

**UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY**

**ROZPOZNÁVANIE POHYBUJÚCICH SA OBJEKTOV PRE
MONITORING CESTNEJ PREMÁVKY**

Bakalárska práca

**UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY**

4595a28f-59d2-4653-9fbe-ed62af21ec77

**ROZPOZNÁVANIE POHYBUJÚCICH SA OBJEKTOV PRE
MONITORING CESTNEJ PREMÁVKY**

Bakalárska práca

Študijný program: aplikovaná informatika
Študijný odbor: 9.2.9. aplikovaná informatika
Školiace pracovisko: Univerzita Komenského v Bratislave, Fakulta matematiky,
fyziky a informatiky, Katedra aplikovanej informatiky
Vedúci bakalárskej práce: RNDr. Zuzana Černeková, PhD.



Univerzita Komenského v Bratislave
Fakulta matematiky, fyziky a informatiky

ZADANIE ZÁVEREČNEJ PRÁCE

Meno a priezvisko študenta: Samuel Titka
Študijný program: aplikovaná informatika (Jednoodborové štúdium, bakalársky I. st., denná forma)
Študijný odbor: 9.2.9. aplikovaná informatika
Typ záverečnej práce: bakalárska
Jazyk záverečnej práce: slovenský

Názov: Rozpoznávanie pohybujúcich sa objektov pre monitoring cestnej premávky
Cieľ: 1. Naštudovať metódy. 2. Vybrať a implementovať jednu metódu. 3. Otestovať
Vedúci: RNDr. Zuzana Černeková, PhD.
Dátum zadania: 22.10.2010
Dátum schválenia: 26.10.2010

doc. RNDr. Mária Márkošová, PhD.
garant študijného programu

študent

vedúci

Čestné prehlásenie

Čestne prehlasujem, že som túto bakalársku prácu vypracoval samostatne s použitím uvedených zdrojov literatúry.

V Bratislave dňa

.....
Samuel Titka

Pod'akovanie

Ďakujem vedúcej bakalárskej práce RNDr. Zuzane Černekovej, PhD. za cenné rady a pripomienky pri vypracovávaní tejto práce.

Abstrakt

Táto bakalárska práca obsahuje podrobný prehľad problematiky vizuálnych monitorovacích systémov cestnej premávky. Zrozumiteľne oboznamuje čitateľa o súčasných prístupoch a metódach detekcie a sledovania pohybu objektov vo videu. V práci sú popísané tri rôzne vlastné implementácie systémov monitorujúcich dopravu počas dňa i noci, ktoré rátajú prejdené vozidlá. Funkčnosť týchto systémov bola otestovaná na rôznych videách z cestnej premávky.

Kľúčové slová:

detekcia pohybu, sledovanie pohybu objektov, odstraňovanie tieňov, rátanie vozidiel, monitoring dopravy, detekcia svetlometov, párovanie svetlometov

Abstract

This bachelor thesis contains an overview of visual traffic surveillance systems. It explains modern approaches of motion detection and object tracking in video streams, and describes three different implementations of day-night traffic surveillance systems. The performance of these vehicle counting systems is also illustrated.

Keywords:

motion detection, object tracking, shadow elimination, vehicle counting, traffic surveillance, headlight detection, headlight pairing

Obsah

1	Predhovor.....	1
2	Úvod.....	2
3	Snímanie scény kamerou	3
4	Segmentácia pohybujúcich sa objektov	3
4.1	Odčítavanie pozadia (Background subtraction).....	3
4.1.1	Priemerovanie pozadia (Averaging background)	4
4.1.2	Kombinácia Gaussovej distribúcie (Mixture of Gaussian distribution)	5
4.1.3	Použitie Kalmanovho filtra	5
4.2	Rozdiel sekvencie snímok (Frames subtraction).....	5
4.3	Optický tok (Optical flow).....	6
4.4	Virtuálne cievky (Virtual loop).....	7
5	Klasifikácia vybratých objektov	7
5.1	Prístupy klasifikácie založené na tvare	8
5.2	Prístupy klasifikácie založenej na spôsobe pohybu objektu	8
5.3	Wavelet metódy klasifikácie objektov	9
6	Sledovanie pohybu vyčlenených objektov	9
6.1	Sledovanie pohybu vyčlenených objektov založené na celom regióne pixelov ...	10
6.2	Sledovanie pohybu vyčlenených objektov založené na aktívnej kontúre	10
6.3	Sledovanie pohybu vyčlenených objektov založené na charakteristických vlastnostiach.....	11
6.4	Sledovanie pohybu vyčlenených objektov založené na 3D modeloch	11
6.5	Kalmanov filter	12
7	Rôzne vylepšenia monitorovacích systémov	12
7.1	Stabilizácia obrazu	12
7.2	Detekcia čiar na ceste.....	13
7.3	Použitie viacerých kamier	13

7.4	Sledovanie cestnej premávky v zlých svetelných podmienkach.....	13
7.5	Odstraňovanie tieňov	13
8	Implementácia monitorovacieho systému cestnej premávky	14
8.1	Použité technológie	15
8.2	Umiestnenie kamery.....	15
9	Monitoring cestnej premávky v nočných hodinách.....	16
9.1	Segmentácia predných svetlometov	16
9.2	Párovanie svetlometov	18
9.3	Sledovanie pohybu párov svetlometov	21
9.4	Funkcionalita počítania vozidiel	22
10	Monitoring cestnej premávky počas dňa	23
10.1	Monitoring cestnej premávky počas dňa použitím rozdielu sekvencie snímok	23
10.1.1	Segmentácia vozidiel	24
10.1.2	Sledovanie pohybu vozidiel.....	27
10.1.3	Funkcionalita počítania vozidiel.....	30
10.2	Monitoring cestnej premávky počas dňa použitím odčítavania pozadia od aktuálnej snímky.....	30
10.2.1	Segmentácia vozidiel	30
10.2.2	Sledovanie pohybu vozidiel.....	33
10.2.3	Funkcionalita počítania vozidiel.....	33
11	Experimentálne výsledky.....	35
11.1	Testovanie monitoringu cestnej premávky v nočných hodinách	35
11.2	Testovanie monitoringu cestnej premávky počas dňa.....	36
11.2.1	Implementácia systému pomocou rozdielu sekvencie snímok.....	36
11.2.2	Implementácia systému pomocou odčítavania pozadia od snímky	38
12	Záver	41
13	Budúca práca.....	41

14	Zoznam použitej literatúry.....	42
15	Zoznam príloh.....	45

1 Predhovor

Preprava ľudí a tovarov je stará ako samotné ľudstvo. Prirodzenou snahou ľudstva bolo prepravovať čo najväčší náklad a hlavne čo najrýchlejšie. Postupne začali budovať cesty, križovatky, mosty, železnice a ďalšie prostriedky prepravy. V súčasnosti je dopravná infraštruktúra jedným z hlavných ukazovateľov ekonomickej vyspelosti krajiny. Prudký rozvoj cestnej komunikačnej siete a neustály rast automobilovej dopravy v posledných rokoch kladie čoraz väčší dôraz na inteligentné dopravné systémy.

Inteligentné dopravné systémy menia tradičné cestné siete na moderné, ktoré poskytujú maximum informácií o dopravnej situácii ich správcom. Tieto informácie zohrávajú významnú úlohu pri zvyšovaní bezpečnosti, kvality a efektívnosti dopravy, a súčasne znižujú aj množstvo vyprodukovaných emisií, energetickú náročnosť a náklady na budovanie novej infraštruktúry. Na ich základe sa môžu rozumne rozhodovať aj jednotlivé subjekty dopravno-prepravného procesu.

Jedným z kľúčových prvkov týchto systémov je monitorovanie cestnej premávky prostredníctvom kamier. Primárnou úlohou monitorovacích systémov je vizuálna detekcia dopravných prostriedkov na ceste. Môžu poskytovať aj informácie o počte automobilov, ich pozícii, rýchlosti, trajektórie pohybu a informácie o hustote premávky, prietoku premávky a iné.

Mojím cieľom je zrozumiteľne oboznámiť čitateľa o súčasných prístupoch a metódach, ktoré využívajú moderné monitorovacie systémy cestnej premávky založené na spracovaní obrazu, a prezentovať rôzne spôsoby implementácie vlastného monitorovacieho systému založeného na niektorých popísaných metódach.

2 Úvod

Počiatky vizuálneho monitorovania cestnej premávky sa datujú už od 80. rokov minulého storočia. Od tohto momentu je neustála požiadavka na robustné detekčné monitorovacie systémy. V súčasnosti je vizuálne sledovanie automobilov jednou z najrýchlejšie sa rozvíjajúcich oblastí počítačového videnia. Na tento účel sa využíva mnoho rôznych pokročilých technológií z oblastí spracovania obrazu, segmentácie, rozpoznávania obrazcov, neurónových sietí, umelej inteligencie a mnoho iných.

Na rozdiel od "slepých" detekčných systémov, ako sú, napríklad, indukčné cievky zabudované v ceste alebo radarové systémy, poskytuje vizuálny monitoring neporovnateľne väčšie množstvo informácií o situácii na ceste. Parametre ako rýchlosť automobilu alebo dĺžka kolóny by v prípade "slepých" systémov mohli byť získané len použitím viacerých senzorov, čo zvyšuje náklady na montáž. Jednoduché upevnenie jednej kamery nad cestu je lacnejšie riešenie. Navyše je takto získaný aj ucelený pohľad na cestnú premávku, ktorý je dôležitý pri porozumení správaniu sa účastníkov dopravy. Následne je možné zaznamenať a rýchlo reagovať na nezvyčajné situácie, ako sú dopravné nehody, jazda automobilu v protismere alebo iné prekážky či osoby na diaľnici.

Sledovanie premávky sa čoraz viac automatizuje a stáva sa nezávislejšie od počasia i dennej doby. Jednu z najväčších výziev pre vizuálny monitoring dopravy predstavuje situácia, keď sa automobily v obraze prekrývajú, čo sa často stáva pri nízko umiestnených kamerách, ktoré snímajú cestu pod malým uhlom. Problémy spôsobujú aj zlé svetelné podmienky, nepriaznivé počasie a malé vizuálne rozdiely medzi automobilmi.

Základnými krokmi pri sledovaní cestnej premávky sú [1], [2]:

1. Snímanie scény kamerou
2. Segmentácia pohybujúcich sa objektov zo snímok videa
3. Klasifikácia vybraných objektov
4. Sledovanie pohybu vyčlenených objektov

Tieto kľúčové kroky sú samostatne popísané v nasledujúcich častiach, po ktorých nasleduje podrobný opis spôsobov implementácie vlastného monitorovacieho systému.

3 Snímanie scény kamerou

Monitorovacie systémy najčastejšie využívajú stacionárne kamery pevne umiestnené nad cestnou premávkou. Zväčša sú to duálne kamery (takzvané day-night), ktoré v závislosti od svetelných podmienok prepínajú medzi farebným videním cez deň a čiernobielym videním v noci. Použité kamery sú buď digitálne alebo analógové. V prípade použitia analógových je potrebná následná digitalizácia signálu.

Odlišné systémy spracovávajú videozáznam s rôznymi parametrami. Základnými parametrami sú rozlíšenie a frekvencia snímok, pri analógových kamerách aj spôsob skenovania (prekladané alebo progresívne skenovanie). Najčastejšia frekvencia snímok sa pohybuje v rozmedzí od 15 do 30 snímok za sekundu. Prílišné znižovanie frekvencie snímok môže spôsobiť rapidný pokles úspešnosti systému. Rozlíšenie snímok býva v rozmedzí od QVGA (320x240) cez VGA (640x480), PAL (768x576) až po SVGA (800x600). S nárastom veľkosti snímky rastie aj časová náročnosť na jej spracovanie. Pomer strán je zväčša 4:3. Na kvalitu obrazu má výrazný vplyv aj kvalita objektívu kamery.

4 Segmentácia pohybujúcich sa objektov


Úlohou procesu segmentácie (nazýva sa aj výberom regiónov záujmu) je vyčlenenie pohybujúcich sa objektov zo snímok. Toto je kľúčovým prvkom v monitorovacích systémoch cestnej premávky, pretože výsledky tohto kroku priamo ovplyvňujú úspešnosť celého systému. Segmentácia je jednou z najzložitejších úloh z oblasti spracovania obrazu. Vyčlenenie pohybujúcich sa objektov zo statického videa je založené na štyroch základných prístupoch [1], [2]:

1. Odčítavanie pozadia (Background subtraction)
2. Rozdiel sekvencie snímok (Frames subtraction)
3. Optický tok (Optical flow)
4. Virtuálne cievky (Virtual loop)

4.1 Odčítavanie pozadia (Background subtraction)

Kvôli jednoduchosti tohto prístupu a častého použitia stacionárnych kamier v monitorovacích systémoch je odčítavanie pozadia jedným z najčastejšie využívaných prístupov. Pred samotným odčítaním je nevyhnutné najskôr získať, prípadne "naučiť sa"

model pozadia. S pozadím sa porovná aktuálna snímka a známe časti pozadia sa z nej odstránia. Objekty, ktoré sa takýmto spôsobom získali, sú považované za objekty popredia [3]. Princíp odčítavania pozadia je znázornený na Obr. 1.



Obr. 1. Princíp odčítavania pozadia od aktuálnej snímky

V prípade monitoringu cestnej premávky je model pozadia pomerne jednoduchý. Je možné si ho predstaviť ako prázdnu cestu bez automobilov. Rovnako je však možné si predstaviť záber na cestu, vedľa ktorej sú stromy s jemne sa pohybujúcimi konármi a listami. Model pozadia teda môže byť chápaný ako statický, prípadne môže obsahovať časti, ktorých pohyb sa periodicky opakuje v čase.

