

Slovenská technická univerzita v Bratislave
Fakulta informatiky a informačných technológií

FIIT-5208-64388

Bc. Štefan Linner

VIZUÁLNA DETEKCIA OHŇA A DYMU
METÓDAMI POČÍTAČOVÉHO VIDENIA

Diplomová práca

Študijný program: Informačné systémy

Študijný odbor: 9.2.6 Informačné systémy

Miesto vypracovania: Ústav aplikovanej informatiky FIIT STU v Bratislave

Vedúci práce: Ing. Vanda Benešová, PhD.

máj 2015

FIIT - 5208 - 64388

Zadanie diplomovej práce

Meno študenta: **Bc. Štefan Linner**

Študijný program: Informačné systémy

Študijný odbor: Informačné systémy

Názov práce: **Vizuálna detekcia ohňa a dymu metódami počítačového videnia**

Samostatnou výskumnou a vývojovou činnosťou v rámci predmetov Diplomový projekt I, II, III vypracujte diplomovú prácu na tému, vyjadrenú vyššie uvedeným názvom tak, aby ste dosiahli tieto ciele:

Všeobecný cieľ:

Vypracovaním diplomovej práce preukážte, ako ste si osvojili metódy a postupy riešenia relatívne rozsiahlych projektov, schopnosť samostatne a tvorivo riešiť zložité úlohy aj výskumného charakteru v súlade so súčasnými metódami a postupmi študovaného odboru využívanými v príslušnej oblasti a schopnosť samostatne, tvorivo a kriticky pristupovať k analýze možných riešení a k tvorbe modelov.

Špecifický cieľ:

Vytvorte riešenie zodpovedajúce návrhu textu zadania, ktorý je prílohou tohto zadania. Návrh bližšie opisuje tému vyjadrenú názvom. Tento opis je záväzný, má však rámcový charakter, aby vznikol dostatočný priestor pre Vašu tvorivosť.

Riadte sa pokynmi Vášho vedúceho.

Pokiaľ v priebehu riešenia, opierajúc sa o hlbšie poznanie súčasného stavu v príslušnej oblasti, alebo o priebežné výsledky Vášho riešenia, alebo o iné závažné skutočnosti, dospejete spoločne s Vaším vedúcim k presvedčeniu, že niečo v texte zadania a/alebo v názve by sa malo zmeniť, navrhnete zmenu. Zmena je spravidla možná len pri dosiahnutí kontrolného bodu.

Miesto vypracovania: Ústav aplikovanej informatiky FIIT STU v Bratislave

Vedúci práce: **Ing. Vanda Benešová, PhD.**

Termíny odovzdania:

podľa harmonogramu štúdia platného pre semester, v ktorom máte príslušný predmet (Diplomový projekt I, II, III) absolvovať podľa Vášho študijného plánu

Predmety odovzdania:

V každom predmete dokument podľa pokynov na www.fiit.stuba.sk v časti:
home > Informácie o > štúdiu > organizácia štúdia > diplomový projekt.

V Bratislave dňa 17. 2. 2014



prof. Ing. Pavol Návrat, PhD.
riaditeľ Ústavu informatiky a softvérového
inžinierstva

Návrh zadania diplomovej práce

Finálna verzia do diplomovej práce¹

Študent:

Meno, priezvisko, tituly: Štefan Linner, Bc.
Študijný program: Informačné systémy
Kontakt: linner.stefan@gmail.com

Výskumník:

Meno, priezvisko, tituly: Vanda Benešová, Ing. PhD.

Projekt:

Názov: Vizualna detekcia ohňa a dymu metódami počítačového videnia
Názov v angličtine: Visual fire and smoke detection using computer vision methods
Miesto vypracovania: Ústav aplikovanej informatiky, FIIT STU, Bratislava
Oblasť problematiky: počítačové videnie

Text návrhu zadania²

Systémy využívajúce metódy počítačového videnia sa stále viac uplatňujú v úlohách z oblasti bezpečnosti, napr. automatická vizuálna identifikácia osôb, automatické vizuálne systémy pre zvyšovanie bezpečnosti automobilovej premávky a pod. Taktiež môžu byť automatické vizuálne systémy úspešne použité pri monitorovaní mimoriadnych udalostí, napr. požiaru v lesných porastoch.

V špeciálnych prípadoch, ako napr. vo veľkých výrobných halách, je taktiež vhodné pre zistenie prítomnosti dymu a ohňa použiť vizuálne metódy automatickej detekcie. Z pohľadu počítačového videnia je daná úloha špeciálny prípad detekcie objektov na základe farby, pohybu a detekcie pozadia.

Analyzujte doteraz publikované metódy pre vizuálnu detekciu dynamicky sa meniacich objektov v obraze z kamery. Sústreďte sa predovšetkým na metódy detekcie s použitím informácie o farbe a vytvorenie modelu pohybu.

Navrhňte metódy detekcie objektov vo videu, ktoré môžu byť využité pre danú aplikáciu. Tieto metódy implementujte s použitím knižnice OpenCV tak, aby vyhodnotenie bolo možné skoro v reálnom čase. Ako zdroj signálu použite video z bezpečnostných kamier.

Experimentálne overte navrhnuté metódy z pohľadu úspešnosti detekcie ako i z pohľadu časovej náročnosti výpočtu. Pri návrhu i vyhodnocovaní predpokladajte možné zmeny svetelných podmienok, pohyb rušivých objektov a pod. Výsledky vyhodnoťte porovnaním s doteraz známymi a publikovanými metódami detekcie, ako je napr. detekcia s použitím štatistického modelu farby.

¹ Vytlačiť obojstranne na jeden list papiera

² 150-200 slov (1200-1700 znakov), ktoré opisujú výskumný problém v kontexte súčasného stavu vrátane motivácie a smerov riešenia

Literatúra³

- BORGES, P., MAYER, J., IZQUIERDO, E.: Efficient visual fire detection applied for video retrieval. In: 16th European Signal Processing Conference (EUSIPCO 2008), Lausanne, Switzerland. 2008.
- CELIK, T., et al.: Fire detection using statistical color model in video sequences. In: Journal of Visual Communication and Image Representation, 2007, 18.2: 176-185.

