

DETEKCIA POHYBU ĽUDÍ VO VEREJNÝCH PRIESTRANSTVÁCH PEDESTRIAN DETECTION IN PUBLIC SPACES

Monika JANČOVIČOVÁ – Roberta ŠTĚPÁNKOVÁ
Slovenská poľnohospodárska univerzita v Nitre



For the creation of sustainable public spaces is necessary to know their everyday users. In this paper we present basic approaches to detect objects applied for use in garden and landscape architecture. The first approach is direct observation of spaces where the observer monitors the selected space and record data about a number of cars, people, activities, directions of movement, gender, age range etc. The second approach is the evaluation of data from cameras that can take the place in real time or it can be done from the records. We describe basic concepts and processes, compare the advantages and disadvantages of both approaches. For selected public space of rural settlements, we applied direct day-long observation and evaluated the results.

Key words: public spaces, motion detection

Človek predstavuje podstatnú zložku tvorby verejných priestranstiev. Tým, že je ich primárnym užívateľom, majú byť tvorené s ohľadom na jeho mierku, aktivity v nich, jeho pohyb a nároky. Verejné priestranstvá vytvorené v tomto duchu majú veľký potenciál udržateľnosti.

Tvorba verejných priestranstiev v sebe zahŕňa analýzy súčasného stavu z rôznych pohľadov - výšky budov, vzdialenosti, rozmery, stav zelene a technických prvkov, prevádzka. Skúmaním aktivít človeka, jeho výskytu, pohybu a trás doplníme informácie o živote vo verejných priestranstvách.

Pre detekciu pohybu ľudí možno využiť metódu priameho pozorovania podľa Tilley, Šilhánkovej, Navrátilovej (1996), kedy pozorovateľ v priebehu dňa vo vopred určených časových intervaloch pozoruje priestranstvo a do pripravených formulárov zapisuje údaje o počte prechádzajúcich osôb, ich pohlaví, vekom rozpätí o aktivitách, ktoré vykonávajú a smeroch ich pohybu. Druhou možnosťou je detekcia pohybu ľudí z kamerových záznamov skúmaného priestranstva. Existujú rôzne prístupy ku spracovaniu týchto záznamov. Ľudské správanie a pohyb je veľmi zložitý predpovedať, preto aj algoritmy a proces vyhodnocovania je pomerne komplikovaný.

Vyhodnocovanie pohybu objektov (ľudí) vo videu sa pritom využíva aj pri analýzach v nákupných centrách, na festivaloch, uliciach, mestských centrách, letiskách, staniciach, pre zvýšenie spokojnosti zákazníka, prevenciu tvorby zhlukovania davu, počítanie návštevníkov miesta, detekciu pohybujúcich sa vozidiel, detekciu tvárí, lodí

v prístavoch. Presnosť niektorých systémov je pritom aj viac než 95%¹. Ďalší vývoj v oblasti detekcie postáv sa zameriava aj na chodcov na cestách - využité algoritmy sú aplikované do automobilov a prepojené s riadiacou jednotkou tak, aby bol automobil schopný dostatočne rýchlo zabrzdiť, ak detekuje chodca (Gavrila, 2000 in Uhrin, 2012).

Detekcia konkrétnych objektov vždy spočíva vo výbere objektu, pripravení kvalitného setu na tréningovanie (tréningové vzorky), tréningu, a následne detekcii daného objektu. Bez ohľadu na detekovaný predmet, vždy je potrebné natréningovanie (vyškolenie) aplikácie na veľkom množstve špecifických obrázkov. Pri detekcii ľudí klasifikátor trénujeme vzorkami, ktoré predstavujú ľudí, ale i inými vzorkami, na ktorých ľudia nie sú. V procese spracovania sa potom stretávame aj s falošne pozitívnymi vyhodnoteniami - také, ktoré mali byť negatívne, ale klasifikátor ich vyhodnotil ako pozitívne (vstup bol napr. kvet, klasifikátor ho vyhodnotil ako človeka). To následne súvisí s vyhodnotením úspešnosti, resp. efektívnosti klasifikátora, či systému.

Klasifikovanie (triedenie) objektov pomocou bodov záujmu je založené na segmentácii a kategorizácii. Základným princípom je vyhľadanie bodov záujmu a lokálnych znakov v ich okolí. Tento prístup bol vyvíjaný pomocou **AdaBoost**. Podľa Uhrina (2012) je prvým krokom nájdenie záujmových bodov, ktoré predstavujú významné miesta obrázka, kde dochádza napríklad k zmene štruktúry, farby alebo svetla. Body záujmu sú jedinečné. Následne dochádza k extrakcii lokálnych znakov okolo týchto bodov. Postup sa aplikuje na všetky obrázky z tréningovej množiny obsahujúce rovnaký objekt. Všetky podobné lokálne znaky z tréningových obrázkov sú zjednotené do spoločnej množiny a sú reprezentované svojím stredom. Známe algoritmy, ktoré extrahujú lokálne znaky, sú napr. SURF (Speeded up robust features) a SIFT (Scale invariant feature transform).

