

UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY

ROZPOZNÁVANIE POHYBUJÚCICH SA OBJEKTOV
PRE MONITORING CESTNEJ PREMÁVKY

Súťažná práca ŠVOČ 2012
Sekcia: Aplikovaná informatika

Rozpoznávanie pohybujúcich sa objektov pre monitoring cestnej premávky

Samuel Titka^{1*}

Školiteľ: Zuzana Černeková²

¹ FMFI UK, Mlynská Dolina, 842 48 Bratislava

² Katedra aplikovanej informatiky, FMFI UK, Mlynská Dolina, 842 48 Bratislava

Abstrakt

Tento článok, ktorý vychádza z bakalárskej práce s rovnakým názvom, obsahuje prehľad problematiky vizuálnych monitorovacích systémov cestnej premávky. Oboznamuje čitateľa o súčasných prístupoch a metódach detekcie a sledovania pohybujúcich sa objektov vo videu. V článku sú popísané tri vlastné implementácie systémov monitorujúcich dopravu počas dňa i noci, ktoré počítajú idúce vozidlá. Jeden zo systémov slúži na prezentáciu a testovanie vlastnej metódy odstraňovania tieňov vozidiel pomocou detekcie hrán ešte pred etapou segmentácie. 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

1 Úvod

V súčasnosti je vizuálne sledovanie automobilov jednou z najrýchlejších sa rozvíjajúcich oblastí počítačového videnia. Využíva sa tu 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 indukčné cievky zabudované v ceste alebo radarové systémy, poskytuje vizuálny monitoring neporovnateľne väčšie množstvo informácií o situácii na ceste.

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.

V nasledujúcej sekcii je popísaný prehľad základných krokov pri sledovaní cestnej premávky [1], [2].

2 Prehľad základných krokov sledovania cestnej premávky

2.1 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 videosignálu.

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. Rozlíšenie snímok býva v rozmedzí od QVGA (320x240) cez VGA (640x480), PAL (768x576) až po SVGA (800x600).

2.2 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 stacionárneho 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)

* stitka@gmail.com
www.amigo.sk/www/bakalarka

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

2.4 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.

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

2.5 Rôzne vylepšenia monitorovacích systémov

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

1. Stabilizácia obrazu – výhodné použiť v prípade prudkých poveternostných podmienok
2. Detekcia čiar na ceste – možnosť rátania automobilov v jednotlivých jazdných pruhoch
3. Použitie viacerých kamier – lepšie pokrytie cestnej premávky, jednoduchšie sledovanie vozidiel pri prekrytiach
4. Sledovanie cestnej premávky v zlých svetelných podmienkach – zabezpečenie funkčnosti aj v nočných hodinách
5. Odstraňovanie tieňov – podstatné zlepšenie výsledkov kroku segmentácie vozidiel

3 Implementácia vlastného monitorovacieho systému cestnej premávky

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.

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

3.2 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.

4 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 [3], 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.

4.1 Segmentácia svetlometov

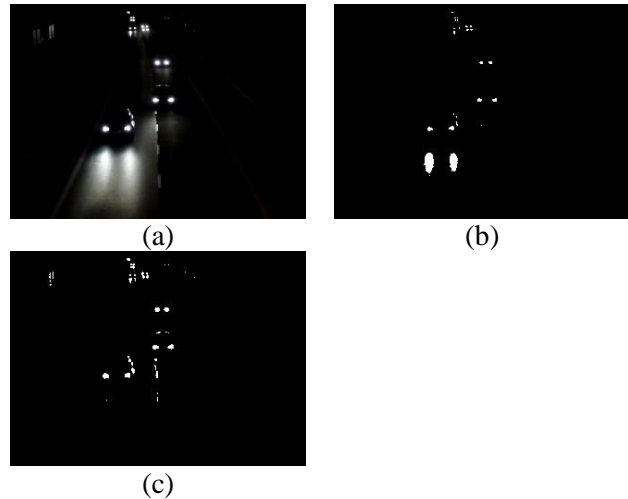
Na detekciu predných svetlometov vozidiel počas noci, teda oblastí s vysokou hodnotou svetlosti v snímke, som namiesto jednoduchého globálneho prahovania použil adaptívne prahovanie. Vychádzal som z experimentálneho pozorovania, keď adaptívne prahovanie dokázalo lepšie odstrániť nežiadany odraz svetla od vozovky. Porovnanie týchto dvoch metód je znázornené na Obr. 1. 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.

Na základe zvolenej prahovej hodnoty sa rozdeľujú 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),

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

kde $T(x,y)$ je vypočítaná prahová hodnota pre každý obrazový bod zvlášť. K tejto prahovej hodnote sa ešte pripočíta konštanta c s hodnotou určenou (pomocou experimentálneho zistenia) na 40. Prahová hodnota $T(x,y)$ je váženým priemerom hodnôt jasu okolia (oblasť s veľkosťou 15x15) daného obrazového bodu.



Obr. 1. 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 svetlometov od vozovky.

Jednotlivé hodnoty jasu 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) [5].

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

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. Použitý je štruktúrny element štvorcového tvaru s veľkosťou 3x3.

