Acta Informatica Pragensia
1(1), 2012, 22–31, DOI: 10.18267/j.aip.2
Online: aip.vse.cz

Sekce / Section:
Recenzované stati / Peer-reviewed papers

Inteligentný systém na analýzu hustoty dopravnej premávky z videozáznamu

Martin Paralič[1]

[1] Katedra telekomunikácií a Multimédií, Elektrotechnická fakulta,
Žilinská Univerzita v Žiline
Univerzitná 1, Žilina 010 26, Slovensko

paralic@fel.uniza.sk

Abstrakt: Tento článok popisuje novú metódu pre monitorovací systém dopravy, s detekciou pohyblivých objektov a stavovým strojom pre meranie hustoty premávky. Navrhnutá metóda je odolná voči svetelným podmienkam a voči otrasom spôsobených vetrom. Na potlačenie týchto nepriaznivých vplyvov sa používa metóda filtrovania pomocou Gaussových pyramíd. Systém umožňuje monitorovať viacero jazdných pruhov a rôzne križovatky v oboch jazdných smeroch.

Klíčová slova: monitorovanie premávky, stavový stroj, Gaussova pyramída

Title: The Intelligent System for the Traffic Density Analysis

Abstract: This paper presents the novel method for video-based traffic monitoring system, with a moving object detection and state machine for the traffic density measurement. Proposed method is robust to a different lightning conditions and tremors caused by the wind. The Gaussian pyramids are used for the elimination of such effects. The multiple road lines and crossroads are monitored by the intelligent state machine in a both directions.

Keywords: Traffic monitoring, State machine, Gaussian pyramid

1 ÚVOD

V inteligentných dopravných systémoch je dôležitou súčasťou monitorovanie a získavanie parametrov o premávke. Získané informácie slúžia na zlepšenie riadenia dopravy, môžu pomôcť cestujúcim dosiahnuť cieľ cesty rýchlejšie a s vynaložením menšieho množstva energie. V súčasnosti sa tieto dopravné parametre získavajú pomocou rôznych magnetických slučiek pod cestami, radarmi a pomocou videokamier. Magnetické slučky [7,8] predstavujú efektívnu metódu pre meranie hustoty premávky za predpokladu, že sú umiestnené ešte počas výstavby vozovky. V zastavaných oblastiach však umiestnenie takejto magnetickej slučky predstavuje problém, pri ktorom je potrebné na cestnej komunikácii vykonať výkopové práce, umiestnenie slučky a opätovné opravy cesty. Radarový systém umožňuje presnejšie meranie rýchlosti, ale zároveň predstavuje vysoké náklady pre každé umiestnené zariadenie. Efektívnejšou metódou je využitie monitorovacej videokamery, ktorá na jednej strane poskytuje širšie možnosti získavania informácií [1, 6] a zároveň nie je potrebný invazívny zásah do cestnej komunikácie.

Princíp činnosti kamerových systému pre monitorovanie premávky možno všeobecne rozdeliť do dvoch etáp. V prvej etape sa obrazová snímka rozdelí na objekty v popredí a pozadí. Objekty v popredí predstavujú pohybujúce sa vozidlá. Objekty v pozadí sú všetky statické i dynamické prvky, ktoré nie sú oblasťou záujmu dopravnej premávky. Z hľadiska analýzy potrebujeme tieto prvky odfiltrovať. V druhej etape sa analyzujú dopravné parametre - počet vozidiel, rýchlosť, hustota premávky a pod.

Existuje množstvo metód pomocou ktorých sa dajú spomínané etapy dosiahnuť. Základným problémom prvej etapy je odfiltrovanie pozadia. Bolo publikovaných množstvo metód určených na detekciu vozidla v obraze. Všeobecne možno zaradiť tieto metódy do troch kategórií:

- *Metódy s odčítaním pozadia* – Pracujú na princípe odhadu pozadia, priemerovaním viacerých po sebe nasledujúcich snímkou. Obvykle pozadie vypočíta ako aritmeticky priemer po sebe nasledujúcich snímkou. spriemerovanie možno realizovať ako aritmetický priemer alebo časový medián. Odčítaním aktuálneho snímku a priemerovaného snímku vznikne rozdielový obraz. Prahovaním rozdielového obrazu sa odfiltrujú tie súčasti obrazu, v ktorých nenastali relevantné zmeny [2, 6].
- *Diferenčné metódy* – Pri diferenčnej metóde vznikne rozdielový obraz odčítaním susedných snímkou. Podobne ako pri metóde odčítavania pozadia sa rozdielový obraz prahuje [1, 4].
- *Metódy na princípe detekcie hrán* – V snímke sa stanoví oblasť, v ktorej sa bude sledovať pohyb vozidiel. Počas prechodu vozidla vyznačenou oblasťou sa zvýši hustota detegovaných hrán. Nevýhodou uvedenej metódy, je detekcia hrán na vodorovnom dopranom značení, hrán na poškodenej vozovke [3,5] a pod.

Avšak s použitím kamerového systému súvisí problematika optických snímačov. Zaznamenaný obraz je ovplyvnený viacerými faktormi. Jedným z faktorov je generovanie šumu na polovodičovom optickom snímači. Okrem toho môže pozadie scény obsahovať rôznorodé dynamické prvky ako sú napríklad pohybujúci sa chodci, koruny stromov vo vetre a pod. Svetelné podmienky sú ovplyvnené pohybom slnka a oblakov, čo spôsobuje zmeny hodnôt jednotlivých obrazových bodov v čase. Tieto vplyvy pôsobia rušivo na systém formou falošnej detekcie pohybu pri metódach odčítania pozadia

a diferenčných metódach. Zmena svetelných podmienok ovplyvňuje optimálnu hranica detekčného prahu. Pri nerovnomernej iluminácii scény je potrebné použiť adaptívne nastavenie prahu a pod. Hranové detektory sú síce odolné voči vplyvom iluminácie obrazovej scény, ale zároveň sú citlivé na rôzne poškodenia cesty, vodorovné dopravné značenia na povrchu vozovky a tiene od okolitých objektov.

Prezentovaná metóda vychádza z princípov vnímania obrazu ľudským okom, ktoré nepotrebuje byť zaostrené na obraz, aby zaregistrovalo pohyb. Taktiež oko nevníma každý obrazový bod ako kamera, ale vníma ich ako komplexný celok. Tento princíp napodobňujeme filtráciou pomocou Gaussovej pyramídy v kapitole 2. Na filtrované obrazy aplikujeme diferenčnú metódu, čím sa detegujú pohybujúce sa objekty. Prahovaním sa získajú binárne obrazy, ktoré slúžia ako vstupné dáta pre stavový stroj. V kapitole 3 sa opisuje stavový stroj, ktorý pomocou kontrolných bodov sleduje prechádzanie vozidiel vo zvolenej oblasti. Princíp stavového stroja umožňuje determinovať smer prechodu vozidla. Kapitola 4 popisuje experimentálne aplikačné rozhranie. Popis experimentov a namerané výsledky sú uvedené v kapitole 5.

1 EXTRAKCIA POHYBLIVÝCH OBJEKTOV

Vstupné dáta pre detekciu pohyblivých objektov predstavujú za sebou nasledujúce farebné RGB snímky získane z video záznamu digitálnej kamery. Pri experimentoch sme mali k dispozícii digitálne videá s dvoma rozlíšeniami 720x576 a 384x288 obrazových prvkov. Obraz bol najprv prevedený na odtiene sivej, vypočítané ako intenzita jednotlivých obrazových prvkov.

$$I = (r + g + b)/3 \tag{1}$$

kde r, g, b sú červený, zelený a modrý kanál pôvodného obrazu. Na intenzitný obraz sa aplikoval dolno-priepustný filter s použitím metódy Gaussovej pyramídy $I(\sigma)$, kde σ predstavuje je počet zmien mierky [9]. Pri každej zmene mierky sa zmenšuje výška a šírka obrazu o polovicu, kde príslušný pixel sa vypočíta spriemerovaním svojej predlohy. Výsledkom filtrácie je teda pod-vzorkovaný obraz. Pre videá s rozlíšením 720x576 sa použila trojnásobná zmena mierky $\sigma = 3$, s dosiahnutím výsledného rozlíšenia 90x72 bodov. Obrázok 1 znázorňuje postupnú zmenu mierky obrazu na nižšie rozlíšenie, ktoré bude ďalej spracované. Pre videá s rozlíšením 384x288 sa použila dvojnásobná zmena mierky $\sigma = 2$, výsledné rozlíšenie bolo 96x72 bodov.