Pri samotnej detekcii je postup rovnaký ako v tréningovej časti. V prvom kroku sa nájdu body záujmu, následne sa extrahujú lokálne znaky a odhadne sa ich stred. Vyhľadajú sa podobné stredy v zjednotenej množine objektov reprezentovaných svojím stredom. Na základe porovnania sa vytvorí hypotéza, ktorá sa spresňuje až do záverečného kroku, ktorým je segmentácia a detekcia objektov na obrázku (Uhrin, 2012).

Okrem predstaveného využitia na segmentáciu objektov na obrázku sa algoritmy SIFT a SURF používajú aj na vyhľadanie rovnakých bodov záujmu na dvoch a viacerých obrázkoch, ktoré zachytávajú rovnaký obsah, ale napríklad sú fotené z rôznych uhlov (Uhrin, 2012).

¹ ViNotion. People Counting System. [online]. Dostupné na: http://www.vinotion.nl/index.php/en/component/ars/repository/downloads/downloads-1/leaflet_vinotion_people_counting_system-pdf

Často využívaným klasifikačným algoritmom je **AdaBoost** (adaptive boosting) - algoritmus strojového učenia. Boosting je metóda na zlepšenie klasifikačnej presnosti.

Základom algoritmu je vhodná lineárna kombinácia slabších klasifikátorov tak, aby výsledkom bol jeden silnejší klasifikátor. V procese klasifikácie je možné dosiahnuť exponenciálne zníženie chyby na trénovaných dátach (v každom kole je rozdelenie váhy aktualizované a označuje dôležitosť príkladu v súbore dát; váha nesprávne vyhodnoteného príkladu rastie, alternatívne správne vyhodnoteného klesá tak, aby sa nový klasifikátor viac zamerával na tieto príklady (Li et al., 2010). Tento algoritmus bol využitý pri detekcii objektov u autorov Viola a Jones (2001), ktorí sú v prácach podobného typu veľmi často spomínaní.

AdaBoost využíva Haarove znaky alebo Edgelet znaky (Uhrin, 2012).

Pri popise vzhľadu sa využívajú:

HOG (histogram of oriented gradients) znaky, ktoré navrhol Dalal (2005), využívajú rozdelenie gradientov obrázka a sú implementované na zachytenie tvarových a vzhľadových črt. Každý obrázok je rozdelený na malé oblasti nazývané bunky. Každý histogram bunky je počítaný pomocou veľkosti gradientu každého pixlu vo vnútri bunky. Histogramy všetkých buniek sa spoja za vzniku HOG features. S cieľom posilniť algoritmus, susedné bunky sú zoskupené do väčších blokov. Finálny popisovač je teda vektorom všetkých zložiek normalizovanej bunkovej odozvy zo všetkých blokov (Li et al., 2010).

Haarove znaky sú tvorené dvomi alebo tromi obdĺžnikmi, ktoré poskytujú informáciu o distribúcii šedej škály (grey level). Pre výpočet výkonu filtra na určitú oblasť obrázka, súčet všetkých hodnôt pixlov v čiernej oblasti sa odpočíta od súčtu všetkých hodnôt pixlov v oblasti bielej (Li et al., 2010). Princíp Haarových znakov je rozdiel medzi intenzitou pixlov v tmavej a svetlej časti filtra nad obrázkom (Uhrin, 2012). Pri detekcii tváre sa využíva fakt, ako uvádza Uhrin (2012), že oblasť očí je väčšinou tmavšia ako lícna oblasť.

Edgelet znaky navrhol Bo Wu (2005) a Jie Xu (2008) ich zlepšil pre detekciu pohybu chodcov. Edgelet je krátky segment čiary alebo krivky, ktorý reprezentuje malú časť obrysu človeka. Bo Wu definuje tri druhy – čiaru, oblúk a symetrickú dvojicu. Pomocou výpočtov sa zisťuje pozícia w na obrázku.

Pre danú plochu sú množinou všetkých čiarok, ktoré vznikajú spojením bodov na okraji dyadických štvorcov. Dyadický štvorec je iteratívne (opakovane) rozdelený štvorec na ďalšie štvorce delením strán v polovici, až kým strana najmenšieho nie je rovná 1 (Donoho, 1999 in Uhrin, 2012).

Kaskáda klasifikátorov - v prípade hľadania objektu na obrázku zaberá tento objekt väčšinou menšiu časť obrázka ako pozadie. S touto myšlienkou prišli Viola a Jones (2006) a navrhli vytvorenie klasifikátora, ktorý je schopný veľmi rýchlo detekovať pozadie na základe pár znakov. Prehľadávanie obrázka spracuje veľké množstvo

častí s pozadím a vďaka rýchlemu klasifikátoru sa tieto výrezy môžu vyradiť ako neobsahujúce hľadaný objekt. Na zostávajúce výrezy sa aplikuje ďalšia iterácia prehľadávania, kedy už môžu byť použité zložitejšie klasifikátory, lebo takýchto výrezov bude každou iteráciou menej. Vzniká jednoduchý rozhodovací stroj, tzv. kaskáda klasifikátorov fungujúca na princípe, že každý klasifikátor môže výrez buď zahodiť, alebo poslať ďalším klasifikátorom na ďalšie rozhodnutie. Výsledné určenie, či sa hľadaný objekt na obrázku nachádza, dáva až posledný klasifikátor (Uhrin, 2012).

