


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta informačních technologií


BAKALÁŘSKÁ PRÁCE

Brno, 2016

Ľuboř Tichý



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ  
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA INFORMAČNÍCH TECHNOLOGIÍ  
ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ  
FACULTY OF INFORMATION TECHNOLOGY  
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

# POČÍTÁNÍ PRŮCHODŮ OSOB DVEŘMI S VYUŽITÍM STACIONÁRNÍ KAMERY

COUNTING OF PEOPLE PASSING THROUGH A DOOR USING A STATIONARY CAMERA

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

L'UBOŠ TICHÝ

VEDOUCÍ PRÁCE

SUPERVISOR

ING. JAKUB SOCHOR

BRNO 2016

## **Abstrakt**

Tato bakalářská práce se zabývá počítáním lidí, kteří procházejí dveřmi. To může být využito v případě, když chceme vědět, kolik osob se nachází ve sledované místnosti. První část je opis existujících metod počítání lidí a druhá se zabývá využitými metodami počítačového vidění. Navrhnutý systém dokáže počítat lidi, a to včetně určení jejich směru pohybu. Poslední část obsahuje vyhodnocení systému.

## **Abstract**

This bachelor thesis deals with counting of people passing through a door. It may be used in case, when we need to know, how many people there are in monitored room. The first part is a description of existing methods of counting people and the second part deals with used computer vision methods. Proposed system can count people, including distinguishing their motion direction. The last part contains an evaluation of the system.

## **Klíčová slova**

počítání osob, detekce osob, kaskáda klasifikátorů, sledování osob

## **Keywords**

counting of people, person detection, cascade of classifiers, tracking

## **Citace**

Luboš Tichý: Počítání průchodů osob dveřmi s využitím stacionární kamery, bakalářská práce, Brno, FIT VUT v Brně, 2016

# Počítání průchodů osob dveřmi s využitím stacionární kamery

## Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracoval samostatně pod vedením pana Ing. Jakuba Sochora. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

.....  
Luboš Tichý  
18. května 2016

## Poděkování

Tímto bych moc rád poděkoval panu Ing. Jakubovi Sochorovi za odbornou pomoc, profesionalitu a za půjčení kamery. Dále bych chtěl poděkovat své rodině a přátelům, kteří mne povzbuzovali a podporovali při psaní této práce.

© Luboš Tichý, 2016

*Tato práce vznikla jako školní dílo na Vysokém učení technickém v Brně, Fakultě informačních technologií. Práce je chráněna autorským zákonem a její užití bez udělení oprávnění autorem je nezákonné, s výjimkou zákonem definovaných případů.*

# Obsah

1	Úvod.....	2
2	Existujúce systémy počítania ľudí.....	3
2.1	Detekcia a sledovanie osoby pohybujúcej sa po hracej ploche .....	3
2.2	Počítanie ľudí prechádzajúcich cez oblasť záujmu.....	4
3	Metódy počítačového videnia .....	7
3.1	Metódy detekcie osoby .....	7
3.2	Metódy sledovania osoby .....	12
4	Návrh systému.....	17
4.1	Spracovanie zdroja .....	18
4.2	Reprezentácia osoby.....	18
4.3	Oblasť záujmu.....	19
4.4	Počítanie a určenie smeru osoby .....	21
5	Implementácia systému.....	23
6	Vyhodnotenie systému .....	26
6.1	Dátová sada .....	26
6.2	Výsledky.....	27
6.3	Diskusia .....	30
7	Záver .....	33

# 1 Úvod

Počítanie prechodov osôb dverami a určenie smeru pohybu má rôzne uplatnenie, od merania návštevnosti, cez meranie prevádzky v miestnosti, až po kontrolu spotreby energie v navštívených miestnostiach.

Meranie návštevnosti má využitie v nákupných centrách, v múzeách, v knižniciach, v koncertných halách, na štadiónoch pri športových podujatiach, kde počet návštevníkov má dôležitý význam. Informáciu o čase, kedy je návštevnosť miestnosti najvyššia, potrebujú manažéri pre efektívny predaj svojich služieb a tovaru a pre strategické rozmiestnenie svojich zamestnancov na najviac frekventované miesta. Miestnosti majú v rôznom čase rôznu návštevnosť a inteligentná domácnosť si s tým dokáže poradiť a kontrolovať spotrebu energie (napr. klimatizáciu) v miestnostiach.

V nasledujúcej kapitole 2 sú opísané už existujúce systémy počítania ľudí, ktorými som bol inšpirovaný. Kapitola 3 opisuje metódy, ktoré sa podieľajú na počítaní – metódy detekcie osôb a metódy sledovania pohybu osôb. Tieto metódy som využil a navrhol som vlastný systém počítania ľudí. Návrh je bližšie popísaný v kapitole 4. Počítanie ľudí je aplikované na videu, ktoré bolo zhotovené stacionárnou kamerou. Kamera bola postavená pri vchode do miestnosti a snímala prechádzajúcich ľudí. Na videu bola určená oblasť záujmu. Osoby prechádzali do oblasti záujmu a cez stredovú čiaru, ktorá určila smer ich pohybu. Kapitola 5 opisuje samotnú implementáciu systému a kapitola 6 obsahuje vyhodnotenie a dosiahnuté výsledky.

## **2 Existujúce systémy počítania ľudí**

Pre počítanie ľudí už existuje niekoľko systémov. Systémy, ktorých cieľom je detekcia, sledovanie a počítanie ľudí, sú popísané v tejto kapitole.

### **2.1 Detekcia a sledovanie osoby pohybujúcej sa po hracej ploche**

Prvý podobný existujúci systém [1] je využitý pri športových podujatiach. Je použitá stacionárna kamera, ktorá zaznamenáva panoramatický pohľad na scénu. Kamera je postavená tak, že záber kamery smeruje na celú postavu osoby. Hracia plocha je plná hráčov, ktorí sú detekovaní a po detekcii je sledovaný ich pohyb. Podobne aj v navrhnutom systéme tejto práce sa využije stacionárna kamera so záberom na celú postavu a osoby pohybujúce sa pred dverami sú detekované a ich pohyb je sledovaný. Tento existujúci systém je zložený z dvoch častí. Prvá časť je detekcia osoby a druhá časť je sledovanie osoby.

#### **2.1.1 Detekcia osoby**

Pre detekciu osôb bola použitá upravená metóda HOG (Histogram of oriented gradients) [2] a z obrazu získa informáciu o celej postave osoby. Pôvodná metóda HOG je použitá aj v navrhnutom systéme tejto práce a je popísaná v podkapitole 3.1.1. Pri detekcii je nutné zväziť do úvahy rýchle pohyby hráčov, ktoré vytvárajú rozmazané časti na obraze a zhoršujú kvalitu detekcie osoby. Rozmazané časti obrazu sa detekujú blob detektorom.

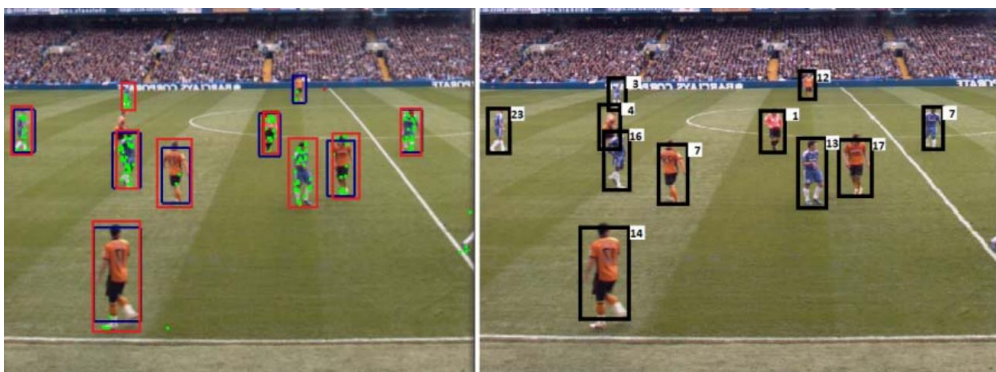
Výsledky detekcie sú reprezentované bounding boxom a predstavujú jednotlivé osoby. Bounding box je box ohraničujúci osobu a jeho použitie našlo uplatnenie aj v navrhnutom systéme tejto práce. Jednotlivé detekcie sú vyjadrené hodnotou, ktorá je nazvaná ako skóre detekcie osoby (person detection score – pds). Pre výpočet tohto skóre sú zahrnuté informácie ako je výška a šírka bounding boxu, počet sledovaných bodov v bounding boxe a príznak, či sa jedná o detekciu rozmazanej časti obrazu.

#### **2.1.2 Sledovanie osoby**

Sledovanie osoby spočíva v sledovaní bodov na obraze. Hlavné vylepšenie metódy sledovania osoby je v porovnávaní histogramov farieb. Obraz je zostavený z viacerých histogramov patriacich do rôznych regiónov. Histogram farieb sa aktualizuje s každou novou snímku a následne sa porovnáva s histogramom odpovedajúcim zo sledovaného regiónu z predchádzajúcej snímky.

Metóda sledovania osoby je vylepšená o skóre sledovania osoby (person tracking score – pts). Nové skóre je definované ako skóre, ktoré je zozbierané z určitého počtu snímok pre lepšiu stabilitu sledovania. Zahŕňa informácie ako je rozdiel vzdialeností dvoch histogramov farieb, šírka a výška sledovaného regiónu odpovedajúcemu bounding boxu a sledované body. Zahŕnuté je takisto aj skóre detekcie osoby pds.

Každý nový detekovaný bod je potrebné zaradiť do sledovaného regiónu. Vypočítajú sa vzdialenosti tohto bodu voči stredom sledovaných regiónov a najkratšia vzdialenosť spomedzi nich rozhodne, ku ktorému regiónu sa zaradiť. Ak veľký počet sledovaných bodov nepatrí k predchádzajúcim výsledkom sledovania, tak sa im priradí nový identifikátor osoby.