Veľkou výhodou prístupu odčítavania pozadia je získanie najkomplexnejších informácií o objektoch popredia. Kvôli zmenám svetelných podmienok počas dňa je nevyhnutné referenčné pozadie aktualizovať v čase. Pri snahe eliminovať aj ďalšie problémy, ako je náchylnosť na náhle zmeny svetlosti či iné neočakávané situácie ako pohyb celej kamery a pribudnutie nového objektu do referenčného pozadia, ale aj spôsob, ako vlastne získať referenčné pozadie v prípade neustáleho pohybu objektov v snímkach, boli predstavené rôzne modely tohto prístupu. Príklady týchto prístupov sú:

1. Priemerovanie pozadia (Averaging background)
2. Kombinácia Gaussovej distribúcie (Mixture of Gaussian distribution)
3. Použitie Kalmanovho filtra

4.1.1 Priemerovanie pozadia (Averaging background)

Model priemerovania pozadia je založený na naučení sa priemeru a štandardnej odchýlky hodnôt pre každý pixel referenčného pozadia [3]. Tento štatistický prístup je výpočtovo nenáročný a vhodný pre aplikácie fungujúce v reálnom čase, kedy sa objekty nepohybujú príliš pomaly a pozadie nie je ničím rušené počas dlhých časových úsekov.

Vylepšením tohto prístupu je metóda selektívnej aktualizácie (Selective updating method), kedy sa upravujú hodnoty priemerov a odchýlok len nemeniacich sa obrazových bodov referenčného pozadia [4].

4.1.2 Kombinácia Gaussovej distribúcie (Mixture of Gaussian distribution)

Stauffer a Grimson vo svojej práci [5] predstavujú model, kde je každý pixel pozadia vytvorený kombináciou Gaussovej distribúcie (normálneho rozdelenia pravdepodobnosti) a následne je aktualizovaný v čase. Gaussova distribúcia zodpovedajúca pozadiu je určená na základe stálosti a premenlivosti každého Gaussiánu danej kombinácie. Hodnoty obrazových bodov, ktoré nezodpovedajú takto určenému pozadiu, sú považované za popredie.

Gaussian Mixture Model (GMM) je jedným z najčastejšie využívaných prístupov modelovania pozadia, pretože je stabilný, dokáže fungovať v reálnom čase a je robustný v prípadoch zmien svetlosti, opakujúcich sa pohybov a dlhodobých zmien scény. Avšak kvôli jeho väčšej výpočtovej náročnosti sa uplatňuje v rôznych obmenách a vylepšeniach [6] a [7].

4.1.3 Použitie Kalmanovho filtra

Tento prístup spadá do modelovania referenčného pozadia použitím predikčných a odhadových algoritmov. Výhodami tejto metódy je použitie pre akékoľvek typy scén, nezávislosť od zmien osvetlenia a adaptovanie sa pri odstránení či pridaní nového objektu do scény [8].

4.2 Rozdiel sekvencie snímok (Frames subtraction)

Metóda nazývaná tiež frame differencing alebo temporal differencing je najjednoduchším a výpočtovo nenáročným spôsobom segmentácie pohybujúcich sa objektov. Prvým krokom je vypočítanie rozdielu medzi zväčša dvomi až tromi za sebou idúcimi snímkami. Odčítavajú sa buď samostatné pixely, alebo kvôli väčšej robustnosti bloky viacerých pixelov. Druhým krokom je aplikovanie prahovej funkcie na získané rozdiely za účelom stanovenia, či je daný rozdiel dostatočne "veľký". Výsledkom tohto postupu sú nájdené čiastočné obrisy pohybujúcich sa objektov, zväčša v podobe binárnej masky [1].

Výhodou metódy odčítavania sekvencie snímok je jej prirodzená adaptívnosť. Naproti tomu problematická je priveľká závislosť od stanoveného časového intervalu

medzi odčítavanými snímkami a rýchlosťou automobilu. Navyše, získajú sa len nekompletné a hrubé obrysy automobilu. Kvôli lepším výsledkom sa môže kombinovať s detekciou hrán, používajú sa aj rôzne algoritmy na automatické určenie hodnôt prahov pre prahové funkcie. Princíp rozdielu sekvencie snímok je znázornený na Obr. 2.



Obr. 2. Princíp rozdielu sekvencie dvoch za sebou idúcich snímok


Existujú rôzne obmeny tohto prístupu. Príkladom môže byť metóda štatistického testu (Statistical test method), ktorá považuje dočasné zmeny v snímke za ekvivalentné k zaznamenaniu pohybu. Zmeny sa však zaznamenajú iba v prípade veľkého posunu objektu alebo v prípade jeho bohatej textúry. Na prekonanie týchto nedostatkov boli vyvinuté rôzne filtre a detekčné masky [2].

4.3 Optický tok (Optical flow)

Pre každý obrazový bod je možné vektorom definovať jeho posunutie medzi predošlou a aktuálnou snímkou. Tento vektor môžeme chápať aj ako rýchlosť. Konštrukcia, ktorá spája rýchlosť s každým obrazovým bodom v snímke, sa nazýva hustý optický tok (dense optical flow) [3].

Výpočet hustého optického toku je veľmi náročný. Problematickými a výpočtovo náročnými sú hlavne nejednoznačné body. Pri predstave pohybu bieleho papiera je jasné, že mnoho bielych pixelov v aktuálnej snímke ostanú biele aj v nasledujúcej snímke. Zmena je viditeľná hlavne na hranách papiera. Preto metóda na výpočet hustého optického toku musí obsahovať aj algoritmus na určenie ľahko sledovateľných bodov a na vyriešenie problému s nejednoznačnými bodmi [3].

V praxi sa teda používa metóda riedkeho optického toku (sparse optical flow). Menšie množstvo ľahko sledovateľných bodov, teda hlavne hrán, rohov a oblastí s bohatou textúrou sú stanovené vopred. Úspešnosť výpočtu riedkeho optického toku potom závisí na kvalite zvolených bodov. Detekcia pohybu touto metódou je znázornená na Obr. 3. Prednosťou je funkčnosť aj pri pohybe kamery. Nevýhodou je náchylnosť na šum [1].



Obr. 3. Znáozornenie riedkeho optického toku pomocou vektorov posunutia (biele čiarky) obrazových bodov znázornených bielymi bodkami

4.4 Virtuálne cievky (Virtual loop)

Prístup virtuálnych cievok je inšpirovaný indukčnými cievkami zabudovanými v ceste. Je založený na myšlienke vytvorenia virtuálnych indukčných cievok v snímkach. Úlohou takto vzniknutých cievok je zaznamenanie prechodu automobilu, a to pomocou detekcie zmeny svetlosti či textúry vo vopred určenej oblasti – cievky. Je teda potrebné ručne určiť oblasti záujmu [2].

V súčasnosti existujú systémy, ktoré si samy automaticky určia regióny záujmu pomocou rôznych algoritmov. Často sa využíva detekcia čiar na cestách [9].

Rozsah použitia virtuálnych slučiek je značne obmedzený. V podstate sa využíva len na počítanie automobilov, a teda na určenie štatistiky pre daný úsek cesty. Výpočtovo je veľmi rýchly.

5 Klasifikácia vybratých objektov

Vstupom do etapy klasifikácie sú samostatné objekty získané v predošlom kroku. Segmentovaním pohybujúcich sa objektov sa mohli získať rôzne ciele, ako automobil, chodec, skupina chodcov i „nezaujímavé“ oblasti a iné pohybujúce sa objekty. Je teda nevyhnutné tieto objekty správne klasifikovať.

Klasifikovanie vychádza z troch rôznych prístupov [1], [2]:

1. Prístupy klasifikácie založené na tvare objektu
2. Prístupy klasifikácie založené na spôsobe pohybu objektu
3. Wavelet metódy klasifikácie objektov

5.1 Prístupy klasifikácie založené na tvare

Táto metóda predpokladá, že systém má určité znalosti, pomocou ktorých rozhoduje, či je daný cieľ požadovaný objekt. Najčastejšie sa objekty klasifikujú do štyroch tried: jeden človek, skupina ľudí, automobil alebo rušenie.

Hlavné črty, z ktorých sa vychádza pri použití tohto prístupu [2], [3]:

1. Pomer strán priliehavého pravouhlého ohraničenia (bounding box) objektu
 - Automobily sú skôr širšie, ako vyššie. U ľudí je to opačne a vo väčšom pomere.
2. Symetria
 - Vozidlá sa vo všeobecnosti javia ako symetrické v horizontálnom smere.
3. Tiene pod automobilom
 - Využitie črty výrazne tmavšej oblasti vozovky vpredu pod automobilom.
4. Vertikálne a horizontálne hrany
 - Vlastnosťou vozidiel sú ich výrazné vertikálne a hlavne horizontálne hrany. Na detekciu hrán automobilov sa častejšie používajú morfológické hranové detektory. Oproti gradientovým dosahujú lepšie výsledky s menšou výpočtovou náročnosťou.
5. Textúry
 - V dôsledku podobnosti vozidiel je aj ich spôsob ovplyvnenia lokálnych hodnôt intenzity veľmi podobný. Na tomto základe sa dá vytvoriť určitý vzor textúry, ktorá môže pomôcť pri detekcii automobilov.
6. 3D modely
 - Podstatou tohto prístupu je projekcia 3D drôteného modelu vozidla do jeho 2D siluety. Prínosom je vysoká úspešnosť aj pri čiastočných prekrytiach automobilov a schopnosť klasifikovať vozidlá do rôznych tried. Tento prístup si však vyžaduje správnu kalibráciu kamery [2], [10], [11].
7. Predné sklo
 - Detekcia predného skla je motivovaná pozorovaním, že je prakticky vždy celé viditeľné, a to aj v prípade, keď jedno vozidlo čiastočne prekryva druhé. Výhodou je, že poskytuje aj mnoho ľahko sledovateľných bodov, navyše, kvôli rôznym tvarom sa dá použiť aj pri klasifikácii typov automobilov [11].

5.2 Prístupy klasifikácie založenej na spôsobe pohybu objektu

Vlastnosti pohybu ľudí a vozidiel sa výrazne odlišujú. Automobily sa pohybujú priamočiaro a vyššou rýchlosťou. Všetky tieto črty sa dajú použiť pri klasifikácii.

Zaujímavým spôsobom určenia stálosti tvaru objektu je analýza zvyškového optického toku (residual flow). Týmto sa zaoberal A. J. Lipton vo svojej práci [12]. Ľudia ako objekty s premenlivým tvarom produkujú svojím pohybom výrazný zvyškový optický tok, na rozdiel od vozidiel.

V týchto prístupoch sa teda najčastejšie rozoberá optický tok, oproti metódam klasifikácie založených na tvare, ktoré analyzujú priestorové črty.

5.3 Wavelet metódy klasifikácie objektov

Spracovanie obrazu spadá do dvoch širokých kategórií: metódy priestorovej domény a metódy frekvenčnej domény. Modifikácia priestorovej domény, čo je samotná obrazová rovina, manipuluje s pixelmi obrazu. Spracovanie frekvenčnej domény je založené na rôznych modifikáciách Fourierovej transformácie [13].

Pri wavelet metóde sa dekomponujú zložité signály na sumu jednoduchých bázových funkcií. Wavelet metódy sú lokálne vo frekvencii aj v čase, a preto lepšie analyzujú dáta v rôznych rozlíšeniach, ako Fourierové transformácie. Obraz sa teda spracováva v mnohých rozlíšeniach. Výhodou je nízka výpočtová náročnosť a jednoduchá implementácia algoritmov. Nedostatkom je citlivosť na šum [14].

Ďalším príkladom spracovania snímky v mnohých rozlíšeniach je Haarová transformácia. Jej základnými funkciami sú ortonormálne wavelety. Haarové vlnky (Haar wavelets, Haar-like features) sa najčastejšie používajú pri detekcii tváre [13]. V práci [15] sú však ukázané dve významné Haarove vlnky, pomocou ktorých sa dá pomerne jednoducho rozpoznať predná časť vozidla. Prvou takouto vlnkou je vertikálny prechod svetlosti medzi kapotou automobilu a tieňom pod ním, druhou prechod medzi kapotou a predným sklom.

6 Sledovanie pohybu vyčlenených objektov

Sledovanie pohybu správne klasifikovaných objektov, v tomto prípade vozidiel, je predpokladom pre určenie ich rýchlosti. Po určení trajektórie pohybu telesa už nie je veľkým problémom určiť aj jeho prejdenú vzdialenosť. Táto skutočnosť spolu so známym časovým úsekom nám jasne definujú rýchlosť vozidla. Pri sledovaní pohybu jednotlivých automobilov je jednoduchšie aj ich rátanie a prípadný výpočet hustoty premávky v danom

čase. Toto je nevyhnutnou súčasťou systémov, ktoré sa snažia porozumieť situácii na ceste a v kritických prípadoch rýchlo zareagovať.

Prvým problémom sledovania je vyhľadanie pozície daného objektu zo sekvencie snímok. Nájdené pozície telies však nemusia byť presné. Druhým problémom je správne vypočítanie trajektórie sledovaného telesa [3].

V súčasnosti sa sledovanie pohybu objektov rozdeľuje do štyroch hlavných kategórií [1]:

1. Založené na celom regióne pixelov
2. Založené na aktívnej kontúre
3. Založené na charakteristických črtách
4. Založené na 3D modeloch

6.1 Sledovanie pohybu vyčlenených objektov založené na celom regióne pixelov

Táto metóda považuje pohybujúci sa objekt ako jedno celistvé teleso. Pre každý takýto objekt sa z jeho celého regiónu obrazových bodov vytvorí šablóna. K týmto šablónam sa v nasledujúcich snímkach hľadajú zodpovedajúce telesá [1].

Pri malých zmenách tvaru a prekrytí objektov je úspešnosť tejto metódy vysoká, avšak v opačnom prípade je tento prístup nedostatočný. So zväčšujúcim sa regiónom obrazových bodov, a teda aj s väčšou šablónou, je nájdenie zodpovedajúceho telesa výpočtovo náročnejšie. Riešením týchto nedostatkov môže byť postupná aktualizácia šablóny v čase či použitie predikčných a odhadových algoritmov (prediction and estimation algorithms).

Samotné porovnávanie šablóny s vyčleneným objektom býva často realizované pomocou farebných histogramov. Histogram je funkcia, ktorá pre každú úroveň jasu udáva počet pixelov danej hodnoty v obraze. Odlesky od karosérie však môžu spôsobiť vážne problémy.

6.2 Sledovanie pohybu vyčlenených objektov založené na aktívnej kontúre

Tento výpočtovo nenáročný prístup sleduje objekt pomocou šablóny, ktorá je vytvorená na základe niektorých bodov aktívnej kontúry (snake model) daného telesa.

