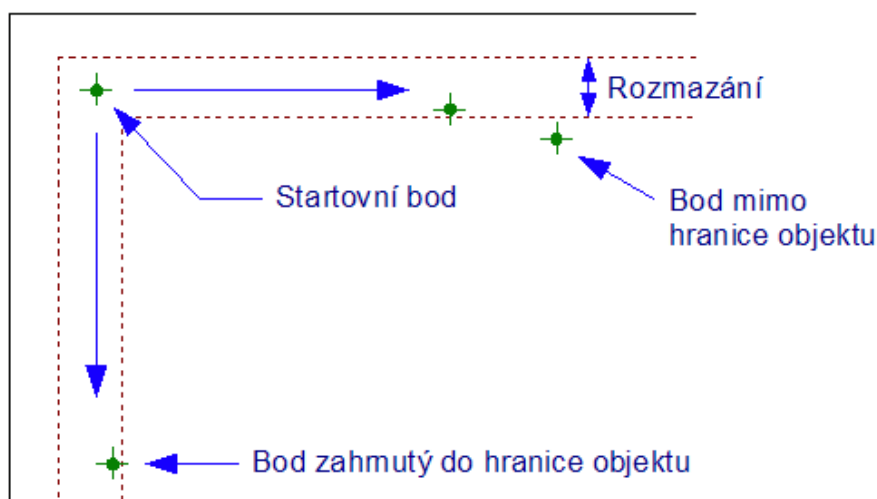
Další výhodou tohoto postupu je nalezení všech hledaných rohů pod určitým úhlem v jednom průchodu. Výsledkem jsou čtyři matice, reprezentující výsledky konvolucí. Tyto matice jsou sloučeny. Nalezených rohů je v obraze velké množství, proto je aplikován třídící

práh, který může být díky značnému odstupu maxim od pozadí nastaven fixně na 90% maximální hodnoty, čímž dojde ke značné filtraci nežádoucích bodů (Obr. 52).



Obr. 52: Výsledek hledání maxim pomocí 2D-FFT (práh=0.9)

Světlé body na Obr. 52 reprezentují všechny nalezené útvary v obraze, odpovídající maskám z Obr. 50 po filtraci fixním prahem. I po aplikaci třídícího prahu je v obraze stále velké množství nesprávně určených rohů. Z nalezených bodů musí být pomocí vhodného postupu vyloučeny ty útvary, které nemohou tvořit vozidlo. Pro filtraci nežádoucích rohů jsem použil iteračního postupu filtrace objektů, které splňují zadané kritérium.



Obr. 53: Princip přiřazování spolu souvisejících rohů tvořících obrys vozidla.

Kritérium pro reprezentaci vozidla bylo stanoveno jako čtveřice (případně více) bodů, které společně mohou vytvářet obrys vozidla. Iterační algoritmus prohledává v obraze všechny body a vytváří z nich jednu či více skupin reprezentujících hledané objekty. Hledání začíná z každého bodu v obraze a prochází všechny možné alternativní cesty, slepé i správné tvořící dohromady hledaný objekt. Při vyhledávání objektů je respektována určitá nepřesnost - rozmazání pozice okrajů vozidla nastavitelná parametrem. Tato nepřesnost umístění jednotlivých bodů je dána jednak parametry snímací soustavy, ale může reprezentovat i úhel, pod kterým může být objekt skloněn vůči kolmici vozovky. Z experimentálních dat byla tato tolerance nastavena na 4 body. Princip vyhledávání jednotlivých bodů a spojování hranic je na Obr. 53.

Z nalezených k sobě vhodně příslušejících rohů jsou následně sestaveny okraje značící nalezené objekty.



Obr. 54: Výsledný obrázek s nalezeným a označeným objektem.

Výsledkem výše popsaného algoritmu jsou tedy aktuální souřadnice nalezených objektů v obraze a označený objekt (Obr. 54).

Uvedený postup je pouze základním nástrojem detekce. Výhodou uvedeného postupu je rychlost zpracování a nenáročnost implementace. Detekční postup dokáže celkem dobře rozpoznat vozidla v jednoduché dopravní scéně (např. otevřená krajina), ale pouze v blízké zóně, kde velikost průmětu vozidla je dominantní oproti dalším objektům ve scéně. Dodatečnou úpravou některých parametrů je ještě možné zvýšit účinnost detekce: V současné podobě je aplikován fixní třídící práh s experimentálně určenou hodnotou 90% maxima. Je

možné předpokládat, že implementací adaptivního algoritmu by se úspěšnost rozpoznání ještě zvýšila. V případě úpravy tvaru konvolučních jader a jejich počtu a v případě úpravy iteračního algoritmu je možné detekovat i další objekty, jako například dopravní značení.

7.2.3 Detekce vozidel s využitím Houghovy transformace

Jedním ze způsobů detekce objektů v obraze je možnost využití některých předpokládaných vlastností tvarů hledaných objektů. V případě detekce vozidel je možné u každého vozidla předpokládat dvě přibližně svislé a vodorovné hranice ohraničující obrys vozidla, které je možné analyticky vyjádřit. V závislosti na skutečném tvaru, pozici, otočení a situování vozidla v rámci dopravní scény se skutečné obrisy budou tomuto předpokladu více či méně přibližovat. Prostá aplikace hranových operátorů na zpracovávaný obraz nevede k uspokojivým výsledkům. Obrisy jsou v závislosti na lokálním průběhu jasové funkce tvořeny nespojitými hranami a velmi ztěžují další zpracování a vyhodnocení. Z těchto důvodů je tedy důležité nalézt vhodný nástroj či transformaci, umožňující detekci takovýchto hranic i v případě jejich silného porušení, či zarušení šumem.


Velmi vhodným nástrojem pro detekci analyticky popsatelných útvarů je integrální *Radonova transformace*, resp. její speciální případ *Houghova transformace* [1], [2], [8].

Houghova transformace patří mezi metody globálního zpracování obrazu. Výhodou metody je, že uvažuje vztahy mezi obrazovými body dislokovanými samostatně v rámci obrazu, jež vytvářejí v rámci obrazu vyšší morfologické celky. Metoda využívá přímé (7.2.3) a zpětné (7.2.8) *Radonovy transformace* pro transformaci bodů mezi předmětovým prostorem a parametrickým prostorem.

Vztah mezi *předmětovým a Radonovým prostorem* je znázorněn na Obr. 55. Uvažujme parametricky vyjádřenou přímku:

$$\rho = x \cdot \cos \theta + y \cdot \sin \theta \quad (7.2.1)$$

Přímka je v předmětovém prostoru jednoznačně určena souřadnicemi l a θ , kde l představuje nejmenší vzdálenost přímky ρ od počátku souřadného systému a θ pak úhel normály přímky vzhledem k ose x souřadného systému (Obr. 55).



Obr. 55: Princip transformace prostorů v Houghově transformaci

Definujme jednorozměrnou projekční funkci (7.2.2) jako jednorozměrný integrál intenzity jasu podél přímky ρ ve vzdálenosti l od počátku souřadné soustavy a pod úhlem θ od osy x :

$$r(\theta, l) = \int_{\rho} f(x, y) dl \quad (7.2.2)$$

Všechny body na přímce ρ splňují vztah (7.2.1). Potom je možné napsat projekční funkci (7.2.2) jako:

$$r(\theta, l) = \iint f(x, y) \delta(x \cdot \sin \theta - y \cdot \cos \theta - l) dx dy \quad (7.2.3)$$

soubor projekčních funkcí (7.2.3) přes všechna θ představuje dopřednou *Radonovu transformaci* vypočítanou na ploše $f(x, y)$ a tvoří *Radonův prostor*, v diskrétní podobě označovaný jako *Radonův akumulátor*, vyjádřený pro přímku ρ . Shodným postupem je možné vytvořit předpis i pro hledání dalších analytických útvarů.

V *Radonově prostoru* (*Radonově akumulátoru*), tedy souboru $r(\theta, l)$ je zvykem vynášet na osy hodnoty L a θ , neboli na svislou osu informaci o poloze přímek p_i v předmětovém prostoru a na vodorovnou osu úhly projekcí (Obr. 55). Jedna analyticky vyjádřená přímka je podle (7.2.2) zobrazena jako přírůstek hodnoty $\Delta r(\theta, l)$, v diskrétní podobě pak jako inkrementace paměťového místa $\Delta r(\theta, l)$ v diskrétním prostoru.

Vlastní vyhledávání primitiv je možné realizovat vyhledáváním maxim v *Radonově akumulátoru*¹⁹. Vybraná maxima je možné snadno transformovat zpět do předmětového prostoru. Transformace celého *Radonova prostoru* pro získání původního obrazu (průběhu funkce $f(x, y)$) vyžaduje *zpětnou Radonovu transformaci*.

¹⁹ Bude popsáno v následující části věnující se aplikaci *RT*

Pro odvození zpětné *Radonovy transformace* existuje více postupů. V následující části uvedu zjednodušený postup vedoucí k transformaci s využitím vlastností dvourozměrné *Fourierovy transformace*. Tento postup přináší v konečném výsledku možnost využití algoritmu rychle inverzní *Fourierovy transformace*, což vede k podstatnému urychlení výpočtů. Podrobnější rozbor je možné nalézt v [1], nebo [3].

Při odvození zpětné *Radonovy transformace* je možné využít věty o centrálním řezu:

Řez 2D Fourierovy transformace obrazu o pod úhlem θ je jednorozměrnou Fourierovou transformací projekce P_θ téhož obrazu o .

Větu o centrálním řezu lze dokumentovat substitucí $r(\theta, l)$ ze vztahu (7.2.3) do vztahu pro jednorozměrnou *Fourierovu transformaci*:

$$R(\theta, \omega) = \iiint f(x, y) e^{-j\omega l} \delta(x \cdot \sin \theta - y \cdot \cos \theta - l) dl dx dy \quad (7.2.4)$$

při využití základní vlastnosti *Diracova impulsu* lze vztah zjednodušit:

$$R(\theta, \omega) = \iint f(x, y) e^{-j\omega(x \cdot \sin \theta - y \cdot \cos \theta - l)} dx dy \quad (7.2.5)$$

po substituci $u = \omega \cdot \sin(\theta)$ a $v = -\omega \cdot \cos(\theta)$ a při porovnání se vztahem pro dvourozměrnou *Fourierovou transformaci*:

$$F(u, v) = \iint f(x, y) e^{-j(ux+vy)-l} dx dy \quad (7.2.6)$$

je vidět, že výsledkem je dvourozměrná *Fourierova transformace* provedená v projekci $u = \omega \cdot \sin(\theta)$ a $v = -\omega \cdot \cos(\theta)$ v rámci jedné přímky ρ .

Pro získání hodnot funkce $f(x, y)$, tedy hodnot obrazových bodů je tedy možné po vhodné substituci provést inverzní *Fourierovu transformaci*:

$$f(x, y) = \frac{1}{4\pi^2} \iint F(u, v) e^{j(ux+vy)} dx dy \quad (7.2.7)$$

Provedeme-li inverzní dvourozměrnou *Fourierovu transformaci* vztahu (7.2.5) a po převodu do polárních souřadnic:

$$f(x, y) = \frac{1}{4\pi^2} \iint R(\theta, \omega) e^{j\omega(x \cdot \sin \theta + y \cdot \cos \theta)} |\omega| d\omega d\theta \quad (7.2.8)$$

získáme vztah pro výpočet obrazových bodů obrazové funkce $f(x, y)$ pomocí algoritmu inverzní dvourozměrné *Fourierovy transformace*, kde $|\omega|$ je determinant jakobiánu transformace souřadnic do polárního vyjádření [3], [42].

Uvedený postup umožňuje výpočet inverzní *Radonovy transformace* pomocí aparátu inverzní *Fourierovy transformace*, který je velmi snadno realizovatelný algoritmy rychlé diskrétní inverzní *Fourierovy transformace FFT*¹. V programovém prostředí *MATLAB* je tento postup využíván funkcemi *radon* a *iradon*.

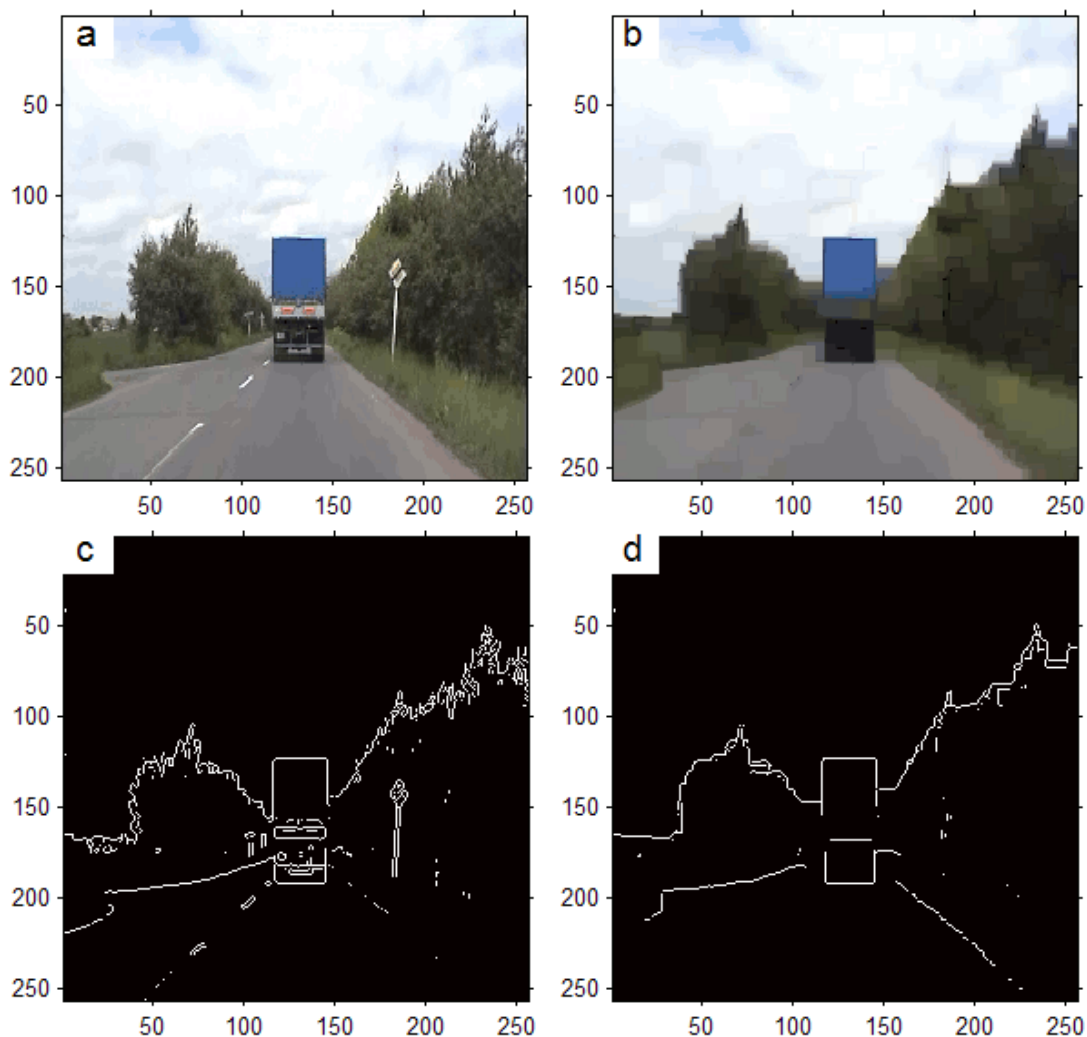
Aplikace Houghovy transformace v segmentaci obrazu

Před vlastním vyhledáním vozidel pomocí *Houghovy transformace* je vstupní obraz (Obr. 56) podroben několika základním operacím. *Houghovu transformaci* je možné aplikovat přímo na šedotónový obraz. V takovém případě bude ale *Radonův akumulátor* zatížen stejnosměrnou hodnotou průběhu jasové funkce a detekce maxim bude ztížena. Pro zvýšení odstupu maxim reprezentujících přímkou v obraze od pozadí je vhodné aplikovat na obraz některý z hranových operátorů.