(a)

(b)

Obr. 2.1: Ukážka systému. Na obrázku a) sú modré bounding boxy – výstup metódy HOG a červené bounding boxy – výstup blob detektora so zelenými sledovanými bodmi. Obrázok b) znázorňuje výstup systému – osoby s identifikačným číslom. Prevzaté z [1].

## 2.2 Počítanie ľudí prechádzajúcich cez oblasť záujmu

Ďalší existujúci systém [3] má využitie na miestach, kde prechádzajú veľké davы ľudí, ako sú napríklad vchody nákupných centier a metier alebo pri rôznych udalostiach, kedy je potrebná informácia o počte návštevníkov. Kamera je umiestnená nad vchodom a záber kamery smeruje kolmo nadol. Umiestnenie kamery nad vchod do miestnosti našlo uplatnenie aj v navrhnutom systéme tejto práce. Tento existujúci systém je zložený z troch častí: detektor, sledovač a počítanie.

### 2.2.1 Detektor osôb

Metóda detekcie pracuje na základe pohybu osoby na obraze. Pre detekciu pohybujúcich sa objektov je použitá metóda nazývaná Background Subtraction a je použitá aj v navrhnutom



systéme tejto práce a opísaná v podkapitole 3.1.3. Pre získanie modelu pozadia je použitá metóda nazývaná foreground/background edge model (FBEM). Výstupom metódy FBEM sú obrysy pohybujúcich sa osôb. Aplikovaním Canny algoritmu sa získa informácia o obryse. Výsledkom je binárny obraz bielych a čiernych pixelov, kde biele pixely značia obrysy.


### **2.2.2 Sledovač osôb**

Úlohou sledovača je odhadnúť zhodu medzi dvoma po sebe idúcimi snímkami. Pre splnenie tejto úlohy sú navrhnuté dve relatívne jednoduché postupy. Prvý postup je založený na tom, že stredy pohybujúcich sa regiónov (osôb) súčasnej snímky sa posunú o krátku vzdialenosť oproti stredom z nasledujúcej snímky. Vypočítajú sa Euklidovské vzdialenosti týchto stredov a porovnajú sa s preddefinovaným prahom.

Avšak, dve osoby sa môžu vyskytnúť blízko seba, čo nezaručuje úspech prvého postupu. Druhý postup berie do úvahy podobnosť medzi veľkosťami pohybujúcich sa regiónov. Tento fakt je založený na tom, že veľkosť regiónov sa príliš nemení medzi snímkami. Podobnosti sa porovnávajú s preddefinovaným prahom.

### **2.2.3 Počítanie osôb**

Záber kamery smeruje kolmo nadol a zachytáva pohyb ľudí zhora nadol a opačne. Pre obojsmerné počítanie osôb prechádzajúcich bránou je nutné určiť dve čiary – pre vchod a pre východ. Oblasť medzi čiarami je oblasťou záujmu. Osoby sa počítajú len v tejto oblasti, čo má veľký vplyv na presnosť počítania. Osoby sú reprezentované bounding boxom, ktorý vstúpil do oblasti záujmu. Každý bounding box zahŕňa informácie o počiatočnom smere, súčasnom smere, súčasnej pozícii a o predchádzajúcej pozícii. Ak súčasná pozícia sa nachádza v oblasti záujmu a predchádzajúca pozícia je mimo oblasti, tak sa určí počiatočný smer, ktorý sa nemení a začína sa počítanie. Počítanie sa končí opačným spôsobom. Ak sa súčasná pozícia nachádza mimo oblasti záujmu a predchádzajúca pozícia je v oblasti, tak počítanie končí pre daný bounding box. Ak nastane situácia, že bounding box je mimo oblasť záujmu a má rovnaký súčasný smer ako počiatočný smer, znamená to, že osoba dvermi neprešla (zmenila smer a vrátila sa) a osoba sa nepočíta. Počítanie s určením oblasti záujmu a s informáciami o pozícii bounding boxu je uplatnené aj v navrhnutom systéme tejto práce.



Obr. 2.2: Ukážka počítania systému. Na obrázku a) je pôvodná snímka v stupňoch šedej. Obrázok b) znázorňuje výstup metódy FBEM – hrany pozadia a popredia a obrázok c) znázorňuje len hrany popredia – objektov. Obrázok d) znázorňuje výstup systému s oblasťou záujmu a s dvoma bounding boxami. Prevzaté z [3].

# 3 Metódy počítačového videnia

Jedným z cieľov práce sa bolo zoznámiť s metódami počítačového videnia, medzi ktoré patrí detekcia a sledovanie osôb na obraze. Kapitola opisuje všeobecne rôzne druhy metód a pri niektorých je aj bližšie popísaná tá metóda, ktorá bola využitá v práci.

## 3.1 Metódy detekcie osoby

Metódy detekcie sa stále vyvíjajú a zlepšujú. Zlepšuje sa ich presnosť, rýchlosť a ďalšie faktory. Najmä pri spracovávaní osôb je potrebné brať do úvahy rozmanitú podobu osôb. Osoba môže mať na sebe rôzne typy oblečení, môže mať rôzne predmety ako sú napríklad klobúky alebo tašky. Pre detekciu osôb existujú rozdielne metódy, ktorých detekcia prebieha na inom princípe.


### 3.1.1 Sliding window

Medzi metódy detekcie patrí napríklad metóda, ktorá skenuje celý vstupný obraz pomocou tzv. sliding window. Sliding window sa posúva po obraze a ak sú vo vnútri sliding window splnené určité kritéria, tak nastáva detekcia. Obraz pozostáva z príznakov. Niektoré metódy extrahujú globálne príznaky ako sú hrany v obraze [4] [5] alebo lokálne príznaky, ktoré využíva aj histogram orientovaných gradientov (HOG) [2]. Metódy [4] a [2] boli použité v tejto práci. Nevýhodou metódy detekcie na celom obraze je, že je citlivá na zmeny, ktoré majú rušivý dopad na výsledok a jej výpočet je náročný.

### Histogram orientovaných gradientov

Histogram orientovaných gradientov [2] od autorov Navneeta Dalala a Billa Triggsa sa považuje pravdepodobne za najlepšiu metódu detekcie ľudí v obraze.


K správne rozpoznávaniu potrebuje klasifikátor vhodné príznaky, ktoré je potrebné získať a v metóde orientovaných gradientov sú zastúpené tzv. HOG deskriptormi. Deskriptor pozostáva z väčšieho množstva histogramov, ktoré sa počítajú na základe gradientov. Gradienty sa počítajú pre každý pixel na obraze zvlášť. Tým, že gradienty sú určené lokálnymi bunkami v obraze, tak metóda prekonáva ostatné metódy aj v tom, že nie je náchylná na zmeny globálneho osvetlenia.



Obr. 3.1: Výpočet gradientov z obrazu rozdeleného do 4x4 blokov po 4x4 pixeloch<sup>1</sup>

Prvým krokom je normalizovať hodnoty farieb a hodnoty gamma. Tento krok je možné vynechať, pretože normalizácia sa dosiahne pri vytváraní deskriptora a má nepatrný vplyv na výkon. Takže prvým krokom je možné považovať výpočet gradientu. Výkon detektora je citlivý na spôsoby výpočtu gradientu a v tomto prípade je najjednoduchší spôsob výpočtu najlepším. Jednoduché 1-D [-1, 0, 1] masky sa použijú pri počítaní vo vertikálnom alebo v horizontálnom smere. Pre farebné obrazy sa počítajú gradienty pre každý farebný kanál zvlášť a vyberie sa iba jeden s najväčšou úrovňou.

Druhým krokom je vytváranie histogramov pre každú bunku zvlášť. Kanále histogramu sú určené orientáciou. Každý gradient bunky sa zaradí podľa orientácie do príslušného kanála.



Obr. 3.2: Histogramy určené podľa orientácie gradientu<sup>2</sup>

Kvôli zmenám osvetlenia je nutné histogramy normalizovať. To vyžaduje bunky zoskupiť do väčších blokov. HOG deskriptor je potom vektor normalizovaných histogramov pre jeden blok. Tieto bloky sa prekrývajú, čo znamená, že každá jedna bunka je súčasťou viacerých deskriptorov. Po zoskupení do blokov nastáva normalizácia. Je možné použiť 4 rôzne metódy normalizácie, ktoré sa ukázali najvhodnejšími. Jedna z metód normalizácie je

<sup>1</sup> Prevzaté z <https://gilscvblog.com/2013/08/18/a-short-introduction-to-descriptors/>.

<sup>2</sup> Prevzaté z <https://gilscvblog.com/2013/08/18/a-short-introduction-to-descriptors/>.


$$f = \frac{v}{\sqrt{\|v\|_2^2 + e^2}}, \quad (1)$$

kde  $v$  je nenormalizovaný vektor, ktorý obsahuje všetky histogramy v danom bloku a  $e$  je nejaká malá konštanta. Finálnym krokom je použiť získané deskriptory v klasifikátore.

### Metóda $C^4$

Autori metódy  $C^4$  [4] veria, že kontúra je najužitočnejšou informáciou pri detekcii osoby. Taktiež si myslia, že porovnávanie susedných pixelov je kľúčové k vytvoreniu kontúry.

Integrálny obraz slúži na rýchly výpočet sumy pixelov zo vstupného obrazu. Ak sa pozrieme na akýkoľvek bod  $(x, y)$ , tak jeho integrálna hodnota bude suma všetkých pixelov od tohto bodu až po bod  $(0, 0)$  vo vnútri obdĺžnika.