Nevyhnutnou súčasťou je pravidelné aktualizovanie tvaru šablóny, aby v každom okamihu čo najlepšie kopírovala skutočný obrys vozidla [1]. Na porovnanie kontúr sa používajú takzvané momenty kontúr (contour moments).

Podobný prístup použili Jamasbi a Behrad [16] vo svojom systéme na sledovanie vozidiel pri veľkej zmene uhlu pohľadu, kde s použitím vylepšenej aktívnej kontúry dosiahli výborné výsledky.

6.3 Sledovanie pohybu vyčlenených objektov založené na charakteristických vlastnostiach

Hlavnou myšlienkou tejto najčastejšie využívanej metódy je sledovanie nie celých objektov, ale len ich vizuálne najjednoduchších črt. Pri prekrytiach automobilov zostanú niektoré ich črty aj naďalej viditeľné, a preto prirodzenou výhodou tohto prístupu je vyššia úspešnosť sledovania. Na diferenciáciu automobilov je potrebné extrahovať najvýznamnejšie vlastnosti, ktoré dokážu čo najlepšie rozlíšiť jednotlivé vozidlá [17].

V článku [18] boli za najjednoduchšie črty považované rohové oblasti s bohatou textúrou. Vylepšenie tejto metódy je popísané v práci [19], kde sa použili nielen lokálne črty, ale aj globálna vlastnosť farba vozidla.

Všeobecne existuje mnoho lokálnych črt, ktoré sa dajú sledovať. Príkladom základných črt môžu byť rohy. Obmenou rohov môžu byť takzvané SIFT (scale-invariant feature transform) črty. Tieto črty sú nezávislé od škálovania i rotácie, čo predstavuje značnú výhodu v systémoch monitorovania cestnej premávky. Využitie týchto vlastností je popísané v práci [20], kde sa tento prístup vyznačuje vysokou robustnosťou v prípade zmien svetlosti, tvaru a veľkosti objektu spôsobenej jeho pohybom.

6.4 Sledovanie pohybu vyčlenených objektov založené na 3D modeloch

Sledovanie vozidiel pomocou 3D modelov bolo použité v prácach [21] a [22]. Prínosom tohto prístupu je presnejšie určenie trajektórie pohybu a menšia závislosť od uhlu pohľadu na scénu. Navyše sú takto získané ďalšie informácie, ako napríklad, že konkrétne vozidlo práve zatočilo vpravo. Nevýhodou je pomerne náročné vyprodukovanie modelu pre daný objekt a ich párovanie. Nevyhnutná je kalibrácia kamery či už pomocou

rôznych kalibračných algoritmov (príkladom môže byť systém popísaný v článku [23]), alebo ručným zadaním parametrov scény.

6.5 Kalmanov filter

Všetky vyššie spomenuté metódy sledovania pohybujúcich sa objektov sa veľmi často kombinujú s predikčnými a odhadovými algoritmi za účelom zrýchlenia a zlepšenia úspešnosti.

Najčastejšie používaným takýmto algoritmom je Kalmanov filter (použitý napríklad v prácach [15], [18], [24]), pretože je efektívny pri odhadovaní stavu lineárneho dynamického systému. Keďže sa veľkosť a pozícia každého automobilu mení lineárne, tak nasledovná pozícia vozidla môže byť predpovedaná na základe známej predošlej pozície a pozorovania.

Základom algoritmu sú dve fázy. Prvou je predpoveď, ktorá využíva zaznamenané informácie na určenie budúcej pozície objektu. Druhou fázou je korekcia, kedy sa na základe nameraných skutočných hodnôt upraví naučený model.

Prednosťou tohto filtra je, že namiesto toho, aby si pamätal celú históriu nameraných hodnôt, je len priebežne aktualizovaný, a teda v pamäti má len model predpovedajúci nasledujúcu iteráciu. Je teda výpočtovo nenáročný a dá sa použiť v reálnom čase [3].

Niekedy je potrebné rozšíriť tento filter za účelom zabezpečenia funkčnosti aj v prípade nelineárnych procesov. Výsledkom je takzvaný rozšírený Kalmanov filter (extended Kalman filter). Toto rozšírenie je vlastne jednoduché linearizovanie nelineárneho procesu. Príkladom použitia rozšíreného Kalmanovho filtra v sledovaní cestnej premávky môže byť práca [21].

7 Rôzne vylepšenia monitorovacích systémov

Kvôli dosiahnutiu lepších výsledkov či rozšírenia funkčnosti sa môžu aplikovať nasledujúce metódy.

7.1 Stabilizácia obrazu

Prudké poveternostné podmienky môžu spôsobiť trasenie kamery, a teda nestabilný obraz vo videosekvencii. Vtedy je výhodné aplikovať stabilizáciu obrazu.

Postup je pomerne jednoduchý. V aktuálnej snímke sa nájdu hrany a rohy a pomocou rotácie, škálovania, translácie a orezania sa spárujú s hranami a rohmi v predošlej snímke [18].

7.2 Detekcia čiar na ceste

Implementácia tejto metódy zabezpečuje možnosť rátania automobilov v jednotlivých jazdných pruhoch a zaznamenanie zmeny jazdného pruhu daného vozidla. Dokonca umožňuje aj lepšie odstrániť tieň spôsobený dopravným prostriedkom [18].

Detekcia čiar na ceste je často realizovaná Houghovou transformáciou. Táto transformácia hľadá rovné čiary v obraze tým, že predpokladá, že každý bod v snímke môže byť súčasťou množiny parametrizovaných priamok [3].

7.3 Použitie viacerých kamier

Táto metóda sa v súčasnosti vyžíva len zriedka, no pravdepodobne jej popularita bude rásť. Dôvodom je lepšie pokrytie cestnej premávky a s tým spojené jednoduchšie sledovanie vozidla aj pri prekrytiach pri pohľade na cestnú premávku z rôznych strán.

Kritickou súčasťou týchto systémov bude spolupráca medzi viacerými kamerami, teda správne spájanie informácií o vozidlách z rôznych uhlov pohľadu [1].

7.4 Sledovanie cestnej premávky v zlých svetelných podmienkach

Rovnako dôležitou súčasťou monitorovacích systémov cestnej premávky je funkčnosť aj v nočných hodinách. Za zlých svetelných podmienok je však zložité segmentovať celé objekty.

Realizovať túto myšlienku je možné na základe pozorovania, že za tmy sú prakticky viditeľné len predné svetlomety automobilov. Po detekcii svetlometov adaptívnym prahovaním nasleduje ich párovanie a sledovanie [24].

7.5 Odstraňovanie tieňov

Pri segmentácii pohybujúcich sa objektov sa často stáva, že okrem samotného automobilu obsahuje daný vyčlenený región aj tieň, ktorý sa s automobilom pohybuje. Odstránením takýchto tieňov sa získajú presnejšie výsledky pri segmentácii a zlepši sa úspešnosť celého systému.

Na základe pozorovaní pohybujúce sa tiene, spôsobené vozidlami, majú nasledujúce vlastnosti [2]:

1. Sú vrhnuté na referenčné pozadie.
2. Ich pixely sú tmavšie ako odpovedajúce pixely na pozadí. Vo farebnej reprezentácii RGB majú teda všetky zložky menšie hodnoty, v reprezentácii HSV tón aj sýtosť farby zostáva, hodnota svetlosti je však nižšia.
3. Pretože referenčné pozadie je zväčša tvorené cestou, ktorá je prakticky monochromatická (pomer RGB zložiek je približne rovnaký), tak v oblasti tieňa je tiež málo rôznych farebných tónov.
4. Hrany vozidiel sú podstatne výraznejšie ako hrany tieňov.

Metóda na odstránenie tieňa môže byť aj veľmi jednoduchá. Príkladom je metóda použitá v systéme [18], kde sa tiene odstraňujú jednoduchým prahovaním pri odčítaní pixelov pozadia od aktuálnej snímky. Hornú aj dolnú prahovú hodnotu tieňov určuje samotný používateľ.

Príklad zložitejšej metódy, založenej na informáciách o farbe a skreslenia textúry s následnou morfológickou rekonštrukciou popredia, je popísaný v práci [25]. Ako reprezentácia farieb bola zvolená HSV reprezentácia, a to kvôli lepšiemu rozlíšeniu medzi zložkami tónu, sýtosti a svetlosti, pretože tiene znižujú len hodnotu svetlosti. Navyše, na detekciu tieňov je použité aj meranie skreslenia textúry, ktoré je založené na pozorovaní, že tiene len málo skreslia textúru pozadia na rozdiel od objektov popredia. Niektoré pixely popredia mohli byť nesprávne klasifikované ako tiene a odstránené. Morfológickým rekonštruovaním pozadia sa však tento nedostatok odstránil.

8 Implementácia monitorovacieho systému cestnej premávky

Mojím cieľom pri implementácii monitorovacieho systému cestnej premávky nebolo vytvorenie samotnej aplikácie monitoringu. Zameral som sa na návrh rôznych riešení tejto problematiky s ich následnou implementáciou. Účelom tohto prístupu je hlavne overenie, prezentovanie a vysvetlenie funkčnosti navrhnutých riešení. Najväčší dôraz som kládol na metódy segmentácie automobilov a sledovania ich pohybu. Funkcionalitu systému som doplnil o počítanie všetkých typov vozidiel.

Ako oblasť záujmu som si vytýčil monitoring ciest mimo miest, a to kvôli nie príliš vysokej a ani príliš nízkej rýchlosti vozidiel. Je to teda priemerný prípad. Navyše, táto scéna je pomerne jednoduchá aj vzhľadom k problematike chodcov a ich skupín.

Mojou snahou bolo zabezpečiť správnu funkčnosť systému počas dňa i noci. Ako dôležité som považoval aj korektné správanie sa monitoringu v priebehu rôznych svetelných podmienok počas dňa. Problematické je hlavne slnečné počasie, kedy automobily vrhajú na vozovku svoje tieň.

Za nemenej dôležitú vlastnosť systému som považoval jeho nízku výpočtovú náročnosť, t. j., aby monitoring vozidiel dokázal bežať v reálnom čase aj na pomerne slabom počítači. Dôraz som kládol aj na vysokú úspešnosť počítania vozidiel a možnosť jednoducho doplniť ďalšie funkcie.

Systémy pre monitoring cestnej premávky počas dňa a noci som sa rozhodol implementovať osobitne, nakoľko riešenia použité pre segmentáciu pohybujúcich sa objektov sú diametrálne odlišné.

8.1 Použité technológie

Riešenia monitorovacieho systému vozidiel som implementoval pomocou jednej z funkčne najrozsiahljších knižníc počítačového videnia v reálnom čase – knižnice OpenCV, ktorá sa distribuuje pod licenciou slobodného softvéru. Použitá knižnica je vo verzii 2.2.

Kvôli vysokej kompatibilite tejto knižnice s programovacím jazykom C++ a vývojovým prostredím Microsoft Visual C++ 2010 som sa rozhodol pre toto vývojové prostredie.

8.2 Umiestnenie kamery

V podstate najdôležitejším predpokladom vysokej úspešnosti systému je správne umiestnenie kamery, ktorá sníma cestnú premávku. Pri návrhu riešenia som vychádzal z predpokladu, že kamera je stabilne umiestnená pomerne vysoko v strede nad vozovkou, čím sa zabezpečí minimálne prekrytie vozidiel v horizontálnom smere. Uhol, ktorý zvierá s cestou, by nemal byť ani príliš veľký alebo malý. V prípade veľkého uhlu hrozí, že vozidlá budú v zábere len veľmi krátko. Naopak, ak by bol uhol malý, hrozí časté prekrytie vozidiel vo vertikálnom smere. Vhodné umiestnenie kamery je znázornené na Obr. 4.



Obr. 4. Ukážka vhodného umiestnenia kamery

9 Monitoring cestnej premávky v nočných hodinách

Sledovanie cestnej premávky v nočných hodinách je rovnako dôležité ako počas dňa. Pri použití kamier s nočným videním sa v princípe od denného monitoringu dopravy nelíši. Nevýhodou tohto prístupu je vyššia cena kamery, avšak získava sa celistvejší pohľad na dopravnú situáciu.

Rozhodol som sa implementovať systém, ktorý si aj v noci vystačí s použitím obyčajnej kamery bez nočného videnia. Je to prístup lacného riešenia. Mojou inšpiráciou bol článok [24], ktorého podstatou je detekcia a párovanie svetlometov vozidiel.


Tento prístup vychádza z pozorovania, že hlavnou črtou vozidiel za zlých svetelných podmienok sú ich predné svetlomety. Kľúčovými krokmi je správna detekcia a spárovanie svetlometov v každej snímke. Následne sa pohyb tohto páru sleduje.

Vyplývajúcim nedostatkom tejto metódy je správna detekcia len tých vozidiel, ktoré majú funkčné oba predné svetlomety.

9.1 Segmentácia predných svetlometov

Na detekciu predných svetlometov vozidiel počas noci, teda oblastí s vysokou hodnotou svetlosti v snímke, som namiesto jednoduchého globálneho prahovania použil adaptívne prahovanie. Vychádzal som z experimentálneho pozorovania, keď adaptívne prahovanie dokázalo lepšie odstrániť nežiadany odraz svetla od vozovky. Porovnanie týchto dvoch metód je znázornené na Obr. 5. Prahovanie je aplikované na šedotónovú snímku.

Prahovacie metódy sú založené na predpoklade, že objekty v obraze sa dajú odlíšiť od pozadia len na základe hodnoty jasu jednotlivých obrazových bodov.



Obr. 5. Porovnanie dvoch metód prahovania. Obrázok (b) je výsledok jednoduchého globálneho prahovania snímky (a). Obrázok (c) je výsledok adaptívneho prahovania snímky (a), ktorý dokázal lepšie odstrániť nežiadany odraz svetlomietov od vozovky.

Na základe zvolenej prahovej hodnoty sa rozdelia obrazové body na body objektov a body pozadia. Rozdiel medzi jednoduchým a adaptívnym prahovaním je, že v prípade adaptívneho prahovania sa hodnota prahu vypočítava pre každý obrazový bod zvlášť [26].