Existujú 3 základné princípy, akými možno detekovať osobu. Prvým je rozpoznanie osôb založené na rozpoznaní tváre. Pri tomto prístupe dochádza k únikom údajov o osobách, ktoré sú otočené chrbtom, alebo majú nejakým spôsobom zakrytú tvár (Uhrin, 2012). Druhý prístup je detekcia extrakciou popredia (odčítaním pozadia) a tretím je rozpoznávanie na základe vlastností ľudskej postavy.

Prístup pracujúci s textúrami v popredí obrázka (extrakcia popredia) má svoje limity v podobe zlučovania blízkych cieľov, prípadne cieľa s jeho tieňom, potreby výrazného kontrastu medzi popredím a pozadím (Munaro, Cenedese, 2011). Táto metóda je vhodná na sledovanie osôb pomocou statických kamerových systémov, pretože na meniacom sa obraze je postava vždy výraznou časťou oproti statickému pozadiu (Uhrin, 2012).

Rozpoznávanie na základe vlastností ľudskej postavy je založené na detekcii pomocou upraveného AdaBoostu, či porovnávania šablón (template matching) (Uhrin, 2012).

Ďalším významným detektorom používaným na vyhľadávanie postáv, ale aj tvárí je SVM (Support Vector Machine) detektor (Uhrin, 2012). SVM sa používa ako jediný silný klasifikátor detekcie chodcov. Avšak, keď sa zvýšil počet vzoriek, čas výpočtu i výpočtová presnosť sa stali problematickými (Li et al., 2010). Najvýznamnejšie práce zaoberajúce sa SVM detekciou sú autorov Mohan et al. (2001), Dalal, Triggs (2005), Papageorgiou, Evgeniou, Poggio (1998).

V posledných rokoch bolo navrhnutých a popísaných množstvo metód, založených na črtách vzhľadu, ktorých efektivita zväčša závisí na veľkosti a variabilite tréningovej vzorky (v rámci popisovača črt) a na spôsobe klasifikácie, ktorý bol aplikovaný.

Viola (2003) predstavil efektívny detektor osôb založený na Haarových znakoch. Takuya Kobayashi (2007) zlepšil HOG (Histogram of oriented gradients) a dosiahol tak vysokú mieru rozpoznania. Bo Wu (2005) pre detekciu ľudí využil Edgelet znaky. A Supriya Rao (2008) navrhol novú metódu detekcie jednotlivých častí ľudského tela. Avšak všetky tieto metódy nie sú dostatočne silné na to, aby odhalili množstvo nepredvídateľných problémov (Li et al., 2010).

Za účelom zvýšenia presnosti, či skrátenia výpočtového času je potrebné využívať ich **fúzie**, napr.:

Detekcia na základe dvoch krokov podľa Li et al. (2010) využíva FBD (full body detection) založenú na Haarových znakoch a HOG črtách, a následne v druhom kroku HSD (head-shoulder detection) s využitím troch detektorov trénovaných Haarovými znakmi, HOG a Edgelet znakmi. Algoritmus AdaBoost Cascade je využitý v oboch krokoch. Výsledky použitej metódy autori porovnali s metódami Viola et al. (2003) a Bo Wu, Nevatia (2005) a získali lepšie výsledky.

Detekcia použitím Coarse-to-fine metódy s využitím Haarových znakov a Shapelet znakov má dve fázy. Detektor je trénovaný cez algoritmus AdaBoost a nakoniec sa skladá z kaskády klasifikátorov. V prvom stanovisku detektor využitím Haarových znakov prehľadá obrázok cez rôzne pohľady a mierky. Dostaneme niekoľko obdĺžnikov oblastí (ROI – Region of interest), ktoré môžu obsahovať chodcov. V druhom stanovisku ich klasifikátor použitím Shapelet znakov triedi a zisťuje, kde sa chodci skutočne nachádzajú. Tento druh kaskádovej štruktúry dosahuje zvýšený výkon detekcie (priemerne 90%) a radikálnu redukciu výpočtového času (metóda je približne o 50% rýchlejšia ako HOG-SVM detekcia) (Yongzhi et al., 2010).

Detekcia na základe jednoduchej ľudskej interakcie pri trénovaní podľa autorov Munaro, Cenedese (2011) – užívateľ je vyzvaný na overenie výsledkov základného detektora vychádzajúceho z odčítania pozadia a obmedzenia proporcií. Táto technika je využiteľná pre akúkoľvek statickú kameru a umožňuje značne zvýšiť výkony detektora založeného na vzhľadových črtách a znížiť potrebný výpočtový čas. Využíva hodnotenie človeka pre zabezpečenie dobrej kvality.