Obr. 56: Vstupní obraz s vozidlem

Před aplikací hranového operátoru je obraz *morfologicky otevřen* s čtvercovým *strukturálním elementem* o velikosti 10x10 obrazových bodů. Dojde tak k potlačení hran reprezentujících drobné a z hlediska detekce vozidel nevýznamné objekty. Na Obr. 57 je zobrazen výsledek aplikace *Sobelova hranového operátoru* na vstupní šedotónový obraz. Pro porovnání výsledků je v levé části zobrazen výsledek hranové detekce bez morfologického otevření a v pravé části s morfologickým otevřením. Na obrázcích je jasně viditelné snížení počtu hran (svislé a vodorovné dopravní značení, okraje stromů), přičemž obrys vozidla je stále dobře patrný.



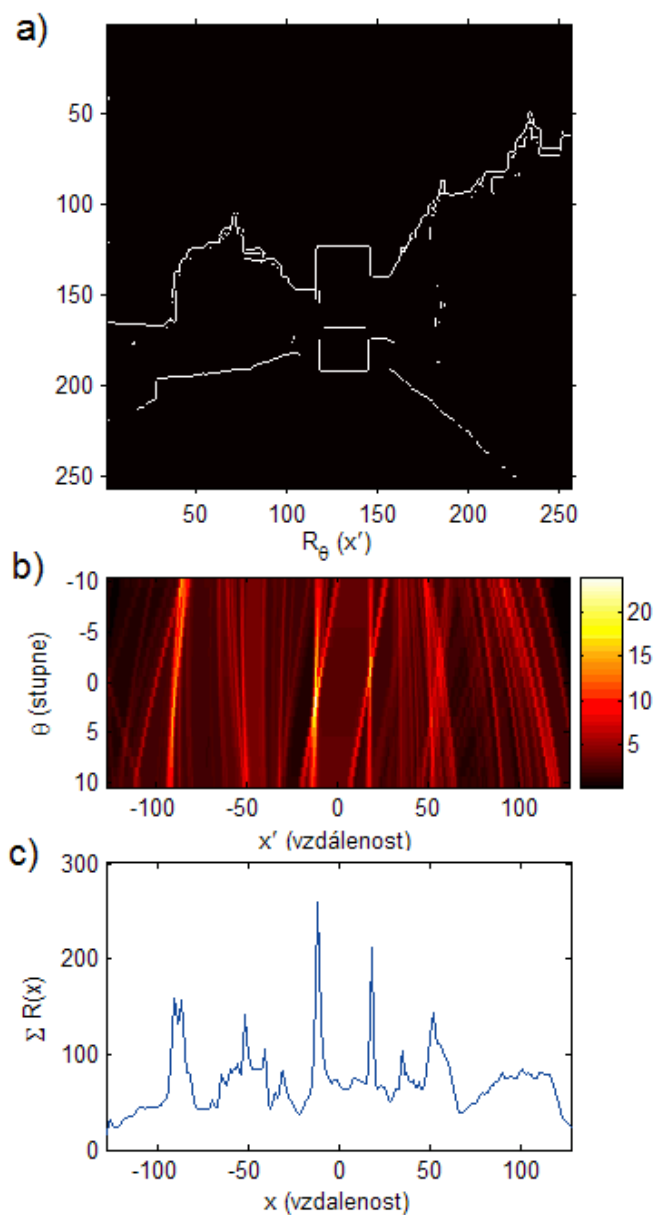
Obr. 57: Aplikace Sobelova operátoru na morfologicky otevřený obraz (obrazy v pravé části)

Při analýze obrazových dat se ukázalo nevhodné provádět *Houghovu transformaci* s parametrem θ v širokém rozsahu $\langle 0^\circ, 180^\circ \rangle$, protože v *Radonově akumulátoru* se objevovala lokální maxima reprezentující obrazové body na rozhraní pozadí a oblohy, které je také možné proložit přímkami.

Vzhledem k požadavku detekce obrysů vozidel je možné využít postupné detekce nejprve svislých hran vozidel, později vodorovných. Rozsah parametru θ byl proto snížen na omezený rozsah $\langle -10^\circ, 10^\circ \rangle$ ²⁰. Omezení rozsahu také pozitivně přispívá k urychlení

²⁰ úhel θ je úhel normály přímky od vodorovné osy

výpočtu. Další omezování rozsahu úhlu vede již ke snížené citlivosti detekce objektů rotovaných o větší úhel od předpokládané základní přibližně svislé polohy.



Obr. 58: Výsledek Houghovy transformace


Na Obr. 58b je zobrazen výsledek *Houghovy transformace* (obsah akumulátoru) pro černobílý hranový obraz²¹ s jedním vozidlem a průběh $\Sigma R(x)$ přes stanovený rozsah úhlu. Na obrázku je vidět několik lokálních maxim, která odpovídají přibližně svislým skupinám

²¹ oproti zvyklostem je akumulátor otočen o 90° pro snazší porovnání se vstupním obrazem

obrazových bodů proložitelných přímkami. Dominantními jsou skupiny bodů tvořící obrysy vozidla. Pro odstranění možného zvlnění v okolí lokálních maxim je *Radonův akumulátor* filtrován dvourozměrným *Gaussovým* filtrem typu dolní propust o velikosti 5x5 bodů. V akumulátoru jsou vyhledány páry maxim x_{i1} a x_{i2} reprezentující svislé hrany vozidel.

Výhodou popsaného postupu je jednorůchodová detekce v globálním měřítku obrazu – tedy v případě výskytu většího počtu vozidel jsou detekovány svislé hrany všech vozidel x_i .

Pro detekci vodorovných hran objektů je využita znalost pozice svislých hran. Ze vstupního obrazu jsou získány části obrazu mezi souřadnicemi x_{i1} a x_{i2} . Vznikne tak úzký segment obrazu pro každé vozidlo Obr. 59.



Obr. 59: Segment obrazu mezi x_{i1} a x_{i2} a průběh $\Sigma f(x, y)$

V tomto segmentu je provedena suma průběhu intenzity jasu²² a výsledkem je průběh s jasnými maximy ohraničujícími svisle vozidlo Obr. 59. Z detekovaných maxim x_i a y_i je určen střed vozidla (7.2.9) pro další operace.

$$S = \left[\left[\frac{x_{i1} + x_{i2}}{2}, \frac{y_{i1} + y_{i2}}{2} \right] \right] \quad (7.2.9)$$


²² V binárním obrazu

Výsledkem výše popsaného postupu je detekce jak svislých, tak i vodorovných hran tvořících vozidlo (Obr. 60). V případě více vozidel ve scéně je nalezeno více párů maxim x_{i1} a x_{i2} a jejich středů S_{i1} . Ke správnému přiřazení těchto souřadnic jednotlivým vozidlům je možné využít například iteračního porovnávání s výsledkem metody z kapitoly 7.2.1.

Sestavíme-li ze segmentů okraje masky vozovky z Obr. 45d vektor podle (7.2.10):

$$V(x) = \sum_{i=1}^{i=y_{max}} M_v(x, y) \quad (7.2.10)$$

pak za správně rozpoznaná vozidla jsou označena pouze ta, jejichž horizontální souřadnice vyhovují podmínce: $V(y_{i1}, y_{i2}) > 0$, tedy jejichž svislé souřadnice protínají některý ze segmentů určený metodou z kapitoly 7.2.1.



Obr. 60: Výsledek detekce vozidla za pomoci Houghovy transformace

Výhodou použití Houghovy transformace pro detekci obrysů vozidla je její značná necitlivost na chyby v obraze zatíženém šumem a necitlivost na poruchy hranic tvořících obrysy vozidla. V případě detekce přímek v obraze se navíc u obrazů dopravní scény ukazuje poměrně značný odstup maxim reprezentujících hrany objektů v Radonově prostoru oproti hodnotám pozadí. Tento odstup je navíc posílen prohledáváním prostoru pouze pro omezené úhly θ . Výsledkem je tedy velmi spolehlivá detekce. Se snižující se velikostí objektů však dochází ke snižování počtu bodů tvořících obrysy vozidla a tím dochází ke snižování lokálních maxim v Radonově prostoru. Metoda popisovaná v této kapitole je tedy použitelná

zejména v blízké zóně pro upřesnění rozměrů dobře viditelných vozidel, jejichž rozměry jsou dominantní oproti dalším objektům.

Detekce vozidel s využitím symetrie objektů

Detekční postup popisovaný v následující části je založen na vyhledávání oblastí s vysokým stupněm symetrie objektů podle vertikální osy. Detekce vozidel je obecně ztížena tím, že se vozidla objevují v obraze reprezentujícím dopravní scénu pod různými úhly, v různém měřítku a rotaci vůči základním souřadnicím snímacího zařízení. Do dopravní scény dále vstupují vozidla z různých směrů a v různém předem těžko predikovatelném počtu. Přímé vyhledávání tvarů nevede k uspokojivým výsledkům.

Jednou ze základních vlastností vozidel je symetrie svislého řezu průmětu vozidla podle vertikální osy. Tato vlastnost je v porovnání s dalšími objekty vyskytujícími se v obraze poměrně výjimečná. Dalšími objekty s výraznou symetrií jsou pouze objekty reprezentující dopravní značení, obrysy některých speciálních útvarů (celé budovy, velké reklamní plochy), případně složitější útvary vzniklé překrytím jednoduchých objektů v obraze.

Metod vyhledání symetrických útvarů existuje velké množství [9], [44]. Základním postupem všech metod je však nalezení vhodného kritéria S pro porovnání hodnot jasové funkce f skupin obrazových bodů w_i ve vzdálenostech r od osy symetrie. Problémem je vyjádření skupin obrazových bodů v závislosti na úhlu předpokládané osy symetrie. Vyhledávání je možné provést v zásadě dvěma základními způsoby:

- vyhledáváním s postupně se měnícím úhlem osy symetrie, např. $\varphi \in \langle 0, \pi \rangle$ a vzdáleností $r \in \langle r_1, r_2 \rangle$ v rámci celého obrazu
- či opačným způsobem: vyhledáváním vzájemně si příslušejících bloků obrazu w_i ve vzdálenostech $r \in \langle r_1, r_2 \rangle$ a poté nalezením maximálních os symetrie

Oba způsoby jsou výpočetně velmi náročné. Při předpokladu symetrie podle osy skloněné o 90° od vodorovné souřadnice x je ale možné celý postup výrazně zjednodušit a využít optimalizovaných výpočtů v rámci řádků a sloupců netransformované matice vstupního obrazu.

Definujme stupeň symetrie skupin obrazových bodů w_i :

$$S_i = \sum_j \Pi(w_i, \hat{w}_i) \quad (7.2.11)$$

kde \hat{w}_i je skupina obrazových bodů symetricky umístěná k w_i a Π je funkce shody.

Při předpokladu vyhledávání s osou symetrie kolmou na vodorovnou osu souřadnic x můžeme nahradit předchozí vztah:

$$S_i = \sum_j \Pi(w(i, j-r), w(i, j+r)) \quad (7.2.12)$$

kde součet hodnot porovnání provádíme v rámci jednoho řádku i přes všechny skupiny obrazových bodů j .

Funkce shody Π přiřazuje každým dvěma skupinám w_i a \hat{w}_i číslo Π – měřítko shody. Funkce pro totožné skupiny w_i a \hat{w}_i dosahuje extrému.

Pro praktickou realizaci může být funkce shody realizována např. jednorozměrnou korelací, jež dosahuje pro shodné skupiny maxima:

$$S_i = \sum_j \text{corr}(w(i, j-r), w(i, j+r)) \quad (7.2.13)$$

případně sumou absolutních diferencí SAD, jež dosahuje pro shodné skupiny minima:

$$S_i = \sum_j \text{SAD}(w(i, j-r), w(i, j+r)) \quad (7.2.14)$$

Obě funkce však přidávají do výpočtu dalších $n = \text{size}(w_i)$ operací. V případě (7.2.13) se jedná o $j \times n$ násobení, v případě (7.2.14) o $j \times n$ sčítání, jež je ovšem snadněji implementovatelné s ohledem na rychlost.

Ke značnému zjednodušení a výpočetnímu urychlení dojde, pokud snížíme velikost w_i na úroveň jediného obrazového bodu. Pak můžeme funkci Π realizovat prostým násobením hodnot jasové funkce symetricky umístěných obrazových bodů:

$$S_i = \sum_j f(i, j-r) \cdot f(i, j+r) \quad (7.2.15)$$

Výsledkem aplikace (7.2.15) na obrazová data je matice S obsahující průběh hodnot symetrie pro všechny řádky i a sloupce j .