Obr. 3.3: Výpočet integrálneho obrazu

Sú definované oblasti (A, B, C, D) a body  $(L_1, L_2, L_3, L_4)$  (Obr. 3.3). Hodnota  $L_1$  je suma všetkých pixelov definovaných v oblasti A. Hodnota  $L_2$  je suma všetkých pixelov definovaných v oblastiach A a B. Hodnota  $L_3$  je suma všetkých pixelov definovaných v oblastiach A a C. Hodnota  $L_4$  je suma všetkých pixelov definovaných v oblastiach A, B, C a D. Z toho vyplýva, že výpočet pre oblasť D je  $L_4 + L_1 - L_2 - L_3$ .

Sobelov operátor slúži pre detekciu hrán objektov v obraze. Niekedy je označovaný aj ako Sobelov filter. Operátor sa skladá z dvoch konvolučných jadier o veľkosti  $3 \times 3$ . Jadrá sú navrhnuté tak, aby reagovali na zmenu jasů pixelov. Posúvaním jadier buď vo vertikálnom smere, alebo v horizontálnom smere po obraze v stupňoch šedej, sa zachytia hrany objektov. Následne je pre každý pixel vypočítaná absolútna veľkosť gradientu a orientácia prechodu. Takto vypočítané hodnoty sa spoja do Sobelovho obrazu.

Na Sobelovom obraze sa zostrojuje vizuálny deskriptor s názvom CENTRIST (CENSus TRansform hISTogram), ktorý slúži pre rozpoznávanie osôb. Na Sobelov obraz sa aplikuje tzv. census transformácia. Census transformácia všeobecne slúži k zisteniu intenzity pixelov.

Zisťovanie prebieha v rámci okna v tvare štvorca s rozmermi 3x3 alebo 5x5, kde intenzita stredového pixelu je nahradená pravdivostnou hodnotou. Takto sa postupne po riadkoch zľava doprava porovnáva celý obraz a výsledkom sú pravdivostné hodnoty po celom obraze. Konkrétne v tejto metóde census transformácia vypočíta hodnoty (2), z ktorých je zostavený CENTRIST deskriptor.

$$\begin{array}{cccccc} 32 & 64 & 96 & 1 & 1 & 0 \\ 32 & 64 & 96 & \Rightarrow 1 & & 0 \\ 32 & 32 & 96 & 1 & 1 & 0 \end{array} \Rightarrow (11010110)_2 \Rightarrow 214 \quad (2)$$

K detekcii objektu je použitý CENTRIST deskriptor. Vytvorí sa detekčné okno, ktoré je rozdelené do blokov. V blokoch sa počítajú vektory príznačkov, ktoré obsahujú množstvo hodnôt reprezentujúce objekt. Na vektor sa aplikuje klasifikátor, ktorý rozhodne o prítomnosti objektu. Po skončení procesu vzniknú viaceré detekcie toho istého objektu, ktoré sa v post procese zlúčia do jednej výslednej detekcie objektu.

### 3.1.2 Part detectors

Ďalší typ metódy detekcie rozdelí obraz na časti, z ktorých sa následne extrahujú lokálne príznaky a detekcia sa aplikuje na jednotlivé časti. Také detektory sa nazývajú tzv. part detectors [6] [7]. Každý detektor detekuje svoju časť (napr. hlava, trup, nohy) a finálnym výsledkom detekcie je spojenie týchto častí a vytvorenie celej postavy osoby. Výhodou je, že osoba bude detekovaná aj v prípade, ak je z časti zakrytá.

### 3.1.3 Metóda detekciou pohybu

Metóda detekcie pracuje na princípe odčítania pozadia (Background Subtraction). Odčítanie pozadia klasifikuje pixely obrazu a rozhoduje či patria do pozadia alebo do popredia obrazu. Na popredí obrazu sú zachytené pohybujúce sa osoby, prípadne svetelné zmeny. Výsledky detekcie majú podobu siluet [8] alebo blobov v obraze. Výsledkom operácie odčítania pozadia je binárny obraz, takzvaná maska popredia (Foreground Mask). Na odstránenie pozadia sa v praxi používajú rôzne techniky. Nevýhodou tejto metódy je citlivosť na zmeny osvetlenia a podmienkou je, aby obraz bol zachytený stacionárnou kamerou a pozadie sa nemenilo.

### Modelovanie pozadia zmesami normálnych rozdelení

Jednou z techník modelovania pozadia je zmesami normálnych rozdelení – Mixture of Gaussians (MOG) alebo Gaussians Mixture Model (GMM) [9]. Modely zobrazujú u jednotlivých prvkoch pravdepodobnosti, do akej množiny patria. Priamo nepriradujú prvky do skupiny, len vracajú pravdepodobnosti podľa podobnosti s inými členmi skupiny.

Pre každý pixel je vytvorený model pozostávajúci z minimálne dvoch rozdelení, jedno zodpovedá objektu a druhé pozadiu. Je možné doplniť model o tretie rozdelenie, ktoré zodpovedá tieňu objektu. Pre detekciu objektu sa potom pixel porovnáva s každým rozdelením a je klasifikovaný k príslušnej triede, v tomto prípade k rozdeleniu.


### Morfologické operácie

Po odčítaní pozadia je v obraze veľké množstvo dier, ktoré je nutné vyplniť. Vyplnenie dier sa dosiahne morfologickými operáciami, ktoré pracujú v doméne pixelov. Základnými operáciami sú dilatácia a erózia.

#### Dilatácia

Dilatácia sa používa na vyplnenie dier v obraze, pričom pridá viac šumu do obrazu a rozšíri objekt. Určí sa štrukturálny element a jeho posunom po obraze sa diery zaplňujú. Ak sa objekt dotkne štrukturálneho elementu, potom sa pridá pixel k objektu a rozťahuje objekt o najbližšie pixely. Dilatácia sa dá vyjadriť ako vektorový súčet dvoch množín X a B:

$$X \oplus B = \{p \in e^2 : p = x + b, x \in X, b \in B\} \quad (3)$$




Obr. 3.4: Dilatácia objektu štrukturálnym elementom

#### Erózia

Ďalšou základnou morfologickou operáciou je erózia. Eróziou sa zjednoduší objekt a odstráni šum z obrazu. Pri erózií sa taktiež určí štrukturálny objekt, ktorým sa odstraňuje šum. Erózia sa dá vyjadriť ako vektorový rozdiel dvoch množín X a B:

$$X \ominus B = \{p \in e^2 : p + b \in X \forall b \in B\} \quad (4)$$



Obr. 3.5: Erózia objektu štruktúrnym elementom

Je možnosť vidieť, že výsledný obraz dilatácie (Obr. 3.4) je rovnaký ako obraz pred eróziou (Obr. 3.5), ale napriek tomu dilatácia a erózia nie sú inverznými operáciami.

### 3.1.4 Metóda s viacerými kamerami

Posledná predstavená metóda detekcie používa obraz z viacerých kamier [10]. Podlaha, po ktorej chodia osoby, predstavuje model mapy, ktorý je rozdelený podľa mriežky do políčok. Model mapy je vyjadrený odhad pravdepodobností, či je alebo nie je osoba prítomná na danom políčku. Pracuje sa s viacerými uhlami pohľadu na scénu, čo vyrieši problém s kolíziami s inými osobami a s prekážkami a taktiež vyrieši problém s citlivosťou na osvetlenie.

## 3.2 Metódy sledovania osoby

Úlohou metódy sledovania osoby je nájdenie tej istej osoby v snímkach, ktoré nasledujú po sebe. Pri sledovaní nastávajú rôzne situácie, ktoré je nutné brať do úvahy. Ide o prostredie, v ktorom sa osoba pohybuje. Toto prostredie sa počas sledovania každú snímku obmieňa, či už ide o jemné alebo prudké zmeny. Ak osoba prechádza snímkami veľmi rýchlo, respektíve frekvencia snímok je nízka, je náročnejšie osobu sledovať. Osoba takisto vykonáva rôzne činnosti pri pohybe, rôzne gestikulácie a podobne. Je potrebné brať do úvahy aj rôzne kolízie s ďalšími prekážkami ako sú napríklad steny, stĺpy, ale aj interakcie s inými osobami. Ako aj pre detekciu osoby, tak aj pre sledovanie jej pohybu, existuje niekoľko metód.

### 3.2.1 Absolútny rozdiel

Prvá predstavená metóda sledovania, ktorá bola použitá v prácach [11] [12], sa zaoberá absolútnym rozdielom snímky voči predchádzajúcej snímke. Rozdiel dvoch za sebou idúcich snímok predstavujú pohybujúce sa objekty. Rozdiel sa získa rôznymi metódami odčítania pozadia alebo inými metódami, ktoré dokážu zistiť rozdiel medzi dvoma snímkami.

### 3.2.2 Metóda založená na príznakoch

V metóde sa najprv z obrazu vymodeluje priestor, z ktorého sa získajú príznaky. Príznaky predstavujú vlastnosti, medzi ktoré patria morfológické vlastnosti, histogram farieb a iné.



Osoba je reprezentovaná vektorom týchto príznakov a princíp sledovania spočíva v hľadaní podobného vektora v nasledujúcej snímke. Zástupcom tejto metódy, ktorá bola použitá v práci je tzv. komprimované sledovanie a sledovanie korelačnými filtrami.

### **Komprimované sledovanie**

Autor Kaihua Zhang s kolegami vytvoril algoritmus sledovania objektu [13], ktorý je založený na príznakoch obrazu. Vytvorí sa model príznakov. Model príznakov je všeobecne objekt reprezentovaný príznakmi. Príznyky boli extrahované z komprimovaného priestoru, ktorý bol vytvorený na základe teórie komprimovaného snímania (compressed sensing). Ideou použitia komprimácie je, že pri malom počte náhodne generovaných lineárnych meraní sa informácia uchová a dokáže sa zrekonštruovať.