Vyššie je uvedený návrh diplomového projektu, ktorý vypracoval(a) Bc. Štefan Linner, konzultoval(a) a osvojil(a) si ho Ing. Vanda Benešová, PhD. a súhlasí, že bude takýto projekt viesť v prípade, že bude pridelený tomuto študentovi.

V Bratislave dňa 21.1.2014



Podpis študenta



Podpis výskumníka

Vyjadrenie garanta predmetov Diplomový projekt I, II, III

Návrh zadania schválený: áno / nie⁴

Dňa: 14. 2. 2014



Podpis garanta predmetov

³ 2 vedecké zdroje, každý v samostatnej rubrike a s údajmi zodpovedajúcimi bibliografickým odkazom podľa normy STN ISO 690, ktoré sa viažu k téme zadania a preukazujú výskumnú povahu problému a jeho aktuálnosť (uvedte všetky potrebné údaje na identifikáciu zdroja, pričom uprednostnite vedecké príspevky v časopisoch a medzinárodných konferenciách)

⁴ Nehodiace sa prečiarknite

ANOTÁCIA

Slovenská technická univerzita v Bratislave

FAKULTA INFORMATIKY A INFORMAČNÝCH TECHNOLOGIÍ

Študijný program: INFORMAČNÉ SYSTÉMY

Autor: Bc. Štefan Linner

Diplomový projekt: Vizuálna detekcia ohňa a dymu metódami počítačového videnia

Vedenie diplomového projektu: Ing. Vanda Benešová, PhD.

máj, 2015

Hlavný cieľ tejto práce je automaticky detegovať oheň a dym vo videu, s využitím metód počítačového videnia, implementovaných v reálnom čase pomocou knižnice OpenCV. Výsledné riešenie musí byť aplikovateľné v existujúcich bezpečnostných kamerových systémoch, čo v konečnom dôsledku znamená pri použití bežných priemyselných alebo domácych kamier. Nutnou podmienkou riešenia je použitie statickej kamery. Z pohľadu počítačového videnia a spracovania obrazu sa jedná o problém detekcie dynamicky meniaceho sa objektu na základe jeho farby a pohybu. V práci sú analyzované metódy detekcie pozadia, ktoré pri použití statickej kamery efektívne segmentujú dynamické objekty vo video-sekvenciách. Ďalej sú analyzované metódy detekcie farby, spolu s teoretickým základom o vnímaní farby, pomocou ktorých je možné bližšie určiť podozrivé oblasti v už segmentovaných objektoch. Následne uvedené metódy detekcie pohybu, ktoré podozrivé oblasti ďalej analyzujú a definitívne prehlasujú za oheň, prípadne dym. Existujúce riešenia v oblasti detekcie ohňa a dymu sú rovnako súčasťou analýzy, po ktorej je predstavený postup navrhovaného riešenia. Podstatnou časťou práce je navrhnutá detekcia pohybu ohňa z pohľadu jedného bodu záujmu a následne z pohľadu zhľadu vektorov. Výsledné metódy detekcie pohybu je možné použiť samostatne pri detegovaní odlišne sfarbených plameňov ohňa alebo pri použití čierneho-bielych kamier.

ANNOTATION

Slovak University of Technology Bratislava

FACULTY OF INFORMATICS AND INFORMATION TECHNOLOGIES

Degree Course: COMPUTER SYSTEMS

Author: Bc. Štefan Linner

Diploma project: Visual fire and smoke detection using computer vision methods

Supervisor: Ing. Vanda Benešová, PhD.

2015, May

The main aim of this thesis is to automatically detect fire and smoke in video, using computer vision methods, implemented in real-time with aid of the OpenCV library. Proposed solution must be applicable in existing security systems, meaning with the use of regular industrial or personal video cameras. Necessary solution precondition is that the camera is static. Given a computer vision and image processing point of view, stated problem corresponds to detection of dynamically changing object, based on his color and moving features. Background detection methods are analyzed in this work. While static cameras are utilized, these methods provide effective segmentation of dynamic objects in a video sequence. Additional analyzed methods are based on color detection, along with theoretical fundamentals about color and machine color perception. With help of these methods, candidate fire-like regions of segmented objects are determined. Motion detection methods are introduced as well, which further analyze these candidate regions and eventually declare the region as fire or possibly smoke. Existing approaches in this field are also part of analysis, following the proposed solution strategy. Important part of this work consists of two motion detection approaches, first based on one local feature point and second based on motion vectors cluster. Resulting detection methods can be used individually to detect unusually colored flames or flames in monochromatic video.

Čestné vyhlásenie

Vyhlasujem, že som diplomovú prácu "Vizuálna detekcia ohňa a dymu metódami počítačového videnia" vypracoval samostatne, pod odborným vedením Ing. Vandy Benešovej, PhD., a použil som iba uvedené zdroje.

V Bratislave, dňa

.....

Bc. Štefan Linner

Pod'akovanie

Touto cestou by som chcel poďakovať vedúcej práce, Ing. Vande Benešovej, PhD., za cenné rady a usmernenie pri písaní tejto záverečnej práce. Jej často nevídaný entuziazmus a ochota pri práci so študentami motivuje k lepším výsledkom nejedného z nich.

Veľká vďaka patrí aj rodičom za ich nekonečnú pomoc, podporu a trpezlivosť a v neposlednom rade aj chápavej a milujúcej priateľke.