Snímka je prahovaná binárne pomocou vzťahu (1),

$$ciel(x, y) = \begin{cases} 1, & zdroj(x, y) > T(x, y) \\ 0, & inak \end{cases} \quad (1)$$

kde $T(x, y)$ je vypočítaná prahová hodnota pre každý obrazový bod zvlášť. K tejto prahovej hodnote sa ešte pripočíta konštanta s hodnotou určenou (pomocou experimentálneho zistenia) na 40. Prahová hodnota $T(x, y)$ je váženým priemerom hodnôt jasů okolia (oblasť s veľkosťou 15x15) daného obrazového bodu. Jednotlivé hodnoty jasů sú vážené na základe Gaussovej funkcie ich vzdialenosti od centra. Výpočet štandardnej odchýlky σ použitej Gaussovej funkcie, ktorá závisí na veľkosti zvoleného okolia, je realizovaná vzťahom (2) [27].

$$\sigma = 0,3 * \left(\frac{velkost\ okolia}{2} - 1 \right) + 0,8 \quad (2)$$

Prahovanie bolo zabezpečené OpenCV funkciou `cv::adaptiveThreshold`. Po prahovaní snímky je aplikovaná morfológická operácia uzatvorenie, ktorá vzniká spojením transformácií dilatácie a erózie. Jej účelom je dosiahnutie lepších výsledkov pri segmentácii tým, že nájdené objekty sa stanú celistvejšími. Táto operácia je aplikovaná len jedenkrát. Použitý je štruktúrny element štvorcového tvaru s veľkosťou 3x3.

V takto získanej binárnej maske sú následne vyhľadane kontúry pomocou OpenCV funkcie `cv::findContours`. Získavané sú iba vonkajšie hlavné kontúry. Kvôli ušetreniu pamäti a aj následne výpočtovej zložitosti sú nájdené obrisy ukladané v zjednodušenej

forme. Použitá je kompresia vertikálnych, horizontálnych a diagonálnych segmentov, kedy sú uložené len ich koncové body.

Aby sa odstránil nežiadany šum, ktorý vznikol v procese prahovania, berú sa do úvahy len tie nájdené kontúry, ktorých dĺžka obvodu je väčšia ako vopred určená hranica. Odstránia sa tak, napríklad, odrazy svetiel od karosérie vozidiel či iné malé oblasti s vysokou hodnotou jasú. Hodnota danej hranice sa líši od rozdielneho umiestnenia či priblíženia kamery. V prípade väčšieho priblíženia môže mať táto hranica vyššiu hodnotu, naopak, pri širokom uhle pohľadu na cestnú premávku by táto hodnota mala byť nižšia, aby sa nestalo, že oblasti predných svetlometov by boli vyhodnotené ako príliš malé.

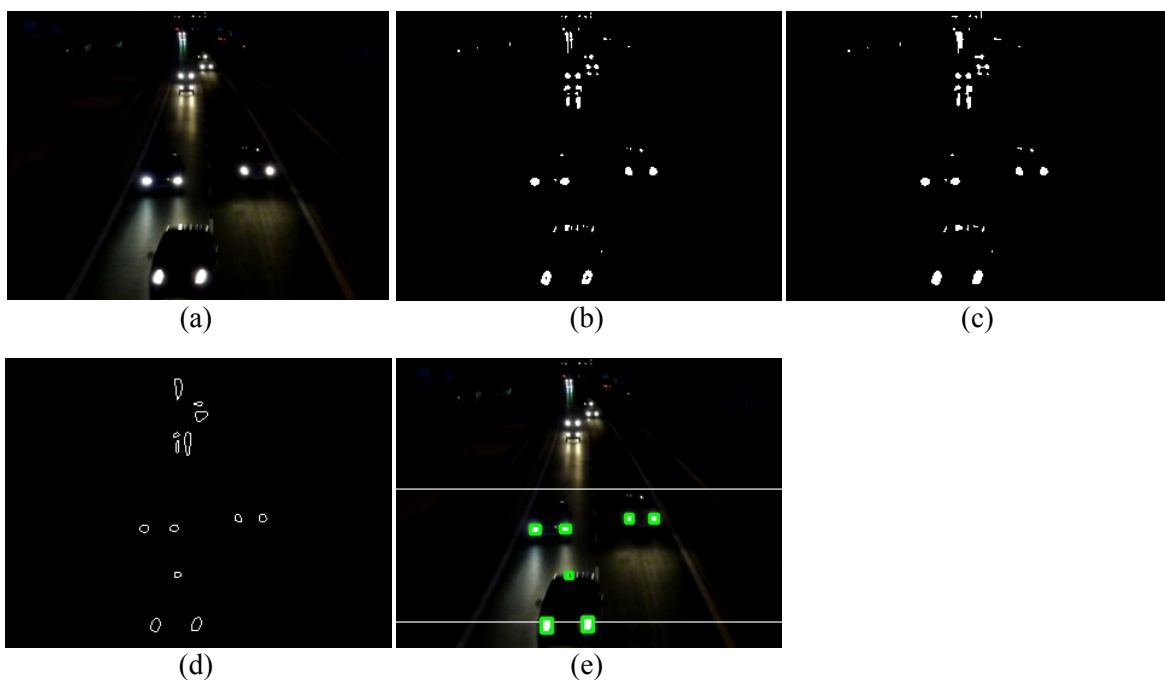
V ďalšom kroku sú získané kontúry nahradené ich konvexnými (zaoblenými) tvarmi za účelom zlepšenia kvality etapy segmentácie. Táto fáza odstraňuje chybné určený tvar predných svetlometov, ktorý mohol vzniknúť počas prahovania.

Kvôli zjednodušeniu práce a zníženiu výpočtovej náročnosti systému sa následne pracuje už len s priliehavými pravouhlými ohraničeniami (bounding box) daných kontúr. Z takto získaných ohraničení sú následne určení kandidáti na predné svetlomety vozidiel. Vychádza sa však len z tých ohraničení, ktorých ľavý horný roh sa nachádza vo vopred určenej oblasti záujmu, a to kvôli pozorovaniu, že v nižšej časti snímky je odraz svetlometov od vozovky menej intenzívny a viac rozptýlený. Tento prístup zvyšuje presnosť segmentácie v prípade odrazu svetla od vozovky (napr. počas dažďa) a odstraňuje aj chyby, ktoré sú spôsobené spojením viacerých svetlometov vozidiel nachádzajúcich sa vo veľkej vzdialenosti od kamery. Veľkosť a vertikálne umiestnenie tejto oblasti záujmu sa mení v závislosti od umiestnenia a priblíženia kamery. Množina kandidátov svetlometov je určená vzťahom (3). Postup detekcie svetlometov je znázornený na Obr. 6.

$$\text{kandidát svetlometu}(x, y) = \{\text{ohraničenie}(x, y); h_1 < y < h_2\} \quad (3)$$

9.2 Párovanie svetlometov

Výsledkom predošlej etapy sú kandidáti na svetlomety vozidiel. Detekcia samotných predných svetlometov je však v mnohých prípadoch zložitá a často sa stáva, že sú nájdené aj iné, nežiadané svetelné zdroje v snímke. Príkladom môžu byť pouličné lampy, rôzne odrazy svetla či už od vozovky alebo samotnej karosérie vozidiel. Preto je dôležité ich následné párovanie. Správne spárované svetlomety určujú práve jedno vozidlo.



Obr. 6. Segmentácia svetlometov. Šedotónová verzia pôvodnej snímky (a) bola najskôr adaptívne prahovaná (b), následne bola aplikovaná morfológická operácia uzatvorenie (c). Na takto vzniknutej maske boli vyhladané kontúry (d), vynechané však boli tie, ktoré mali príliš malý obvod. V poslednom kroku sa kontúry previedli na ich priliehavé pravouhlé ohraničenia (e).

Pri párovaní svetlometov som vychádzal z článku [24]. Prispôsobený algoritmus je založený na výpočte pravdepodobnosti, že dvaja kandidáti svetlometov i a j tvoria pár, a teda patria jednému vozidlu. Táto pravdepodobnosť je určená vzťahom (4),

$$P_{\text{pár}}(i, j) = P_{\text{vzdialenosť}}(i, j) * P_{\text{uhol}}(i, j) \quad (4)$$

kde $P_{\text{vzdialenosť}}(i, j)$ je pravdepodobnosť vypočítaná na základe vzdialenosti medzi svetlometom i a svetlometom j . $P_{\text{uhol}}(i, j)$ je pravdepodobnosť, ktorá vychádza z veľkosti uhla, ktorý zvierajú spojnice svetlometov s vodorovnou priamkou.

Pravdepodobnosť $P_{\text{vzdialenosť}}(i, j)$ je definovaná vzťahom (5).

$$P_{\text{vzdialenosť}}(i, j) = \begin{cases} \frac{1}{\sigma_1 \sqrt{2\pi}} e^{-\frac{(d(i,j) - \mu_{\text{vzdialenosť}})^2}{2\sigma_1^2}}, & \mu_{\text{vzdialenosť}} - h_1 \leq d(i, j) \leq \mu_{\text{vzdialenosť}} + h_1 \\ 0, & \text{inak} \end{cases} \quad (5)$$

Z tohto vzťahu vyplýva, že ak je euklidovská vzdialenosť $d(i, j)$ kandidátov svetlometov buď príliš veľká, alebo, naopak, príliš malá oproti priemernej vzdialenosti svetlometov $\mu_{\text{vzdialenosť}}$, tak hodnota $P_{\text{vzdialenosť}}(i, j)$ je nulová. Prah h_1 mal experimentálne určenú hodnotu 15. Ostatní kandidáti svetlometov, ktorých $d(i, j)$ vyhovuje daným hraniciam, majú hodnotu pravdepodobnosti definovanú na základe výpočtu Gaussovej funkcie (normálneho rozdelenia pravdepodobnosti), ktorej hodnota je vyššia približovaním

euklidovskej vzdialenosti $d(i, j)$ k hodnote priemernej vzdialenosti svetlometov $\mu_{vzdialenosť}$.

Priemerná vzdialenosť svetlometov bola získaná experimentálnym pozorovaním vzdialenosti svetlometov vozidiel v snímkach videa. Táto priemerná hodnota sa jasne mení zmenou priblíženia a umiestnenia kamery.

Výpočet veľkosti uhlu $uhol(i, j)$, ktorý zvierajú spojnice svetlometov i a j s vodorovnou priamkou, vychádza zo vzťahu (6),

$$uhol(i, j) = \sin^{-1} \frac{|y_i - y_j|}{d(i, j)} \quad (6)$$

kde y_i a y_j sú ypsilonové súradnice ľavých dolných rohov priliehavých pravouhlých ohraničení daných kandidátov svetlometov a $d(i, j)$ je ich euklidovská vzdialenosť.


Podobne, ako pri výpočte pravdepodobnosti $P_{vzdialenosť}(i, j)$, je aj vo vzťahu (7)

$$P_{uhol}(i, j) = \begin{cases} \frac{1}{\sigma_2 \sqrt{2\pi}} e^{-\frac{(uhol(i, j) - \mu_{uhol})^2}{2\sigma_2^2}}, & uhol(i, j) \leq \mu_{uhol} + h_2 \\ 0, & \text{inak} \end{cases} \quad (7)$$

na určenie pravdepodobnosti na základe veľkosti uhla $P_{uhol}(i, j)$ použitá Gaussova funkcia. Rovnako i v tomto prípade sa neuvažuje o páre takých svetlometov, ktorých uhol $uhol(i, j)$ presahuje danú hranicu určenú priemernou hodnotou uhla μ_{uhol} a prahu h_2 (s experimentálnou hodnotou 0,07rad). Hodnota μ_{uhol} môže nadobúdať v prípade kamery upevnenej pod určitým uhlom aj nenulové hodnoty.

σ_1 a σ_2 v rovniciach sú štandardné odchýlky Gaussových funkcií.

Pravdepodobnosť $P_{pár}(i, j)$ je počítaná medzi všetkými kandidátmi svetlometov navzájom. Následne je zo zoznamu kandidátov odstránený nájdený najpravdepodobnejší pár svetlometov. Tento postup sa opakuje, až kým zoznam kandidátov nie je prázdny, alebo ak sa nenájde žiadny vhodný pár – pár, ktorý dosahuje minimálnu pravdepodobnosť páru svetlometov. Svetlomety pred a po párovaní sú znázornené na Obr. 7.



Obr. 7. Párovanie svetlometov. Z množstva nájdených kandidátov na svetlomet v snímke (a) boli algoritmom vybrané správne dvojice predných svetlometov vozidiel (c).

9.3 Sledovanie pohybu párov svetlometov

Výsledné spárované svetlomety sú reprezentované spoločným priliehavým pravouhlým ohraničením, ktoré obsahuje oba svetlomety. Toto ohraničenie spolu s ďalšími údajmi ako je napríklad jednoznačné identifikačné číslo (jednoznačná farba), určuje práve jedno vozidlo v snímke. Pohyb takéhoto vozidla (ľavého dolného rohu jeho priliehavého pravouhlého ohraničenia) je sledovaný pomocou jednoduchého predikčného lineárneho algoritmu, ktorého výhodou je výpočtová nenáročnosť.

Tento algoritmus vychádza z pozorovania, že pohyb automobilov v snímkach je v podstate lineárny. Odhadovaná pozícia vozidla s_{t+1} v nasledujúcej snímke je určená na základe jeho skutočnej pozície s_t v aktuálnej a skutočnej pozície s_{t-1} v predošlej snímke pomocou (8) a (9),

$$s_{t+1} = s_t + \Delta s \quad (8)$$

$$\Delta s = s_t - s_{t-1} \quad (9)$$

kde Δs je zmena pozície vozidla medzi aktuálnou a predošlou snímkou. Vzhľadom na stabilný tvar a stabilnú pozíciu ohraničenia svetlometov medzi snímkami dosahuje tento algoritmus veľmi dobré výsledky. Sledovanie vozidiel je znázornené na Obr. 8.

Vozidlá v aktuálnej snímke boli buď novo nájdené, alebo sa vyskytovali už v predošlej snímke. Snahou je pre každé vozidlo v aktuálnej snímke nájsť odpovedajúceho predchodcu v predošlej snímke, a tým sledovať jeho pohyb.