Pre účel sledovania je potrebné určiť počiatočnú pozíciu objektu. Na každej snímke sa z okolia sledovaného objektu zozbierajú pozitívne vzorky a ďalej od jeho stredu sa zozbierajú negatívne vzorky. Vzorky slúžia k aktualizácii Bayesovho klasifikátora, ktorý ich klasifikuje a zaradí ich do pozadia alebo do popredia. Ďalej sledovanie objektu prebieha tak, že na nasledujúcej snímke sa naznačí pár vzoriek, ktoré by mohli byť potencionálnym objektom. Objektom sledovania je práve jedna vzorka z týchto vzoriek, ktorú klasifikátor vyhodnotí s najvyšším skóre.

### **Sledovanie korelačnými filtrami**

Ďalším zástupcom, ktorý má blízko k typu metódy založenej na príznakoch je sledovanie korelačnými filtrami [14]. Jadrom moderných sledovačov je klasifikátor, ktorý má za úlohu rozlíšiť cieľ od okolitého prostredia. Aby klasifikátor zvládol spracovať každý obraz, tak je typicky natrénovaný s rôznymi veľkosťami vzoriek, ktoré boli popremiestňované po obraze. Také vzorky si poradia s každým prirodzeným obrazom a takisto aj s redundanciou – prekrývajúce pixely sú spojené do jedného. Vzorky sa získavajú vhodným analytickým modelom, ktorý je ďalej bližšie predstavený.

Najprv sa uskutoční lineárna regresia. Ide o grafickú metódu korelácie (vyjadrenie závislosti). Vyráta sa rovnica regresnej krivky, ktorá najlepšie vystihuje umiestnenie priesečníkov hodnôt  $x$  a  $y$ . Vzdialenosť od priamky musí byť čo najmenšia a vypočíta sa metódou najmenších štvorcov. Výpočet vyjadruje rovnica:


$$(f(x_i) - y_i))^2 + \lambda \|w\|^2, \quad (5)$$

kde  $\lambda$  je konštanta, ktorá kontroluje hodnotu  $w$  a  $w$  predstavuje maticu dát vzorky.

Určí sa základná vzorka (pozitívny prípad) a niekoľko ďalších vzoriek vytvorených transláciou (negatívne prípady) základnej vzorky. Tieto vzorky tvoria vektor, s ktorým sa natrénuje klasifikátor. Permutačná matica (6) je operátorom cyklického posunu.

$$P = \begin{bmatrix} 0 & 0 & 0 & \dots & 1 \\ 1 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ 0 & 0 & \dots & 1 & 0 \end{bmatrix} \quad (6)$$

Matica sa posúva a modeluje malé translácie, ktoré je možné zrežovať do jednej veľkej. Vzniká tzv. cirkulatná matica (Obr. 3.6). Ide o špeciálny tvar matice, kedy všetky vstupy zapísané do prvého riadka popisujú celú maticu C typu nxn. Cirkulatnú maticu je možné diagnostikovať pomocou diskkrétnej Fourierovej transformácie, čo zníži využitie pamäte a dobu výpočtu. Cirkulantné matice obohacujú metódu o klasické spracovanie signálov a o moderné korelačné filtre.



Obr. 3.6: Cirkulatná matica a jej modelovanie

Pre lineárnu regresiu je táto formulácia ekvivalentná ku korelačným filtrom. Pre nelineárnu kernel regresiu sa odvodí kernelový korelačný filter (Kernelized Correlation Filter – KCF) a pre viac kanálov je duálny korelačný filter (Dual Correlation Filter – DCF).

### 3.2.3 Lucas-Kanade algoritmus

Jednoduchý algoritmus, ktorý slúži pre výpočet optického toku. Optický tok je založený na myšlienke, že hodnota jasů pixelov v obraze má plynulý prechod, pretože susedné pixely majú približne rovnakú hodnotu jasů. Lucas-Kanade algoritmus dokáže určiť pohyb dôležitých bodov na obraze. Algoritmus predpokladá, že body spĺňajú nasledujúce vlastnosti obrazu:

- Sledovanému bodu medzi snímkami sa hodnota jasů nemení.
- Bod sa pohne o krátku vzdialenosť medzi dvoma snímkami.
- Bod a jeho blízke okolie sa podobne pohybujú.

## TLD sledovanie

Zástupca techniky Lucas-Kanade, ktorý bol použitý v práci, využíva metóda sledovania objektu s názvom Tracking-Learning-Detection (TLD) [15] od autora Zdenka Kalala a jeho kolegov a zahŕňa tri časti:

- sledovanie – sledovanie prebieha na každej snímke, pokiaľ je objekt viditeľný
- detekcia – detektor sa snaží lokalizovať objekt na snímke, aby sa jeho pozícia znova aktualizovala pre sledovanie
- učenie – P-N učenie odhaduje chyby a aktualizuje detektor, aby sa poučil z chýb a nezopakoval ich

Detektor prehľadáva snímku a rozhoduje, či sa objekt na nej nachádza alebo nie. Je to binárny klasifikátor. Zvažuje do úvahy veľké množstvo možností, ako snímku prehľadať s rôznymi veľkosťami objektu a preto klasifikácia musí prebehnúť čo najrýchlejšie. Systém používa tri fázy počas, ktorých sa rozhoduje. Počas prvej sa pomocou odtieňov šedej vyfiltruje 50% možností. Potom nasleduje fáza, v ktorej prebehne porovnávanie pixelov. Poslednou fázou je aplikovanie klasifikátora.

Detektor používa dátovú štruktúru, ktorá reprezentuje objekt. Dátová štruktúra pozostáva z kolekcie pozitívnych a negatívnych možností a používa sa taktiež pre určenie podobnosti konkrétneho miesta s jeho okolím.

Sledovač je založený na Median-Flow sledovači [16] navrhnutý rovnakými autormi. Sledovanie prebieha na každej snímke, pokiaľ je objekt sledovania viditeľný. Sledovač rozhoduje o počte bodov, ktoré sa presunú z bounding boxu z predchádzajúcej snímky. Bounding box je obdĺžnik, ktorý ohraničuje objekt záujmu. Autori použili techniku Lucas-Kanade a jej pyramidovú implementáciu. Median-Flow sledovač zlyháva ak objekt vyjde z obrazu alebo sa príliš rýchlo pohybuje. TLD spája detekciu a sledovanie a kombinuje ich bounding boxy do jedného výsledného.

Detektor používa P-N učenie pre zistenie chýb, aby sa im neskôr vyhol a nezopakoval ich. Učenie používa P-aktualizácie a N-aktualizácie. P-aktualizácie zlepšujú vlastnosti detekcie pozitívnymi príkladmi. Sú založené na tom, že hľadajú spoľahlivú trajektóriu pohybu objektu. N-aktualizácie získavajú pozadie, prekážky a iné negatívne elementy, a tým zvyšujú počet negatívnych príkladov.