Obsah

1	ÚVOD	1
2	ANALÝZA PROBLÉMU	3
2.1	DETEKCIA NA ZÁKLADE POZADIA	3
2.1.1	<i>Problémy detekcie pozadia.....</i>	<i>5</i>
2.1.2	<i>Základné modelovanie pozadia</i>	<i>6</i>
2.1.3	<i>Štatistické modelovanie pozadia</i>	<i>7</i>
2.2	DETEKCIA NA ZÁKLADE FAREBNÉHO MODELU	10
2.2.1	<i>Farba</i>	<i>11</i>
2.2.2	<i>Farebné priestory</i>	<i>14</i>
2.3	DETEKCIA POHYBU	17
2.3.1	<i>Lokálne príznaky.....</i>	<i>18</i>
2.4	EXISTUJÚCE RIEŠENIA	20
2.4.1	<i>Detekcia ohňa.....</i>	<i>21</i>
2.4.2	<i>Detekcia dymu.....</i>	<i>24</i>
3	NÁVRH RIEŠENIA	27
3.1	KONCEPT POSTUPU RIEŠENIA	27
3.2	EXPERIMENTY S NAVRHOVANÝMI PRÍSTUPMI	29
3.2.1	<i>Detekcia pozadia a farby.....</i>	<i>29</i>
3.2.2	<i>Detekcia pohybu.....</i>	<i>33</i>
3.2.3	<i>Klasifikácia pomocou Support Vector Machine</i>	<i>35</i>
3.3	POSTUP RIEŠENIA	37
3.4	DETEKCIA POHYBU	38
3.4.1	<i>METÓDA 1: Bod záujmu</i>	<i>39</i>
3.4.2	<i>METÓDA 2: Zhluk vektorov pohybu.....</i>	<i>45</i>
3.5	POPIS IMPLEMENTÁCIE.....	48
4	OVERENIE RIEŠENIA	50
4.1	VLASTNÝ DATASET	50
4.2	SPÔSOB VYHODNOTENIA ÚSPEŠNOSTI	51
4.3	METÓDA 1: BOD ZÁUJMU	51
4.3.1	<i>Trénovacie dáta.....</i>	<i>51</i>
4.3.2	<i>Trénovanie klasifikátora</i>	<i>58</i>
4.3.3	<i>Výsledky predikcie</i>	<i>59</i>
4.4	METÓDA 2: ZHLUK VEKTOROV POHYBU	62
4.4.1	<i>Trénovacie dáta.....</i>	<i>62</i>
4.4.2	<i>Trénovanie klasifikátora</i>	<i>65</i>
4.4.3	<i>Výsledky predikcie</i>	<i>66</i>
4.5	ZHODNOTENIE VÝSLEDKOV.....	68
5	ZÁVER	71
	ZOZNAM POUŽITEJ LITERATÚRY.....	72
	PRÍLOHA A: UKÁŽKY	75
A.1	EXPERIMENTY	75

A.2	METÓDA 1: BOD ZÁUJMU	76
A.3	METÓDA 2: ZHLUK VEKTOROV	81
A.4	POUŽÍVATEĽSKÉ ROZHRANIE	84
PRÍLOHA B: TECHNICKÁ DOKUMENTÁCIA		85
B.1	IMPLEMENTÁCIA	85
B.2	INŠTALAČNÁ PRÍRUČKA	91
B.3	POUŽÍVATEĽSKÁ PRÍRUČKA	93
PRÍLOHA C: OBSAH ELEKTRONICKÉHO MÉDIA		98

Zoznam ilustrácií

Obr. 2.1: Modelový príklad detekcie na základe pozadia [5]	3
Obr. 2.2: Ľavý stĺpec obsahuje príklad scény s dynamickým pozadím a pravý stĺpec masku falošného popredia získanú štatistickým prístupom detekcie [7]	5
Obr. 2.3: Postupne meniace sa osvetlenie od najslabšieho po najsilnejšie (zľava doprava) a výsledná maska falošného popredia scény získaná štatistickým prístupom detekcie [8].....	6
Obr. 2.4: Príklad pravdepodobnosti hodnoty pixela f_{XX}, Φ (Rov. 2.2) [19].....	9
Obr. 2.5: Príklad podmienených pravdepodobností P_{kX}, Φ , zobrazené ako funkcia premennej X [19]	10
Obr. 2.6: Biele svetlo prechádzajúce skleneným hranolom [16]	11
Obr. 2.7: Viditeľné spektrum elektromagnetického žiarenia.....	12
Obr. 2.8: Priebeh funkcií zodpovedajúcej farby štandardu CIE 1931 [17]	13
Obr. 2.9: Chromatický diagram (po obvode zobrazeného tvaru sa nachádzajú zodpovedajúce vlnové dĺžky žiarenia v nm) [17].	14
Obr. 2.10: Farebný priestor RGB (modifikovaný obrázok z [16]).....	15
Obr. 2.11: Farebný model HSI [16]	16
Obr. 2.12: (1) iníciačný obrázok, (2) nasledujúci obrázok, (3) výsledný optický tok. [12]	18
Obr. 2.13: Znázornené prípady na základe závislosti vlastných čísel α a β [14]. Podstatné sú oblasti, ktoré oddeľujú hrubé čiary. V ľavom dolnom rohu sú homogénne oblasti, v pravom dolnom a ľavom hornom rohu sú oblasti hrán. Ostatná časť prislúcha oblasti nájdeného rohu.	19
Obr. 2.14: ROC krivka [23].....	22
Obr. 2.15: Konvexný obal oblasti ohňa [24]	23
Obr. 2.16: Klasifikácia snímok ohňa na základe prítomnosti ohňa podľa [24]	23
Obr. 2.17: Príklad oblasti podobnej ohňu [24]	24
Obr. 2.18: Snímka videa pri zisťovaní zjemňovania ostrosti hrán pozadia dymom [26]	24
Obr. 2.19: Porovnanie kontúr hraníc segmentovaných oblastí [26]. Na spodnom videu vodič úmyselne mení intenzitu stretávacích svetiel, čím sú splnené požiadavky všetkých charakteristík dymu okrem poslednej predstavenej – kontúry.	25
Obr. 2.20: Komerčné riešenie detekcie dymu	26
Obr. 3.1: Prehľad konceptu metódy detekcie ohňa.....	28
Obr. 3.2: Základné modelovanie pozadia; a) Originálna snímka videa s aplikovaným mediánovým filtrom; b) Rozdiel aktuálnej snímky a modelu pozadia v absolútnej hodnote; c) Prah rozdielu aktuálnej snímky a pozadia; d) Popredie snímky po aplikovaní morfológických operácií na masku popredia	30
Obr. 3.3: Štatistické modelovanie pozadia; a) Originálna snímka; b) Maska popredia; c) Maska popredia po morfológických operáciách; d) Popredie snímky	30
Obr. 3.4: Porovnanie základného a štatistického prístupu modelovania pozadia; a) základný; b) štatistický.....	31
Obr. 3.5: Odtieň a sýtosť pixelov manuálne zvolených oblastí ohňa.....	31
Obr. 3.6: Príklad vstupnej snímky videa, detekcie pozadia a úspešnej detekcie farby (zľava)	32
Obr. 3.7: Porovnanie úspešnosti detekcie ohňa na základe farby.....	32
Obr. 3.8: Pohybové vlastnosti ohňa.....	33
Obr. 3.9: Porovnanie spôsobov vyhľadania bodov záujmu (hore rovnomerný raster, dole Shi-Tomasi detektor) 34	
Obr. 3.10: Porovnanie pohybu bežných objektov vľavo s pohybom ohňa vpravo (ideálny prípad).....	35
Obr. 3.11: Porovnanie pohybu bežného objektu vľavo s pohybom ohňa vpravo (neideálny prípad)	35
Obr. 3.12: Vrchný rad znázorňuje výsledky klasifikácie s postupným znižovaním hodnoty parametra C (zľava). Ľavý obrázok v spodnom rade znázorňuje podporné vektory (zakrúžkované pozorovania) a pravý obrázok prezentuje výsledky pri zhutnení tréningových dát najmä v problematickej oblasti.	36
Obr. 3.13: Upravený postup riešenia detekcie ohňa. Použitie detekcie farby a detekcie pozadia je voliteľné.....	38