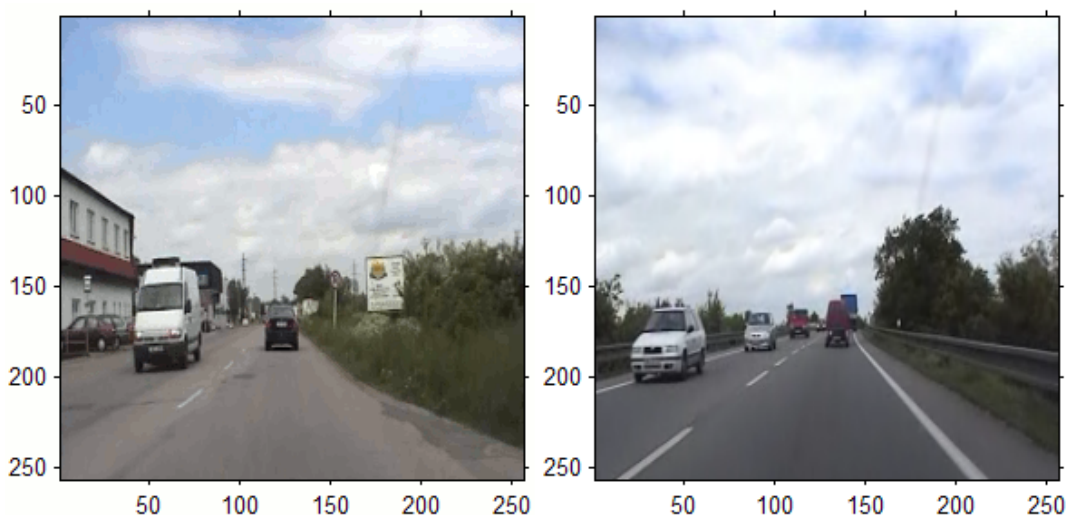
Pro získání průběhu symetrie podle vertikální osy provedeme sumaci S podle i :

$$S_j = \sum_i S_i \quad (7.2.16)$$

Přímá detekce podle (7.2.15) v šedotónovém obraze není možná. V šedotónovém obraze bude funkce shody (7.2.11) nabývat maxima i pro skupiny obrazových bodů se shodnou intenzitou jasu, např. pro skupiny obrazových bodů tvořících konstantní barevné plochy, či obrazové body s nulovou nebo maximální intenzitou jasu. Z tohoto důvodu je nutné provádět výpočet (7.2.15) a (7.2.16) na vhodně upravené reprezentaci obrazu, např. na binárním obraze reprezentujícím hrany v obraze.

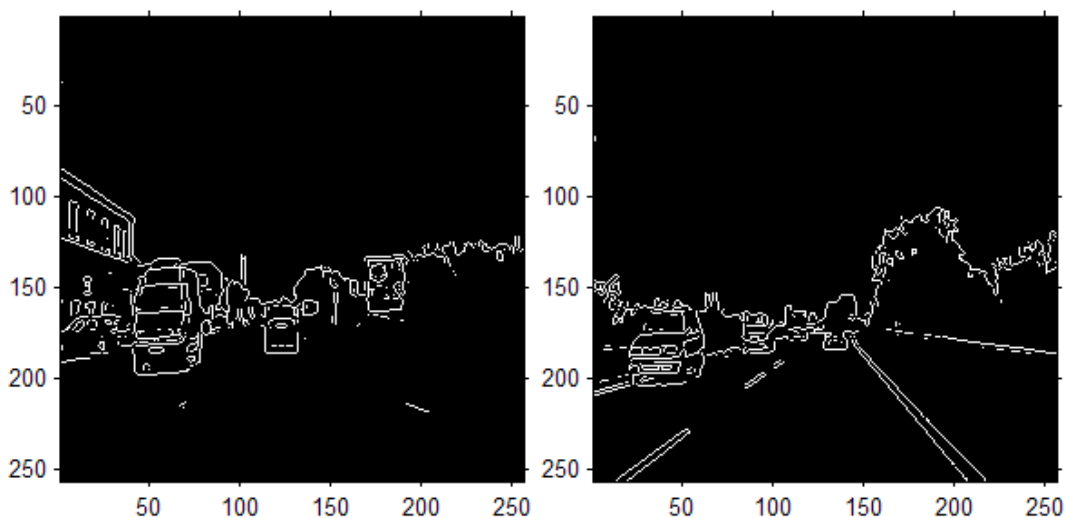
7.2.4 Aplikace detekce symetrických objektů v oblasti detekce vozidel

Na Obr. 61 jsou zobrazeny snímky reprezentující různý počet vozidel v různých konfiguracích vůči vozidlu se snímající kamerou. Detekce vozidel je v tomto případě silně ztížena výskytem dalších strukturálních objektů v obraze, jako jsou budovy, či svislé značení v okolí vozovky.



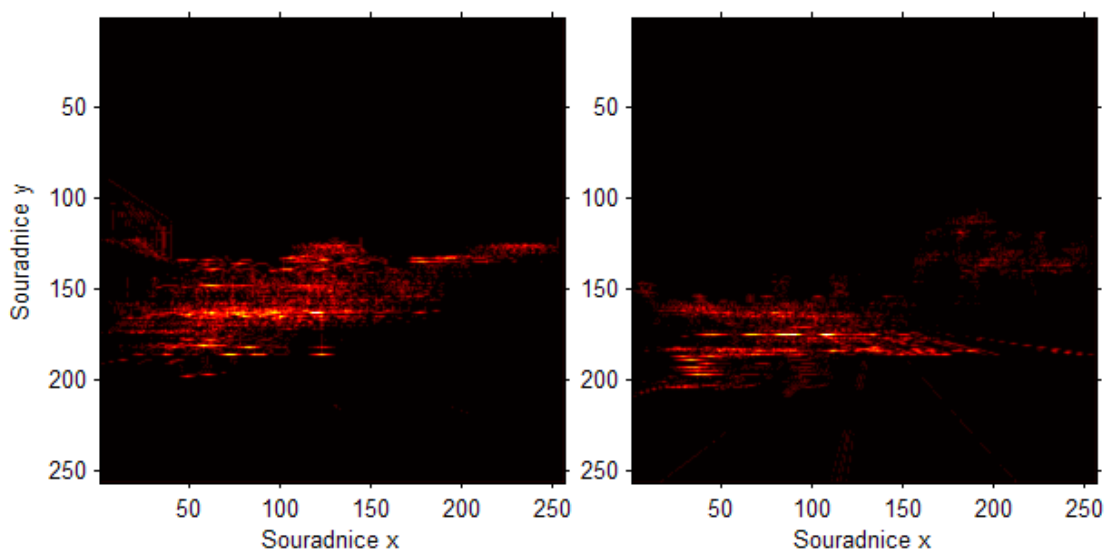
Obr. 61: Příklady vstupních obrazů s vozidly

Přímá aplikace algoritmu detekce symetrických objektů podle (7.2.15) nevede ke správným výsledkům. Před aplikací (7.2.15) je nutné obraz transformovat do prostoru zvýraznění okrajů objektů. Vhodným nástrojem je v tomto případě *Sobelův*, nebo *Prewittův* hranový operátor, jenž zvýrazní hrany a potlačí části obrazu s malou změnou jasové funkce (Obr. 62).

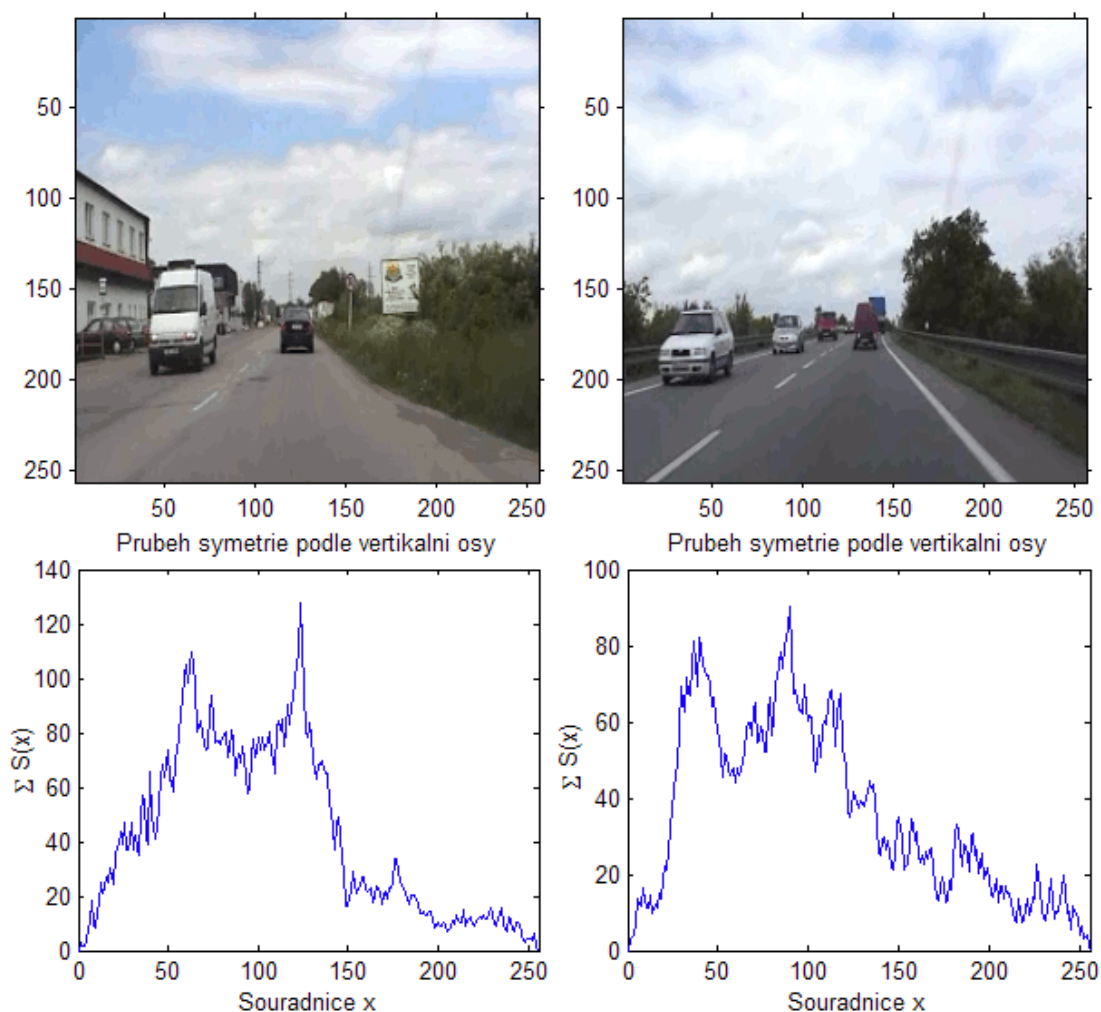


Obr. 62: Aplikace hranového operátoru na vstupní obraz

Z Obr. 62 je zřejmá nadsegmentace obrazu ztěžující přímou detekci vozidel způsobená vlastnostmi hranových operátorů. Na takto upravený obraz je ale již možné aplikovat postup popsany (7.2.15). Výsledkem je *Akumulátor* (Obr. 63) obsahující hodnotu $S(i, j)$ podle (7.2.15). Vzhledem k volbě kritéria odpovídají oblasti maxima průběhu symetrie podle vertikální osy maximálním hodnotám jasu v *Akumulátoru* $S(i, j)$.

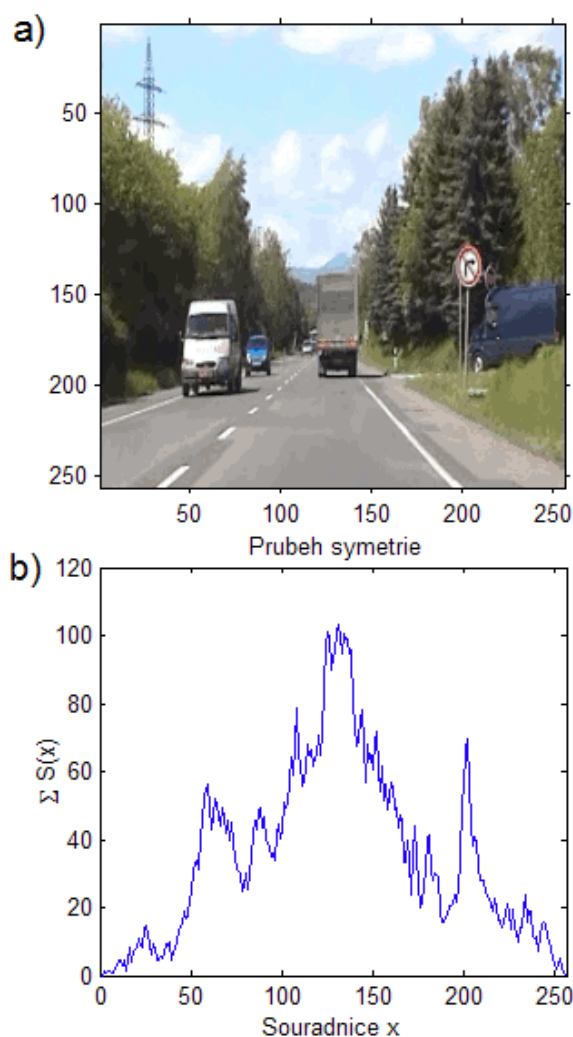


Obr. 63: Průběh symetrie podle svislé osy (*Akumulátor* $S(i, j)$)



Obr. 64: Průběh S_j pro vstupní obrázky (souř. x odpovídá vstupním obrazům)

Před dalším zpracováním je prostor $S(i, j)$ filtrován dvourozměrným *gaussovským* filtrem o rozměrech 5×5 obrazových bodů pro snížení možnosti uvážnutí dalších vyhledávacích algoritmů v lokálních extrémech. Z matice $S(i, j)$ je již možné podle (7.2.16) sestavit průběh symetrie v obraze. Na Obr. 64 je zobrazen průběh $S(j)$ pro vstupní obrázky (pro větší názornost zobrazeny nad průběhy $S(j)$). Z Obr. 64 je vidět, že lokální maxima průběhu $S(j)$ odpovídají pozici symetrických objektů v obraze.




Obr. 65: Průběh $S(j)$ pro obraz s vysokým stupněm symetrie levé a pravé části obrazu

Nalezení maxim odpovídajících vozidlům v obraze není jednoduché. Akumulátor $S(i, j)$ reprezentuje hodnoty symetrie vypočítané pro jednotlivé řádky podle (7.2.15) pro souřadnici j . Při sumaci $S(i, j)$ však dochází ke sčítání hodnot $S(j)$ vzniklých lokálním výskytem symetrických objektů, které jsou však superponovány na hodnoty vzniklé globální symetrií levé části obrazu vůči pravé části. Na Obr. 65a je zobrazen příklad obrazu, kde je tento jev obzvláště dobře patrný. Výsledkem je typický průběh $S(j)$ s maximem ve střední části a poklesem hodnot ke krajům obrazu (Obr. 65b). Tento jev však není možné jednoduše potlačit, protože globální symetrie obrazu je velmi proměnná v závislosti na obsahu scény - symetričnosti objektů v levé a v pravé části pozadí (porovnejte průběhy Obr. 64 a Obr. 65).