V takto získanej binárnej maske sú následne vyhľadané kontúry pomocou OpenCV funkcie `cv::findContours`. Získavané sú iba vonkajšie hlavné kontúry. Kvôli ušetreniu pamäti a aj následne výpočtovej zložitosti sú nájdené obrysy 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 jasu. 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 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 (určená parametrami h_1 a h_2), 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. 2.

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


4.2 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, nežiadane 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.

Pri párovaní svetlometov som vychádzal z článku [3]. Prispôbený 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.



Obr. 2. Segmentácia svetlometov. Šedotónová verzia pôvodnej snímky (a) bola najskôr adaptívne prahovaná (b), následne bola aplikovaná morfológická operácia uzatvorenie (c). Na takto vzniknutej maske boli vyhľadované kontúry (d), vynechané však boli tie, ktoré mali príliš malý obvod. V poslednom kroku sa kontúry previedli na ich priliehavé pravouhlé ohraničenia (e).

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

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

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 $\mu_{\text{vzdialenosť}}$.

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)

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

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 $P_{výber}(i, j)$ 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. 3.

4.3 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.



Obr. 3. Párovanie svetlometov. Z množstva nájdených kandidátov na svetlomet v snímke (a) boli algoritmom vybrané správne dvojice predných svetlometov vozidiel (b).

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. 4.



(a)

Obr. 4. (a) 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.

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.

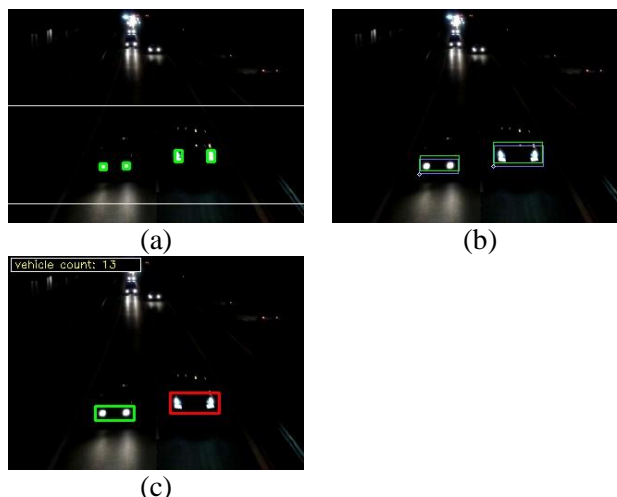
4.4 Funkcionalita počítania vozidiel

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 približenia 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. 5.



Obr. 5. Postup nočného monitoringu. V pôvodnej snímke sú najskôr vyhladaní 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 snímkach zarátané (c).

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

5.1 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 skontvertované 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.

Získané snímky absolútnych rozdielov sú následne prahované za účelom získania binárnych masiek pohybujúcich sa objektov pomocou vzťahov (10) a (11),

$$maska_{sýtost}(x,y) = \begin{cases} 1, & rozdiel_{sýtost}(x,y) > T_{sýtost} \\ 0, & rozdiel_{sýtost}(x,y) \leq T_{sýtost} \end{cases} \quad (10)$$

$$maska_{svetlost}(x,y) = \begin{cases} 1, & rozdiel_{svetlost}(x,y) > T_{svetlost} \\ 0, & rozdiel_{svetlost}(x,y) \leq T_{svetlost} \end{cases} \quad (11)$$


kde $T_{sýtost}$ a $T_{svetlost}$ sú prahy (s experimentálne určenými hodnotami 80 a 50, v poradí). Následne je vytvorená spoločná binárna maska vozidiel zjednotením masiek zložky sýtosti a svetlosti. Toto zjednotenie spolu s použitými prísnejšími hodnotami prahov $T_{sýtost}$ a $T_{svetlost}$ 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. 6.

Problémom tohto prístupu segmentácie je závislosť od stanoveného časového intervalu medzi odčítavanými snímkami (parameter videa počet snímok 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 uzatvorenia. Počet iterácií dilatácie a erózie tejto operácie bol stanovený na 3. Na odstránenie šumu je potom aplikovaná morfológická operácia otvorenia. Obe operácie používajú štvorcový štruktúrny element

s veľkosťou 3x3. Masky popredia po aplikovaní týchto operácií sú znázornené na Obr. 7.



Obr. 6. Segmentácia vozidiel pomocou absolútného rozdielu dvoch za sebou idúcich snímok s odstránením tieňov. Medzi zložkami svetlosť (Value) aktuálnej (a) a predošlej snímky je vypočítaný absolútny rozdiel (c). Rovnako aj medzi zložkami sýtost' (Saturation) je vypočítaný absolútny rozdiel (d). V ďalšom kroku sú tieto dve získané snímky prahované rôznymi prahmi. Nakoniec sa vzniknuté binárne masky zjednotia do jednej (b).



Obr. 7. Morfológické operácie na binárnej maske popredia (znázornenej na Obr. 6. (b)). Obrázok (a) vznikol aplikovaním morfológických operácií uzatvorenia a otvorenia. 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 vyhladané 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. 8.