Predpokladaná pozícia, ktorá odhaduje skutočnú pozíciu daného vozidla v aktuálnej snímke, sa hľadá pomocou výpočtu euklidovskej vzdialenosti. Táto vzdialenosť je rátaná medzi pozíciou daného aktuálneho vozidla a predpoveďami budúcich pozícií všetkých vozidiel z minulej snímky. Následne je nájdená najmenšia táto vzdialenosť a ak spĺňa

podmienku, aby nepresiahla určitý prah (s experimentálne určenou hodnotou 5), tak sa našli odpovedajúce vozidlá.

Pre vozidlá, ktoré boli nájdené v predošlej snímke po prvýkrát, ešte nie je možné odhadnúť ich budúcu pozíciu. Je to dôsledkom ich neznámej predošlej pozície. Preto, ak sa nespĺnila predošlá podmienka pri hľadaní odpovedajúcich vozidiel, tak sa tento pár automobilov určuje pomocou výpočtu euklidovskej vzdialenosti medzi pozíciou aktuálneho vozidla a pozíciami všetkých vozidiel z predošlej snímky. Ak nájdená najmenšia takáto vzdialenosť nepresiahla daný prah (s hodnotou 15), tak je určený odpovedajúci pár vozidiel. Navyše sa overuje, či bol predchodca daného vozidla v predošlej snímke nájdený po prvýkrát.

Vozidlá od svojich predchodcov dedia určité vlastnosti. Tieto vlastnosti sú napríklad ich jednoznačné identifikačné číslo (farba) a vek (počet predošlých snímok, v ktorých bolo dané vozidlo nájdené a sledované). K veku sa prirodzene pripočíta ďalšia snímka.

Ak sa pre niektoré vozidlo nenašiel jeho predchodca alebo jeho predchodca bol už spárovaný s iným aktuálnym automobilom, tak je toto vozidlo považované za novo nájdené. Jeho vek je automaticky určený na jednu snímku a priradené jednoznačné identifikačné číslo je z množiny nepoužitých identifikačných čísel.




Obr. 8. Sledovanie pohybu vozidiel. Zeleným obdĺžnikom je znázornená skutočná pozícia dvojice svetlometov v predošlej snímke. Skutočná pozícia svetlometov v aktuálnej snímke je znázornená modrým obdĺžnikom. Malá biela kružnica ukazuje odhadovanú pozíciu ľavého dolného rohu modrého obdĺžnika.

9.4 Funkcionalita počítania vozidiel

Rátanie vozidiel (bez rozdielu ich typu) je uskutočňované len v jednom smere cestnej premávky, a to v smere automobilov približujúcich sa ku kamere. Vzhľadom na použité sledovanie pohybu vozidiel je samotná implementácia tejto funkcionality pomerne jednoduchá.

Započítaniu vozidla predchádzajú dve podmienky. Prvou z nich je približujúci sa smer pohybu automobilu. Tento smer je určený na základe známej pozície prvého výskytu vozidla a jeho známej pozície v čase zarátania. Druhou podmienkou je, aby vek daného automobilu dosiahol určitú hodnotu. Táto hodnota, čiže minimálny počet snímok, v ktorých vozidlo musí byť nájdené za účelom jeho započítania, je závislá od umiestnenia a priblíženia kamery, ale aj od priemernej rýchlosti automobilov na danom úseku.

Takýto prístup zabezpečuje vysokú robustnosť funkcionality rátania vozidiel. Prípadné chyby, či už spôsobené v etape segmentácie, párovania alebo sledovania vozidiel, sa často objavujú len v jednej samotnej snímke, a teda nepretrvávajú v sekvencii viacerých snímok. Výsledná úspešnosť rátania vozidiel je teda vysoká. Celkový postup nočného monitoringu je znázornený na Obr. 9.



Obr. 9. Postup nočného monitoringu. V pôvodnej snímke sú najskôr vyhľadani kandidáti na svetlomety (a), ktorí sú následne spárovaní do dvojíc za účelom detekcie vozidla. Jednotlivé vozidlá sú po správnom sledovaní (b) vo väčšom počte za sebou idúcich snímok zarátané (c).

10 Monitoring cestnej premávky počas dňa

Rozhodol som sa implementovať dva diametrálne odlišné prístupy riešenia monitoringu cestnej premávky počas dňa. Motiváciou bola možnosť ich následného porovnania ale aj chuť experimentovať. Hlavný rozdiel týchto prístupov spočíva v odlišnom spôsobe segmentácie vozidiel a ich sledovania. Naopak, rátanie automobilov je uskutočnené rovnakým spôsobom.

10.1 Monitoring cestnej premávky počas dňa použitím rozdielu sekvencie snímok

Hlavnou myšlienkou tohto prístupu je detekcia pohybujúcich sa objektov pomocou počítania rozdielu sekvencie snímok. Výhodou je veľmi nízka výpočtová náročnosť ale aj jednoduchosť implementácie. Napriek tomu dosahuje táto metóda dobré výsledky. Pohyb

nájdeneých vozidiel je určený sledovaním ich jednoznačných črt. V nasledujúcich odsekoch je bližšie popísaný postup implementácie.

10.1.1 Segmentácia vozidiel

Úloha tejto etapy spočíva v nájdení oblastí s vozidlami v snímke. Automobily, ako pohybujúce sa objekty, menia svoju pozíciu postupom času. Ak sú teda porovnané dve za sebou idúce snímky, sú nájdené zmeny polohy vozidiel.

Jednou z najväčších výziev segmentácie vozidiel je ich segmentácia bez tieňa, ktorý vrhajú. Za týmto účelom je absolútny rozdiel sekvencie dvoch snímok aplikovaný dvakrát na ich rôzne farebné zložky.

V prvom kroku sú predošlá a aktuálna snímka skonvertované z RGB do HSV farebnej reprezentácie. HSV reprezentácia dokáže rozlišovať medzi zložkami tónu (Hue), sýtosti (Saturation) a svetlosti (Value) farieb. Vychádza sa z pozorovania, že tieň v podstate znižujú len hodnotu svetlosti. V skutočnosti na základe experimentálneho pozorovania sa čiastočne menili aj zložky tónu a sýtosti.

Zložka tónu aktuálnej aj predošlej snímky nebola použitá kvôli výskytu vysokého šumu. Absolútny rozdiel sekvencie dvoch snímok je aplikovaný len na zložky sýtosti farby a svetlosti pomocou vzťahov (10) a (11),

$$\text{rozdiel}_{sýtost}(x, y) = |\text{predošlá}_{sýtost}(x, y) - \text{aktuálna}_{sýtost}(x, y)| \quad (10)$$

$$\text{rozdiel}_{svetlost}(x, y) = |\text{predošlá}_{svetlost}(x, y) - \text{aktuálna}_{svetlost}(x, y)| \quad (11)$$

kde $\text{rozdiel}_{zložka}(x, y)$ je absolútny rozdiel hodnôt obrazových bodov so súradnicami x a y v danej zložke.

Získané snímky absolútnych rozdielov sú následne prahované za účelom získania binárnych masiek pohybujúcich sa objektov pomocou vzťahov (12) a (13),

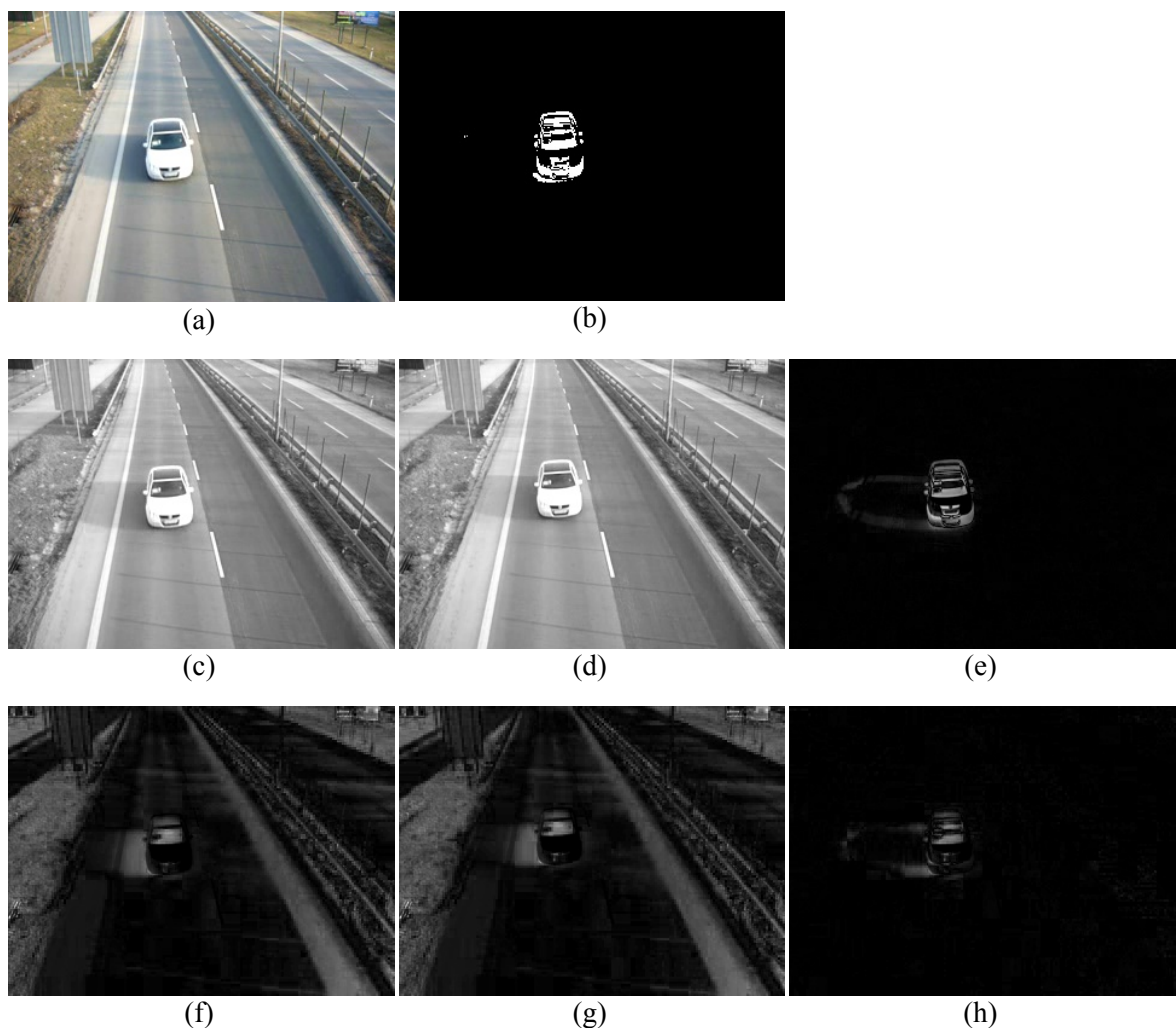
$$\text{maska}_{sýtost}(x, y) = \begin{cases} 1, & \text{rozdiel}_{sýtost}(x, y) > T_{sýtost} \\ 0, & \text{rozdiel}_{sýtost}(x, y) \leq T_{sýtost} \end{cases} \quad (12)$$

$$\text{maska}_{svetlost}(x, y) = \begin{cases} 1, & \text{rozdiel}_{svetlost}(x, y) > T_{svetlost} \\ 0, & \text{rozdiel}_{svetlost}(x, y) \leq T_{svetlost} \end{cases} \quad (13)$$

kde $T_{sýtost}$ a $T_{svetlost}$ sú prahy (s experimentálne určenými hodnotami 80 a 50). Následne je vytvorená spoločná binárna maska vozidiel zjednotením masiek zložky sýtosti

a svetlosti. Toto zjednotenie spolu s použitými prísnejšími hodnotami prahov $T_{sýtosť}$ a $T_{svetlosť}$ zabezpečuje čiastočné odstránenie nežiadanych tieňov bez výrazného poškodenia binárnej masky segmentovaného vozidla.


Keďže sa zložka svetlosť nápadne podobá šedotónovej verzii danej snímky, mohlo by sa zdať, že by stačilo počítať absolútny rozdiel len šedotónových snímok. Výsledkom by však bolo, že v prípade prísnejšieho prahu pri prahovaní za účelom získania binárnej masky by síce tieňe boli odstránené, ale za cenu chýbajúcich častí vozidiel. V opačnom prípade by boli segmentované vozidlá celistvejšie, ale s tieňmi. Samotná segmentácia vozidiel absolútnym rozdielom sekvencie snímok je znázornená na Obr. 10.



Obr. 10. Segmentácia vozidiel pomocou absolútného rozdielu dvoch za sebou idúcich snímok s odstránením tieňov. V prvom kroku sú aktuálna (a) a predošlá snímka skonvertované do HSV farebnej reprezentácie. Medzi zložkami svetlosť (Value) aktuálnej (c) a predošlej (d) snímky je vypočítaný absolútny rozdiel (e). Rovnako aj medzi zložkami sýtosť (Saturation) aktuálnej (f) a predošlej (g) snímky je vypočítaný absolútny rozdiel (h). V ďalšom kroku sú tieto dve snímky absolútnych rozdielov prahované rôznymi prahmi. Nakoniec sa vzniknuté binárne masky zjednotia do jednej (b).

Problémom tohto prístupu segmentácie je závislosť od stanoveného časového intervalu medzi odčítavanými snímkami (parameter videa počet snímkov za sekundu) a rýchlosťou vozidiel. Ďalšou nevýhodou je výraznejšia detekcia len hrán vpredu a vzadu na vozidlách. Boky automobilov sa často jemne strácajú, čo môže spôsobovať problémy. Nezvyklé nie je ani predelenie jedného vozidla na dva rôzne pohybujúce sa objekty.


Na odstránenie šumu spoločne so získaním celistvejšej binárnej masky automobilov, a teda vyriešenia problému predelenia vozidiel, sú následne aplikované morfológické operácie. Najskôr na získanie kompletnejšej masky je použitá operácia uzatvorenie. Počet iterácií dilatácie a erózie tejto operácie bol stanovený na 3. Na odstránenie šumu je potom jedenkrát aplikovaná morfológická operácia otvorenie. Obe operácie používajú štvorcový štruktúrny element s veľkosťou 3x3. Masky popredia po aplikovaní týchto operácií sú znázornené na Obr. 11.