<i>Obr. 3.14: Postup detekcie pohybu</i>	<i>39</i>
<i>Obr. 3.15: Sekvencia vektorov pohybu je daná sledovaním bodu záujmu v čase t</i>	<i>40</i>
<i>Obr. 3.16: Výsledok SVM predikcie bodu. Pozitívne body sú označené fialovou farbou, negatívne zelenou.</i>	<i>45</i>
<i>Obr. 3.17: Modelovanie heat-mapy. Vrchný rad reprezentuje stav po získaní troch snímok videa, spodný rad po získaní 13-tich snímok.</i>	<i>45</i>
<i>Obr. 3.18: Diagram základných prípadov použitia</i>	<i>48</i>
<i>Obr. 3.19: Náhľad používateľského rozhrania.....</i>	<i>49</i>
<i>Obr. 4.1: Ukážka vlastného datasetu</i>	<i>50</i>
<i>Obr. 4.2: Závislosť odchýlky zmeny smeru ideálneho ohňa od počtu vektorov danej sekvencie.</i>	<i>52</i>
<i>Obr. 4.3: Pomer smeru (hore, doprava, dole, doľava) ku počtu vektorov</i>	<i>53</i>
<i>Obr. 4.4: Histogram hodnôt príznaku stredná hodnota smeru.</i>	<i>53</i>
<i>Obr. 4.5: Histogram hodnôt príznaku odchýlka dĺžky.</i>	<i>53</i>
<i>Obr. 4.6: Histogram hodnôt príznaku stredná hodnota dĺžky.</i>	<i>54</i>
<i>Obr. 4.7: Závislosť odchýlky zmeny smeru od počtu vektorov danej sekvencie.</i>	<i>55</i>
<i>Obr. 4.8: Pomer smeru (hore, doprava, dole, doľava) ku počtu vektorov.</i>	<i>55</i>
<i>Obr. 4.9: Histogram hodnôt príznaku odchýlka dĺžky.</i>	<i>56</i>
<i>Obr. 4.10: Závislosť odchýlky zmeny smeru od počtu vektorov danej sekvencie.</i>	<i>56</i>
<i>Obr. 4.11: Pomer smeru (hore, doprava, dole, doľava) ku počtu vektorov.</i>	<i>57</i>
<i>Obr. 4.12: Histogram hodnôt príznaku odchýlka dĺžky.</i>	<i>57</i>
<i>Obr. 4.13: Porovnanie úspešnosti metódy 1 pri použití rôznych parametrov</i>	<i>60</i>
<i>Obr. 4.14: Histogram priemernej odchýlky smeru vektorov.....</i>	<i>62</i>
<i>Obr. 4.15: Histogram priemernej odchýlky dĺžky vektorov</i>	<i>63</i>
<i>Obr. 4.16: Histogram priemernej strednej hodnoty smeru vektorov</i>	<i>63</i>
<i>Obr. 4.17: Histogram priemernej odchýlky smeru vektorov.....</i>	<i>64</i>
<i>Obr. 4.18: Histogram priemernej odchýlky dĺžky vektorov</i>	<i>64</i>
<i>Obr. 4.19: Histogram priemernej strednej hodnoty smeru vektorov</i>	<i>64</i>
<i>Obr. 4.20: Porovnanie úspešnosti metódy 2</i>	<i>67</i>
<i>Obr. 4.21: Porovnanie výsledkov pri bežne sfarbenom ohni</i>	<i>68</i>
<i>Obr. 4.22: Porovnanie úspešnosti detekcie farby s detekciou pohybu na rôzne sfarbených ohňoch</i>	<i>69</i>
<i>Obr. 4.23: Porovnanie výsledkov detekcie pohybu pri rôznych pomeroch konverzie RGB do odtieňov sivej</i>	<i>70</i>

1 Úvod

Hlavnou motiváciou vizuálnej detekcia ohňa a dymu metódami počítačového videnia je závažnosť nastáť takejto situácie, prakticky v ktorejkoľvek oblasti nášho sveta. Katastrofické scenáre, ktoré tento živel so sebou často prináša, privolávajú pozornosť každého z nás. Vznikajú tak rôzne normy a metodiky o bezpečnosti a ochrane zdravia pri práci, ktoré sa snažia predchádzať vzniku takýchto situácií, no zlyhanie rôznych faktorov, ako napríklad ľudského, nemožno nikdy úplne odstrániť. Preto sú minimálne rovnako potrebné aj metódy včasnej a efektívnej detekcie už vzniknutej situácie, čo je aj predmetom tejto práce.

Naskytuje sa tak možnosť využitia výsledkov práce pri „online“ detekcii vzniknutých situácií metódami počítačového videnia pomocou bežných bezpečnostných a monitorovacích kamier, ktoré už sú inštalované v mnohých rizikových oblastiach. Tento spôsob detekcie môže byť v interiéroch doplnený fyzickými detektormi dymu. V exteriéroch však odpadá táto jednoduchá a účelná možnosť detekcie, a využitie metód počítačového videnia môže v tomto prípade predstavovať najjednoduchší a zároveň najefektívnejší spôsob (či už z pohľadu údržby, alebo z pohľadu nákladov). Na rozsiahlu plochu, ktorú pokryje jedna kamera, by bolo v určitých prípadoch ľahko potrebné inštalovať aj niekoľko stoviek tradičných požiarnych detektorov.