Obr. 8. Nahradenie nájdených kontúr v maske popredia ich konvexnými tvarmi. Obrázok (b) je konečná podoba binárnej masky popredia pôvodnej snímky (a).

5.2 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 príznakov nachádzajúcich sa v týchto oblastiach. Vo všeobecnosti existuje mnoho typov takýchto príznakov.

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

Najčastejšie používanými príznakmi 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 [4].


Na nájdenie jednoznačných príznakov v aktuálnej snímke bola použitá OpenCV funkcia `cv::goodFeaturesToTrack`, ktorá hľadá oblasti silných rohov.

Silné rohy sú vyhľadávané v oblasti každého nájdeného vozidla či iného pohybujúceho sa objektu v šedotónovej verzii aktuálnej snímky. Výsledkom je detekcia množiny jednoznačných príznakov pre každé vozidlo zvlášť. Nájdené silné rohy na vozidlách sú znázornené na Obr. 9.



Obr. 9. (a) Príklad nájdených silných rohov na vozidlách.

Rovnako dôležitým krokom, ako nájsť unikátne príznaky, 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. Sledovanie príznakov je znázornené na Obr. 10.



Obr. 10. (a) Sledovanie pohybu vozidiel. 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 príznaky a k nim sú vyhľadané 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.

5.3 Funkcionalita počítania vozidiel

Počítanie vozidiel vychádza z algoritmu popísaného v nočnom monitoringu dopravy. Automobily sú zarátané až po ich sledovaní vo väčšom počte snímkov (napríklad 20 snímkov). Postup denného monitoringu je znázornený na Obr. 11.



(a) (b)

Obr. 11. Postup denného monitoringu. V aktuálnej snímke sú najskôr nájdené pohybujúce sa vozidlá (a), ktoré sú po sledovaní vo väčšom počte snímok zarátané (b).

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

Implementácia tohto monitorovacieho systému je založená na princípe segmentácie porovnaním statického pozadia s aktuálnou snímku.

6.1 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 FGDStatModel, ktorý 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. 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 snímku. 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 snímku, čo zabezpečuje prispôbovivosť 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 – získané sú tak 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. 12.



(a) (b)

Obr. 12. 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 aplikovaná morfológická operácia uzatvorenie. Následne sú vyhladané 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. 13.

6.2 Sledovanie pohybu vozidiel


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

6.3 Funkcionalita počítania vozidiel

Princíp rátania vozidiel je rovnaký ako v oboch predošlých implementáciách monitorovacieho systému. Postup denného monitoringu je znázornený na Obr. 14.



Obr. 13. 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 rozmazá (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. 14. Postup denného monitoringu. Vozidlá sú po nájdení sledované jednoduchým predikčným algoritmom (a), 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 snímkov je vozidlo zarátané (b).

7 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 snímkov 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. Dosiagnuté výsledky sú popísané v nasledovných častiach.

7.1 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. Dosiagnuté výsledky sú znázornené v tabuľke Tab. 1.

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%

7.2 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 tiene automobilov. Ďalšie 4 videá (s celkovou dĺžkou 8 minút a 57 sekúnd) sú nasnímané počas slnečného dňa, kedy vozidlá vrhajú veľké, pomerne výrazné tiene.

7.2.1 Testovanie monitoringu cestnej premávky počas dňa – systém implementovaný rozdielom sekvencie snímkov

Spracovanie jednej snímky trvalo v priemere 28,84ms. Spracovanie snímkov, v ktorých boli nájdené a sledované vozidlá, trvalo v priemere

29,65ms. Dosiagnuté výsledky sú znázornené v tabuľke Tab. 2.

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

Videa	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%
Slnečné počasie	183	180	1	2
		98,36%	0,55%	1,09%
Všetky	375	364	5	6
		97,07%	1,33%	1,6%

7.2.2 Testovanie monitoringu cestnej premávky počas dňa – systém implementovaný odčítaním 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 funkcionality rátania, klesla na 11 minút a 42 sekúnd (4 videá nasnímané v zamračenom počasí potom mali 4 minúty a 57 sekúnd a 4 videá zo slnečného počasia mali celkovú dĺžku 6 minút a 45 sekúnd). Spracovanie jednej snímky trvalo v priemere 22,06ms. Spracovanie snímkov, v ktorých boli nájdené a sledované vozidlá, trvalo v priemere 22,51ms. Dosiagnuté výsledky sú znázornené v tabuľke Tab. 3.

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%

8 Záver

V tomto článku 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 porovnaním aktuálnej snímky s pozadím. Objekty boli následne sledované jednoduchým predikčným algoritmom.

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

Pod'akovanie

Ďakujem školiteľke RNDr. Zuzane Černekovej, PhD. za cenné rady a pripomienky.

Referencie

- [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] 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>>.

- [4] BRADSKI, Gary – KAEHLER, Adrian. 2008. *Learning OpenCV*. 1. vyd. USA : O'Reilly, 2008. ISBN 978-0-596-51613-0.
- [5] *OpenCV 2.1 C++ Reference*. [online]. [cit. 2011-05-10]. Dostupné na internete: <<http://opencv.willowgarage.com/documentation/cpp/index.html>>.