Obr. 11. Morfológické operácie na binárnej maske popredia (znázornenej na Obr. 10. (b)). Obrázok (a) vznikol aplikovaním troch morfológických operácií uzatvorenie, ktoré nasledovala jedenkrát aplikovaná operácia otvorenie. Na obrázku (b) je pre porovnanie znázornená maska, ktorá je výsledkom segmentácie bez odstraňovania tieňov.

V ďalšom kroku segmentácie sú v takto vzniknutej binárnej maske vyhládané kontúry (pomocou OpenCV funkcie `cv::findContours`). Kontúry, ktorých dĺžka obvodu nedosahuje určenú prahovú hodnotu, sú však odstránené. Tento krok zabezpečuje odstránenie väčšieho šumu či iných malých nežiadanych nájdených oblastí v snímke. Hodnota daného prahu závisí od priblíženia a umiestnenia kamery. Je dôležité, aby táto hodnota nebola príliš veľká, čo by spôsobilo chybné považovanie automobilu za šum.

Jednotlivé kontúry sú ďalej nahradené ich konvexnými tvarmi, čo značne zlepšuje presnosť segmentácie. Vyplnia sa tak prípadné chýbajúce „vyhryznuté“ časti nájdených vozidiel. Konečná podoba masky popredia je znázornená na Obr. 12.



Obr. 12. Nahradenie nájdených kontúr v maske popredia ich konvexnými tvarmi. Obrázok (b) je konečná podoba binárnej masky popredia pôvodnej snímky (a). Vznikla vyhľadáním kontúr v binárnej snímke (d) a ich nahradením konvexnými tvarmi. Masku (d) je výsledkom aplikovania morfológických operácií na masku (c).

10.1.2 Sledovanie pohybu vozidiel

V dôsledku nie veľmi stabilnej binárnej masky vozidla získanej v predošlej etape segmentácie, ktorej tvar sa môže medzi snímkami výrazne meniť, nie je vhodné použiť princíp jednoduchého sledovania pohybu vozidiel, ako v prípade nočného monitoringu. Výsledkom by bolo časté zlyhanie sledovania, pretože daná odhadovaná pozícia by sa v mnohých prípadoch podstatne líšila od skutočnej.

Riešením tohto problému môže byť nie sledovanie samotných oblastí vozidiel, ale sledovanie jednoznačných črt nachádzajúcich sa v týchto oblastiach. Vo všeobecnosti existuje mnoho typov takýchto črt.

Podstatou sledovania, založenom na tomto prístupe, je použitie čo najunikátnejších malých oblastí v snímke. Takéto obrazové body (prípade spolu s ich okolím) nie je zložité sledovať z jednej snímky do druhej, pretože je málo pravdepodobné, že by danej jednoznačnej črte odpovedalo viacero nájdených výsledkov z druhej snímky. V prípade použitia nejednoznačných črt je vysoko pravdepodobné, že sa nájde veľa podobných oblastí.

Najčastejšie používanými črtami sú obrazové body, ktoré majú silnú deriváciu v dvoch ortogonálnych smeroch. Z tohto dôvodu sa tieto unikátne oblasti často nazývajú rohmi. Rohy obsahujú dostatočne veľké množstvo informácií za účelom ich sledovania z jednej snímky do druhej [3].

Na nájdenie jednoznačných črt v aktuálnej snímke bola použitá OpenCV funkcia `cv::goodFeaturesToTrack`, ktorá hľadá oblasti silných rohov. Táto funkcia implementuje definíciu z článku [28]. V prvom kroku je určená „kvalita“ rohov v každom pixeli zdrojovej snímky, a to pomocou výpočtu druhých derivácií a následného určenia minimálnej vlastnej hodnoty matíc – blokov v obraze (oblasť 2x2 susedov daného obrazového bodu). Výsledkom je snímka, v ktorej je pre každý obrazový bod uložená táto vlastná hodnota. Ďalším krokom je potlačenie hodnôt, ktoré nie sú súčasťou lokálneho maxima získaného z ich okolia 3x3 (aplikované je teda non-maxima suppression). Následne sú vynechané tie rohy, ktorých vlastná hodnota je menšia ako vopred určený prah. Tento krok zaručuje určitú minimálnu prípustnú kvalitu rohov. V poslednom kroku sú získané rohy zoradené podľa kvality. V prípade, že sa rohy nachádzajú príliš blízko pri sebe, je ponechaný len ten silnejší [27].

Silné rohy sú vyhľadávané v oblasti každého nájdeného vozidla či iného pohybujúceho sa objektu v šedotónovej verzii aktuálnej snímky. Výsledkom je detekcia množiny jednoznačných črt pre každé vozidlo zvlášť. Nájdené silné rohy na vozidlách sú znázornené na Obr. 13.



Obr. 13. Príklad nájdených silných rohov na vozidlách


Rovnako dôležitým krokom, ako nájsť unikátne črty, je aj ich sledovanie z aktuálnej snímky do predošlej. Na tento účel bola použitá OpenCV funkcia

cv::calcOpticalFlowPyrLK, ktorá slúži na výpočet riedkeho optického toku. Vstupom do tejto metódy sú, okrem iného, aj šedotónové verzie aktuálnej a predošlej snímky spolu s vopred získanými silnými rohmi. Výstup je vo forme nájdených odpovedajúcich obrazových bodov v minulej snímke k daným jednoznačným črtám spoločne s hodnotami presnosti sledovania týchto črt. Pomocou týchto hodnôt sú následne vynechané tie nájdené body, ktoré sú priveľmi odlišné od pôvodných.

Implementácia tejto metódy je založená na Lucas-Kanade (LK) algoritme na výpočet riedkeho optického toku. LK algoritmus vychádza z lokálnych informácií, ktoré sú získané z malého okolia daného bodu záujmu. Problematické sa tak stáva sledovanie rýchlejšie pohybujúcich sa bodov, pretože sa môžu ľahko vytratiť z určeného malého okna. Na vyriešenie tejto nevýhody bol vytvorený „pyramídový“ LK algoritmus, ktorý vychádza z pyramíd snímok. Hľadanie danej črty začína v najvyššej úrovni tejto pyramídy (snímka je v najnižšom rozlíšení) a postupne, v prípade neúspechu, sa aplikuje až na najnižšiu úroveň (snímka je v najvyššom rozlíšení) [3].

LK algoritmus vychádza z nasledujúcich predpokladov. Prvým je pomerne konštantná hodnota svetlosti daného obrazového bodu, teda rohy, ktoré sú sledované, sa nemenia v čase (v prípade sledovania v obrázkoch s viac kanálmi je to stálosť hodnôt vo všetkých kanáloch). Ďalším predpokladom je relatívne pomalý pohyb objektov vzhľadom na počet snímok za sekundu. Posledným nemenej dôležitým predpokladom je, že susedné obrazové body danej sledovanej črty ostávajú jej susedmi aj v ďalšej snímke [3].

Parameter veľkosti okna tejto funkcie bol určený na 10x10 pixelov. Na základe experimentálneho pozorovania nebolo potrebné použiť vytváranie pyramíd snímok. Jednak zvyšovalo výpočtovú náročnosť a jeho vynechanie nemalo takmer žiadny vplyv na úspešnosť sledovania jednoznačných črt. Sledovanie črt je znázornené na Obr. 14.



Obr. 14. Sledovanie pohybu vozidiel. Pohyb vozidiel je sledovaný na základe ich jednoznačných črt. Nájdené unikátne rohy sú znázornené malými zelenými bodkami. Tieto rohy sú sledované z aktuálnej snímky (vľavo) do predošlej snímky (vpravo).


V podstate požadovaným konečným výsledkom vyššie spomenutých metód sú pre všetky vozidlá v aktuálnej snímke určené ich jednoznačné črty a k týmto črtám sú vyhladané odpovedajúce body v predošlej snímke.

Nech v_t je vozidlo z množiny pohybujúcich sa objektov nájdených v aktuálnej snímke a v_{t-1} je vozidlo z množiny objektov vyskytujúcich sa v predošlej snímke. Nech M_1 je množina všetkých jednoznačných bodov patriacich vozidlu v_t a M_2 je množina bodov, ktoré vznikli ich sledovaním do predošlej snímky. Vozidlo v_{t-1} je predchodcom vozidla v_t práve vtedy, keď existuje bod z množiny M_2 , ktorý patrí vozidlu v_{t-1} .

Ďalej sa postupuje prakticky rovnako ako v prípade nočného monitoringu.

10.1.3 Funkcionalita počítania vozidiel

Počítanie vozidiel vychádza z algoritmu popísaného v nočnom monitoringu dopravy. Automobily sú zarátané až po ich sledovaní vo väčšom počte snímok (napríklad 20 snímok). Postup denného monitoringu je znázornený na Obr. 15.



Obr. 15. Postup denného monitoringu. V aktuálnej snímke sú najskôr nájdené pohybujúce sa vozidlá (a), ktoré sú po sledovaní (b) vo väčšom počte snímok zarátané (c).

10.2 Monitoring cestnej premávky počas dňa použitím odčítavania pozadia od aktuálnej snímky

Implementácia tohto monitorovacieho systému je založená na princípe segmentácie porovnávaním statického pozadia s aktuálnou snímkou.

10.2.1 Segmentácia vozidiel

Kľúčovým krokom pri segmentácii pohybujúcich sa objektov týmto prístupom je získanie statického referenčného pozadia. Nemenej dôležité je aj jeho postupné aktualizovanie v čase. Počas hustej cestnej premávky je však prakticky nemožné získať pozadie, teda statickú snímku, v ktorej by sa nenachádzalo žiadne vozidlo či iný

pohybujúci sa objekt. Riešením tohto problému je postupné budovanie referenčného modelu pozadia.

V knižnici OpenCV sú implementované dva modely metód odčítavania pozadia. Oba dokážu postupne budovať statické pozadie aj v prípade neustále sa pohybujúcich objektov a následne ho aktualizovať v čase. Odlišujú sa v použitých prístupoch a myšlienkach.

Prvý je pomerne zložitý a prepracovaný model FGStatModel. Jeho implementácia je založená na článku [29]. Hlavnou myšlienkou je formulácia Bayesovho rozhodovacieho pravidla na určenie, či je daný obrazový bod súčasťou popredia alebo pozadia. Pozadie je formované statickými ale i nestatickými objektmi. Statické sú popísané štatistikou najvýznamnejších farieb. Nestatické objekty sú popísané štatistikou najvýznamnejších spoločných farebných výskytov. Tento model je robustný v prípadoch náhlych zmien v obraze i periodických pohyboch (napríklad pohyb lístia stromov). Je možné ho aktualizovať v čase. Model FGStatModel som však nepoužil, pretože je výpočtovo veľmi náročný a nedosahoval výsledky v reálnom čase.

Použil som druhý model, ktorý je založený na kombinácii Gaussovej distribúcie, GaussianBGModel. Jeho implementácia vychádza z článku [30]. Implementovaná je však len časť bez detekcie tieňov. Každý obrazový bod referenčného pozadia je tvorený k počtom Gaussiánov. Rôzne Gaussiány reprezentujú rôzne farby, ktoré daný obrazový bod nadobúda. Váhový parameter kombinácie určuje dĺžku času, kedy dané farby ostali v scéne. Jednotlivé obrazové body pozadia sú len tie, ktoré obsahujú určitý počet najpravdepodobnejších farieb. Ostatné sú považované za popredie. Najpravdepodobnejšie farby sú tie, ktoré sa nemenili počas dlhšej doby.

Použitie tohto modelu v implementácii monitoringu cestnej premávky počas dňa je nasledovné. Prvým krokom je jeho inicializácia s parametrami a snímkou. Dva Gaussiány boli modelované použitím prahu pozadia s hodnotou 0,6. Veľkosť okna bola určená na 50 za účelom rýchleho prispôsobenia sa pri zmenách v scéne. Hodnota veľkosti okna je inverzná k rýchlosti učenia a slúži na výpočet určitej štatistiky. Po správnej inicializácii je tento model aktualizovaný v každom kroku aktuálnou snímkou, čo zabezpečuje prispôsobivosť na zmeny v scéne. Pozadie je prakticky vždy vymodelované do 15 sekúnd.

Primárnym vstupom do tohto modelu sú šedotónové či plnofarebné snímky. Vzhľadom na neimplementovanú časť detekcie tieňov som sa rozhodol trochu experimentovať. Na rozdiel od prvého spôsobu odstránenia tieňov pomocou HSV reprezentácie, kedy sa porovnávala sekvencia dvoch snímok, som v tomto prípade použil úplne odlišnú myšlienku. Snahou bolo odstrániť tieňe zo snímky ešte pred procesom segmentácie, a to pomocou detekcie hrán.

Myšlienka je založená na pozorovaní, že vozidlá, na rozdiel od tieňov, majú na ceste silné horizontálne i vertikálne hrany. Hrany pohybujúcich sa tieňov automobilov nie sú také výrazné.

Hrany sú miesta v obraze, kde sa prudko mení hodnota jasu obrazových bodov. Na ich detekciu v snímke je ako konvolučná maska použitý Prewittov operátor. Vyhľadávanie hrán je aplikované len v horizontálnom a vertikálnom smere. Použitím konvulčných masiek k_1 až k_4 znázornených v (14)

$$k_1 = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} \quad k_2 = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix} \quad k_3 = \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix} \quad k_4 = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad (14)$$

na aktuálnu snímku sú získané 4 rôzne snímky, v ktorých boli nájdené hrany v dvoch horizontálnych a dvoch vertikálnych smeroch. Následne, za účelom odstránenia slabých a zvýraznenia silných hrán, teda aj za účelom odstránenia hrán vrhnutých tieňom a zvýraznenia hrán vozidiel, je aplikované jednoduché binárne prahovanie. Hodnota prahu pre vertikálny a horizontálny smer sa líši. Získané sú tak 4 binárne snímky nájdených hrán. Ako posledný krok detekcie hrán je zjednotenie 4 binárnych snímok do jednej. Výsledok detekcie hrán je znázornený na Obr. 16.