Absolutní hodnoty maxim v oblasti výskytu symetrických objektů jsou tedy rozdílné (Obr. 65b) a není možné na jejich detekci použít nástroje s konstantní volbou prahu.

Řešením je použití adaptivních parametrických metod, vhodně určujících práh ze statistických popisných charakteristik získaných z průběhu $S(j)$, či neparametrických adaptivních metod, jako je např. mediánových filtr upravujících lokální hodnotu prahu na základě výpočtu z hodnot průběhu signálu v okolí maxima [7].

Pro odstranění jevu popisovaného v předchozí části byla zvolena adaptivní metoda potlačení prahu založená na výpočtu střední hodnoty signálu $S(j)$. Výpočet odhadu střední hodnoty probíhá ze vzorků v bezprostředním okolí prohledávaného místa. Střední hodnota signálu $S(j)$ představuje dominantní hodnotu symetrie v akumulátoru $S(i, j)$ vzniklou symetrií levé a pravé části obrazu. Jejím adaptivním potlačením je možné zvýraznit v signálu pouze maxima, odpovídající symetrickým objektům vyskytujícím se v obraze (vozidlům, budovám...). Úkolem metody je tedy snížení počtu lokálních maxim odpovídajících drobným objektům a odstranění nerovnoměrné střední hodnoty průběhu $S(j)$. Schematické zobrazení principu použité metody je zobrazeno na Obr. 66.




Obr. 66: Struktura metody výpočtu prahu pro hodnoty $S(j)$

Pro výpočet celkové úrovně signálu v bezprostředním okolí j -tého vzorku $S(j)$ jsou uvažovány dvě skupiny vzorků v pořadí před a po j -tém vzorku $S(j)$. Z obou skupin vzorků je vypočítána střední hodnota signálu. V následujícím kroku je vybrána maximální hodnota z obou skupin. Tak je zajištěno přizpůsobení hodnoty prahu v místě vzorku předcházejícího, či následujícího za maximem průběhu vzniklým superpozicí s globální symetrií obrazu. Vhodným nastavením konstant výpočtu aktuální hodnoty prahu a počtu vzorků pro výpočet střední hodnoty před a za j -tým vzorkem je možné optimalizovat chování algoritmu pro různé skupiny signálů. Vyčleněním několika vzorků v okolí j -tého vzorku (ochranných vzorků) je možné optimalizovat poměr středních hodnot skupin okolních vzorků vůči j -tému vzorku a tím upravovat chování metody s ohledem na velikost gradientu maxima. Koeficienty k a m

umožňují nastavit výsledné hodnoty prahu v celém rozsahu průběhu $S(j)$. Vhodné koeficienty a počet vzorků vstupujících do algoritmu byly odvozeny experimentálně pro velký počet vstupních snímků. Podrobné odvození je možné nalézt např. v [7], či [41].

Na Obr. 67 je uveden výsledek metody pro průběh $S(j)$ z Obr. 65. Pro názornost je modrou barvou vyznačen původní průběh $S(j)$ a zelenou barvou je vyznačen průběh prahu $T(j)$ vypočítaného výše popsaným postupem²³.



Obr. 67: Průběh $S(j)$ - modře a hodnoty prahu $T(j)$ - zeleně

Z Obr. 67 je jasně patrná minimalizace počtu lokálních maxim, která jsou v uvažována v další části pro odhad pozice objektů a vyrovnání středních hodnot pod jednotlivými maximy (rozdíl maxim a prahu), což usnadňuje jejich následné vyhledání. Vhodným nastavení výše popsaného postupu je možné zvýraznit či potlačit hodnotu prahu v okolí objektů splňujících požadované kritérium (velikost objektu, symetričnost objektu, ostrost hranic objektu vůči pozadí).

Při vyhledávání objektů je možné využít předpokladů o umístění objektů v obraze. Šířka lokálních maxim funkce $S(j)$ je dána hodnotou symetrie objektu, vzdáleností mezi maximy a odstupem objektů v horizontální rovině. Budeme-li uvažovat minimální velikost objektů λ_i , pak vzdálenost os symetrie Y dvou sousedních objektů je minimálně $\Delta > \lambda_i$. Tento

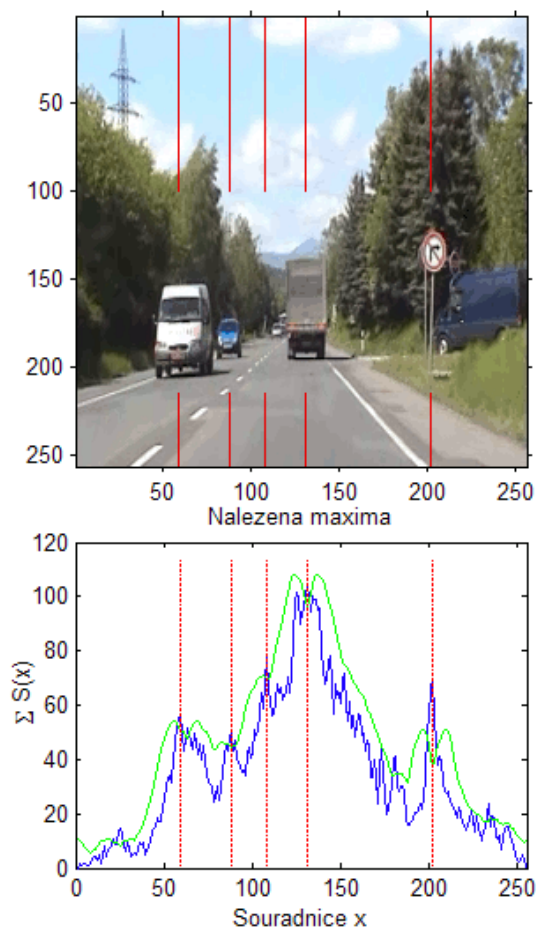
²³ Počet postranních vzorků = 24 + 24, k=1.1, m=0

poznatek umožňuje po prostém vyhledání maxima funkce $S(j)$ položit okolí $j \in \langle j - \lambda_i, j + \lambda_i \rangle$ rovno nule a tím jej vyloučit z dalšího vyhledávání.

Vyhledání m maxim je tedy možné realizovat iteračním hledáním maxim funkce $S(j)$ podle postupu:

1. vyhledání maxima funkce $Y = S(j)$, $n = n + 1$
2. vymazáním maxima a jeho okolí $S(j - \lambda_i, j + \lambda_i) = 0$;
3. posouzením podmínky: $n < m$
4. posouzením podmínky: ve funkci se již nenacházejí další maxima

Výsledkem uvedeného postupu je nalezení maximálně m maxim os symetrie akumulátoru $S(i, j)$. Na Obr. 68 je zobrazen výsledek hledání maxim pro předchozí obraz. Pro názornost je zobrazen průběh $S(j)$ spolu se vstupním obrazem se zpětně vyneseny osami symetrie Y (červeně) při zadaném parametru $m=5$.



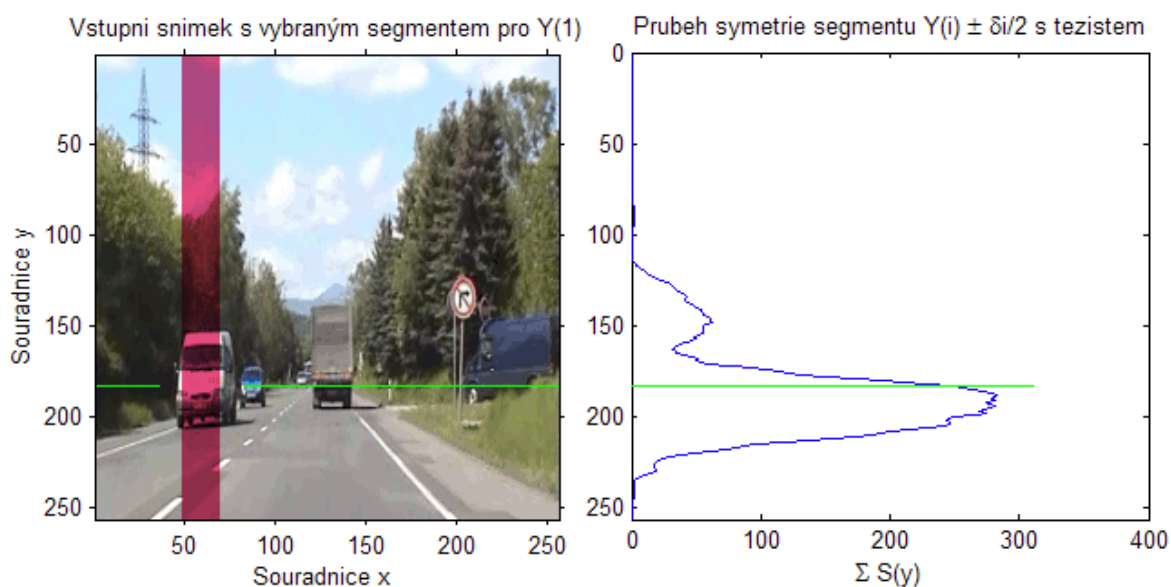
Obr. 68: Průběh $S(j)$ - modře s hodnotami prahu $T(j)$ - zeleně a nalezenými maximy - červené osy

Z průběhu $S(j)$ (Obr. 68) je patrné, že byla nalezena maxima reprezentující všechny symetrické objekty splňující zadaná kritéria. Mezi nalezenými objekty se vyskytují i takové objekty, které se jeví jako symetrické, splňující zadaná kritéria, nerepresentují však skutečné objekty vozidel. Například v Obr. 68 je to svislé dopravní značení, nebo virtuální objekt vzniklý sloučením vzájemně symetrických hran dvou sousedících vozidel (3. osa zleva). Výskyt těchto os symetrie není možné základními nízkosegmentačními postupy spolehlivě vyloučit, ani to není žádoucí. Tyto objekty budou vyloučeny jako nevhodné v dalších nadstavbových algoritmech sledujících např. pohyb objektů v obraze, či hodnotících další globální vlastnosti sledovaných vozidel. Z uvedeného příkladu je také jasně patrné vyhledání os symetrie z průběhu $S(j)$ pro objekty s rozdílným umístěním ve scéně vůči snímací kameře a s rozdílnou velikostí, což se projeví rozdílnými průběhy lokálních maxim v $S(j)$ (na Obr. 68 zejména osy 1 až 4).

Pro nalezení vertikální osy symetrie X^i každého objektu je možné využít shodného předpokladu o symetrii vodorovných hran objektů, podobně jako při vyhledávání vertikálních os. Známe-li vertikální osu symetrie objektu Y^i , je možné při předpokladu minimální šířky vozidla λ_i , stanovit výběrový pruh obrazu o velikosti $Y^i \pm \lambda_i/2^{24}$ kolem vertikální osy symetrie. V tomto výřezu obrazu je možné po transponování²⁵ výřezu stanovit podle (7.2.15) průběh symetrie podle horizontální osy a její průběh $S(i)$ podle (7.2.16).

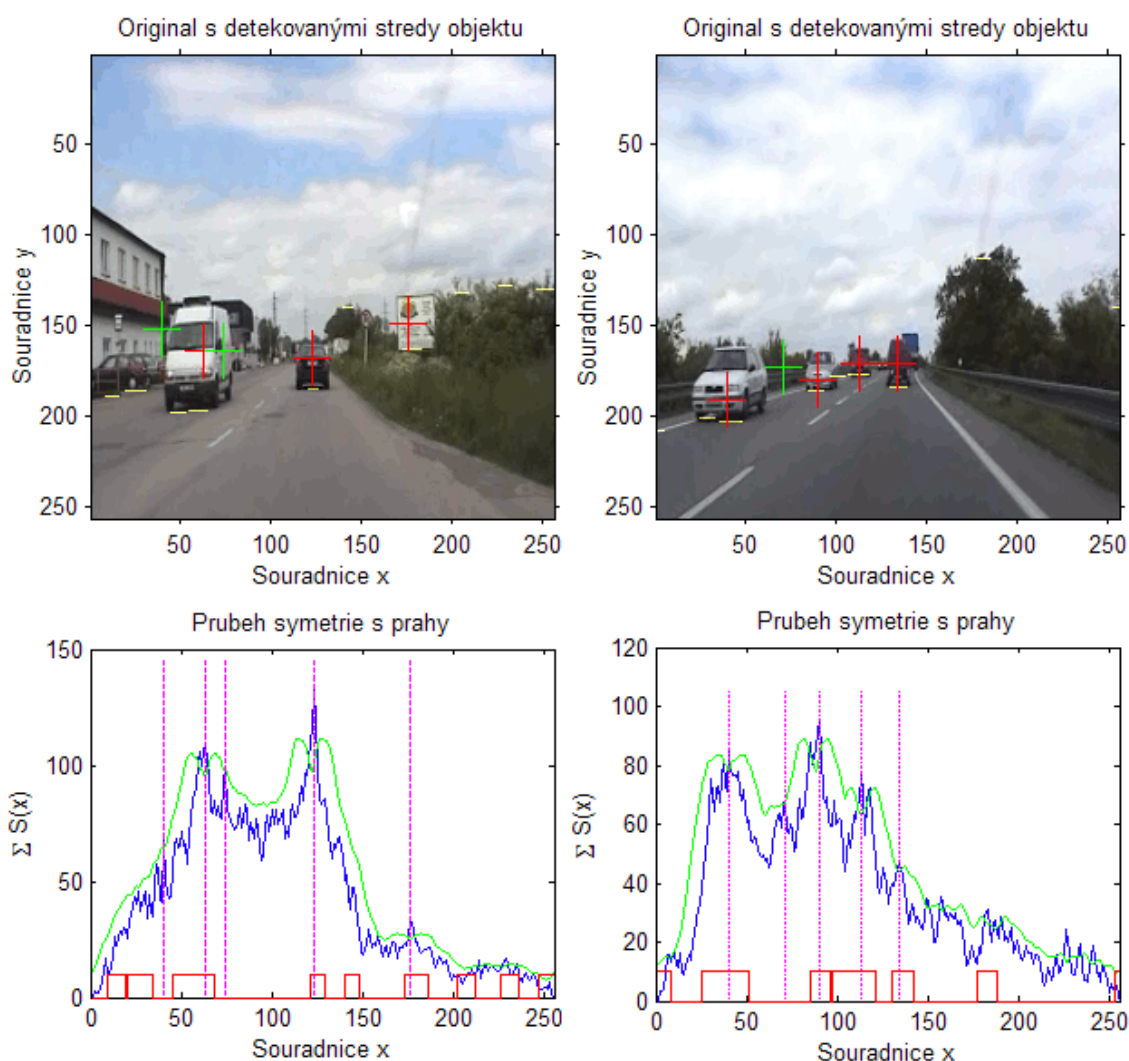
²⁴ Pro urychlení výpočtu je možné vyhledávat i v užším výběrovém segmentu obrazu - nižší přesnost