Rovnako sa ešte naskytuje možnosť využitia „off-line“ detekcie. Príkladom môže byť potreba rôznych spravodajských televíznych staníc rafinovať vyhľadávanie v katastrofických archívnych záberov podľa výskytu ohňa alebo dymu v zábere [2].

Potrebu využitia metód počítačového videnia ešte umocňuje fakt existencie funkčných kamerovo-monitorovaných oblastí v reálnom čase, ktorý bol zdôraznený aj v časopise New Scientist: *„Existuje príliš veľa kamier, ale príliš málo párov očí na ich sledovanie.“* [2]. Bohužiaľ, replikovať ľudskú inteligenciu, ako aj ľudské videnie, nie je jednoduché [3]. Z dôvodu veľkých výziev, kladených na spracovanie obrazu, ako aj celkovú komunitu počítačového videnia, nie je v súčasnosti možné vlastniť plne spoľahlivý systém na detekciu ohňa bez prítomnosti ľudského faktora, ktorý eliminuje najväčší problém súčasných riešení, ktorým sú plané poplachy.

V skorších publikáciách na detekciu ohňa sa však ešte neuvažovalo o detekcii dymu [3]. Samotný dym sa však môže objaviť vo výhlade inštalovaných kamier skôr ako oheň a keďže pohyb dymu je rýchlejší, a rýchlejšie zaberá väčšiu časť sledovaného priestoru, z pohľadu počítačového videnia sa môže jednať o minimálne rovnako lukratívny objekt záujmu--.

Pre dosiahnutie lepších výsledkov detekcie, sú v súčasnosti využívané kombinácie bežných kamier a infračervených kamier [3]. Cieľom tejto práce však je detekcia s použitím iba bežných kamier. Výsledné riešenie by malo byť aplikovateľné na existujúce riešenia bežných

kamerových systémov, zaznamenávajúcích viditeľné spektrum elektromagnetického žiarenia, bez dodatočných nákladov na hardvér alebo softvér.


2 Analýza problému

Uvažovaný problém detekcie ohňa a dymu vo video sekvenciách zasahuje do troch hlavných oblastí počítačového videnia. Prvou analyzovanou v tejto kapitole je detekcia na základe pozadia (angl. *background subtraction*), ktorá je východiskovým bodom pre detegovanie akéhokoľvek pohyblivého objektu. Následne je priblížená metóda detekcie objektov na základe farebného modelu, ktorá predstavuje nenáročný spôsob klasifikácie objektov podľa ich farebného spektra. Poslednou uvedenou, rozsiahlejšou oblasťou, je detekcia na základe charakteristík pohybu objektu (angl. *motion detection*).

Metódy detekcie pozadia a pohybu sú aplikovateľné na sekvenciu obrázkov, zatiaľ čo detekciu farebného modelu možno použiť aj na samostatný obrázok.

2.1 Detekcia na základe pozadia

Ako už bolo spomenuté v úvode kapitoly, východiskovým bodom pre ľubovoľné pozorovania pohyblivých objektov vo videu je práve detekcia na základe pozadia (angl. *background subtraction*) [4]. Video predstavuje sekvenciu snímok (obrázkov), ktoré sú v ideálnych podmienkach a pri použití statických kamier odlišné iba v pohybujúcom sa objekte (teda popredí skúmanej scény) [12]. Príkladom najjednoduchšieho prístupu detekcie by bolo uvažovanie o prvej snímke ako o pozadí scény, a pohyblivým objektom (resp. objektami) by bol rozdiel každého bodu nasledujúceho obrázka a tohto pozadia (Obr. 2.1). Pre eliminovanie malých zmien a iných nedostatkov je tento rozdiel často práhovaný (angl. *thresholded*) alebo zoskupovaný pomocou morfologických operácií.



Obr. 2.1: Modelový príklad detekcie na základe pozadia [5]

V reálnom poňatí však z dôvodu vplyvu zmien osvetlenia scény, alebo vplyvu pomaly meniacich sa častí pozadia, musí byť model pozadia neustále adaptovaný [4]. Pre dosiahnutie žiadaného výsledku boli vyvinuté viaceré sofistikovanejšie metódy, ktoré uvádzame aj so stručným priblížením podľa [6]:

- **Základné modelovanie pozadia:** V tomto prístupe sa už na rozdiel od vyššie uvádzaného príkladu vopred neurčí jedna snímka, ktorá reprezentuje pozadie, ale pozadie je modelované pomocou základných štatistických vlastností ako priemer, medián, poprípade analýzou histogramu v čase.
- **Štatistické modelovanie pozadia:** Pozadie je modelované pomocou jedného alebo viacerých normálových rozdelení (angl. *Mixture of Gaussians*), poprípade pomocou odhadovania pravdepodobností bodov pozadia metódou *Kernel density estimation*.
- **„Fuzzy“ modelovanie pozadia:** Pozadie je modelované pomocou *fuzzy running average*, alebo *Type-2 fuzzy mixture of Gaussians*. Popredie je následne detegované využitím *Sugeno integral* alebo *Choquet integral*.
- **Zhlukovanie pozadia:** Modelovanie pozadia je v tomto prípade riešené známymi algoritmami pre zhlukovanie. Každý prichádzajúci bod obrázka (v zmysle sekvencií snímok) je porovnávaný s existujúcimi zhlukmi a následne vyhodnocovaný podľa toho, či je daný zhluk súčasťou pozadia. Predpokladá sa, že každý bod snímky je súčasťou konkrétneho dočasného zhluku. Využívaný je napríklad *K-Means algoritmus* alebo metóda *Codebook*.
- **Modelovanie pozadia neurónovými sieťami:** Jednotlivé body sú klasifikované ako pozadie alebo popredie pomocou neurónových sietí, trénovaných na určitom počte snímok „čistého“ pozadia.
- **Vlnkové modelovanie pozadia:** Model pozadia je definovaný v dočasnej doméne, využívajúci koeficienty *diskrétnej vlnkovej transformácie*.
- **Odhadovanie pozadia:** Každý bod snímky, ktorý sa výraznejšie odlišuje od jeho predpokladanej hodnoty je pomocou *Kalmanovho*, *Wienerovho*, alebo *Tchebychevho filtra* deklarovaný ako popredie.