Obr. 16. Odstraňovanie tieňov pomocou detekcie hrán. V pôvodnej snímke (a) sú nájdené silné horizontálne a vertikálne hrany (b).

Binárnymi hranovými snímkami, v ktorých boli odstránené tieňe, je inicializovaný a následne aj aktualizovaný použitý Gaussiánový model pozadia. Získanou výhodou tohto prístupu je aj zanedbanie náhlych zmien svetlosti v snímkach, ktoré mohli byť, napríklad, spôsobené automatickou úpravou svetlosti kamery v prípade prechádzajúceho veľkého vozidla.

V ďalšom kroku je pomocou použitého Gaussiánového modelu získané popredie. Kvôli náchylnosti etapy detekcie hrán na šum je výsledné popredie výrazne zašumené. Vzniknutý šum je nutné odstrániť. Na tento účel bol využitý jednoduchý priemerovací šumový filter. Nová hodnota jasu obrazového bodu je získaná ako aritmetický priemer hodnôt jasov jeho okolia (veľkosť okolia bola určená na 3x3). Po aplikovaní tohto filtra už získané popredie nie je binárne, preto je opäť použité jednoduché prahovanie. Výsledkom je popredie s odstráneným šumom. Osamotené pixely boli zanedbané, ich zhluky boli, naopak, zvýraznené.

Ďalší postup je v princípe totožný s predošlými implementáciami monitorovacieho systému. Na masku popredia je jedenkrát aplikovaná morfológická operácia uzatvorenie. Následne sú vyhľadane kontúry, ktoré sa neskôr nahradia ich konvexnými tvarmi, čo je dôležitý krok. Vyčlenené vozidlá majú totiž často „vyhryznuté“ časti. Kontúry s príliš malou dĺžkou obvodu sú zanedbané, čo zabezpečuje odstránenie väčšieho šumu, ktorý je často spôsobený nedostatkom odstraňovania tieňov pomocou detekcie hrán. Tento nedostatok spôsobuje vznik väčšieho šumu pri prechode pohybujúceho sa tieňa cez členitý povrch (ako napríklad trávnaté oblasti pri vozovke).


Následne sa rovnako ako v prípade sledovania nočnej premávky pracuje už len s priliehavými pravouhlými ohraničeniami daných konvexných tvarov, ktoré sa nachádzajú vo vopred určenej oblasti detekcie. Postup detekcie vozidiel je znázornený na Obr. 17.

10.2.2 Sledovanie pohybu vozidiel


Kvôli vyššej výpočtovej náročnosti použitého modelu pozadia už nebolo možné sledovať vozidlá pomocou ich jednoznačných číť, a preto bol použitý jednoduchý predikčný algoritmus rovnako ako v prípade nočného monitoringu cestnej premávky.

10.2.3 Funkcionalita počítania vozidiel

Princíp rátania vozidiel je rovnaký ako v oboch predošlých implementáciách monitorovacieho systému. Postup denného monitoringu je znázornený na Obr. 18.



Obr. 17. Detekcia pohybujúcich sa vozidiel. V pôvodnej snímke (a) sú najskôr vyhladané hrany (b). Následne je zo snímky (b) odčítané pozadie za účelom získania binárnej masky popredia (c). Na túto masku je aplikovaný jednoduchý šumový filter, ktorý ju jemne rozmaže (d). Aplikované je jednoduché prahovanie a morfológická operácia uzatvorenie (e) a následne sú na tejto maske vyhladané kontúry nahradené ich konvexnými tvarmi (f) a (g). Kontúry sú prevedené na ich priliehavé pravouhlé ohraničenia (h).



Obr. 18. Postup denného monitoringu. Vozidlá sú po nájdení (a) sledované jednoduchým predikčným algoritmom (b), ktorý odhaduje (malá modrá bodka) ľavý dolný roh skutočnej pozície (znázornená červeným obdĺžnikom) v aktuálnej snímke na základe poznanej predošlej (zelený obdĺžnik) pozície. Po sledovaní vozidla vo väčšom počte snímok je vozidlo zarátané (c).

11 Experimentálne výsledky

Implementované riešenia boli testované na rôznych videách z cestnej premávky. Videá sa líšia umiestnením a priblížením kamery spolu s rozdielnou dennou dobou. Frekvencia nasnímaného videa je 30 snímok za sekundu. Jeho rozlíšenie je 320x240 obrazových bodov. Kamera bola umiestnená vysoko nad premávkou. Rýchlosť vozidiel na danom úseku je obmedzená na 90 km/h.

Pri testovaní som kládol dôraz hlavne na úspešnosť funkcionality rátania vozidiel, ktorá zodpovedá celkovej úspešnosti všetkých častí systému. Dôležitou súčasťou testovania bola aj schopnosť behu systému v reálnom čase.

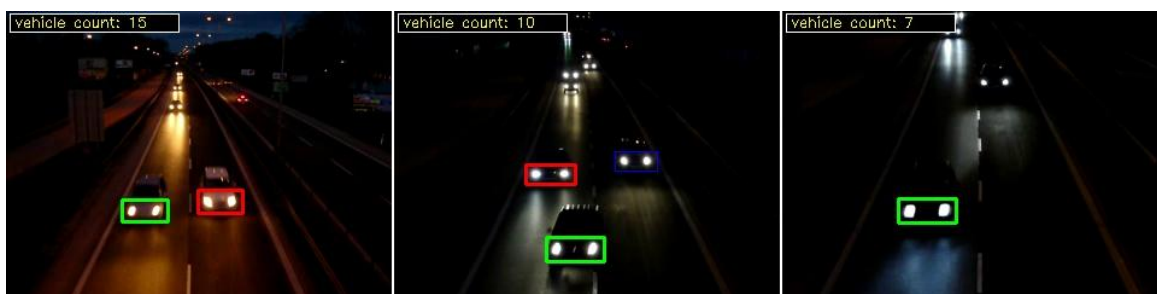
Jednotlivé programy popísaných troch riešení monitoringu dopravy boli testované na notebooku s dvojjadrovým procesorom s frekvenciou 2,26 GHz. Dosiachnuté výsledky sú popísané v nasledovných častiach.

11.1 Testovanie monitoringu cestnej premávky v nočných hodinách

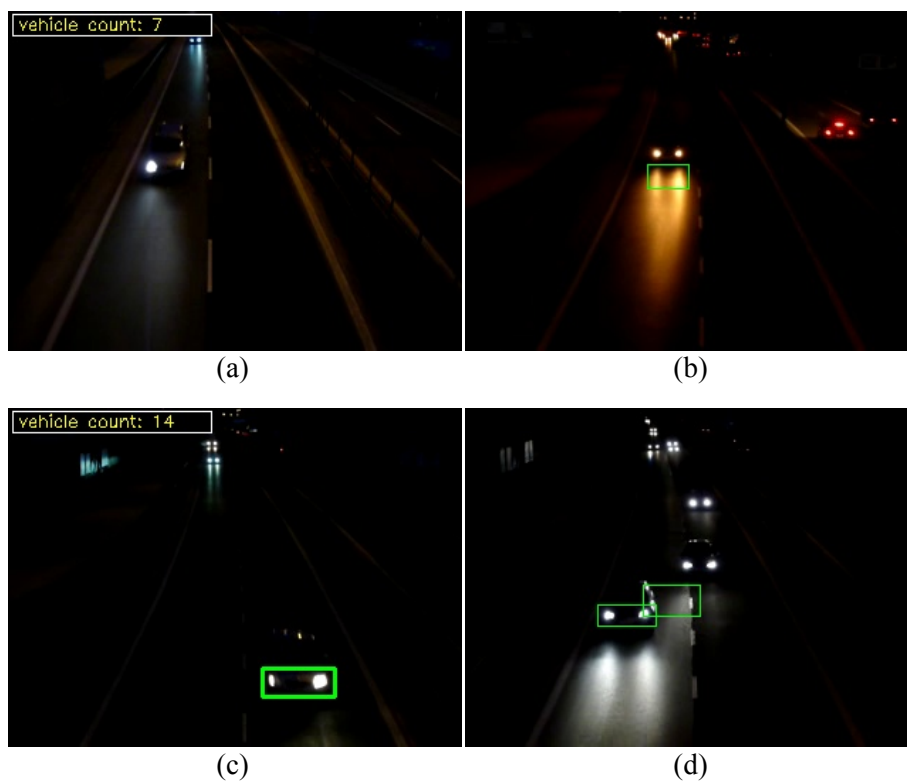
Aplikácia monitoringu nočnej premávky bola otestovaná na 6 videách s celkovou dĺžkou 7 minút 22 sekúnd. Spracovanie jednej snímky trvalo v priemere 9,05ms. Dosiachnuté výsledky sú znázornené v tabuľke Tab. 1. Funkčnosť a zaujímavé situácie sú znázornené na Obr. 19 a Obr. 20.

Tab. 1. Úspešnosť funkcionality rátania vozidiel v nočných hodinách

Skutočný počet vozidiel	Počet správne zarátaných vozidiel	Počet nezarátaných vozidiel	Počet nesprávne zarátaných vozidiel
124	123	1	0
	99,19%	0,81%	0%



Obr. 19. Znázornenie funkčnosti systému nočného monitoringu na snímkach z troch rôznych videí



Obr. 20. Zaujímavé situácie nočného monitoringu. Na obrázku (a) je jediné nezarátané vozidlo z dôvodu neskorej detekcie svetlometov, pretože malo nefunkčný jeden stretávací svetlomet. Na obrázku (b) je znázornená nesprávna detekcia dvojice svetlometov, kedy boli nájdené ich odrazy od vozovky. Keďže táto chybná detekcia bola len v 1-3 snímkach, automobil bol zarátaný správne. Na obrázku (c) je správne zarátané vozidlo napriek nefunkčnému jednému stretávaciemu svetlu. Na obrázku (d) je znázornená nesprávna detekcia páru svetlometov – odraz svetla od karosérie a odraz svetla od čiary na ceste. Objavila sa však len v 1-2 snímkach, takže boli automobily zarátané správne.

11.2 Testovanie monitoringu cestnej premávky počas dňa

Oba implementované systémy denného monitoringu boli podrobené testom na 8 videách s celkovou dĺžkou 16 minút a 6 sekúnd. 4 videá (s celkovou dĺžkou 7 minút a 9 sekúnd) sú nasnímané v zamračenom počasí, a teda neobsahujú pohybujúce sa tieň automobilov. Ďalšie 4 videá (s celkovou dĺžkou 8 minút a 57 sekúnd) sú nasnímané počas slnečného dňa, kedy vozidlá vrhajú veľké, pomerne výrazné tieň.

11.2.1 Implementácia systému pomocou rozdielu sekvencie snímok

Spracovanie jednej snímky trvalo v priemere 28,84ms. Spracovanie snímok, v ktorých boli nájdené a sledované vozidlá, trvalo v priemere 29,65ms. Dosiiahnuté výsledky sú znázornené v tabuľke Tab. 2. Funkčnosť a zaujímavé situácie sú znázornené na Obr. 21 až Obr. 26.

Tab. 2. Úspešnosť funkcionality rátania vozidiel počas dňa – rozdiel sekvencie snímok

Videá	Skutočný počet vozidiel	Počet správne zarátaných vozidiel	Počet nezarátaných vozidiel	Počet nesprávne zarátaných vozidiel
Zamračené počasie	192	184	4	4
		95,84%	2,08%	2,08%
Slnéčné počasie	183	180	1	2
		98,36%	0,55%	1,09%
Všetky	375	364	5	6
		97,07%	1,33%	1,6%




Obr. 21. Znáozornenie funkčnosti systému denného monitoringu založeného na rozdieli sekvencií snímok na troch rôznych videách



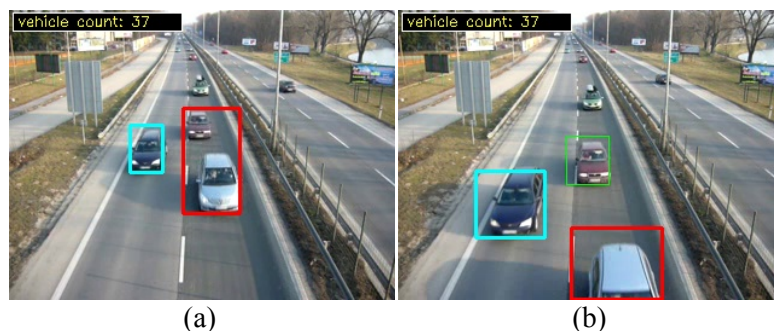
Obr. 22. Zaujímavá situácia. Po prechode správne nájdeného vozidla (a) bol nesprávne zaznamenaný pohyb jeho konca (b). Vozidlo však bolo zarátané korektne



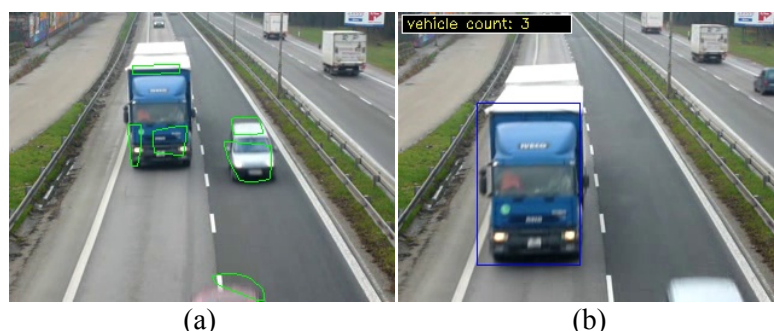
Obr. 23. Zaujímavé situácie. Z dôvodu chybnjej segmentácie bolo vozidlo na obrázku (a) určené ako dva automobily. Zarátané bolo správne. Vozidlo na obrázku (b) však z rovnakého dôvodu bolo chybnje zarátané dvakrát.



Obr. 24. Zaujímavá situácia. Dvakrát zarátaný autobus (a) kvôli chybnjej segmentácie (b).



Obr. 25. Zaujímavá situácia. Neskorá detekcia vozidla v zelenom obdĺžniku (b) viedla k jeho nezarátaniu. Neskoro nájdené bolo z dôvodu predošlého nesprávneho určenia dvojice vozidiel ako jeden automobil (a).