Ďalšie možnosti skúmania ľudí vo verejných priestranstvách popisujú Merad et al. (2010), ktorí využívajú detekciu hlavy a tzv. skeleton graph, Benfold a Reid (2011) pracujú so stabilným viac-cieľovým sledovaním v reálnom čase videa. Ďalší autori sa zaoberajú aj zisťovaním trasy pohybu ľudí - Beleznai, Frühstück, Bischof (2006), či pohlavia pozorovaných osôb – Collins et al. (2009), Davis a Gao (2004), Sabir et al. (2013).

Materiál a metódy

Tilley, Šilhánková, Navrátilová (1996) v práci popisujú dva celky sledovania verejného priestranstva. Mapovanie správania a sčítanie pohybu peších. Mapovanie správania odráža činnosti ľudí vo verejných priestoroch (analýzou možno zistiť, akými aktivitami tento priestor žije - akými prvkami ich možno posilniť, či oslabiť). Vzhľadom na množstvo ľudí sa napr. sleduje, či je optimálna šírka chodníkov, či postačujú a pod. Pozorovaním získame informácie o využívaných a nevyužívaných častiach územia. Pri pozorovaní sa prechádza z jedného konca sledovanej oblasti

na druhý, zaznamenáva sa to, čo pozorovateľ vidí. Pozorovanie by sa malo opakovať každú hodinu v priebehu celého dňa. Sčítanie pohybu skúma počet ľudí v priestore, vzťahy a konflikty medzi chodcami a vozidlami a pod. Obe techniky majú etapy: príprava projektu, predvýskum, príprava podkladov, zber dát, spracovanie, záverečná správa.

Pri tomto pozorovaní sme sledovali informácie o počte áut, peších, cyklistov, pohlaví, smeroch pohybu. Cieľom bolo porovnať pozorovanie v intervaloch 15-tich minút s celodennými záznamami o pohybe vo verejnom priestranstve, aby sme zistili, či je interval skúmania postačujúci a skutočne odzrkadľuje jeho využívanie.

Výsledky a diskusia


Zvolené verejné priestranstvo v obci Hruboňovo predstavuje časť komunikácie, pozorovali sme ho 12.7.2013 (pracovný deň) v intervale 6:00 do 21:00 bez prerušenia. Zapisovali sme čas, počet prechádzajúcich osôb, áut a smer ich pohybu. Následne sme v päťminútových intervaloch tieto údaje vyhodnotili. Podľa Tilley, Šilhánkovej, Navrátilovej (1996) je pre mapovanie správania zvolený interval 12-15 minút každú hodinu. V grafe (Obrázok 1) uvádzame prehľad počtu áut a chodcov z celodenného pozorovania v intervale prvých 15 minút z každej hodiny a aj celkový počet z každej hodiny.

Obrázok 1 Pozorovaná oblasť v obci a smery



Figure 1 Observed area in village and directions

Obrázok 2 Výsledky celodenného pozorovania



počet chodcov (15 min.) – súčet všetkých prechádzajúcich v intervale 15 minút
 sum of pedestrians (15 min.) - sum of pedestrians during 15 minutes observation
 počet chodcov – súčet všetkých osôb prechádzajúcich v intervale 1 hodiny
 sum of pedestrians – sum of pedestrians during 1 hour
 počet áut (15 min.) – súčet všetkých automobilov prechádzajúcich územím za 15 minút
 sum of cars (15 min.) – sum of cars go through observed area during 15 minutes interval
 počet áut – súčet všetkých automobilov za hodinu
 sum of cars – sum of cars during 1 hour of observation

Figure 2 Results from all-day observation

Z pohľadu štatistických výsledkov, pri vydelení počtu peších prechádzajúcich územím v priebehu hodiny štyrmi (60 min/4 = 15 min) a porovnaní so sledovaným intervalom 15 minút, dostávame výsledky: v 3 prípadoch vychádza tento údaj rovnaký, v 6 prípadoch je počet prechádzajúcich ľudí za hodinu/4 väčší ako počet ľudí pozorovaných v intervale 15 minút a v 6 prípadoch je ich počet nižší. Celkovo prešlo územím počas celého sledovaného obdobia 68 osôb. Po sčítaní 15-minútových intervalov sledovania podľa Tilley, Šilhánková, Navrátilová (1996), prešlo územím celkovo 18 osôb.

$$68/(4 \times 15) = 1,1333$$

$$18/15 = 1,2$$

Interval 15 minút sledovania osôb poskytuje porovnateľné informácie, ako keď územie pozorujeme celý deň a údaje prevedieme na rovnaký porovnávací časový interval.

V priebehu pozorovania sme zapisovali aj informácie o prechádzajúcich autách. Celkovo prešlo územím 232 áut. V intervaloch 15-tich minút by táto hodnota dosiahla úroveň 54.