Každá z uvedených metód využíva rozdielne prístupy, no rieši rovnaké úlohy detekcie pozadia. Medzi tieto úlohy patrí inicializácia pozadia, vytvorenie modelu pozadia, udržiavanie tohto modelu pozadia a v neposlednom rade detekcia popredia [4].

Na záver uvádzame citáciu, ktorá vychádza z výkonnostných porovnaní v [9] a [10]: „Čítajúc danú literatúru, môžu byť vyvedené dva hlavné poznatky: (1) Najviac používané prístupy sú tie štatistické, vďaka ich robustnosti vzhľadom na kritické situácie. (2) V súčasnosti sú videné viaceré pokroky v oblasti štatistického prístupu modelovania *Mixture of Gaussians* ...“ [6]


„Detekcia pozadia, je pre mnohé aplikácie počítačového videnia rýchly, no menej exaktný spôsob lokalizovania pohyblivých objektov.“ [6]

2.1.1 Problémy detekcie pozadia

Všetky úlohy detekcie pozadia vo video sekvenciách narážajú na rôzne výzvy, s ktorými sa každý z prístupov detekcie snaží vysporiadať „po svojom“. Ich robustnosť je teda priamo úmerná úspešnosti, s akou sa dané prístupy vysporiadajú s existujúcimi výzvami, medzi ktoré patrí podľa [6] šum obrázka, šum kamery, automatické zaostrovanie kamery, čas dňa, zmena umelého osvetlenia, pohybujúce sa objekty pozadia, vložené objekty do pozadia, uspané objekty popredia, zobudené objekty popredia, tieň objektov a iné. Z uvedených výziev vo všeobecnosti vyplývajú dva hlavné problémy, ktorými sú:

- dynamické pozadia,
- a zmeny osvetlenia.

Klasickým príkladom problémovej detekcie sú skúmané prostredia, ktoré nie sú interiéry s nemenným umelým osvetlením. Väčšina exteriérových scén totiž obsahuje v samotnom pozadí dynamické objekty, ktoré by boli za bežných okolností vďaka ich priestorovým a časovým zmenám ľahko falošne identifikované ako popredie. Konkrétnym príkladom dynamického pozadia sú listy stromov vo vetre alebo rozvírená hladina vody (Obr. 2.2). Efekt dynamického pozadia však spôsobuje aj často vídaný šum kamery.



Obr. 2.2: Ľavý stĺpec obsahuje príklad scény s dynamickým pozadím a pravý stĺpec masku falošného popredia získanú štatistickým prístupom detekcie [7]

Zmeny osvetlenia sú už často prítomné aj v interiéroch aj v exteriéroch, kde najväčšiu úlohu zohráva zmena času dňa, ako aj zmena umelého osvetlenia. Zmeny osvetlenia sú veľkým

problémom pre všetky prístupy detekcie, keďže dokážu radikálne ovplyvniť, resp. zmeniť, každý bod skúmanej scény (vzhľadom na reflektančné vlastnosti každého z povrchov). Postupné zmeny osvetlenia (Obr. 2.3) sú menej problémové ako napríklad náhla zmena v podobe vypnutie hlavného zdroja svetla v uzavretej miestnosti. No ako je vidieť na Obr. 2.3, aj menej problémový prípad spôsobuje rozsiahle falošné detekcie popredia.



Obr. 2.3: Postupne meniace sa osvetlenie od najslabšieho po najsilnejšie (zľava doprava) a výsledná maska falošného popredia scény získaná štatistickým prístupom detekcie [8]

2.1.2 Základné modelovanie pozadia

V tejto časti sa pokúsime podrobnejšie popísať jeden zo základných prístupov k modelovaniu pozadia pomocou strednej hodnoty štatistického súboru – mediánu.* Uvedená metóda predpokladá výskyt scén s meniacim sa pozadím v čase a snaží sa teda modelovať pozadie dynamicky [12]. Princíp metódy spočíva v aktualizovaní intenzity každého z pixelov pozadia na základe posledných K snímok videa. Hlavný problém metódy nastáva v prípade výskytu pomaly sa pohybujúcich objektov, ktoré sú v závislosti od stanoveného K absorbované do modelu pozadia. Pre lepšie pochopenie uvádzame popis krokov algoritmu podľa [12]:

1. Inicializácia algoritmu prebieha zozbieraním prvých K snímok videa. Pre každú pozíciu pixela je v prípade čierno-bieleho obrázka určený medián jeho intenzity na základe všetkých K snímok. Pri RGB obrázku je medián určený zvlášť pre každý kanál pixela. Pixely výsledného modelu pozadia sú následne tvorené zistenými mediánmi.
2. Vypočítanie rozdielu medzi ďalšou zachytenou snímkou $K + 1$ a súčasným modelom pozadia.
3. Odstránenie prítomného šumu pomocou práhovania vypočítaného rozdielu (ďalej ako *maska popredia*).
4. Upravenie masky popredia použitím morfologických operácií ako napríklad *morfologické otvorenie* a *morfologické uzavretie* s ohľadom na odstránenie nežiadanych artefaktov alebo vyplnenie neidentifikovaných „dier“ popredia. Výsledná maska popredia reprezentuje regióny pohyblivého objektu.

* medián je 50 %-ný kvantil, vyjadrujúci funkčnú hodnotu v bode 0,5 danej pravdepodobnostnej funkcie

5. Prepočítanie nového mediánu modelu pozadia na základe posledných K snímok. Najstaršia snímka už nie je zahrnutá do výpočtu.
6. Návrat ku kroku 2.

„Modelovanie pozadia na základe filtrovania mediánom je jednoduché na pochopenie a aj úspešne* aplikované.“ [12]. Príklad segmentácie touto metódou je zobrazený na Obr. 2.1. Piaty krok algoritmu je však napríklad oproti filtrovaniu s použitím priemernej hodnoty pamäťovo aj výpočtovo náročný z dôvodu potreby ukladať posledných K snímok a usporiadať každú postupnosť snímok na úrovni pixelov. Oproti robustnejším metódam je však stále znateľne rýchlejší.