²⁵ Transpozice umožňuje využití rychlé implementace příkazu *sum*



Obr. 69: Vstupní obraz se zvýrazněným segmentem $Y^l \pm \lambda_l/2$ a odpovídající průběh $S(i)$

Na Obr. 69 je zobrazen příklad obrazu se zvýrazněným segmentem $Y^l \pm \lambda_l/2$ pro první vyhledanou vodorovnou osu symetrie. Segment obrazu pro vyhledávání je získán z obrazu reprezentujícího hrany, vytvořeného před vyhledáváním vodorovných os symetrie. Z tohoto segmentu je již vypočítán podle (7.2.15) a (7.2.16) průběh symetrie $S(i)$ pro konkrétní Y^l (Obr. 69b). Ve vybraném segmentu hranového obrazu se kromě hran vozidla vyskytují i hrany dalších objektů, značně ovlivňujících průběh symetrie (zejména stín pod vozidlem, horizont v obraze...). Proto prosté vyhledávání maxima funkce $S(i)$ nevede k uspokojivým výsledkům - střed vozidla je často posunut směrem k maximu $S(i)$ mimo vozidlo. Vzhledem k výchozímu předpokladu výskytu pouze jednoho vozidla na souřadnici Y^l lze předpokládat značný stupeň korelace mezi místem s maximální kumulací vodorovných hran a středem vozidla. Proto je tato informace také zahrnuta do vyhledávání $S(i)$. V průběhu symetrie je tak vyhledáváno nikoliv maximum, ale místo těžiště průběhu $S(i)$ (Obr. 69b), přesněji aproximující vertikální střed vozidla.



Obr. 70: Obrazy s nalezenými symetrickými objekty a průběhy symetrií (červenými kříži označeny validované detekcí průběhu zakřivení masky vozovky)

Na Obr. 70 jsou zobrazeny výsledky uvedeného postupu pro předchozí příklady vstupních obrazů Obr. 64. V obrazech jsou označeny kříži středy horizontálně i vertikálně symetrických objektů. Tímto postupem jsou obecně vyhledány objekty s vysokým stupněm horizontální symetrie, tedy i jiné objekty než jsou vozidla (Obr. 66 - svislé dopravní značení). K dodatečné filtraci nalezených objektů, zejména snížení počtu objektů nerepresentujících vozidla, je možné dále využít postup popsany v kapitole: *Odhad polohy vozidel na základě vlastností masky vozovky*. Na Obr. 70 jsou zobrazeny průběhy symetrie spolu s prahy, potlačujícími drobná maxima a nalezenými maximy odpovídajícími symetrickým objektům. Z nalezených maxim jsou vybrána pouze ta, jejichž osy symetrie Y' se nalézají v místech

označených rozborem zakřivení masky jako místa potenciálního výskytu vozidla (červený binární průběh na Obr. 70 dole, žluté segmenty ve vstupních obrazech).

Popsaný způsob detekce symetrických vozidel vede ke spolehlivé detekci objektů s vysokým stupněm symetrie podle svislé osy. Postup využívá faktu, že symetrickými objekty v dopravní scéně jsou převážně vozidla. V dopravní scéně se mohou objevit i další objekty s vysokým stupněm symetričnosti, jako jsou části domů, dopravní značení, vozidla v těsné blízkosti či virtuální objekty vzniklé hranami sousedních objektů. Tyto objekty metoda není schopna řádně klasifikovat. K jejich další validaci je nutné využít vyšších nadstavbových postupů provádějících například sledování pohybu objektů, či vyhodnocujících další vlastnosti objektů. S výhodou je také možné využít kombinace výsledků s předchozími metodami.

Velkým pozitivem metody je možnost ovlivňovat výpočetní rychlost v matici $S(i, j)$ - *akumulátoru* a přesnost metody. Výpočetní čas je závislý přibližně kvadraticky na šířce *akumulátoru*. Předchozí výsledky byly dosaženy pro velikost *akumulátoru* 256x256 bodů, tedy velikost shodnou s velikostí vstupního obrazu. Při snížení velikosti *akumulátoru* podvzorkováním vstupního obrazu např. na velikost 64x64 obrazových bodů dojde k více než šestnáctinásobnému²⁶ urychlení metody²⁷, avšak za cenu snížení přesnosti metody dané výpočtem v řídké matici.

Na Obr. 71 je zobrazen výpočet os symetrie předchozího obrazu pro tři proměnné velikosti *akumulátoru*. V levé části je zobrazen výsledek s *akumulátorem* o velikosti 256² obrazových bodů. Výpočet v tomto případě trval 3,7 s. Při podvzorkování původního obrazu na velikost 128² obrazových bodů došlo ke čtyřnásobnému urychlení (doba výpočtu 820 ms). V zobrazení středů vozidel je již patrná menší přesnost v detekci vozidel (nepřesnost je i ve vyjádření symetrie podle horizontální osy). Při zmenšení velikosti použitého *akumulátoru* na 64² obrazových bodů je celý výpočet proveden během 180 ms, nepřesnost určení středů vozidel je již ale srovnatelná s velikostí vozidla.

Díky možnosti ovlivňovat rychlost metody na úkor přesnosti v širokém rozsahu je možné použít tuto metodu nejen pro periodické občerstvování informace o pozici vozidel, ale i ke sledování pohybu vozidel.

²⁶ Dosahované urychlení je ve skutečnosti vyšší, díky odstranění latencí ve vyhodnocování větvících podmínek cyklů

²⁷ Např. na CPU Intel 1.8 GHz trval výpočet v *akumulátoru* o velikosti 256x256 bodů 3.7s, zatímco v *akumulátoru* o velikosti 64x64 bodů pouze 185 ms



Obr. 71: Průběh symetrie v obraze pro velikosti akumulátoru 256^2 (3,7 s), 128^2 (820 ms) a 64^2 (185 ms) bodů (červenými kříži jsou označeny úspěšně detekované objekty, zelenými kříži další maxima symetrie)

7.2.5 Kumulativní metoda vyhledávání obrysů vozidel

Výstupem předchozí popisované metody jsou středy objektů, potenciálně reprezentujících vozidla. Pomocí této metody však není možné přímo stanovit obrysy vozidla, tedy velikost detekovaného objektu. V následující části je popsán původní postup stanovení obrysů vozidla při znalosti pozice objektu. Postup využívá *kumulativní metody* potlačení šumu v signálu, sestaveném z několika po sobě jdoucích snímků, k určení velikosti objektu.

Objekty tvořící dopravní scénu je možné rozdělit do několika skupin podle kritéria rychlosti změny průběhu jasové funkce v závislosti na čase (reprezentovaném jednotlivými ekvidistantně nasnímanými snímky). Výchozím předpokladem je v tomto případě lokální změna průběhu jasové funkce v oblasti zájmu, označeném předchozí metodou stanovení středu vozidla. Lze předpokládat, že u pohybujících se vozidel nastávají pouze minimální změny průběhu jasové funkce v rámci vnějších obrysů vozidla a že vozidlo má statické vnější rozměry. Vzhledem k pohybu vozidla nesoucího snímací zařízení má však i pozadí

nestacionární charakter. Proto se pozadí, vozovka a objekty stacionární vůči vozidlu se snímacím zařízením vyznačují značným optickým tokem a rozměry měnícími se podle axonometrického zkreslení. Tyto předpoklady však nejsou dokonale splněny. Průběh jasové funkce v rámci obrysů vozidla je ovlivněn zejména proměnným osvětlením vozidla v průběhu jízdy a také změny rozměrů objektu jsou závislé na relativní rychlosti vůči vozidlu se snímacím zařízením. Také optický tok pozadí je značně proměnný. Ve středu horizontu pohledu je díky axonometrickému zkreslení scény optický tok nulový, zatímco u okrajů scény je maximální.


Provedeme-li však vhodné transformace potlačující některé z těchto vlivů, je možné pomocí těchto poznatků separovat objekty v jednotlivých po sobě následujících snímcích a pomocí *kumulativní metody* zvýšit odstup obrazových bodů s přibližně konstantní hodnotou reprezentujících vozidlo od značně proměnných obrazových bodů představujících pozadí.

Vstupem metody je počáteční snímek I_n a souřadnice $S = \{x_l, y_l, \dots, x_p, y_p\}$, označující středy potenciálních p objektů (Obr. 71). Pro každý z objektů O^i je nutné vyhledat v následujících n snímcích ekvivalentní segmenty obrazu s posunutými objekty. Pro tyto účely je stanovena šablona z výchozího snímku o rozměrech $T^i = (x_i \pm \lambda_i, y_i \pm \lambda_i)$, kde λ_i je předpokládaný poloměr velikosti nejmenšího objektu i v okolí souřadnice středu objektu. Tato šablona je vyhledávána v každém z následujících max. k snímcích I_{n+k} . Omezíme-li podmínkou maximální možný posun objektu O^i o ΔS_{max} v rovině snímku od výchozího bodu mezi snímky, pak je možné stanovit výběrové prohledávací okno o velikosti:

$$W^i = (S^i \pm n \cdot \Delta S_{max}) \quad (7.2.17)$$

Prohledávání je pak možno realizovat v každém z následujících snímků I_{n+k} pouze v okně W^i , což přispívá ke značnému urychlení výpočtu.

Na Obr. 72 je zobrazen příklad vstupního obrazu I_n s vyznačenými souřadnicemi S^l prvního objektu (zeleně). V obraze je dále vyznačena červeně šablona o velikosti $T^l = (x_l \pm \lambda_l, y_l \pm \lambda_l)$ jež bude v následujících max. k snímcích vyhledávána ve vyhledávacím okně W^l (žlutá).



Obr. 72: Vstupní snímek s vyznačeným středem objektu a prohledávacím oknem W^i

Vlastní vyhledávání pozice šablony T^i i -tého objektu v okně W^i o rozměrech (u, v) je obvykle realizováno například pomocí algoritmu dvourozměrné korelace [4]:

$$r_{corr2}^i(u, v) = \frac{\sum_x \sum_y (I^i(x+u, y+v) - \bar{I}^i) \cdot (T^i(x, y) - \bar{T}^i)}{\sqrt{\left(\sum_x \sum_y (I^i(x+u, y+v) - \bar{I}^i)^2 \right) \cdot \left(\sum_x \sum_y (T^i(x, y) - \bar{T}^i)^2 \right)}} \quad (7.2.18)$$

kde \bar{I} a \bar{T} jsou střední hodnoty vstupního obrazu a šablony. Tento výpočet je možné částečně optimalizovat s ohledem na rychlost. Odstraníme-li ze snímků I_{n+k} a šablony T^i předem střední hodnotu a provedeme-li výpočet korelace bez normalizačního koeficientu, kdy je pro nás zajímavá pouze relativní hodnota maxima r , pak je možné výpočet zjednodušit:

$$r_{corr2}^i(u, v) = \sum_x \sum_y (I^i(x+u, y+v) T^i(x, y)) \quad (7.2.19)$$

Výsledkem provedení (7.2.19) je matice $R^i(u, v)$ obsahující vypočtené koeficienty korelací mezi částí prohledávaného okna W^i a šablonou T^i z prvního snímku (Obr. 73). Vyhledání nejpřesnější pozice šablony T^i ze vstupního snímku v okně W^i snímku I_{n+k} je pak provedeno vyhledáním maxima v matici $R^i(u, v)$. Před vlastním vyhledáním maxima je ještě vhodné filtrovat matici $R^i(u, v)$ vhodným např. *Gaussovským* dolnofrekvenčním filtrem pro snížení možnosti uvážnutí vyhledávací funkce v lokálním extrému.

Při hledání pozice šablony T^i v k snímcích podle (7.2.19) je tak nutné provést celkem $k \cdot (u-x) \cdot (v-y) \cdot x \cdot y$ násobení, což značně zpomaluje výpočet. Urychlení je možno dosáhnout


zmenšením prohledávaného okna W^i , jehož minimální velikost je však omezena podmínkou (7.2.17), či zmenšením šablony T^i což má za následek snížení přesnosti výpočtu.

Podstatného urychlení výpočtu bez nežádoucího ovlivnění velikosti matic W^i a T^i je možné dosáhnout náhradou výpočtu dvourozměrné korelace některým z oblíbených algoritmů výpočtu SAD^{28} [4]:

$$r_{SAD}^i(u, v) = \sum_x \sum_y abs(I^i(x+u, y+v) - T^i(x, y)) \quad (7.2.20)$$

Algoritmus SAD je díky své jednoduchosti extrémně rychlý a efektivní a je snadno implementovatelný na většině počítačových mikroprocesorů. Jeho značnou výhodou oproti výpočtu korelace je nahrazení operací násobení shodným počtem operací sčítání, jež jsou však snadněji implementovatelné a jsou většinou mikroprocesorů mnohem rychleji proveditelné. Další výhodou oproti dvourozměrné korelaci je odolnost proti přítomnosti stejnosměrné hodnoty v maticích W^i a T^i , odpadá tak nutnost výpočtu střední hodnoty.

Výsledkem je podobně jako v případě výpočtu dvourozměrné korelace matice $R^i(u, v)$, obsahující výsledné koeficienty. Vlastní hledání pozice šablony T^i v $R(u, v)$ je provedeno vyhledáním globálního minima $R^i(u, v)$. Před vlastním hledáním je matice $R^i(u, v)$ opět filtrována dvourozměrným Gaussovským dolnofrekvenčním filtrem.



Obr. 73: Příklady matic $R^i(u, v)$ získaných výpočtem 2D-korelace a SAD pro I_{n+3} (modře min, červ. označeno max)

Na Obr. 73 je zobrazen příklad matic $R_{corr2}^i(u, v)$ s vyznačeným maximem a $R_{SAD}^i(u, v)$ s vyznačeným minimem, získaných výpočtem dvourozměrné korelace a výpočtem prostřednictvím algoritmu SAD pro šablonu T^i a okno W^i získané ze snímku I_{n+3} po snímku

²⁸ SAD – Sum of Absolute Differences - suma absolutních diferencí

z Obr. 72. Přesnost obou algoritmů je srovnatelná, ale výpočetní čas na výpočet algoritmu SAD je více než šestkrát nižší než na výpočet dvourozměrné korelace²⁹.