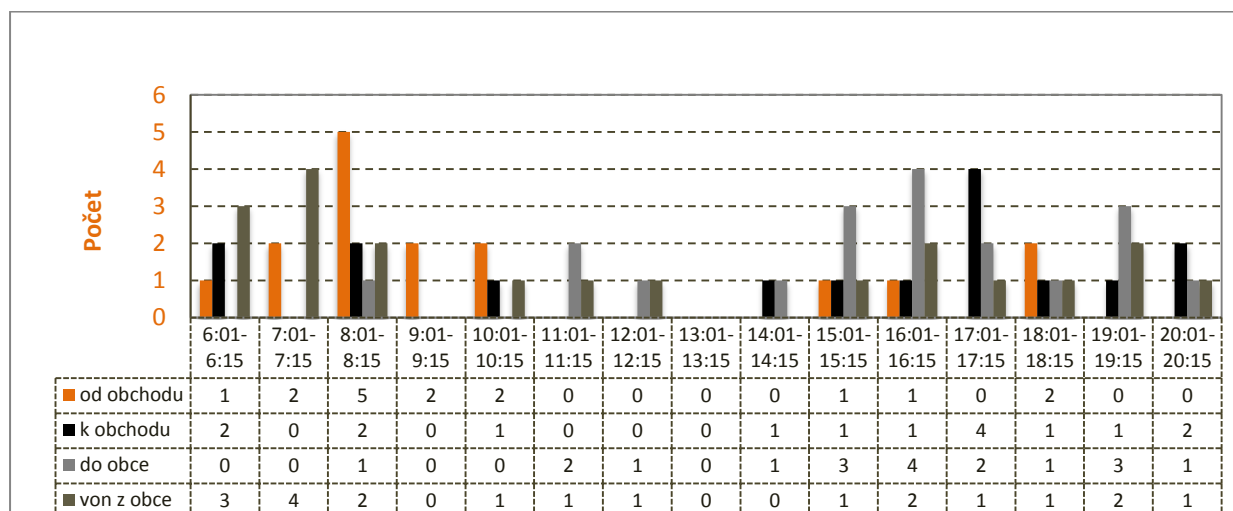
$$232/(4 \times 15) = 3,8667$$

$$54/15 = 3,6$$

Štatisticky prejdú územím za minútu cca 4 automobily. Tento údaj vychádza aj pri vydelení celkovej sumy áut (232) za deň počtom 15-minútových intervalov (60), aj pri sčítaní áut za 15minútové intervaly (54) a vydelením ich počtom (15).

Okrem pozorovania, kto územím prechádza, sme sledovali i smery pohybu osôb, či už peších, cyklistov alebo pasažierov v automobiloch. Porovnali sme zistenia, keby sme pozorovanie uskutočnili len predpísaných 15 minút z každej hodiny (Obrázok 2) a údaje z celodenného nepretržitého pozorovania (Obrázok 3).