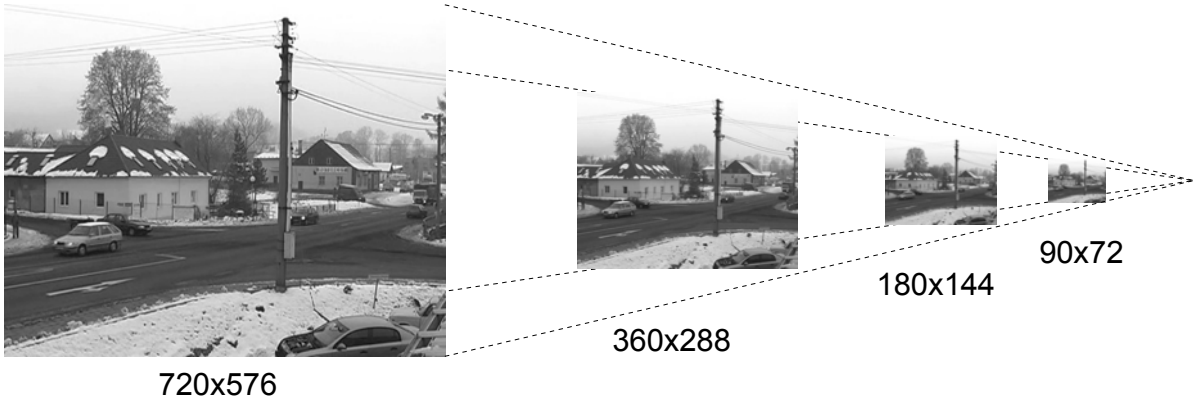

Obr. 1. Filtrácia pomocou Gaussovej pyramídy.

Na susedné obrazy v nízkom rozlíšení, ktoré vznikli filtrovaným pomocou Gaussovej pyramídy, sa aplikovala diferenčná metóda. Snímky na obrázku 2 znázorňujú jednotlivé kroky diferenčnej metódy. Obrazy 2a,b predstavujú susedné snímky, z ktorých sa vypočíta rozdielový obraz. Prahovaním rozdielového obrazu vznikne binárna maska v nízkom rozlíšení, obr. 2c. Na binárnu masku sa aplikuje dilatácia, pomocou ktorej sa doplnia chýbajúce časti obrazu, obr. 2d. Rozdielový snímok v nízkom rozlíšení bol prahovaný binárne. Binárne obrazy v nízkom rozlíšení označujú logickou jednotkou pohyblivé objekty a logickou nulou statické pozadie. Pri uvedenom spôsobe filtrácie sa drobné pohyby a lokálne zmeny v scéne javia ako statické pozadie. Na zacelenie detegovaných pohyblivých objektov sa použila dilatácia s maskou 3x3. Pomocou interpolácie sa binárna maska prevedie na pôvodné rozmery obrazu, obr. 2e. Na obr. 2f je znázornený logický súčin masky pohybujúcich sa vozidiel a intenzitného snímku.