Předpokládáme-li maximální rychlost posunu objektu mezi snímky v rovině snímku, pak u objektů nacházejících se v krajní části obrazu může vlivem jejich pohybu v reálné 3D scéně dojít k posunu prohledávacího okna W^i mimo rozměry obrazu. Týká se to zejména vozidel, pohybujících se protisměrně vůči vozidlu se snímací kamerou, či vozidel odbočujících ze směru snímajícího vozidla. V takovém případě je vhodné prohledávání omezit podmínkou maximální změny souřadnic:

$$S_{new}^i = (S^i \pm n \cdot \Delta S_{max}), S_{new}^i \in |(\text{size}(I_{n+k}) - \xi)| \quad (7.2.21)$$

kde ξ reprezentuje ochranné pásmo u okrajů snímku I_n . Ochranným pásmem je umožněn částečný posun vyhledávacího okna W^i mimo souřadnice snímku I_{n+k} , kdy ve vyhledávacím okně je nalezena jen část hledaného objektu. V takovém případě je nutné prodloužení obrazu, jež je realizováno rozšířením obrazovými body s nulovou hodnotou jasu. Další prohledávání v následujících I_{n+k} snímcích je zastaveno (Obr. 74 - snímek I_{n+4}).

Výsledkem výše popsaného postupu je tedy matice snímků, reprezentujících objekty posunuté vůči výchozí poloze nad nestacionárním pozadím. Na Obr. 74 je zobrazen výsledek vyhledávání pro první objekt ze snímku Obr. 72. Střed objektu (zobrazen červeně) je vždy uprostřed nově nalezeného okna W^i . Zeleně je pak vyobrazena posouvající se hranice ξ limitující výpočet v okrajích obrazu. Na krajním pravém snímku (I_{n+4}) je zobrazena situace, kdy je výpočet ukončen, protože objekt se již pohybuje mimo obraz (není splněna podmínka (7.2.21)).



Obr. 74: Výsledná řada snímků sledujících původní objekt

Matice snímků z Obr. 74 reprezentuje objekty pohybující se v ploše obrazu. Pohyb objektů však odpovídá reálnému pohybu objektů v třírozměrné scéně, kdy se objekty vlivem

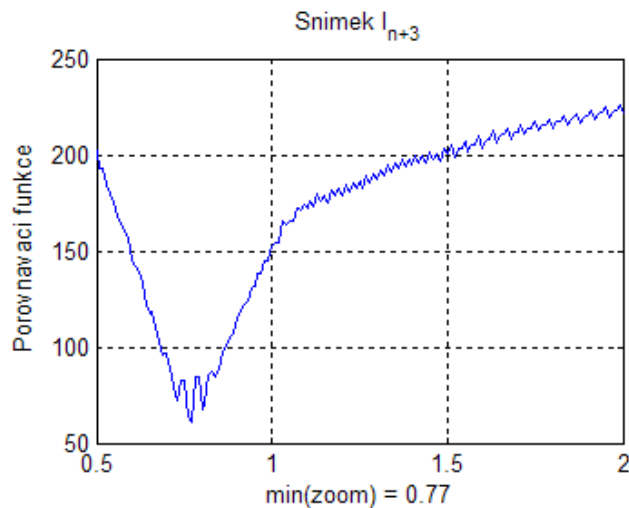
²⁹ Při velikosti $W^i = 151 \times 101$ obrazových bodů a velikosti $T^i = 21 \times 21$ obrazových bodů

rozdílné rychlosti přibližují, či vzdalují od vozidla nesoucího snímací zařízení. Z tohoto důvodu se v dvourozměrném zobrazení mění jejich velikost.

Velikost objektů musí být tedy normována na velikost odpovídající objektu z výchozího snímku. Normování každého snímku I_{n+k} probíhá vytvořením řady snímků s proměnným faktorem zvětšení v rozsahu od z_{min} do z_{max} (typicky 0,5 – 2), které jsou pomocí (7.2.22) porovnány s výchozím snímkem.

$$Z_{SAD}^i(z) = \sum_x \sum_y abs(I_n^i(x, y) - zoom(I_{n+k}^i(x, y))) \quad (7.2.22)$$

Výsledkem je průběh funkce $Z(z_{min} - z_{max})$, která dosahuje minima pro snímky se shodným nastavením měřítka (Obr. 75).



Obr. 75: Příklad průběhu funkce Z_{SAD}^i pro snímek I_{n+3}

Provedeme-li tento postup pro všechny snímky z Obr. 74, získáme již řadu snímků $J^i(1..k)$ s totožnými objekty, odpovídajícími si posunutím v obraze i měřítkem (Obr. 76).



Obr. 76: Snímky s normovanou velikostí objektu

Na takto připravený obrazový signál je již možné aplikovat *kumulativní metodu* zvýraznění obrazových bodů reprezentujících vozidlo oproti obrazovým bodům pozadí. Metoda *kumulativních* součtů vychází z poměrně jednoduchého principu zvýraznění korelovaných signálů v nekorelovaném šumovém pozadí. Při předpokladu ideálního modelu signálu je možné dosáhnout maximálního odstupu těchto skupin obrazových bodů. Ideálním stavem je v tomto případě signál s maximálně korelovanými obrazovými body, zatížený šumovým signálem s vlastnostmi ideálního bílého šumu [6]. V našem případě je užitečný signál reprezentován obrazovými body tvořícími vozidlo, které se nacházejí ve skupině obrazových bodů tvořících pohybující se pozadí.

Výchozím předpokladem je vysoký stupeň korelace mezi obrazovými body vozidla v průběhu jednotlivých snímků a naopak značně nižší korelace mezi obrazovými body tvořícími rychle se pohybující pozadí.

Ani jeden z těchto předpokladů však v reálném signálu není bezezbytku splněn. Po předchozích transformacích je tvar i velikost vozidla vyrovnána. Přesto jsou obrazové body reprezentující vozidlo zatíženy některými faktory, snižujícími stupeň korelace mezi jednotlivými realizacemi:

- obrazový signál je zatížen šumem snímací soustavy
- intenzita obrazových bodů tvořících vozidlo je ovlivněna proměnným momentálním osvětlením snímané scény
- úpravy v předchozích transformacích zanášejí do obrazu obtížně popsatelné degradace (změna měřítka následovaná filtrací, prodloužení obrazu...)

Také obrazové body tvořící pozadí se charakteru šumového signálu pouze přibližují. Při stacionárním pozadí a nepohybujícím se vozidle není možné *kumulativní metodu* použít,

protože obrazové body tvořící pozadí, se svým charakterem přiblíží obrazovým bodům tvořícím vozidlo. Předpokládáme-li však pohyb vozidla, lze také předpokládat značný obrazový tok. Vzhledem k fixaci vozidla v jednotlivých snímcích pomocí nástrojů popsaných výše, je veškerý optický tok soustředěn do obrazových bodů tvořících pozadí. Se zvětšující se diferencí rychlostí pohybu vozidla oproti pohybu pozadí tak bude klesat stupeň korelace mezi obrazovými body tvořícími pozadí v jednotlivých realizacích signálu a metoda bude účinnější.

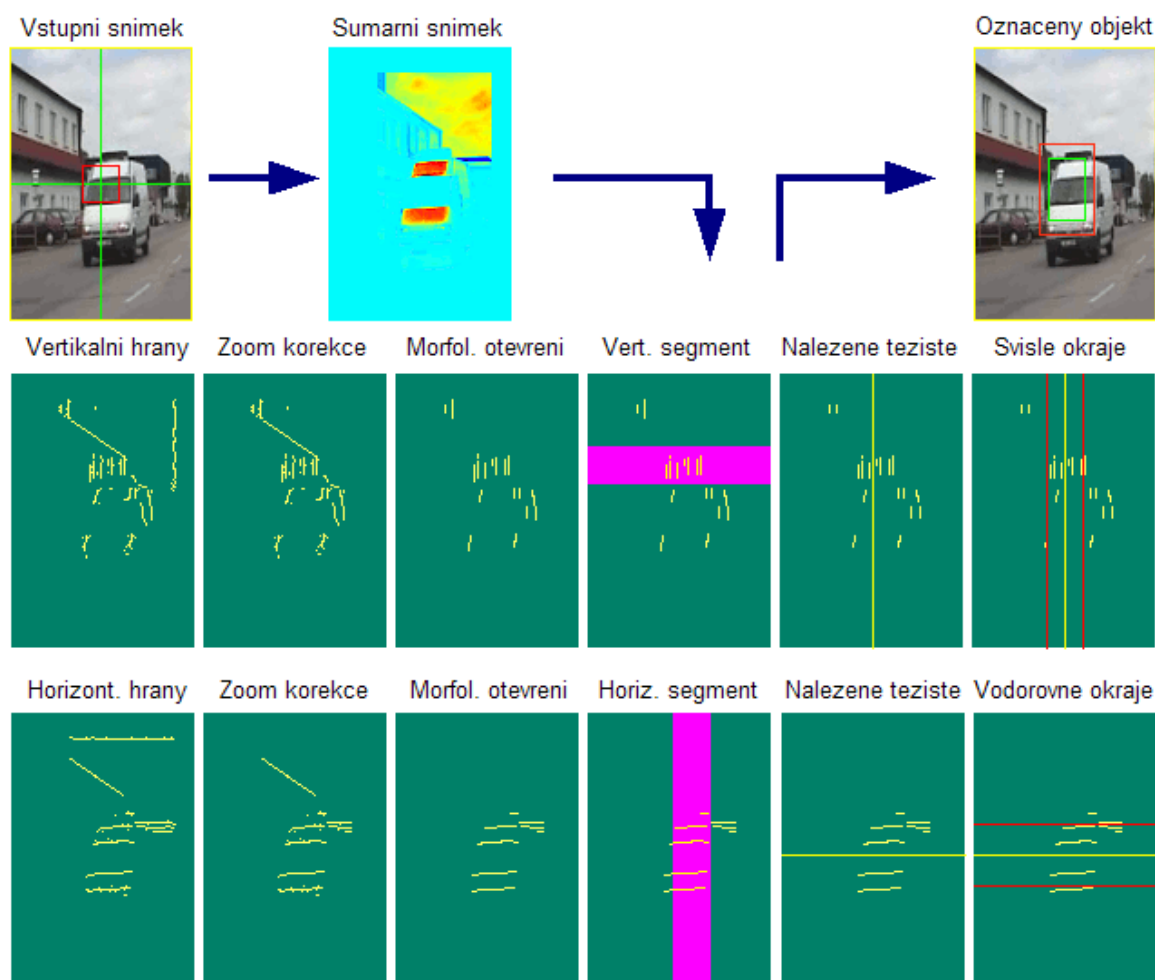
Před aplikací *kumulativní metody* zvýraznění obrazových bodů tvořících objekt je z jednotlivých realizací signálu (Obr. 76) odstraněna střední hodnota. Následně jsou jednotlivé realizace signálu sčítány do výsledného signálu. Vzhledem k předpokladu charakteru signálu, jenž se ideálnímu signálu pouze přibližuje, je v každém kroku vyhodnocován přírůstek parametru SNR ³⁰. Je-li přírůstek SNR menší než hranice α , je sčítání ukončeno. Tak jsou ošetřeny situace, kdy např. z důvodu změny osvětlení scény již další sčítání nepřináší podstatné vylepšení výsledného signálu. Parametr SNR je reprezentován množstvím hran získaných hranovým operátorem v oblasti zájmu (okolí středu výběrového okna W^i) oproti počtu hran ve snímku S vzniklém kumulací dílčích snímků J_n^i :

$$SNR_i = \frac{|E[\text{edge}(W_i)]|}{|E[\text{edge}(S)]|} \quad (7.2.23)$$

Výsledkem uvedeného postupu je sumární snímek S , se značně zvýrazněnými částmi tvořenými obrazovými body vozidla. Na Obr. 77 je zobrazen výsledný sumární snímek pro objekt z Obr. 72³¹. Ze snímku jsou jasně patrné části karoserie zvýrazněné pomocí předchozího postupu. Ostatní části vozidla (podvozek, okno) jsou díky značně proměnné intenzitě osvětlení zvýrazněny minimálně. Odstup zvýrazněných částí od pozadí je v tomto případě minimálně o jeden řád. Značný stupeň korelace projevuje také část oblohy, jejíž optický tok je v obraze minimální. Tento fakt je možné velmi dobře potlačit využitím masky oblohy získané metodou shlukování popsanou v předchozích kapitolách. Jelikož však obloha neobsahuje skokové změny průběhu jasové funkce, nepůsobuje ani nadsegmentaci obrazu.

³⁰ Signal to Noise Ratio – poměr užitečného signálu k šumu

³¹ Pro odlišení je zvolena barevná mapa zvýrazňující maxima (červeně) a minima (modře) signálu



Obr. 77: Postup extrakce okrajů ze sumárního snímku

Na Obr. 77 je uveden postup extrakce obrysů vozidla. Horizontální a vertikální obrysy tvořící vozidlo jsou separovány odděleně. Hrany jsou v prvním kroku získány *Sobelovým hranovým operátorem* s předepsanou orientací. Pro odstranění nadsegmentace je nejprve provedena korekce odstraněním artefaktů vzniklých sčítáním okrajů snímků s rozdílným nastavením měřítka (Obr. 76). Poté jsou snímky reprezentující vertikální a horizontální hrany podrobeny morfologickému otevření se strukturálním elementem ve tvaru vektoru 1×3 a 3×1 bodů, odstraňujícím jiné než svislé, či vodorovné hrany.

V takto získaném obraze je zvolen segment s největším zastoupením hran, v němž je vypočítáno těžiště – tvořící nově zpřesněný vertikální a horizontální střed vozidla. Předpokládáme-li dále vertikální a horizontální symetrii objektu, je možné překloupat obě části obrazu podle os těžiště a sečíst. Po sečtení obou částí obrazů s hranami je již možné najít maximum průběhu, reprezentující vzdálenost okrajů vozidla od středu.

Tímto postupem je tedy získán nový zkorigovaný střed vozidla a upravené obrysy vozidla. Nalezené obrysy reprezentují pouze oblasti, které byly kumulací metodou zvýrazněny. Části vozidla tvořené okrajovými částmi mají vlivem zakřivení více proměnné osvětlení v průběhu pohybu vozidla a nejsou tak předchozím postupem dostatečně zvýrazněny. Tento fakt je reprezentován faktorem η , zvětšujícím rozsah predikovaných hranic, jenž pak lépe vystihující skutečné obrysy vozidla (Obr. 77 - červený rámeček).