Obrázok 3 Výsledky celodenného pozorovania v intervaloch 15 min. – smery pohybu



od obchodu – smer pohybu od obchodu ku križovatke

from market - path direction from market to crossroad

k obchodu – smer pohybu od križovatky k obchodu

to market – path direction from crossroad to market

do obce – smer pohybu do obce

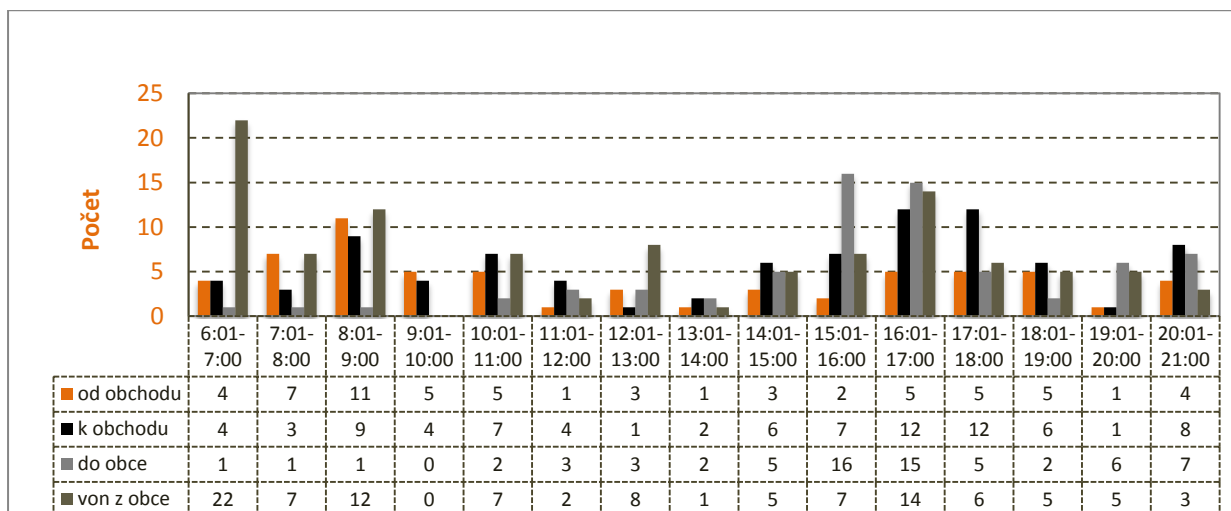
to village – path direction to village

von z obce – smer pohybu von z obce

from village – path direction from village

Figure 3 Results from all-day observation in 15 minutes intervals – directions

Obrázok 4 Výsledky celodenného pozorovania – smery pohybu



od obchodu – smer pohybu od obchodu ku križovatke
 from market - path direction from market to crossroad
 k obchodu – smer pohybu od križovatky k obchodu
 to market – path direction from crossroad to market
 do obce – smer pohybu do obce
 to village – path direction to village
 von z obce – smer pohybu von z obce
 from village – path direction from village

Figure 4 Results from all-day observation - directions

Štatisticky, celkový počet presunov smerom od obchodu v priebehu celého dňa bolo 62, k obchodu 86, smerom do obce ich bolo 69 a von z obce 104. Podľa Tilley, Šilhánkovej, Navrátilovej (1996) je celkový počet v sledovaných 15-minútových intervaloch počas dňa 16 (od obchodu), 16 (k obchodu), 19 (do obce) a 20 von z obce.

$$62/(4 \times 15) = 1,03333$$

$$16/15 = 1,066667$$

$$86/(4 \times 15) = 1,43333$$

$$16/15 = 1,066667$$

$$69/(4 \times 15) = 1,15$$

$$19/15 = 1,266667$$

$$104/(4 \times 15) = 1,733333$$

$$20/15 = 1,333333$$

Interval 15 minút sledovania v tomto prípade ukazuje mierne odchýlky voči pozorovaniu celodennému. Najväčšia odchýlka sa vyskytla pri smere „von z obce“, kedy sme celodenným pozorovaním získali údaj 104, pričom pri intervaloch sledovania každých 15 minút to bolo 20. Ak by sme ho vynásobili štyrmi (počet 15-minútových intervalov do hodiny), dostávame hodnotu 80, čo predstavuje 4/5 skutočného počtu detekovaných z tohto smeru.

Z hľadiska náročnosti aplikácie popísaných metód získavania informácií o pohybe ľudí vo verejných priestranstvách (priame pozorovanie podľa Tilley, Šilhánkovej,

Navrátilovej (1996) vs. počítačom vyhodnotené kamerové záznamy prostredníctvom programov) majú oba prístupy svoje výhody i nevýhody.

Jednoduchosť prevedenia je zrejmá pri metodike priameho pozorovania podľa Tilley, Šilhánkovej, Navrátilovej (1996). Pozorovateľ si vyberie stanovisko, pripraví podklady a v stanovenom čase zapisuje údaje kedykoľvek je to potrebné. Z pohľadu časovej náročnosti prípravy na samotné získanie, resp. vyhodnotenie údajov pri počítačových vyhodnoteniach, nie sú bežne voľne dostupné programy, prípadne ak nejaké sú, zväčša nie sú vhodné. Ak by sa vychádzalo z metód popísaných v niektorom z citovaných článkov, autori v nich nezdieľajú zdrojové kódy, programy nemožno stiahnuť a overiť, či skutočne fungujú aj pre náš prípad a nie je v nich podrobne popísané, ako pokus zopakovať (váhy, nastavovanie, použité prvky, nastavenie kamery a pod.). V prípade, že by sa programovalo od samého začiatku, je pomerne problematické proces a nastavenia vyladiť, aby bolo vyhodnotenie úspešné. Je potrebná veľká a dobrá tréningová vzorka, čo znamená natočiť veľa videí. Jednak výseky ľudí (naše objekty záujmu), ale i objekty, ktoré nie sú ľudia (napr. stromy). Vhodne pripraviť prvotnú fázu predstavuje komplexný problém, kde vstupujú maličkosti – počasie, či je zamračené, svetlosť, kvalita kamery a pod., scéna (iné pozadie predstavuje stena na chodbe, iné je v parku, resp. v exteriéri), pri nepriaznivých poveternostných podmienkach sa môže triasť kamera a pod.). Pritom rozpoznanie objektov v priestore sa javí ako jednoduché, najmä kvôli priamemu pozorovaniu človekom, kedy sleduje priestor a jednoducho v ňom detekuje prvky.

Napísať program, ktorý nahradí pozorovanie človekom v reálnom čase je komplikované. Časovo náročné je napísať samotný program. Pri programovaní takýchto aplikácií na spracovanie obrazu, resp. počítačové videnie sa využívajú väčšinou voľne dostupné tzv. Open Source knižnice (OpenCV) – obsahujúce základné funkcie. Druhým krokom je tréning vzorkami, ktoré sme pripravili z videa. V testovacej vzorke zisťujeme, či je v obrázku človek, alebo nie. Ak zistíme, že výsledky sú nepostačujúce, celý proces začína odznova. Sledovanými parametrami sú čas vyhodnocovania a efektivita (úspešnosť) – napr. môže postačovať úspešnosť detekcie 80%, ak je video vyhodnocované v reálnom čase aj na slabom hardwari – podľa toho sa spraví algoritmus. Úspešnosť sa zvyčajne vyhodnocuje pomocou matice Precision/Recall Graph.