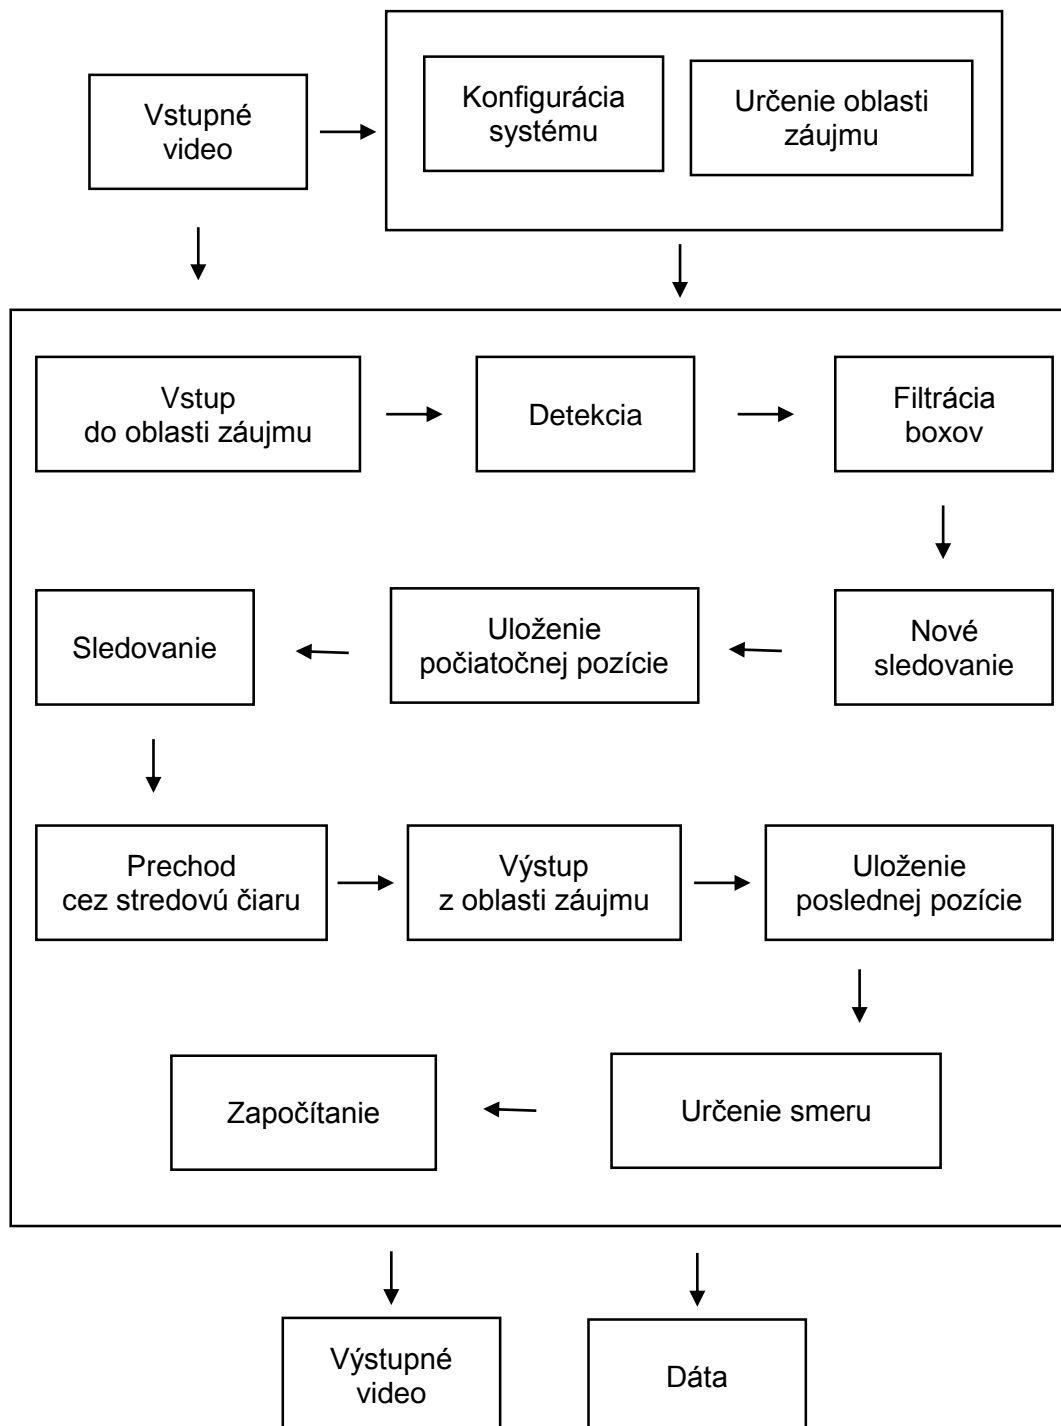
### 3.2.4 Mean-shift

Posledná predstavená metóda bola použitá v prácach [17] [18] a zobrazí body obrazu do viac dimenzionálneho priestoru príznakov. Dimenzie priestoru predstavujú kvantifikovateľné vlastnosti obrazu, medzi ktoré patria súradnice bodov a ich informácia o farbe. Zobrazenie sa vykoná na celý obraz pričom vzniknú na obraze zhluky, ktoré predstavujú jednotlivé objekty. Analýzou tohto obrazu je možné tieto zhluky zlúčiť.

Pri metóde Mean-shift sa zvolí oblasť záujmu – kernel. Na začiatku algoritmu sa zvolí náhodne pozícia a pomocou kernelu sa vypočíta gradient hustoty bodov v danom okolí. Vo vypočítanom smere gradientu posunieme túto pozíciu. Postup sa iteratívne opakuje až do okamihu, kedy sa všetky body zaradia do určitého zhluku.

# 4 Návrh systému

Cieľom bakalárskej práce je navrhnuť systém, ktorý počíta prechody osôb dverami a určí ich smer pohybu.



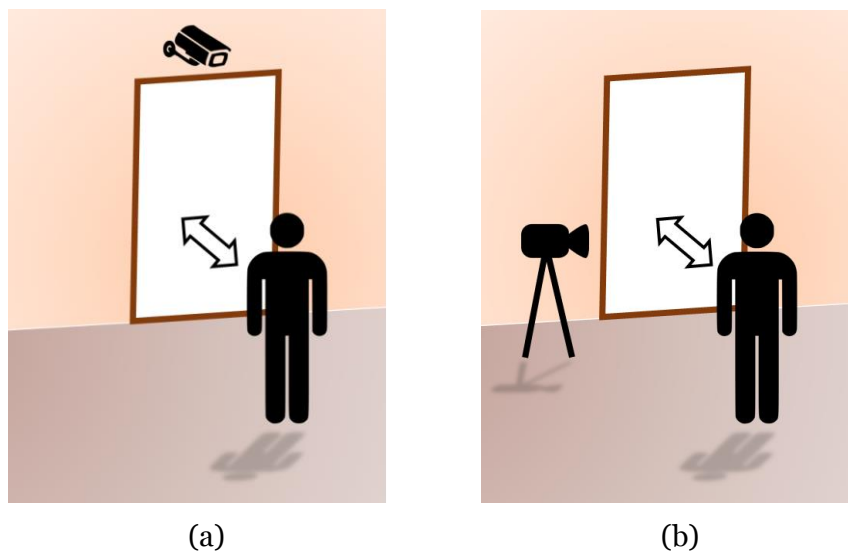
Obr. 4.1: Grafický návrh systému

Najprv je potrebné spracovať zdroj (vstupné video) a pripraviť systém pre proces počítania. Samotný proces počítania pozostáva z detekcie osôb, ktoré vstúpili do oblasti záujmu, zo sledovania ich pohybu cez stredovú čiaru, až pokiaľ nevystúpia z oblasti záujmu. Po výstupe z oblasti záujmu sa osoba započíta a z počiatkovej a z poslednej pozície sa určí smer pohybu osoby. V tejto kapitole je popísaný návrh jednotlivých častí systému (Obr. 4.1) a prepojenie medzi nimi.

## 4.1 Spracovanie zdroja

Súčasťou práce je nasnímať scénu s využitím stacionárnej kamery. Kameru je možné umiestniť priamo nad dvere do miestnosti alebo vedľa dverí, pričom v oboch prípadoch sa sníma priestor pred dverami (Obr. 4.2). Po tomto priestore sa pohybujú osoby.

Systém pracuje v cykle postupne s jednotlivými snímkami, ktoré sú extrahované zo zdroja. Zdrojom môže byť video súbor, sekvencia snímok alebo kamera, ktorá naživo sníma obraz. V jednom cykle sa pracuje s jednou snímkou, ku ktorej sa priradí poradové číslo.



Obr. 4.2: Umiestnenie kamery. Na obrázku a) je umiestnenie kamery nad dverami a na obrázku b) je umiestnenie kamery vedľa dverí.

## 4.2 Reprezentácia osoby

Vhodným riešením poskytujúcim jednoduchú prácu s osobou je použitie bounding boxu. V systéme je osoba reprezentovaná bounding boxom a je hlavnou dátovou štruktúrou systému. Dátová štruktúra bounding boxu obsahuje:

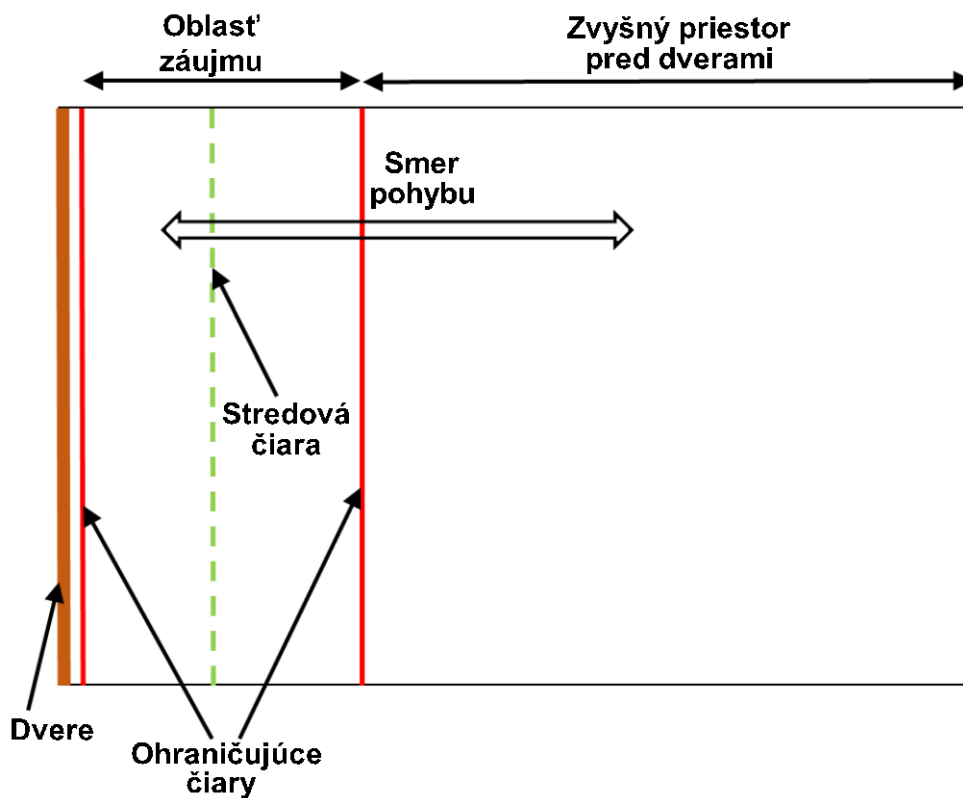
- súradnice x a y ľavého horného bodu

- šírku a výšku
- číslo snímky, na ktorej bol získaný
- príznak určujúci detekciu, sledovanie alebo počítanie

Pozícia bounding boxu na snímke je definovaná jeho šírkou, výškou a súradnicami  $x$  a  $y$  ľavého horného bodu. Osoby môžu byť na rovnakej pozícii v snímke, ale v rôznom čase a je nutné uložiť aj číslo snímky, na ktorej bol bounding box získaný. S bounding boxom sa pracuje pri detekcii, pri sledovaní pohybu a pri počítaní. Aby bolo možné jednoznačne určiť jeho typ, tak ku každému je nastavený príznak určujúci o aký typ bounding boxu ide.