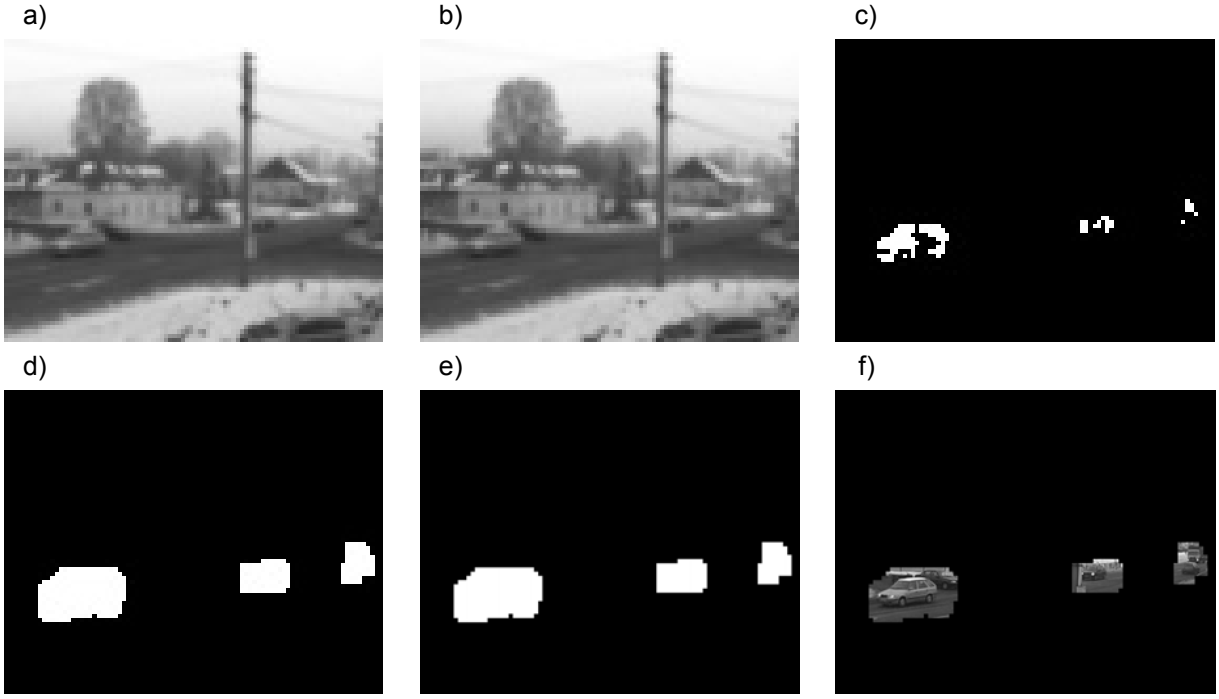

Obr. 2. Detekcia pohyblivých objektov: a) Predchádzajúci rámec, b) Aktuálny rámec, c) Rozdielový rámec po prahovaní, d) Rozdielový rámec po dilatácii, e) Maska v pôvodnom rozlíšení, f) Aplikovanie masky na pôvodný intenzitný obraz.

Postupnosť maskovacích obrazov možno využiť na sledovanie pohybu vozidiel a ich počtu, prípadne na hrubé meranie rýchlosti vozidiel. Z maskovaného obrazu možno extrahovať ďalšie parametre ako je počet náprav, typ a farba vozidla. Na sledovanie počtu prechádzajúcich vozidiel používame stavový stroj, pre ktorý je jedným zo vstupných parametrov postupnosť po sebe idúcich maskovacích obrazov 2e.

2 STAVOVÝ STROJ

Stavový stroj modeluje prostredie v ktorom objekt prechádza priestorom cez kontrolné body. Kontrolný bod $K_i(x_i, y_i)$ je definovaný svojimi súradnicami x_i, y_i, kde i je poradové číslo kontrolného bodu a nadobúda jeden z binárnych stavov $K_i \in \{0,1\}$. Kontrolný bod signalizuje binárny stav 1 pre prítomnosť pohyblivého objektu a 0 pre neprítomnosť objektu na používateľom definovaných súradniciach. Pomocou dvoch kontrolných bodov K_1 a K_2 možno signalizovať stavovému stroju prítomnosť a smer pohybujúceho sa objektu po myslenej priamke určenej oboma bodmi.

STAV $[K_1, K_2]$	POPIS STAVU
[0,0]	Počiatočný stav bez pohyblivých objektov.
[0,1]	Objekt prichádza k bodu K_2 alebo odchádza od bodu K_1.
[1,0]	Objekt prichádza k bodu K_1 alebo odchádza od bodu K_2.
[1,1]	Objekt prechádza súčasne kontrolnými bodmi K_1 a K_2.

Tabuľka 1. Kombinácie stavov signalizačných bodov.