Obr. 26. Zaujímavá situácia. Z dôvodu chybnjej segmentácie, kedy boli namiesto jednej veľkej kontúry nájdených veľa malých (a), bolo nákladné vozidlo neskoro zaznamenané (b) a nezarátané.


11.2.2 Implementácia systému pomocou odčítavania pozadia od snímky

K správne mu behu tohto systému je nevyhnutné počiatkové naučenie sa modelu pozadia. Preto na začiatku každého testovacieho videa bolo vyčlenených 33 sekúnd na jeho získanie. Z tohto dôvodu celková dĺžka 8 videí, kedy sa testovala funkcionlita rátania, klesla na 11 minút a 42 sekúnd (4 videá nasnímane v zamračenom počasí potom mali 4 minúty a 57 sekúnd a 4 videá zo slnečného počasía mali celkovú dĺžku 6 minút a 45 sekúnd). Spracovanie jednej snímky trvalo v priemere 22,06ms. Spracovanie snímok, v ktorých boli nájdené a sledované vozidlá, trvalo v priemere 22,51ms. Dosiahnuté výsledky sú znázornené v tabuľke Tab. 3. Funkčnosť a zaujímavé situácie sú znázornené na Obr. 27 až Obr. 31.

Všetky tri implementované monitorovacie systémy splnili požiadavku behu v reálnom čase a úspešnosť rátania vozidiel bola vysoká.

Tab. 3. Úspešnosť funkcionality rátania vozidiel počas dňa – odčítavanie pozadia

Videa	Skutočný počet vozidiel	Počet správne zarátaných vozidiel	Počet nezarátaných vozidiel	Počet nesprávne zarátaných vozidiel
Zamračené počasie	140	136	1	3
		97,14%	0,72%	2,14%
Slnečné počasie	138	137	1	0
		99,28%	0,72%	0%
Všetky	278	273	2	3
		98,2%	0,72%	1,08%



Obr. 27. Znáročenie funkčnosti systému založeného na odčítavaní pozadia na troch rôznych videách počas dňa



Obr. 28. Zaujímavá situácia. Nie príliš nezvyklá situácia rozdelenia kontúry vozidla v nižšej časti snímky (b) z dôvodu jeho rozmazania kvôli pomalej uzávierke kamery. Vo väčšej diaľke je vozidlo ostrejšie a kontúra určená správne (a).



Obr. 29. Zaujímavá situácia. Nezarátané modré vozidlo z dôvodu straty sledovania jeho pohybu, a teda získania nedostatočného počtu snímkov, v ktorých muselo byť sledované, aby bolo zarátané.



Obr. 30. Zaujímavá situácia. Dvakrát zarátaný nákladný automobil. Z dôvodu straty sledovania jeho pohybu bol dvakrát nájdený, dostatočne dlho sledovaný, a teda aj zarátaný.



Obr. 31. Zaujímavá situácia. Nesprávne zaznamenaný pohyb tieňa (a) z dôvodu vzniknutého väčšieho šumu v oblasti pohybujúceho sa tieňa na členitom povrchu (b). Tieň však nebol zarátaný.

12 Záver

V prvej časti tejto práce bolo popísaných mnoho prístupov a metód, ktoré využívajú moderné monitorovacie systémy cestnej premávky založené na spracovaní obrazu. Snahou bolo vytvorenie zrozumiteľného prehľadu pre čitateľa. Poukázané bolo aj na základnú problematiku sledovania dopravy spoločne s možnými vylepšeniami a rozšíreniami daných systémov.

V druhej časti boli popísané a následne aj otestované tri možné implementácie systémov monitorujúcich cestnú premávku za účelom rátania počtu prejdencých vozidiel. Prvým z nich bol systém fungujúci v nočných hodinách za zlých svetelných podmienok, ktorý segmentuje predné svetlomety automobilov prahovaním. Kvôli určeniu pozície vozidla boli svetlomety následne párované použitím Gaussových funkcií. Ďalej boli po ich sledovaní jednoduchým predikčným algoritmom jednotlivé vozidlá zarátané.

Druhý systém monitorujúci dennú premávku segmentuje vozidlá pomocou rozdielu sekvencie dvoch snímok. Na odstránenie pohybujúcich sa tieňov boli snímky skonvertované do HSV farebnej reprezentácie. Vyčlenené vozidlá boli následne sledované robustným algoritmom vychádzajúceho zo sledovania jednoznačných črt jednotlivých automobilov.

Tretí predstavený implementovaný systém slúžiaci na experimentovanie v oblasti odstraňovania tieňa ešte pred etapou segmentácie pohybujúcich sa objektov vychádza z detekcie hrán v snímkach. Hrany tieňov vrhnutých vozidlami nie sú až tak výrazné, ako hrany samotných automobilov. Detekcia pohybu bola zabezpečená porovnávaním aktuálnej snímky s pozadím. Objekty boli následne sledované jednoduchým predikčným algoritmom.

13 Budúca práca

Jednotlivé systémy pracujúce osobitne počas dňa a noci by bolo vhodné spojiť do jedného systému. Medzi denným a nočným monitoringom by sa prepínalo na základe celkovej svetlosti danej snímky. Funkcionalita systému by mohla byť obohatená aj o určovanie rýchlosti vozidiel. Nevyhnutnou súčasťou by bola správna kalibrácia kamery za účelom získania informácií o vzdialenostiach objektov od kamery.

14 Zoznam použitej literatúry

- [1] LIU, Meng – WU, Chengdong – ZHANG, Yunzhou. 2008. A review of Traffic Visual Tracking technology. In *International Conference on Audio, Language and Image Processing*. [online]. 2008, p. 1016-1020. Dostupné na internete:
<<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4590198&isnumber=4589950>>.
- [2] WANG, Guolin – XIAO, Deyun – GU, J. 2008. Review on vehicle detection based on video for traffic surveillance. In *IEEE International Conference on Automation and Logistics*. [online]. 2008, p. 2961-2966. Dostupné na internete:
<<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4636684&isnumber=4636108>>.
- [3] BRADSKI, Gary – KAEHLER, Adrian. 2008. *Learning OpenCV*. 1. vyd. USA : O'Reilly, 2008. ISBN 978-0-596-51613-0.
- [4] LIU, Zhi-fang – YOU, Zhisheng. 2007. A Real-time Vision-based Vehicle Tracking and Traffic Surveillance. In *Eighth ACIS International Conference on Software Engineering, Artificial Intelligence, Networking, and Parallel/Distributed Computing*. [online]. 2007, vol. 1, p. 174-179. Dostupné na internete:
<<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4287497&isnumber=4287453>>.
- [5] STAUFFER, C. – GRIMSON, W. E. L. 1999. Adaptive background mixture models for real-time tracking. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. [online]. 1999, vol. 2, p. 246-252. Dostupné na internete:
<<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=784637&isnumber=17024>>.
- [6] BAILO, G. a kol. 2005. Background estimation with Gaussian distribution for image segmentation, a fast approach. In *Proceedings of the 2005 IEEE International Workshop on Measurement Systems for Homeland Security, Contraband Detection and Personal Safety Workshop*. [online]. 2005, p. 2- 5. Dostupné na internete:
<<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1502544&isnumber=32237>>.
- [7] SUO, Peng – WANG, Yanjiang. 2008. An improved adaptive background modeling algorithm based on Gaussian Mixture Model. In *9th International Conference on Signal Processing*. [online]. 2008, p. 1436-1439. Dostupné na internete:
<<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4697402&isnumber=4697053>>.
- [8] SCOTT, J. – PUSATERI, M. A. – CORNISH, D. 2009. Kalman filter based video background estimation. In *Applied Imagery Pattern Recognition Workshop (AIPRW)*. [online]. 2009, p. 1-7. Dostupné na internete:
<<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5466306&isnumber=5466281>>.
- [9] PAN, Xinting – GUO, Yunlong – MEN, Aidong. 2010. Traffic Surveillance System for Vehicle Flow Detection. In *Second International Conference on Computer Modeling and Simulation*. [online]. 2010, vol. 1, p. 314-318. Dostupné na internete:
<<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5421377&isnumber=5421314>>.

- [10] BUCH, N. – ORWELL, J. – VELASTIN, S. A. 2010. Urban road user detection and classification using 3D wire frame models. In *Computer Vision, IET*. [online]. 2010, vol. 4, no. 2, p. 105-116. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5475471&isnumber=5475468>>.
- [11] YANG, Jun a kol. 2011. Feature fusion for vehicle detection and tracking with low-angle cameras. In *2011 IEEE Workshop on Applications of Computer Vision (WACV)*. [online]. 2011, p. 382-388. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5711529&isnumber=5711474>>.
- [12] LIPTON, Alan J. 1999. Local Application of Optic Flow to Analyse Rigid versus Non-Rigid Motion. In *ICCV99 Workshop on Frame-Rate Applications*. [online]. 1999. Dostupné na internete: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.33.2383&rep=rep1&type=pdf>>.
- [13] GONZALEZ, Rafael C. – WOODS, Richard E. 2002. *Digital Image Processing*. 2. vyd. USA : Prentice Hall, 2002. ISBN 0-201-18075-8.
- [14] FTÁČNIK, Milan. 2010. *Obrazové transformácie*. [online]. 2010. Dostupné na internete: <<http://sccg.sk/~ftacnik/IP-3.pdf>>.
- [15] LU, Wenhao – WANG, Shengjin – DING, Xiaqing. 2009. Vehicle detection and tracking in relatively crowded conditions. In *IEEE International Conference on Systems, Man and Cybernetics*. [online]. 2009, p. 4136-4141. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5346721&isnumber=5345886>>.
- [16] JAMASBI, B. – MOTAMEDI, S. A. – BEHRAD, A. 2007. Tracking vehicle targets with large aspect change. In *IEEE Workshop on Motion and Video Computing*. [online]. 2007, p. 22. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4118818&isnumber=4118789>>.
- [17] CHEN, Thou-Ho – LIN, Yu-Feng – CHEN, Tsong-Yi. 2007. Intelligent Vehicle Counting Method Based on Blob Analysis in Traffic Surveillance. In *Second International Conference on Innovative Computing, Information and Control*. [online]. 2007, p. 238. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4427883&isnumber=4427647>>.
- [18] HUANG, Lili. 2010. Real-time multi-vehicle detection and sub-feature based tracking for traffic surveillance systems. In *2nd International Asia Conference on Informatics in Control, Automation and Robotics (CAR)*. [online]. 2010, vol. 2, p. 324-328. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5456534&isnumber=5456517>>.
- [19] HUANG, Lili – Barth, M. 2010. Real-time multi-vehicle tracking based on feature detection and color probability model. In *IEEE Intelligent Vehicles Symposium (IV)*. [online]. 2010, p. 981-986. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5548060&isnumber=5547951>>.
- [20] CHOI, Jae-Young – SUNG, Kyung-Sang – YANG, Young-Kyu. 2007. Multiple Vehicles Detection and Tracking based on Scale-Invariant Feature Transform. In *IEEE Intelligent*

- Transportation Systems Conference*. [online]. 2007, p. 528-533. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4357684&isnumber=4357619>>.
- [21] LOU Jianguang a kol. 2005. 3-D model-based vehicle tracking. In *IEEE Transactions on Image Processing*. [online]. 2005, vol. 14, no. 10, p. 1561-1569. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1510690&isnumber=32345>>.
- [22] YAN, Bo a kol. 2010. Deformable 3-D model based vehicle matching with weighted Hausdorff and EDA in traffic surveillance. In *2010 International Conference on Image Analysis and Signal Processing (IASP)*. [online]. 2010, p. 22-27. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5476171&isnumber=5476039>>.
- [23] THI, Tuan Hue – LU, Sijun – ZHANG, Jian. 2008. Self-Calibration of Traffic Surveillance Camera using Motion Tracking. In *11th International IEEE Conference on Intelligent Transportation Systems*. [online]. 2008, p. 304-309. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4732673&isnumber=4732517>>.
- [24] CHENG, Hsu-Yung – LIU, Po-Yi – LAI, Yen-Ju. 2010. Vehicle tracking in daytime and nighttime traffic surveillance videos. In *2nd International Conference on Education Technology and Computer (ICETC)*. [online]. 2010, vol. 5, p. V5-122-V5-125. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5529800&isnumber=5529772>>.
- [25] WANG, Chuanxu – ZHANG, Weijuan. 2009. A Robust Algorithm for Shadow Removal of Foreground Detection in Video Surveillance. In *Asia-Pacific Conference on Information Processing*. [online]. 2009, vol. 2, p. 422-425. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5197227&isnumber=5197113>>.
- [26] BLÁZSOVITS, Gábor. 2006. *Interaktívna učebnica spracovania obrazu*. [online]. 1. vyd. Bratislava : Knižničné a edičné centrum FMFI UK, 2006. Dostupné na internete: <<http://dip.sccg.sk/>>. ISBN 80-89186-08-4.
- [27] *OpenCV 2.1 C++ Reference*. [online]. [cit. 2011-05-10]. Dostupné na internete: <<http://opencv.willowgarage.com/documentation/cpp/index.html>>.
- [28] SHI, Jianbo – TOMASI, C. 1994. Good features to track. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. [online]. 1994, p. 593-600. Dostupné na internete: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=323794&isnumber=7716>>.
- [29] LI, Liyuan a kol. 2003. Foreground object detection from videos containing complex background. In *Proceedings of the eleventh ACM international conference on Multimedia*. [online]. 2003, p. 2-10. Dostupné na internete: <<http://doi.acm.org/10.1145/957013.957017>>.
- [30] KAEWTRAKULPONG, P. – BOWDEN, R. 2001. An Improved Adaptive Background Mixture Model for Real-time Tracking with Shadow Detection. In *Proc. 2nd European Workshop on Advanced Video Based Surveillance Systems*. [online]. 2001. Dostupné na internete: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.12.3705&rep=rep1&type=pdf>>.

15 Zoznam príloh

Príloha A: CD médium – bakalárska práca v elektronickej podobe, zdrojové kódy jednotlivých riešení monitoringu dopravy, skompilované programy monitoringu, ukázkové videá funkčnosti systémov, ukázkové snímky z monitoringu dopravy.