### 4.3 Oblasť záujmu

Osoba sa pohybuje po snímanom priestore, avšak nemusí prejsť dverami. Osoba sa môže tesne pred prechodom dvermi otočiť a vrátiť späť alebo sa vôbec nepriblíži k dverám. Riešením tejto situácie určenie oblasti záujmu. Oblasť záujmu je oblasť na snímke ohraničená dvomi čiarami so stredovou čiarou (Obr. 4.3). Ohraničujúce čiary vymedzujú priestor, na ktorom prebieha proces počítania a stredová čiara pomáha určiť smer pohybu. Orientácia oblasti záujmu závisí od umiestnenia kamery. V prípade kamery umiestnenej vedľa dverí (Obr. 4.2b) je oblasť záujmu vertikálne orientovaná a v prípade kamery umiestnenej nad dverami (Obr. 4.2a) je horizontálne orientovaná. Oblasť záujmu slúži pre rýchlejšiu a presnejšiu prácu systému.



Obr. 4.3: Priestor pred dverami s vertikálne orientovanou oblasťou záujmu

Vstupom osoby do oblasti záujmu (Obr. 4.4a) sa považuje situácia, kedy viac ako polovica bounding boxu sa nachádza v oblasti a výstupom osoby z oblasti záujmu (Obr. 4.4b) sa považuje situácia, kedy viac ako polovica bounding boxu sa nachádza mimo oblasti.



Obr. 4.4: Na obrázku a) je bounding box v oblasti záujmu a na obrázku b) je už mimo oblasti záujmu.



## 4.4 Počítanie a určenie smeru osoby

V nasledujúcich podkapitolách je bližšie popísaný návrh hlavného procesu počítania.

### 4.4.1 Detekcia

Najprv prebehne detekcia osoby na snímke. Výsledkom detekcie je bounding box detekcie. Ak sa box nachádza v oblasti záujmu a má adekvátnu veľkosť, tak sa uloží. Výstupom detektora sú uložené bounding boxy, ktoré sa nachádzajú v oblasti záujmu a majú adekvátnu veľkosť. Po detekcii osoby nasleduje sledovanie jej pohybu.

### 4.4.2 Filtrovanie výsledkov detekcie

Pred zavedením nového sledovania osoby sa najprv novo detekované osoby (bounding boxy) prefiltrujú, aby nedošlo k sledovaniu tej istej osoby. Algoritmus filtrovania spočíva v porovnávaní bounding boxov zo sledovania a z detekcie. Ak sa bounding box zo sledovania zhoduje s bounding boxom z detekcie v poradovom čísle snímky, na ktorej bol box získaný a v jeho pozícii v snímke, tak sa pri zhode bounding box detekcie vyradí a nepoužije sa pri novom sledovaní osoby. Zhoda v pozícii boxov nastane, ak platí vzťah:

$$\left| \left( x_d + \frac{w_d}{2} \right) - \left( x_s + \frac{w_s}{2} \right) \right| \leq t, \quad (7)$$

kde  $x$  je súradnica,  $w$  je šírka bounding boxu detekcie, resp. sledovania a  $t$  je nejaký zadaný prah. Zvyšné boxy z detekcie sa stanú novými počiatočnými boxami sledovania.

### 4.4.3 Sledovanie

Po detekcii osoby a filtrácií boxov začína sledovanie pohybu osoby. Box z detekcie sa použije ako počiatočný box pre sledovanie novej osoby a zároveň sa uloží ako bounding box počítania, ktorý určuje počiatočnú pozíciu danej osoby. Osoba je sledovaná v oblasti záujmu a jej pohyb sa každú snímku uloží v podobe bounding boxu sledovania.

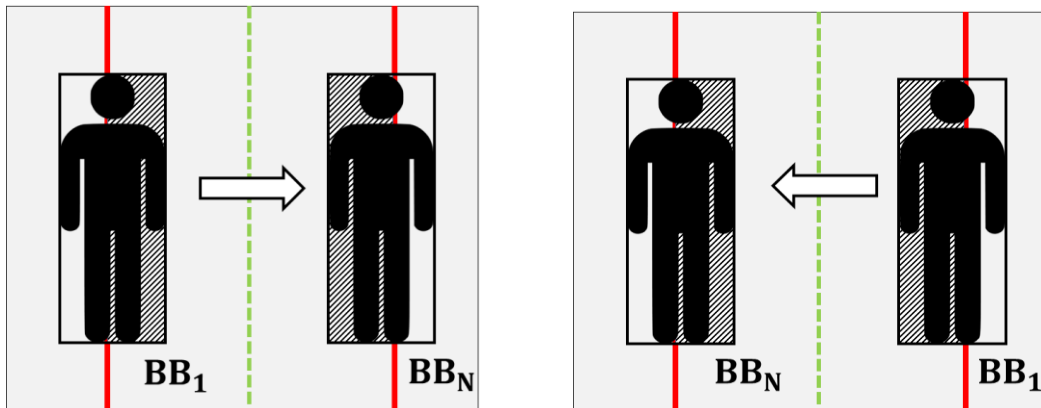
Môže nastať situácia, keď osobu prekryje prekážka na scéne a osoba sa stratí. V takejto situácii sa počká preddefinovaný počet snímok na jej návrat. Pri prekročení limitu čakania na jej návrat sa táto situácia berie ako výstup osoby z oblasti záujmu a nasleduje počítanie.

Výstupom sledovača sú bounding boxy predstavujúce pohyb osôb v oblasti záujmu.

### 4.4.4 Počítanie a určenie smeru

Ak osoba vyjde z oblasti záujmu, jej posledná známa pozícia sa uloží v podobe bounding boxu počítania a nasleduje počítanie. Sú dva typy bounding boxov počítania – počiatočný box a posledný box. Využíja sa stredová čiara v oblasti záujmu, pomocou ktorej sa určí smer pohybu

osoby. Princíp určenia smeru je taký, že ak sa počiatočný box nachádza na opačnej strane od poslednej známej pozície vzhľadom k stredovej čiare, tak sa určí smer osoby (Obr. 4.5) a osoba sa započíta. Avšak v prípade, ak počiatočná pozícia a posledná pozícia sa nachádza na tej istej strane vzhľadom k stredovej čiare – osoba neprešla stredovou čiarou, tak započítanie a určenie smeru osoby neprebehne.



Obr. 4.5: Určenie smeru pohybu. Na obrázku je oblasť záujmu, v ktorej je počiatočný bounding box  $BB_1$ , ktorý bol uložený pri vstupe do oblasti záujmu a posledný bounding box  $BB_N$ , ktorý bol uložený pri výstupe osoby z oblasti záujmu. Osoba prešla cez čiaru a bol určený jej smer pohybu.

## 5 Implementácia systému

Systém bol implementovaný podľa návrhu popísaného v predchádzajúcej kapitole 4. s využitím jazyka C/C++ a knižnice OpenCV 2.4.9<sup>3</sup>.

Pri spustení programu je potrebné zadať jeden parameter, ktorým je cesta ku konfiguračnému súboru. Konfiguračný súbor obsahuje nastavenia, ktoré je nutné nastaviť pred behom hlavného algoritmu. V nastaveniach sú zahrnuté najmä rôzne prahy, cesta k zdroju, typ metódy detekcie a sledovania, ktorá bude použitá a informácie o oblasti záujmu.

Metóda detekciou pohybu a metóda HOG bola implementovaná pomocou funkcií z knižnice OpenCV. Pre detekciu osôb metódou C<sup>4</sup>, bola použitá implementácia od autora Jianxin Wu<sup>4</sup>. Pri metódach sledovania bola použitá knižnica OpenTLD<sup>5</sup>, zdrojové kódy kompresívneho sledovania<sup>6</sup> a knižnica KCFcpp<sup>7</sup>, ktorá zahŕňa implementáciu sledovania korelačnými filtrami. Pre návrh systému boli prevzaté metódy detekcie upravené tak, aby ich výstup bol vo forme bounding boxov a metódy sledovania, aby pracovali s bounding boxami.



Obr. 5.1: Výstupné video

<sup>3</sup> <http://opencv.org/>

<sup>4</sup> <https://sites.google.com/site/wujx2001/home/c4>


<sup>5</sup> <http://www.gnebehay.com/tld/>

<sup>6</sup> <http://www4.comp.polyu.edu.hk/~cslzhang/CT/CT.htm>

<sup>7</sup> <https://github.com/joaofaro/KCFcpp>

Výstupné video (Obr. 5.1) obsahuje definovanú oblasť záujmu a jej ohraničujúce čiary vyznačené oranžovou a fialovou čiarou a stredovú čiaru vyznačenú modrou čiarou. Na okraji videa sa nachádzajú dvere, cez ktoré osoby prechádzajú. V horných rohoch videa je počet prechodov v odpovedajúcom smere. Napríklad pri prechode osoby vpravo sa zvýši počet prechodov na pravej strane a podobne. Bounding boxy detekcie sú vyznačené zelenou farbou a bounding boxy sledovania sú vyznačené červenou farbou. Pri dolnom rohu bounding boxu sledovania je identifikačné číslo osoby.

Výstupné dáta sa ukladajú do textového súboru. Jeden riadok textového súboru je jeden prechod osoby. Informácia o prechode pozostáva z poradového čísla snímky a z písmena, ktoré znamená smer pohybu osoby. Po skončení systému je možné výstupné dáta spracovať skriptom, ktorý vytvorí štatistiku (Obr. 5.2, Tabuľka 5.1).



Obr. 5.2: Ukážka grafu po skončení programu – počet osôb prejdenných za každú minútu

<b>typ štatistiky</b>	<b>čas [min]</b>	<b>počet osôb</b>
najmenšia prevádzka smerom von	2., 4.	2
najmenšia prevádzka smerom dovnútra	10.	0
najväčšia prevádzka smerom von	17.	6
najväčšia prevádzka smerom dovnútra	18.	4
priemerná prevádzka smerom von	–	6
priemerná prevádzka smerom dovnútra	–	5
celkový počet ľudí, ktorí prešli smerom von	–	59
celkový počet ľudí, ktorí prešli smerom dovnútra	–	53

Tabuľka 5.1: Ukážka štatistiky po skončení programu


# 6 Vyhodnotenie systému

Jeden z cieľov práce bolo zaobstarať vhodnú dátovú sadu a vyhodnotiť na nej systém. Podkapitoly obsahujú popis dátovej sady, na ktorej bolo vykonané vyhodnotenie a samotné vyhodnotenie systému.