2.1.3 Štatistické modelovanie pozadia

„Jednoduché[†] metódy detekcie pozadia majú výhodu vo výpočtovej rýchlosti, ale zlyhávajú v nekontrolovaných prostrediach.“ [19]. Štatistické modelovanie pozadia sa snaží spomínané problémy detekcie, ako zmeny osvetlenia a dynamické pozadia, modelovať adaptívne pomocou multimodálnych (viacvrcholových) rozdelení početností štatistického súboru [19], [20]. Existuje viacero prístupov (algoritmov) k štatistickému modelovaniu; v tejto časti je popísaný reprezentatívny z nich, publikovaný v [21] autormi Stauffer a Grimson. Táto metóda používa zmes normálových (Gaussových) rozdelení (angl. *Mixture of Gaussians*) na modelovanie multimodálneho pozadia sekvencie obrázkov [19]. Každému pixelu sekvencie obrázkov zodpovedá viacero normálových rozdelení, reprezentujúcich rozmiestnenie pravdepodobnosti pozorovania určitej intenzity alebo farby daného pixela. Každé rozdelenie reprezentuje rozmiestnenie jedného povrchu (objektu), ktoré sa vyskytuje, resp. môže vyskytovať, na danej pozícii obrázka. Predpokladom tohto prístupu je, že pozadie sa bude vyskytovať na danej pozícii častejšie ako popredie a že toto pozadie bude mať relatívne malý rozptyl možných hodnôt intenzít, resp. farieb. Tento predpoklad umožňuje zakomponovať do modelu pozadia viaceré nekonzistentné povrchy pozadia. Povrch pozadia je reprezentovaný strednou hodnotou normálového rozdelenia a nekonzistencia je reprezentovaná rozptylom normálového rozdelenia, a môže byť spôsobená napríklad šumom kamery, textúrou povrchu, alebo zmenami osvetlenia povrchu.

Každý zo spomínaných potencionálnych povrchov, vyskytujúcich sa v danom bode sekvencie obrázkov budeme reprezentovať stavom k z množiny $\{1, 2, \dots, K\}$ [19]. Celkový počet možných stavov povrchov K sa zvykne pohybovať v rozmedzí 3 až 7 stavov. Nie všetky z modelovaných povrchov však reprezentujú pozadie. Istá časť stavov je vymedzená aj pre modelovanie

* v súčasnosti

[†] resp. základné metódy

popredia. Náhodná veličina $\mathbf{k}$, ktorá zapríčiňuje výskyt daného stavu k^* v čase $t = 1, 2, \dots$ je zjednodušená v podobe parametra ω_k , označovaného aj ako *váha*. Váha reprezentuje pravdepodobnosť (nezávislú od skúseností) $P(k) = \omega_k$ tak, že $\sum_{k=1}^K \omega_k = 1$.

Nepredpovedateľné správanie scény v podobe $\mathbf{k}$ je nepriamo pozorované hodnotou pixela X [19]. Hodnota X je podmienená aktuálnym stavom k , a má isté pravdepodobnostné rozmiestnenie dané funkciou $f(X|k)$, spôsobené spomínanou nekonzistenciou povrchu. Hodnota X je generovaná náhodnou veličinou $\mathbf{X}$. Ďalej popisovaný postup algoritmu by sa dal zovšeobecniť ako: „Riešením problému segmentácie popredia je odhadnúť v každej vzorke času t najpravdepodobnejší stav k na základe pozorovaní vzorkovaných z náhodnej veličiny $\mathbf{X}$, spolu s procedúrou vymedzenia stavov popredia od stavov pozadia.“ [19].

Vo všeobecnosti môže byť náhodná veličina $\mathbf{X}$ modelovaná zmesou viacrozmerných Gaussových rozdelení, každé pre jeden stav k (Rov. 2.1). Parametre normálového rozdelenia stavu k sú $\theta_k = (\mu_k, \sigma_k)$ a príslušná kovariančná matica Σ_k .


Rov. 2.1: N-rozmerné Gaussové rozdelenie [19]

$$f_{X|k}(X|k, \theta_k) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma_k|^{\frac{1}{2}}} e^{-\frac{1}{2}(X-\mu_k)^T \Sigma_k^{-1} (X-\mu_k)}$$

Popisovaná metóda však podstatne zjednodušuje uvedený model, a predpokladá, že rozmery $\mathbf{X}$ sú nezávislé, čím je kovariančná matica zjednodušená na n -rozmerný vektor rozptylov σ_k^2 a ďalej predpokladá, že rozptyly každého rozmeru X sú rovnaké. Takéto zjednodušenie teda znamená, že v prípade troch rozmerov lineárneho farebného priestoru RGB má každý kanál (farba) rovnaké štatistické vlastnosti. Pre lineárne priestory môže byť takáto prognóza ešte akceptovateľná, avšak v prípade nelineárnych priestorov ako HSI je použitie tejto metódy potrebné zvážiť (pozri časť 2.2.1 *Farba*).

Pravdepodobnosť hodnoty ľubovoľného pixela môže byť nakoniec modelovaná ako suma všetkých rozdelení stavov k (keďže stavy považujeme za disjunktné), váhovaných podľa pravdepodobnosti výskytu stavu $P(k)$ (Rov. 2.2). Parameter Φ reprezentuje množinu všetkých potrebných parametrov $\{\omega_1 \dots \omega_k, \theta_1 \dots \theta_k\}$.

* Podobne ako v [19], používame pre zvýšenie prehľadnosti nasledovnú formátovaciú notáciu: znak k kurzívou reprezentuje hodnotu náhodnej veličiny a znak $\mathbf{k}$ tučným písmom reprezentuje samotnú náhodnú veličinu; a teda vzorkovacia udalosť $\mathbf{k} = k$.



Obr. 2.4: Príklad pravdepodobnosti hodnoty pixela $f_X(X, \Phi)$ (Rov. 2.2) [19]

Rov. 2.2: Pravdepodobnosť hodnoty pixela [19]

$$f_X(X, \Phi) = \sum_{k=1}^K P(k) f_{X|k}(X|k, \theta_k)$$


Na Obr. 2.4 je znázornený príkladný jednorozmerný model pre niektoré z pixelov. Pravdepodobnosť $f_X(X, \Phi)$ je znázornená v závislosti od hodnoty $X \in \{0, 1, \dots, 255\}$, ďalej $K = 3$, $\omega_k = \{0.2, 0.2, 0.6\}$, $\mu_k = \{80, 100, 200\}$, $\sigma_k = \{20, 5, 10\}$.