Kombinácie dvoch binárnych signalizačných bodov generujú 4 základné stavy ako sú uvedené v tabuľke 1. Pohyblivý objekt môže teda prechádzať kontrolnými bodmi buď v priamom smere od bodu K_1 k bodu K_2, alebo v opačnom smere od bodu K_2 k bodu K_1. Z toho vyplývajú dve možné postupnosti prechodu stavovým strojom, znázornené na obrázku 3a,b.

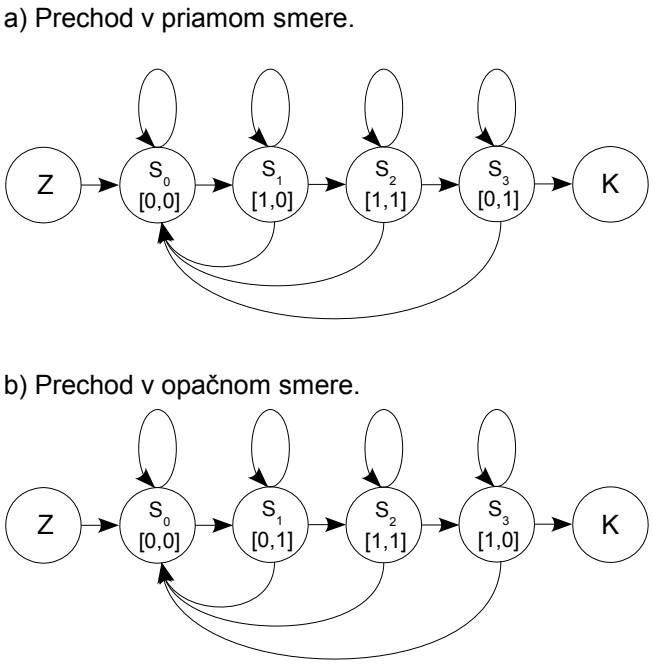

Obr. 3. Prechod stavovým strojom v priamom a opačnom smere.

Nulová signalizácia predstavuje základný stav, kedy kontrolné body neregistrujú žiadny pohyblivý objekt. Ak signalizuje iba jeden bod, po priamke sa približuje pohybujúci sa objekt z niektorého smeru. Súčasná signalizácia oboch kontrolných bodov reprezentuje stav, kedy je pohyblivý objekt v centre pozorovania. Predpokladá sa, že objekt bude pokračovať v rovnakom smere ako prišiel. V opačnom prípade by stroj vyhodnotil situáciu ako chybu signalizácie a nastavil by sa do počiatočného stavu. Pri prechode objektu môže stavový stroj zotrvať vo svojom aktuálnom stave alebo postúpiť do najbližšieho vyššieho stavu. Ak nasleduje kombinácia kontrolných bodov, ktorá nezodpovedá vyššiemu stavu, stavový stroj sa vyresetuje do počiatočného stavu. Po prechode každým stavom sa zvyšuje hodnota počítadla pre priamy, prípadne pre opačný smer, v závislosti od smeru jazdy. Vďaka uvedeným vlastnostiam dokáže stavový stroj určiť smer pohybu a zároveň čiastočne eliminovať niektoré falošné detekcie. Ako je zrejmé z princípu fungovania stavového stroja, je rozumné zvoliť vzdialenosť kontrolných bodov tak, aby mohli nastať kombinácie jednotlivých stavov. Kontrolné body by mali byť umiestnené na trajektórii pohybu. Mali by sa nachádzať v takej vzdialenosti, aby dokázali pokryť najmenší detegovaný objekt. Súčasne musí byť minimálna vzdialenosť väčšia, ako je dĺžka dráhy najrýchlejšieho objektu na scéne. V experimentoch bola táto vzdialenosť zvolená ako vzdialenosti náprav bežného osobného vozidla, nachádzajúceho sa v kontrolovanej oblasti.