## 6.1 Dátová sada

Referenčná dátová sada (Obr. 6.1) bola získaná stacionárnou kamerou, ktorá bola umiestnená vedľa dverí (Obr. 2.1b). Osoby prechádzali cez dvere menzy počas rušnej obedovej prestávky. Na 6651 snímkach bolo zachytených 90 osôb, ktoré prešli dverami. Zachytené boli aj osoby, ktoré vstúpili do oblasti záujmu, ale neprešli dverami a pohybovali sa po priestore pred kamerou. Dátová sada obsahuje všetky výnimočné situácie, ktoré môžu nastať pri pohybe osôb cez dvere. Obsahuje osoby, ktoré sa prekrývali, zastavili alebo rýchlo prebehli pred kamerou.


Dátová sada bola anotovaná tak, že jednotlivé snímky boli očíslované poradovým číslom. Pri výstupe osoby z oblasti záujmu sa uložilo poradové číslo snímky a uložil sa smer pohybu, ktorý vykonala. S takto anotovanou dátovou sadou sa porovnal výstup systému pri vyhodnotení.



Obr. 6.1: Referenčná dátová sada, na ktorej prebehlo vyhodnotenie – vchod do menzy



(a)



(b)



(c)



(d)

Obr. 6.2: Ďalšie dátové sady s oblastami záujmu

## 6.2 Výsledky

Na vyhodnotenie boli použité ROC (receiver operating characteristic) krivky. (Obr. 6.3, Obr. 6.4, Obr. 6.5). Vertikálna os označuje true positive rate a horizontálna os označuje false positive rate. Hodnoty boli vypočítané podľa vzorcov:


$$\text{true positive rate} = \frac{\text{positives correctly classified}}{\text{total positives}} \quad (8)$$

$$\text{false positive rate} = \frac{\text{negatives incorrectly classified}}{\text{total negatives}} \quad (9)$$

Hodnota positives correctly classified označuje počet správne započítaných prechodov, total positives označuje celkový počet prechodov, negatives incorrectly classified označuje počet nesprávne započítaných prechodov a total negatives označuje počet správne nezapočítaných prechodov.

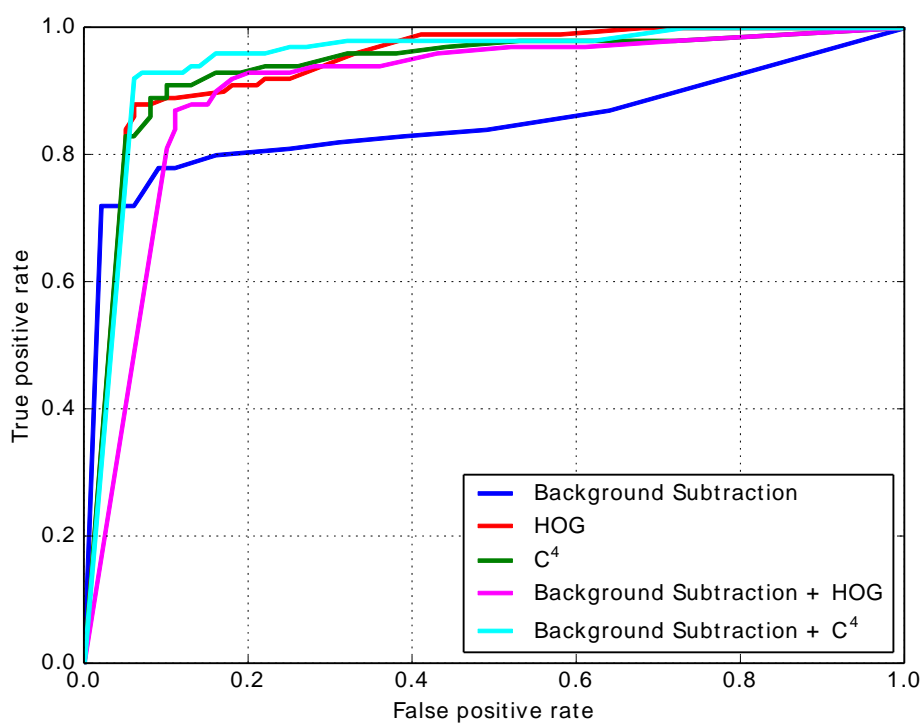
Pri vyhodnotení boli menené prahy v systéme. Menil sa prah vo vzorci (7), ktorý určoval vzdialenosť stredov bounding boxov pri filtrácii a rozhodoval, či sa jedná o novú osobu alebo

už sledovanú osobu. Zároveň sa menil aj prah vzdialenosti, ktorú musela osoba prejsť, aby sa jej pohyb určil ako prechod cez stredovú čiaru oblasti záujmu.




Obr. 6.3: ROC krivky kompresívneho sledovania (KS)






Obr. 6.4: ROC krivky sledovania korelačnými filtermi (SKF)



Obr. 6.5: ROC krivky TLD

Využilo sa vyhodnotenie ROC kriviek a systém sa spustil s prahmi, ktoré patria bodu na ROC krivke s najlepším výsledkom. Výstup systému sa zaznamenal do tabuliek, ktoré sa nachádzajú v prílohe a z týchto údajov sa zostrojil graf (Obr. 6.6). Úspešnosť bola percentuálne vyjadrená počtom správne započítaných osôb z celkového počtu 90 osôb, ktoré prešli dverami.



Obr. 6.6: Graf úspešnosti


## 6.3 Diskusia

Z grafu (Obr. 6.6) je vidieť, že detekcia pohybu má nízku úspešnosť (72%–80%). Metóda detekcie pohybu zlyháva pri hustom prechode osôb, kedy osoby prechádzajúce blízko seba sú zlúčené do jednej detekcie (Obr. 6.7). Taktiež zlyháva v niektorých prípadoch, kedy pri otvorení dvier nastane zmena osvetlenia v miestnosti, čo má vplyv na modelovanie pozadia.

Naopak je z grafu vidieť, že ostatné hodnoty úspešnosti systému sú vyššie (88%–97%). K úspešnému započítaniu prechodu osoby dvermi prispieva vhodne definovaná oblasť záujmu. Systém zlyháva pri vzdialenosti medzi ohraničujúcou čiarou a stredovou čiarou, ktorá je menšia ako polovica šírky bounding boxu osoby. Pri väčšej vzdialenosti sa správne určí vstup a výstup osoby z oblasti záujmu. Okrem určenia smeru má stredová čiara aj iný význam. Použitím stredovej čiary sa systém vyhne situáciám, kedy osoba vstúpi do oblasti záujmu, ale dverami neprejde.

Úspešnosť nebola 100%, pretože systém zlyháva pri započítaní prechodu osoby, ktorá je prekrytá inou osobou (Obr. 6.8) alebo pohyb osoby je príliš rýchly. Pri strate osoby systém počká na jej návrat toľko snímok, koľko by jej trvalo prejsť celú oblasť záujmu v prípade, ak by sa nestratila. Pri nižšom počte systém zlyhával a vyšší počet by systém zbytočne spomalil.

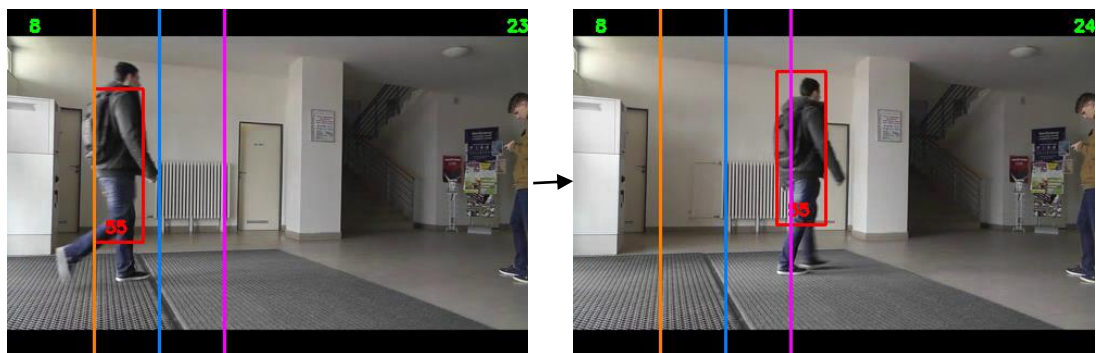
Systém zvláda real time počítať prechody bez straty výkonu a presnosti. Vhodným rozšírením by bolo rozpoznanie osoby, kedy by systém nie len určil počet osôb v miestnosti, ale taktiež by určil, kto konkrétne prešiel dverami.



Obr. 6.7: Chybný prípad systému — nesprávna detekcia vstupu osoby do oblasti záujmu pri metóde detekcie pohybu. Na obrázku a) je vidieť výstup metódy detekcie pohybu a na obrázku b) je vidieť výsledok detekcie.



Obr. 6.8: Chybný prípad systému, kedy osoba bola prekrytá inou osobou. Vľavo prešli 3 osoby a systém ich započítal len 2.



(a)



(b)

Obr. 6.9: Bezchybné prípady systému. Na obrázku a) osoba č.55 prešla vpravo a pravé číslo sa zvýšilo z 23 na 24. Na obrázku b) osoba č.91 prešla vľavo a ľavé číslo sa zvýšilo z 21 na 22.

## 7 Záver

Výsledkom bakalárskej práce je funkčný systém pre počítanie prechodov osôb dverami. Pri vhodnom určení oblasti záujmu, systém dokáže správne určiť počet navštívených osôb a počet osôb, ktoré miestnosť opustili. Taktiež dokáže zmerať prevádzku v miestnosti, v ktorom čase bola miestnosť najviac navštevovaná a naopak, v ktorom bola najmenej navštevovaná. Veľký prínos má aj to, že dokáže pracovať real time a ihneď získava informáciu o prechode osoby. Úspešnosť systému je v najlepšom prípade až 97%.