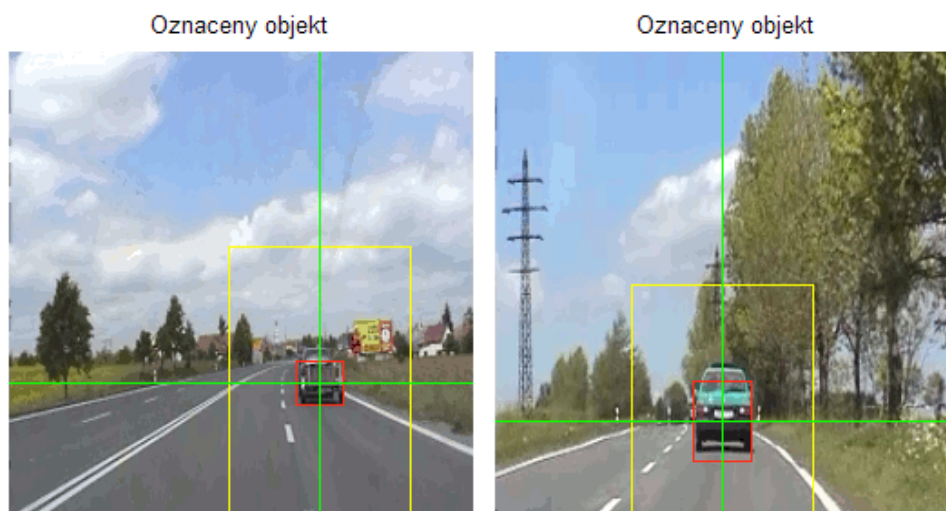


Obr. 78: Detekce obrysů vozidla kumulací metodou

Na Obr. 78 jsou zobrazeny příklady detekce dalších objektů v dopravní scéně spolu se sumárními snímky získanými předchozím postupem. V horní části je zobrazen druhý objekt z předchozího Obr. 72. V dolní části je pak zobrazen objekt pohybující se v mírné pravotočivé zatáčce. Pro porovnání účinnosti postupu jsou zobrazeny hranové snímky získané Sobelovým hranovým operátorem s detekcí hran prováděnou v obou směrech v původním obrazu a v kumulativním obrazu. V porovnání výsledků je vidět značný odstup v počtu hran v oblasti vozidla a značného snížení počtu hran pozadí.

V obou případech je také zobrazen kříž udávající polohu středu vozidla. Tento střed je předchozím postupem upřesněn a ve spojení s výpočtem obrysů vozidla tak dochází k novému zpřesnění polohy i v případě, kdy vstupní souřadnice získané předchozími metodami nejsou přesně centrovány do středu objektu.

Příklady dalších objektů jsou zobrazeny na Obr. 79. Pro názornost je zobrazen celý vstupní snímek I_I včetně původního prohlédávacího okna W^I . Zeleně jsou pak označeny nové středy objektů a červeně jejich okraje.



Obr. 79: Příklady detekce dalších objektů

8 Závěr

Předkládaná práce se svým obsahem zaměřuje především na problematiku metod detekce silničních vozidel v obraze, využitelných v systémech inteligentního vedení vozidel. Tyto systémy dnes využívají především radarových prostředků, či dalších čidel umístěných ve vozidlech. Systémy využívající obrazové snímače k detekci dalších vozidel jsou zatím díky složitosti separace objektů od nestacionárního pozadí stále ve fázi vývoje, přestože jejich využití přináší zcela nové možnosti získávání velkého množství informací.

V dizertační práci je v úvodní části analyzován současný stav metod rozpoznávání obrazu s nestacionárním pozadím, aplikovaných v systémech autonomního vedení vozidel. Rozbor hlavních nevýhod těchto metod pro mne byly motivací pro hledání dalších, alternativních přístupů k detekci vozidel. Nutnou podmínkou pro vývoj detekčních postupů vhodných pro detekci vozidel bylo vytvoření vhodného souboru vstupních dat. V práci je popsána problematika výběru vhodného snímacího zařízení, postupu snímání z jedoucího vozidla a předzpracování naměřených dat. Bez vhodně připravených dat by nebylo možné realizovat vývoj jednotlivých separačních algoritmů. Těchto dat a vyvinutých postupů jejich předzpracování bude možno využít i při dalších pracích na vývoji systémů autonomního vedení vozidel.

Stěžejní částí práce je věnována kapitola „Zpracování obrazu“. V této kapitole popisují několik vlastních způsobů detekce vozidel a dalších prvků tvořících obrazovou scénu, za pomocí moderních technik zpracování obrazu. Tyto techniky jsou založeny na statistickém přístupu k datům a využívají dalších možností detekce vozidel, například detekce symetrie, *kumulativní metody* zvýraznění vozidel v okolním signálu, *Houghovy* transformace k hledání obrysů vozidel, či algoritmu *k-means* k detekci vozovky.

Hlavní přínosy práce

Všechny cíle, vytyčené v úvodní části práce, se podařilo bezezbytku splnit a věřím, že práce kromě toho, že přináší konkrétní specializované nízkoúrovňové detekční metody, přispěje svým uceleným obsahem i ke zřehlednění problematiky a poslouží také jako podklad pro další práci v této komplexní oblasti.

Hlavními výstupy práce jsou navržené konkrétní metody detekce vozidel a dalších prvků tvořících obraz dopravní scény. Vlastnosti těchto metod jsou podrobeny diskuzi

v závěru každé z kapitol. Věřím, že tyto metody poslouží v budoucnu jako základ pro vývoj komplexního systému autonomního vedení vozidel a že se podaří docílit fúze s dalšími, například radarovými systémy, vyvíjenými na naší univerzitě.

Shromáždění podkladový materiál umožní další pokračování vývoje v dnes velmi perspektivní oblasti zpracování obrazu orientované do dopravní techniky.

9 Seznam literatury

- [1] Forsyth D., Ponce J.: „*Computer Vision: A Modern Approach*“, Prentice Hall, August 24, 2002, ISBN: 0-130851-98-1
- [2] Castleman K.: „*Digital Image Processing*“, Prentice Hall, September 2, 1995, ISBN: 0-132114-674
- [3] Russ J.: „*The Image Processing Handbook, Fourth Edition*“, CRC Press LLC, London, 2002, ISBN:0-8493-1142-X
- [4] Osterman Y., Zhang Y.: „*Video processing and communications*“, Prentice-Hall, 2002, ISBN:0-13-017547-1
- [5] Betke M., Haritaglu E., Davis L.: “*Multiple vehicle detection and tracking in hard real time*”, IEEE Intelligent Vehicles Symposium, pp. 351–356, 1996.
- [6] Sovka P., Pollák P.: „*Výbrané metody číslicového zpracování signálů*“, ČVUT Praha 2001, ISBN: 80-01-02416-4
- [7] Bezoušek P., Šedivý P.: „*Radarová technika*“, ČVUT Praha 2004, 80-01-03036-9
- [8] Klíma M., Bernas M., Hozman J., Dvořák P.: „*Zpracování obrazové informace*“, ČVUT Praha 1999, ISBN: 80-01-01436-3
- [9] Stentiford F.: „*Attention based facial symmetry detection*“, International Conference on Advances in Pattern Recognition, Bath, UK, 22-25 August, 2005

- [10] Ying R., Chin-Seng C., Yeong K.: „*Motion detection with nonstationary background*“, Machine Vision and Applications, Springer-Verlag, 2003
- [11] Christophe P. B.: „*Discrete Wavelet Analysis for Fast Optic Flow Computation*“, Applied and Computational Harmonic Analysis, Volume 11, Number 1, July 2001 , pp. 32-63(32)
- [12] Bruhn A., Weickert J., Schnorr C.: „*Lucas/Kanade Meets Horn/Schunck: Combining Local and Global Optic Flow Methods*“, International Journal of Computer Vision 61(3), 211–231, 2005
- [13] Hofmann U., Rieder A., Dickmanns E. D.: „*Radar and vision data fusion for hybrid adaptive cruise control on highways*“, Machine Vision and Applications, vol. 14, pp.42–49, 2003.
- [14] Jianye L., Yang M., Wang H.: „*Vision-based Road Detection in Urban Traffic*“, State Key Laboratory of Intelligent Technology and Systems, Tsinghua University, China 2006
- [15] ZuWhanKim: „*Realtime Road Detection by Learning from One Example*“, Application of Computer Vision Volume 1. Seventh IEEE Workshops 2005, Page(s):455 – 460
- [16] Kovář B.: „*Identifikace zóny zájmu v obraze*“, Diplomová práce, ČVUT Praha, 1998
- [17] Chaturvedi P.: „*Real-Time Identification of Driveable Areas in Semi-Structured Terrain*“, Proc. SPIE Vol. 4364, p. 302-312, Unmanned Ground Vehicle Technology III, 2001, 2001SPIE.4364..302C

- [18] Broggi A., Cantoni V., Vallone U., Fascioli A.: „*SnowcatTrackDetection in Snowy Environments*“, IEEE Intelligent Vehicles Symposium, National Institute of Informatics, Tokyo 2001
- [19] Hong T., Rasmussen C., Chang T., Shneier M.: „*Road Detection and Tracking for Autonomous Mobile Robots*“, Proceedings of SPIE Aerosense Conference Vol. 4715, Orlando, Florida, 1-5 April, 2002
- [20] Manduchi R., Castano A., Talukder A., Matthies A.: „*Obstacle Detection and Terrain Classification for Autonomous Off-Road Navigation*“, Autonomous Robots 18, 81–102, 2005
- [21] Stephen Se., Brady M.: „*Road feature detection and estimation*“, Machine Vision and Applications, vol. 14, pp 157–165, 2003.
- [22] Birdal T., Ercil A.: „*Real-time automated road, lane and car detection for autonomus driving*“, Biennial on DSP for in-Vehicle and Mobile Systems, Sait Halim Pasa Mansion- Istanbul, Turkey, 2007
- [23] Iochi L.: „*Robust Color Segmentation through Adaptive Color Distribution Transformation*“, Lecture Notes in Computer Science, Volume 4434/2007, Springer Berlin 2007, ISBN: 978-3-540-74023-0
- [24] Žák L.: „*Shluková analýza I.-III.*“, Automatizace 3/47 – 5/47., Praha 2004
- [25] Zehang Sun, Ronald Miller, George Beibs, David DiMeo: „*A Real-time Precrash Vehicle Detection System*“, IEEE Workshop on Applications of Computer Vision, pp. 171-176, Orlando, December 2002.

- [26] Zhao T., Nevatia R.: „*Car Detection in Low Resolution Aerial Images*“, IEEE Intl. Conf. Computer Vision, pages 710.-717., 2001
- [27] Hinz S.: „*Integrating local and global features for vehicle detection in high resolution aerial imagery*“, ISPRS Archives, Vol. 34, pages 17.-19, September 2003
- [28] Prati A., Mikic I., Grana C., Trivedi M.: „*Shadow Detection Algorithms for Traffic Flow Analysis: a Comparative Study*“, Intelligent Transportation Systems, 2001, Page(s):340 – 345, Digital Object Identifier: 10.1109/ITSC.2001.948680
- [29] Neskovic P., Cooper L.: „*Providing context for edge extraction in the application of car detection from video streams*“, Institute for Brain and Neural Systems, Brown University 2006
- [30] Vergauwen M., Pollefeys M., Gool L.: „*A stereo-vision systém for support of planetary surface exploration*“, MachineVisionandApplications 14: 5-14, 2003
- [31] Papageorgiou C., Poggio T.: „*A Trainable Object Detection Systém: Car Detection in Static Images*“, C.B.C.L. Paper No. 180, Massachusetts Institute of Technology, October 1999
- [32] Dlagnekov L., Belongie S.: „*Recognizing Cars*“, UCSD CSE Tech Report CS2005-0833, October 13 2005
- [33] Leung B.: „*Component-based Car Detection in Street Scene Images*“, Thesis, Massachusetts Institute of Technology, October 2004
- [34] Hofmann U., Rieder A., Dickmanns E. D.: „*Radar and vision data fusion for hybrid adaptive cruise control on highways*“, Machine Vision and Applications, vol. 14, pp.42–49, 2003.

- [35] Veeraraghavan H., Masoud O., Papanikolopoulos N.: „*Vision-based Monitoring of Intersections*“, The IEEE 5th International Conference on Intelligent Transportation Systems 3-6 September 2002, Singapore. pp. 7-12, ISBN: 0-7803-7389-8
- [36] Krüger W.: „*Robust real-time ground plane motion compensation from a moving vehicle*“, Machine Vision and Applications, vol. 11, 1999.
- [37] Andreone L., Antonello P. C., Bertozzi M., Broggi A., Fascioli A., Ranzato D.: „*Vehicle Detection and Localization in Infra-Red Images*“, The IEEE 5th International Conference on Intelligent Transportation Systems 3-6 September 2002, Singapore. pp. 141-146, ISBN: 0-7803-7389-8
- [38] Matsushita Y., Ofek E., Tang X.: „*Full-frame Video Stabilization*“, In Proc. Computer Vision and Pattern Recognition, volume 1, pages 50--57, 2005
- [39] Litvin A., Konrad J., Karl W.: „*Probabilistic video stabilization using Kalman filtering and mosaicking*“, IS&T/SPIE Symposium on Electronic Imaging, Image and Video Communications and Proc., Santa Clara, CA, USA, Jan. 20-24, 2003
- [40] Keith J.: „*Video Demystified*“, LLH Technology Publishing, Eagle Rock, USA, 3. vydání, 2001.
- [41] Garvanov I., Kabakchiev C.: „*One- and Two-Dimensional CFAR Processors in the Presence of Strong Pulse Jamming*“, Cybernetics and Information Technologies, Volume 2, No 1. Bulgarian Academy of Sciences, Sofia, 2002, ISSN: 1311-9702
- [42] Krpec V.: „*Využití Houghovy transformace při segmentaci biomedicínských obrazů*“, Diplomová práce, Fakulta informatiky, Masarykova univerzita, Brno, 2003

- [43] Wilson M., Dickson S., Poppet: „*A Robust Road Boundary Detection and Tracking Algorithm*“, BMVC 1999, Nottingham UK, 13-16 September 1999, ISBN 1-901725-09-X
- [44] Stentiford F.: „*Attention based symmetry in colour images*“, IEEE International Workshop on Multimedia Signal Processing, Shanghai, China, Oct 30 - Nov 2, 2005