Celý proces závisí od naprogramovania, nastavenia parametrov (veľkosť, pohyb, detekcia farby kože a pod.) Naprogramovanie môže byť na interiéry (nie je tam ostré slnko, vibrácia kamery, členité pozadie,...). Pri exteriéroch je dôležitá dobrá pozícia kamery, detekcia je možná na základe pohybu alebo siluety (vzhľadom na vzdialenosť nie priamo detekcie tváre), môže vzniknúť problematika tieňov, otrasy kamery vo vetre, v priestore sa môže vyskytnúť človek na bicykli, s kočíkom a pod. Rovnako spracovanie závisí aj od počtu kamier – z viacerých uhlov sa dá vyhotoviť 3D scéna, z ktorej by bola detekcia presnejšia.

Pri metodike priameho pozorovania podľa Tilley, Šilhánkovej, Navrátilovej (1996) je presnosť detekcie ovplyvnená segmentáciou priestoru (čím viac ľudí priestorom

prechádza za jednotku času, tým menší pozorovaný výsek verejného priestranstva volíme, pozornosťou človeka a podmienkami, ktoré pri pozorovaní má.

Súhrn

Pre tvorbu udržateľných verejných priestranstiev je nevyhnutné poznať ich každodenných užívateľov. V práci predstavujeme základné prístupy k detekcii objektov aplikované pre využitie aj v oblasti záhradnej a krajinnej architektúry. Prvým prístupom je priame pozorovanie priestranstva, kedy pozorovateľ sleduje vybraný priestor a zapisuje si údaje o počte áut, ľudí, aktivitách, smeroch pohybu, pohlaví, vekovom rozpätí a pod. Druhým prístupom je vyhodnocovanie údajov z kamier, ktoré môže prebiehať v reálnom čase alebo zo záznamov. Venujeme sa popisu základných pojmov a procesov, porovnaniu výhod a nevýhod oboch prístupov. Na vybrané verejné priestranstvo vidieckeho sídla sme aplikovali celodenné priame pozorovanie a výsledky vyhodnotili.

Kľúčové slová: verejné priestranstvá, detekcia pohybu

Príspevok bol spracovaný vďaka finančnej podpore grantového projektu KEGA 001SPU-4/2014 Zelená infraštruktúra a mestské poľnohospodárstvo a VEGA v rámci projektu VEGA 1/0769/12 Tvorba udržateľných verejných priestorov vidieckych sídiel modernými metódami.

Literatúra

- BELEZNAI, Csaba. – FRÜHSTÜCK, Bernhard. – BISCHOF, Horst. 2006. Human Tracking by Fast Mean Shift Mode Seeking. *Journal of Multimedia*. Vol. 1. No.1. 8 s.
- BENFOLD, Ben – REID, Ian. 2011. *Stable Multi-Target Tracking in Real-Time Surveillance Video*. 8 s.
- COLLINS, Matthew – ZHANG, Jianguo – MILLER, Paul – WANG, Hongbin. 2009. Full body image feature representations for gender profiling. IEEE. 12th International Conference on Computer Vision Workshops. s. 1235-1242. 978-1-4244-4441-0/09.
- DALAL, Navneet - TRIGGS, Bill. 2005. Histograms of oriented gradients for human detection. In LI et al. 2010. *Pedestrian Detection Based on A New Two-Step Framework*. Second International Workshop on Education Technology and Computer Science. s. 56-59
- DAVIS, James W. – GAO, Hui. 2004. Gender Recognition from Walking Movements using Adaptive Three Mode PCA. IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops. 8 s. 1063-6919/04.
- GAVRILA, Dariu. 2000. Pedestrian Detection from a Moving Vehicle. In UHRIN, Matej. *Autodetekcia obsahu obrázkov pre účely komunikatívnej grafiky*: diplomová práca. Brno: Masarykova univerzita. 53s.