3 TESTOVACIE APLIKAČNÉ ROZHRANIE

Navrhnutý algoritmus bol zrealizovaný v programovacom jazyku C++ s použitím knižnice OpenCV. Aplikačné rozhranie obsahuje funkcie na prehrávanie videa, pričom pôvodnú rýchlosť možno spomaliť alebo zrýchliť, pre účel manuálnej anotácie. Počas experimentov bolo možné definovať len 2 kontrolné body pre stavový stroj. Principiálne však možno doplniť ďalšie stavové stroje s viacerými kontrolnými bodmi. Body možno umiestniť na obraz kliknutím myši, alebo priamo zadaním číselných súradníc. Body signalizujú prechod vozidla. Znakmi '+' / 'x' sa zobrazuje signalizácia stavov prítomnosť / neprítomnosť pohyblivého objektu na súradniciach kontrolných bodov K_1 a K_2. Obrázok 4 znázorňuje umiestnenie kontrolných bodov v jednotlivých video záznamoch.

a) Chlebovice b) Lesopark c) Priemyselná d) Hlinská

Obr. 4. Rozmiestnenie kontrolných bodov na križovatkách.

Aplikácia umožňuje z videa vystrihnúť fotografiu vozidla prechádzajúceho súčasne oboma kontrolnými bodmi, pre ďalšie možné spracovanie obrazu. Po prejdení vozidla sa zaznamenáva časový údaj / číslo rámca a počet prechodov v priamom, príp. opačnom smere. Číslo pri kontrolnom bode predstavuje počet vozidiel, ktoré daný bod opustilo.

4 EXPERIMENT

Testovanie prebehlo na počítačovom jadre Intel Atom N280 (1.66GHz). Testovanie prebehlo na 4 videosekvenciách (H264-MPEG4-AVC) rôznych križovatiek, kde každý záznam trval približne 1 hodinu. V každom zázname boli umiestnené 2 kontrolné body pre výjazd z križovatky, ktorý bol najbližšie ku kamere. Meranie prebehlo v oboch jazdných smeroch. Za priamy smer (P) sa považoval ten jazdný pruh, ktorý bol umiestnený bližšie ku kamere. Teda kamera mala priamy výhľad na vozidlo. Vzhľadom na spôsob umiestnenia kamery mohli byť vozidlá prichádzajúce opačným smerom (O) čiastočne, alebo úplne prekryté vozidlami, ktoré prechádzali v priamom smere.

KRIŽOVATKA [ROZLÍŠENIE]	DĺŽKA VIDEA	POČET PREJAZDOV		POČET DETEKCIÍ		ÚSPEŠNOSŤ	
Chlebovice [720x576]	1h02m03s	P:	773	P:	728	P:	94,2%
		O:	720	O:	627	O:	87,1%
Lesopark [384x288]	1h05m39s	P:	286	P:	273	P:	95,5%
		O:	408	O:	361	O:	88,4%
Hlinská [384x288]	1h00m01s	P:	577	P:	531	P:	92,0%
		O:	683	O:	584	O:	85,5%
Priemyselná [384x288]	1h06m44s	P:	232	P:	216	P:	93,1%
		O:	398	O:	343	O:	86,2%
Priemer						P:	93,7%
						O:	86,7%

Tabuľka 2. Experimentálne výsledky, P – jazdný pruh s priamym výhľadom na vozidlo, O – opačný/vzdialenejší jazdný pruh.

VIDEO ČÍSLO	POČET PREJAZDOV	POČET DETEKCIÍ	ÚSPEŠNOSŤ
1.	127	125	0,98%
2	52	52	100%
3	50	49	0,98%
4	47	45	0,95%
5	63	62	0,98%
Priemer			0,98%

Tabuľka 3. Výsledky od Laparmonpinyo [5] pre podobný experiment.

Experimentálne výsledky v tabuľke 2, vykazujú vysokú úspešnosť navrhnutého algoritmu detekcie vozidiel v priamom smere (93,7%). Pri podobnom experimente dosiahol Laparmonpinyo [5] priemernú úspešnosť až 98%, tab. 3. Avšak v jeho experimente sa pohybovali vozidlá iba v jednom smere po diaľnici. Počet bol zo štatistického hľadiska niekoľkonásobne nižší a umiestnenie kamery bolo nad vozovkou. V našom experimente bola umiestnená kamera na statíve z bočného pohľadu na križovatku. Vhodnejším umiestnením kamery nad vozovku by sme mohli úspešnosť ešte zvýšiť. Kontrolné body by sa umiestnili osobitne pre každý jazdný pruh. Prevažnú väčšinu chybových detekcií totiž spôsobili vozidlá, ktoré súčasne prichádzali k protiľahlému kontrolnému bodu, čím vygenerovali v stavovom stroji chybový stav. Výsledky v opačnom jazdnom pruhu mali nižšiu úspešnosť (priemer 86,7%). Dôvodom pre vyššiu chybovosť boli vozidlá, ktoré zakrývali výhľad na vzdialenejší jazdný pruh. V prípade nákladných vozidiel dochádzalo až ku úplnému prekrývaniu osobných vozidiel. Menej častým dôvodom bol súčasný príchod vozidiel ku kontrolným bodom