Vybrané publikace autora:

- [45] Dobrovolný M.: „*Aplikace morfologického otevření obrazu v detekci vozidel*“, Slaboproudý obzor, Ročník 61, číslo 4, ISSN: 0037-668X
- [46] Dobrovolný M.: „*Image information exploitation in ACC systems*“, ELEKTRO 2006, Žilina 2006, ISBN 80-8070-544-5
- [47] Dobrovolný M.: „*Konvoluční detekce vozidel v obraze*“, IV. International Scientific Conference: „Challenges in Transport and Communications“, Pardubice 2006, ISBN 80-7194-880-2
- [48] Dobrovolný M., Doleček R.: „*Metody detekce překážek v jízdě vozidla*“, 16. oborový den vědeckých a pedagogických pracovníků vysokých škol, Praha 2004, ISBN: 80-7083-895-7
- [49] Dobrovolný M.: „*ACC systémy v dopravě*“, Semináře katedry KEEZ, DFJP Pardubice 2004

10 Seznam zkratk a symbolů

α	minimální požadovaný přípustek <i>SNR</i> v kumulační metodě
<i>A/D</i>	analogově – digitální (převod, převodník)
<i>ACC</i>	Adaptive Cruise Control – systémy adaptivního vedení vozidla
<i>argmin()</i>	funkce s návratovou hodnotou rovnající se minimální hodnotě parametrů
<i>avi</i>	Audio Video Interleave – kontejnerový formát pro multimediální data
C_i	komponenta rozkladu (produkt disjunktního rozkladu)
δ	Diracův impulz
<i>double</i>	číselný formát s plovoucí řádovou čárkou dle IEEE754 – nativní formát programu <i>MATLAB</i> (vnitřně 64 bitový)
E_p	Eukleidovský <i>p-rozměrný</i> prostor
$f(x), f(x,y)$	jasové funkce, vyjadřuje intenzitu jasu obrazových bodů
<i>FFT</i>	algoritmus rychlé diskrétní Fourierovy transformace
<i>fps</i>	Frames per second – počet snímků za sekundu – obnovovací frekvence
φ	úhel symetrie
<i>HSV</i>	tříslučkový barevný model
I_n	vstupní jasový obrazový snímek
<i>ITS/IDS</i>	Intelligent Transport Systems – inteligentní dopravní systémy
$J(1..k)$	řadu snímků s totožnými objekty, odpovídajícími si posunutím v obraze i měřítkem
k	požadovaný / výsledný počet shluků
<i>k-means</i>	shlukovací algoritmus
l	vzdálenost přímky ρ od počátku souřadného systému
λ	vzdálenost v Eukleidovském prostoru
λ'	minimální velikost <i>i-tého</i> objektu
μ	střední hodnota
M_o	maska oblohy
M_p	maska pozadí

M_v	maska vozovky
$N(o_i, o_j)$	měřítka nepodobnosti dvou objektů
nD	n -rozměrný prostor
η	faktor pokrytí obrysů vozidla u kumulativní metody
O	zdrojová množina rozkladu
ω	úhel projekce v <i>Houghově transformaci</i>
$ \omega $	determinant jakobiánu transformace souřadnic do polárního vyjádření
p	počet znaků objektu
$\Pi(o_i, o_j)$	měřítka podobnosti dvou objektů
θ	úhel normály přímky ρ vzhledem k ose x souřadného systému
ρ	přímka se souřadnicemi l a θ
<i>RGB</i>	aditivní tříslůžkový barevný model
$\mathbf{R}^i(u, v)$	matice koeficientů korelace / <i>SAD</i> vypočítaných v prohledávaném okně W
r_{corr2}^i	koeficient dvourozměrné korelace i -tého objektu
r_{SAD2}^i	koeficient dvourozměrného algoritmu <i>SAD</i> i -tého objektu
R^n	prostor reálných čísel (v prostředí <i>MATLAB</i> reprezentovaná typem <i>double</i>)
S	souřadnice středu vozidla
σ	směrodatná odchylka
$S(i,j)$	akumulátor symetrie
$\mathbf{S}(j)$	vertikální součet akumulátoru symetrie $\mathbf{S}(i,j)$
<i>SAD</i>	Sum of Absolute Differences - suma absolutních diferencí
<i>SNR</i>	Signal to Noise Ratio – poměr užitečného signálu k šumu měřený počtem hran
$T(j)$	adaptivně vypočítaný práh symetrie
T^i	šablona získaná ze vstupního snímku
<i>UINT8</i>	unsigned 8bit integer – osmibitový bezznaménkový celočíselný typ
$V(x)$	vektor vertikálně sečtených segmentů masky vozovky pod vozidly
$W^i(u, v)$	prohledávané okolí (prohledávané okno) i -tého objektu
\hat{w}_i	skupina obr. bodů symetrická k odpovídající skupině w_i ve vzdálenosti r

X	množina vstupních dat pro algoritmus <i>k-means</i> s prvky x_i
ξ	interval výběru v histogramu kolem střední hodnoty μ
x_1, \dots, x_n	prvky množiny X vstupující do shlukovacího algoritmu <i>k-means</i>
x_{i1}, x_{i2} a y_{i1}, y_{i2}	souřadnice okrajů vozidla v ose x a v ose y
ξ	okrajové ochranné pásmo u vstupního snímku I_n
Y^i	osa symetrie <i>i-tého</i> objektu
Z	matice objektů před standardizací a normalizací
Z_{SAD}^i	průběh funkce měřítka v rozsahu od z_{min} do z_{max}
Z^n	prostor celých čísel

11 Seznam ilustrací

Obr. 1: Architektura Inteligentních dopravních systémů.....	8
Obr. 2: Příklad komplexní dopravní situace snímané s malou elevací.....	14
Obr. 3: Umístění snímací kamery v měřicím vozidle, [25].....	15
Obr. 4: Snímací kamera použitá pro snímání vstupních dat.....	16
Obr. 5: „avi2jpg“ – program pro automatizovaný převod video sekvencí do jednotlivých bmp / jpeg snímků.....	20
Obr. 6: „avi2jpg“ – výběr video sekvence pro převod do jpeg snímků.....	21
Obr. 7: „bmp2jpg“ - výběr sekvence snímků.....	22
Obr. 8: „bmp2jpg“ - možnosti změn v rámci jména souboru.....	22
Obr. 9: Efekt prokládání pulsů na rychle se pohybujícím objektu.....	24
Obr. 10: Nevhodné potlačení efektu prokládání (mediánový filtr).....	24
Obr. 11: Výsledný obraz (lichý puls).....	25
Obr. 12: Dopravní situace.....	27
Obr. 13: Histogram předchozího obrázku (jasová složka).....	28
Obr. 14: Upravený histogram pro parametry μ a σ_1	29
Obr. 15: Výsledek vyřiznutí bodů reprezentujících vozovku (žlutá b.) pro μ a σ_1	29
Obr. 16: Upravený histogram pro parametry μ a $\sigma_2 = 3\sigma_1$	30
Obr. 17: Vybraná část vozovky při μ a $\sigma_2 = 3\sigma_1$	31
Obr. 18: Geometrická reprezentace HSV modelu.....	32
Obr. 19: Separace složek původního obrázku v HSV modelu (zleva: V, H, S).....	33
Obr. 20: Histogram S složky obrázku v HSV modelu.....	33
Obr. 21: Upravený histogram S složky obrázku v HSV modelu pro parametry μ a σ_1	34
Obr. 22: Výsledek separace bodů reprezentujících vozovku (žlutá b.) pro μ a σ_1 při použití HSV modelu.....	34
Obr. 23: Upravený histogram S složky obrázku v HSV modelu pro parametry μ a $\sigma_2 = 3\sigma_1$	35
Obr. 24: Výsledek separace bodů reprezentujících vozovku (žlutá barva) pro μ a $\sigma_2 = 3\sigma_1$ při použití HSV modelu.....	36

Obr. 25: Třírozměrné vyjádření intenzity obrazových bodů obrazu.....	37
Obr. 26: Třírozměrné vyjádření intenzity obrazových bodů obrazu - obraz otočen o cca 60° doprava pro lepší zviditelnění shluků obrazových bodů.....	38
Obr. 27: Histogram linearizovaného obrazu s vyznačenými iniciačními μ_j (červené svislé čáry) při parametru $k=3$	43
Obr. 28: Histogram (pro větší přehlednost zobrazen spojitě) s vypočtenými shluky jasových hodnot a konečnými hodnotami μ_j (větší svislé čáry).....	44
Obr. 29: Výsledek shlukování obrazu v prostoru R1 (segmentace podle jasu).....	45
Obr. 30: Výsledek shlukování obrazu v prostoru R1 (segmentace podle jasu) - obraz otočen o cca 60° doprava pro lepší zviditelnění shluků obrazových bodů.....	45
Obr. 31: Postup úpravy masky vozovky.....	46
Obr. 32: Výstup algoritmu k-means: maska (s indexy 1..k, $k=3$), segmentace v jasové oblasti.....	48
Obr. 33: Obraz s grafickým vyjádřením masek obrazu ($k=3$) segmentace shlukováním (k-means) v jasové oblasti.....	49
Obr. 34: Výstup algoritmu k-means: maska (s indexy 1..k, $k=3$), segmentace v R3 (barvy RGB).....	50
Obr. 35: Výsledek shlukování obrazu v prostoru R5 (segmentace podle barev, prostorových souřadnic), pro $k = 3$ shluků.....	51
Obr. 36: Výstup algoritmu k-means: maska (s indexy 1..k, $k=3$), segmentace v R5 (barva, prostor. souřadnice).....	52
Obr. 37: Maska vozovky po morfologickém otevření. Obraz s grafickým vyjádřením masek obrazu ($k=3$), segmentace v R5 (barva, prostor. souřadnice).....	52
Obr. 38: Výsledek shlukování obrazu v prostoru R5 (segmentace podle RGB, prostorových souřadnic), pro $k = 4$ shluků.....	53
Obr. 39: Maska vozovky. Obraz s grafickým vyjádřením masek obrazu ($k=4$), segmentace v R5 (barva, prostor. souřadnice).....	54
Obr. 40: Výsledky shlukování K-means při $p_{barev}/p_{souř}=0.66$ v R5 (barva, prostor. souřadnice), Levý sloupec: $k=3$ shluky, pravý sloupec $k=4$ shluky.....	55
Obr. 41: Příklady obrazů po aplikaci segmentace shlukováním v prostoru R5 (tři barvy, souřadnice - se sníženým vlivem), pro $k=3$	56
Obr. 42: Příklady obrazů po aplikaci segmentace shlukováním v prostoru R3 (barvy), pro $k=3$	57

Obr. 43: Porovnání výsledků segmentace shlukováním K-means aplikovaným pouze na jasovou složku (obrázky vlevo) a v prostoru R5 (tři barvy, souřadnice - se sníženým vlivem), pro $k=3$	58
Obr. 44: Deformace okraje masky v místě výskytu objektů.....	60
Obr. 45: Separace segmentů okraje masky vozovky pod vozidly.....	61
Obr. 46: Detekované segmenty hrany masky vozovky promítnuté do zdrojových obrazů.....	62
Obr. 47: Vstupní obraz.....	64
Obr. 48: Obraz po morfologickém otevření.....	64
Obr. 49: Obraz po aplikaci Robertsova hranového operátoru s jasně patrnými obrysy hledaného objektu.....	65
Obr. 50: Příklad konvolučních jader pro vyhledání rohů obrysu objektu.....	66
Obr. 51: Příklad výsledku konvoluce jádra masky levého horního rohu se vstupním obrazem (detail maxima).....	66
Obr. 52: Výsledek hledání maxim pomocí 2D-FFT (práh=0.9).....	67
Obr. 53: Princip přiřazování spolu souvisejících rohů tvořících obrys vozidla.....	67
Obr. 54: Výsledný obrázek s nalezeným a označeným objektem.....	68
Obr. 55: Princip transformace prostorů v Houghově transformaci.....	70
Obr. 56: Vstupní obraz s vozidlem.....	72
Obr. 57: Aplikace Sobelova operátoru na morfologicky otevřený obraz (obrazy v pravé části).....	73
Obr. 58: Výsledek Houghovy transformace.....	74
Obr. 59: Segment obrazu mezi x_{i1} a x_{i2} a průběh $\sum f(x, y)$	75
Obr. 60: Výsledek detekce vozidla za pomocí Houghovy transformace.....	76
Obr. 61: Příklady vstupních obrazů s vozidly.....	79
Obr. 62: Aplikace hranového operátoru na vstupní obraz.....	80
Obr. 63: Průběh symetrie podle svislé osy (Akumulátor $S(i, j)$).....	80
Obr. 64: Průběh S_j pro vstupní obrazy (souř. x odpovídá vstupním obrazům).....	81
Obr. 65: Průběh $S(j)$ pro obraz s vysokým stupněm symetrie levé a pravé části obrazu.....	82
Obr. 66: Struktura metody vypočtu prahu pro hodnoty $S(j)$	83
Obr. 67: Průběh $S(j)$ - modře a hodnoty prahu $T(j)$ - zeleně.....	84
Obr. 68: Průběh $S(j)$ - modře s hodnotami prahu $T(j)$ - zeleně a nalezenými maximy - červené osy.....	85

Obr. 69: Vstupní obraz se zvýrazněným segmentem $Y1 \pm \lambda 1/2$ a odpovídající průběh $S(i)$.	87
Obr. 70: Obrazy s nalezenými symetrickými objekty a průběhy symetrií (červenými kříži označeny validované detekcí průběhu zakřivení masky vozovky).....	88
Obr. 71: Průběh symetrie v obraze pro velikosti akumulátoru 2562 (3,7 s), 1282 (820 ms) a 642 (185 ms) bodů (červenými kříži jsou označeny úspěšně detekované objekty, zelenými kříži další maxima symetrie).....	90
Obr. 72: Vstupní snímek s vyznačeným středem objektu a prohledávacím oknem W_i	92
Obr. 73: Příklady matic $R_i(u,v)$ získaných výpočtem 2D-korelace a SAD pro I_{n+3} (modře min, červ. označeno max).....	93
Obr. 74: Výsledná řada snímků sledujících původní objekt.....	94
Obr. 75: Příklad průběhu funkce Z_iSAD pro snímek I_{n+3}	95
Obr. 76: Snímky s normovanou velikostí objektu.....	96
Obr. 77: Postup extrakce okrajů ze sumárního snímku.....	98
Obr. 78: Detekce obrysů vozidla kumulační metodou.....	99
Obr. 79: Příklady detekce dalších objektů.....	100