Zadanie práce zahŕňa štúdium metód počítačového videnia ako sú metódy detekcie a sledovania, návrh a implementáciu systému, ktorý dokáže určiť koľko ľudí prešlo dverami s určením smeru pohybu. Zadanie zahŕňalo zaobstaranie dátovej sady, na ktorej sa vykonalo vyhodnotenie systému. Jednotlivé požiadavky boli splnené tak, že boli naštudované metódy detekcie a sledovania osoby, bol navrhnutý a implementovaný systém v jazyku C/C++ a bola zaobstaraná dátová sada, na ktorej bolo vykonané vyhodnotenie. K práci bol vytvorený plagát a prezentačné video.

Aplikácia poskytuje rozšírenie v podobe rozpoznávania osôb, ktoré navštívili miestnosť.

# Literatúra

1. THALER, M. a W. BAILER. Real-time Person Detection and Tracking in Panoramic Video. In: *Computer Vision and Pattern Recognition Workshops (CVPRW), 2013 IEEE Conference on* [online]. IEEE, 2013, s. 1027 - 1032 [cit. 2015-12-10]. Dostupné z: [http://www.cv-foundation.org/openaccess/content\\_cvpr\\_workshops\\_2013/W19/papers/Thaler\\_Real-Time\\_Person\\_Detection\\_2013\\_CVPR\\_paper.pdf](http://www.cv-foundation.org/openaccess/content_cvpr_workshops_2013/W19/papers/Thaler_Real-Time_Person_Detection_2013_CVPR_paper.pdf)
2. DALAL, N. a T. BILL. Histograms of Oriented Gradients for Human Detection. In: *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, sv. I [online]. San Diego, CA, USA: IEEE, 2005, s. 886 - 893 [cit. 2015-12-21]. Dostupné z: <https://lear.inrialpes.fr/people/triggs/pubs/Dalal-cvpr05.pdf>
3. YU, S. et al. A robust method for detecting and counting people. In: *Audio, Language and Image Processing, 2008. ICALIP 2008. International Conference on* [online]. Shanghai: 2008, s. 1545 - 1549 [cit. 2016-04-19]. Dostupné z: <http://wenku.baidu.com/view/aed59e3987c24028915fc351>
4. JIANXIN, W. G. CHRISTOPHER a M.. R. JAMES. Real-Time Human Detection Using Contour Cues. In: *Proc. The 2011 IEEE Int'l Conference on Robotics and Automation* [online]. Shanghai: IEEE, 2011, s. 860-67 [cit. 2016-04-06]. Dostupné z: [https://smartechnology.gatech.edu/bitstream/handle/1853/44693/ICRA\\_final.pdf](https://smartechnology.gatech.edu/bitstream/handle/1853/44693/ICRA_final.pdf)
5. PAPAGEORGIOU, C. a T. POGGIO. A Trainable Pedestrian Detection system. In: *International Journal of Computer Vision*. 2000, s. 15-33.
6. BO, W. a N. RAM. Detection of Multiple, Partially Occluded Humans in a Single Image by Bayesian Combination of Edgelet Part Detectors. In: *IEEE International Conference on Computer Vision* [online]. Los Angeles: 2005, s. 90-97 [cit. 2016-04-08]. Dostupné z: <http://iris.usc.edu/outlines/papers/2005/wu-nevatia-iccv.pdf>
7. MIKOLAJCZYK, K. C. SCHMID a A. ZISSERMAN. Human detection based on a probabilistic assembly of robust part detectors. In: *8th European Conference on Computer Vision, Prague, Czech Republic, May 11-14, 2004. Proceedings, Part I*, sv. 3021 [online]. Springer Berlin Heidelberg, 2004, s. 69-82 [cit. 2016-04-04]. Dostupné z: [http://nichol.as/iss/mikolajczyk2004\\_eccv\\_probabilistic\\_assembly.pdf](http://nichol.as/iss/mikolajczyk2004_eccv_probabilistic_assembly.pdf)
8. BARNICH, O. S. JODOGNE a M. VAN DROOGENBROECK. Robust analysis of silhouettes by morphological size distributions. In: *Advanced Concepts for Intelligent Vision Systems*. 2006, s. 734-45.
9. ZIVKOVIC, Z. Improved Adaptive Gaussian Mixture Model for Background Subtraction. In: *Pattern Recognition, 2004. ICPR 2004. Proceedings of the 17th International*

- Conference on*, sv. 2. 2004, s. 28 - 31 [cit. 2016-04-17]. Dostupné z: <http://www.zoranz.net/Publications/zivkovic2004ICPR.pdf>
10. FLEURET, F. et al. Multi-Camera People Tracking with a Probabilistic Occupancy Map. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2008, s. 267 - 282 [cit. 2016-04-08]. Dostupné z: <http://infoscience.epfl.ch/record/145991/files/FleuretBLFo8.pdf>
  11. PRABHAKAR, N. et al. Object Tracking Using Frame Differencing and Template Matching. In: *Research Journal of Applied Sciences, Engineering and Technology* [online]. Singhal: 2012, s. 5497-501 [cit. 2016-04-20]. Dostupné z: <http://maxwellsci.com/print/rjaset/v4-5497-5501.pdf>
  12. SINGLA, N. Motion Detection Based on Frame Difference Method. In: *International Journal of Information & Computation Technology* [online]. 2014, s. 1559-65 [cit. 2016-04-20]. Dostupné z: [http://www.ripublication.com/irph/ijict\\_spl/ijictv4n15spl\\_10.pdf](http://www.ripublication.com/irph/ijict_spl/ijictv4n15spl_10.pdf)
  13. KAIHUA, Z. Z. LEI a Y. MING-HSUAN. Real-time compressive tracking. In: A. Fitzgibbon et al. (Eds.): *ECCV 2012, Part III* [online]. 2012, s. 866–79 [cit. 2016-04-08]. Dostupné z: [http://www4.comp.polyu.edu.hk/~cslzhang/CT/eccv\\_ct\\_camera.pdf](http://www4.comp.polyu.edu.hk/~cslzhang/CT/eccv_ct_camera.pdf)
  14. HENRIQUES, J. F. et al. High-Speed Tracking with Kernelized Correlation Filters. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence*, sv. 37 [online]. 2015, s. 583-96 [cit. 2016-04-21]. Dostupné z: [http://www.robots.ox.ac.uk/~joao/publications/henriques\\_tpami2015.pdf](http://www.robots.ox.ac.uk/~joao/publications/henriques_tpami2015.pdf)
  15. KALAL, Z. K. MIKOLAJCZYK a J. MATAS. Tracking-Learning-Detection. In: *Pattern Analysis and Machine Intelligence*.. 2012, s. 1409-22.
  16. KALAL, Z. K. MIKOLAJCZYK a J. MATAS. Forward-Backward Error: Automatic Detection of Tracking Failures. In: *International Conference on Pattern Recognition*. 2010, s. 23-26.
  17. AVIDAN, S. Ensemble Tracking. In: *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, sv. II. 2005. ISBN 0-7695-2372-2.
  18. EMAMI, E. Online failure detection and correction for CAMShift tracking algorithm. In: *2013 Iranian Conference on Machine Vision and Image Processing (MVIP)*. 2013, s. 180–83.

# Zoznam príloh

Príloha A: DVD

Príloha B: Tabuľky rýchlostí

Príloha C: Tabuľky úspešností

## Príloha A

Obsah DVD:

pisomná správa\ – písomná správa vo formáte PDF, zdrojový tvar písomnej správy

zdrojové texty programu\ – zdrojové kódy programu, dátové sady, konfiguračné súbory

plagát a video\ – prezentačné video a plagát

readme.txt – návod k inštalácií



# Príloha B

typ detekcie	čas [s]	snímky [počet/s]
$C^4$	532	12
HOG	218	30
Odčítanie pozadia	96	68
Odčítanie pozadia + $C^4$	232	28
Odčítanie pozadia + HOG	116	56

Tabuľka B.1: Metódy detekcie s metódou sledovania CT

typ detekcie	čas [s]	snímky [počet/s]
$C^4$	530	12
HOG	223	29
Odčítanie pozadia	105	62
Odčítanie pozadia + $C^4$	241	27
Odčítanie pozadia + HOG	130	50

Tabuľka B.2: Metódy detekcie s metódou sledovania KCF

typ detekcie	čas [s]	snímky [počet/s]
$C^4$	628	10
HOG	312	21
Odčítanie pozadia	125	52
Odčítanie pozadia + $C^4$	289	23
Odčítanie pozadia + HOG	157	52

Tabuľka B.3: Metódy detekcie s metódou sledovania TLD

# Príloha C

typ detekcie	počet osôb	úspešnosť
Background Subtraction	72	80%
HOG	83	92%
$C^4$	86	95%
Background Subtraction + HOG	83	92%
Background Subtraction + $C^4$	87	97%

Tabuľka C.1: Vyhodnotenie úspešnosti s komprimovaným sledovaním

typ detekcie	počet osôb	úspešnosť
Background Subtraction	65	72%
HOG	80	89%
$C^4$	80	89%
Background Subtraction + HOG	79	88%
Background Subtraction + $C^4$	85	94%

Tabuľka C.2: Vyhodnotenie úspešnosti so sledovaním korelačnými filtermi

typ detekcie	počet osôb	úspešnosť
Background Subtraction	70	78%
HOG	84	93%
$C^4$	85	94%
Background Subtraction + HOG	83	92%
Background Subtraction + $C^4$	82	91%

Tabuľka C.3: Vyhodnotenie úspešnosti s TLD