- KOBAYASHI, Takuya – HIDAKA, Akinori – KURITA, Takio. 2007. Selection of Histograms of Oriented Gradients Features for Pedestrian Detection. In LI, Zhen – WEI, Zhiqiang – YIN, Bo – JI, Xiaopeng – SHAN, Ruobing. 2010. *Pedestrian Detection Based on A New Two-Step Framework*. Second International Workshop on Education Technology and Computer Science. s. 56-59.
- LI, Zhen – WEI, Zhiqiang – YIN, Bo – JI, Xiaopeng – SHAN, Ruobing. 2010. *Pedestrian Detection Based on A New Two-Step Framework*. Second International Workshop on Education Technology and Computer Science. s. 56-59.
- MERAD, Djamel – AZIZ, Kheir-Eddine – THOME, Nicolas. 2010. Fast People Counting Using Head Detection From Skeleton Graph. IEEE. s. 233-240. 978-0-7695-4264-5/10.
- MOHAN, A. - PAPAGEORGIOU, C. - POGGIO, T. - KANA, C. 2001. Example-based object detection in images by components. In UHRIN, Matej. *Autodetekcia obsahu obrázkov pre účely komunikatívnej grafiky: diplomová práca*. Brno: Masarykova univerzita. 53 s.
- MUNARO, Matteo – CENEDESE, Angelo. 2011. *Scene specific people detection by simple human interaction*. IEEE International Conference on Computer Vision Workshops. s. 1250-1255. 978-1-4673-0063-6/11.
- PAPAGEORGIOU, C. – EVGENIOU, T. - POGGIO, T. 1998. A Trainable Pedestrian Detection System. In UHRIN, Matej. *Autodetekcia obsahu obrázkov pre účely komunikatívnej grafiky: diplomová práca*. Brno: Masarykova univerzita. 53s.
- RAO, Supriya – PRAMOD, N.C. – PATURU, Chaitanya Krishna. 2008. People Detection in Image and Video Data. In LI, Zhen – WEI, Zhiqiang – YIN, Bo – JI, Xiaopeng – SHAN, Ruobing. 2010. *Pedestrian Detection Based on A New Two-Step Framework*. Second International Workshop on Education Technology and Computer Science. s. 56-59.
- SABIR, Azhin – AL-JAWAD, Naseer – JASSIM, Sabah – AL-TALABANI, Abdulbasit. 2013. *Human Gait Gender Classification based on Fusing Spatio-Temporal and Wavelet Statistical Features*. 5th Computer Science and Electronic Engineering Conference. University of Essex, UK. s. 140-145. 978-1-4799-0383-2/13.
- TILLEY, Julie – ŠILHÁNKOVÁ, Vladimíra – NAVRÁTILOVÁ, Jitka. 1996. *Metodika operatívneho zlepšení verejného priestoru*. Výpis. United States Peace Corps, Washington D.C. Útvar hlavného architekta, Magistrát města Brna (ÚHA MMB) Brno. 1996.
- UHRIN, Matej. *Autodetekcia obsahu obrázkov pre účely komunikatívnej grafiky: diplomová práca*. Brno: Masarykova univerzita. 53 s.
- ViNotion. People Counting System. [online]. Dostupné na: http://www.vinotion.nl/index.php/en/component/ars/repository/downloads/downloads-1/leaflet_vinotion_people_counting_system-pdf
- VIOLA, Paul A. - JONES, Michael J. 2001. Rapid object detection using a boosted cascade of simple features. In UHRIN, Matej. *Autodetekcia obsahu obrázkov pre účely komunikatívnej grafiky: diplomová práca*. Brno: Masarykova univerzita. 53s.
- VIOLA, Paul A. – JONES, Michael J. – SNOW. 2003. Detecting Pedestrians Using Pattern of Motion and Appearance. In LI, Zhen – WEI, Zhiqiang – YIN, Bo – JI,

Xiaopeng – SHAN, Ruobing. 2010. *Pedestrian Detection Based on A New Two-Step Framework*. Second International Workshop on Education Technology and Computer Science. s. 56-59.

VIOLA, Paul A. - JONES, Michael J. - TIEU, K. 2006. Robust Real-time Object Detection. In UHRIN, Matej. *Autodetekcia obsahu obrázkov pre účely komunikatívnej grafiky*. diplomová práca. Brno: Masarykova univerzita. 53s.

YONGZHI, Wang – JIANPING, Xing – XILING, Luo – ZHANG, Jun. 2010. *Pedestrian Detection Using Coarse-to-fine Method with Haar-like and Shapelet Features*. IIEE. 4 s. 978-1-4244-7874-3/10.

XU, Jie – YE, Getian, HERMAN, Gunawan – ZHANG, Bang. 2008. An Efficient Approach to Detecting Pedestrians in Video. In LI, Zhen – WEI, Zhiqiang – YIN, Bo – JI, Xiaopeng – SHAN, Ruobing. 2010. *Pedestrian Detection Based on A New Two-Step Framework*. Second International Workshop on Education Technology and Computer Science. s. 56-59.

WU, R. – NEVATIA, R. 2005. Detection of multiple, partially occluded humans in a single image by bayesian combination of edgelet part detectors. In LI, Zhen – WEI, Zhiqiang – YIN, Bo – JI, Xiaopeng – SHAN, Ruobing. 2010. *Pedestrian Detection Based on A New Two-Step Framework*. Second International Workshop on Education Technology and Computer Science. s. 56-59.

Kontaktná adresa:

Ing. Monika Jančovičová, Slovenská poľnohospodárska univerzita v Nitre, Fakulta záhradníctva a krajinného inžinierstva, Katedra záhradnej a krajinnej architektúry, Tulipánova 7, 949 01 Nitra, Slovenská republika, tel.: 037/ 641 5422, e-mail: monika.jancovicova@gmail.com