z opačných smerov. V reálnej aplikácii sú dve možnosti, ako dosiahnuť vysokú úspešnosť pre obidva jazdné smery. Prvá možnosť je umiestnenie kamery nad vozovkou, kolmo k smeru jazdy. Použili by sa dva stavové stroje, pričom kontrolné body by sa umiestnili osobitne pre každý jazdný pruh. Druhá možnosť pozostáva s použitia dvoch kamier s bočným výhľadom pre obidva smery. Kontrolné body by sa umiestnili na okraj vozovky, aby neboli ovplyvňované vozidlami v opačnom smere.

5 ZÁVER

Navrhli sme výpočtovo nenáročný detekčný systém pre pohybujúce sa vozidlá. Systém umožňuje zhotoviť fotografie prechádzajúcich vozidiel s robustným filtrovaním scény pozadia. V budúcnosti by sme chceli s takto zhotovených snímkou získavať ďalší dopravný parameter – počet náprav vozidla. Taktiež by sme chceli porovnať úspešnosť detekcie s hranovým detektorom [5], ale pri dodržaní rovnocenných podmienok pre obidve metódy.

POĎAKOVANIE:

Tato publikácia vznikla vďaka podpore v rámci operačného programu Výskum a vývoj pre projekt: Centrum excelentnosti pre systémy a služby inteligentnej dopravy II., ITMS 26220120050 spolufinancovaný zo zdrojov Európskeho fondu regionálneho rozvoja.

ZOZNAM POUŽITEJ LITERATÚRY

[1] CUCCHIARA R., PICCARDI M., MELLO P. *Image Analysis and Rule-Based Reasoning for a traffic Monitoring System*, IEEE Transaction on Intelligent Transportation systems, vol. 1., June 2000, pp. 119-130.

[2] FATHY M., SIYAL M.Y. *Image Processing Techniques For Real-Time Qualitative Road Traffic Data Analysis.* Real-Time Imaging, vol. 5, August 1999, pp. 271-278.

[3] HA D.M., LEE J.M., KIM Y.-D. *Neural-edge-based vehicle detection and traffic parameter extraction.* Image and Vision computing, vol. 22, September 2004, pp. 899-907.

[4] KIRATIRATANAPRUK K., DUBEY P., SIDDHICHAI S. *A gradient based foreground detection technique for object tracking in a traffic monitoring system.* IEEE Conference on Advanced Video and Signal Based Surveillance, September 2005, pp. 377-381.

[5] LAPARMONPINYO P., CHITSOBHUK O. *A video-based traffic monitoring system based on gradient-edge and detection window techniques.* The 2nd International Conference on Computer and Automation Engineering (ICCAE), 2010.

[6] ZHOU J., GAO D., ZHANG D. *Moving Vehicle Detection for Automatic Traffic Monitoring*, IEEE Transaction on Vehicular Technology, vol. 56, January 2007, pp. 51-59.

[7] COIFMAN B. *Vehicle re-identification and travel time measurement in real-time on freeways using existing loop detector infrastructure*. Transportation Research Record 1643, Transportation Research Board, 1998, pp. 181-191.

[8] STERN S. *Traffic Flow Data Acquisition Using Magnetic-Loop Vehicle Detectors,* Highway Research Record Number 154, Highway Research Board, National Research Council, 1965, pp. 38-52.

[9] OLKKONEN H., PESOLA P. *Gaussian Pyramid Wavelet Transform for Multi-resolution Analysis of Images*, Graphical Models and Image Processing, Vol. 58, Issue 4, July 1996, pp. 394-398.