Počas celého priebehu algoritmu a detegovaní popredia sú všetky použité parametre z Φ neustále prepočítavané na základe pozorovaní X spolu s odhadovaním stavu k na základe X . Odhadovanie stavu k je z nekompletných pozorovaní X vykonávané pomocou EM algoritmu (angl. *Expectation-Maximization*). V prípade konkrétneho pozorovania X je prislúchajúci stav k určený pomocou Rov. 2.3, ktorá vyberá taký stav k , pre ktorý nadobúda funkcia podmienených pravdepodobností $P(k|X, \Phi)$, závislá od X , maximum (pozri Obr. 2.5).

Rov. 2.3: Odhad stavu k na základe X [19]

$$\begin{aligned} \hat{k} &= \underset{k}{\operatorname{argmax}} P(k|X, \Phi) \\ &= \underset{k}{\operatorname{argmax}} \omega_k f_{X|k}(X|k, \theta_k) \end{aligned}$$

$P(k|X, \Phi)$ je podmienená pravdepodobnosť stavu k pozorovanou hodnotou X na základe bayesovskej teórie. V prípade výskytu predtým nepozorovanej hodnoty je vytvorený nový stav $K + 1$, s malou, ale nenulovou pravdepodobnosťou ω_{K+1} a s neurčitým normálovým rozdelením s neznámou strednou hodnotou a nekonečným rozptylom. Budúce nepozorované hodnoty (resp. hodnoty, ktoré nie sú modelovateľné ani jedným zo súčasných stavov K) budú následne priradené tomuto stavu $K + 1$. Podľa príkladu na Obr. 2.5 by pri pozorovaní hodnoty $X = 150$ bol odhadnutý stav $k = 1$ (pozri aj Obr. 2.4), avšak práve v takomto prípade bude použitý stav $K + 1$.



Obr. 2.5: Príklad podmienených pravdepodobností $P(\mathbf{k}|\mathbf{X}, \Phi)$, zobrazené ako funkcia premennej X [19]

Po odhade stavu k je následne potrebné rozhodnúť, či je daný stav súčasťou pozadia, alebo popredia [19]. Povrch, modelovaný stavom k , je vo všeobecnosti považovaný za pozadie, ak sa vyskytuje často (má vysoké ω_k) a nemá príliš veľký rozptyl. Toto tvrdenie je konkretizované Rov. 2.4, ktorá určuje najmenšie možné b , kedy daná suma pravdepodobností stavov ω_k dosahuje hodnotu väčšiu ako stanovená pravdepodobnosť T . Kľúčové v tejto rovnici však je, že sčítavané stavy k sú usporiadané od najväčšieho po najmenší na základe vzťahu ω_k/σ_k . Takto usporiadané stavy $k = 1, 2, \dots, B$ sú považované za stavy pozadí a zvyšné stavy za výsledné popredie.

Rov. 2.4: Vymedzenie stavov k , reprezentujúcich pozadie [19]

$$B = \underset{b}{\operatorname{argmin}} \left(\sum_{k=1}^b \omega_k > T \right)$$

2.2 Detekcia na základe farebného modelu

„Detekcia farby bola jednou z prvých techník detekcie, použitej pri vizuálnej detekcii ohňa, a stále je využívaná v takmer každej metóde detekcie. Väčšina prístupov založených na farbe používa farebný priestor RGB, niekedy v kombinácii s priestorom HSI/HSV. Hlavným dôvodom pre použitie RGB je fakt, že takmer každá kamera viditeľného spektra má senzory detegujúce video vo formáte RGB ...“ [3]. Esenciálnym princípom detekcie na základe farebného modelu je istý spôsob klasifikácie bodov (pixelov) skúmaného obrázka [11]. Väčšina prác zameraných na detekciu ohňa využíva klasifikáciu na základe pravidiel (angl. *rule-based*).

Atribútmi, na základe ktorých je klasifikácia vykonávaná, sú práve parametre reprezentácie každého bodu obrázku v podobe istého farebného priestoru. Tento obrázok môže, no nemusí byť v kontexte video sekvencie. Pod detekciou na základe farebného modelu môžeme uvažovať aj detekcie v čierno-bielych obrázkoch, keďže sa stále jedná o istý spôsob reprezentácie bodov obrázka, no v tomto prípade iba pomocou jediného atribútu, resp. kanála.


Z tohto dôvodu možno využiť detekciu na základe farebného modelu aj pri detekcii dymu, ktorý nedisponuje špecifickými „farebnými“ charakteristikami ako oheň, no je možné sledovať isté vlastnosti pixelov dymu aj na základe jeho reprezentácie v konkrétnom farebnom modeli.

V nasledujúcich častiach bližšie priblížime pojem farby a farebných priestorov z pohľadu počítačového videnia. Poznatky o farbe ako takej a rovnako aj poznatky o reprezentácii videnia ľuďmi aj informačnými technológiami sú dôležité nielen pri akejkoľvek detekcii objektov, ale aj pri akejkoľvek úlohe počítačového videnia vo všeobecnosti.

2.2.1 Farba

Existujú dva pohľady na farbu [12]. Prvým je pohľad fyzikálny, ktorý sa pozerá na podstatu farby z reálneho hľadiska, a druhý je pohľad psychologický, ktorý vychádza z vnemu tejto fyzikálnej veličiny ľuďmi. Vnímanie farby ľuďmi nie je presné, u niektorých dokonca výrazne nepresné až žiadne. Pre pochopenie tohto faktu je v ďalších odsekoch vysvetlená podstata farby z fyzikálneho hľadiska.

Základy k pochopeniu farby položil v roku 1666 Isaac Newton, keď zistil, že slnečné svetlo prechádzajúce cez sklenený hranol nie je obyčajné biele svetlo, ale je rozložené na rôzne farebné odtiene, nazývané aj farebné spektrum (Obr. 2.6) [16].




Obr. 2.6: Biele svetlo prechádzajúce skleneným hranolom [16]

Toto biele svetlo, respektíve svetlo vo všeobecnosti, je viditeľná časť elektromagnetického žiarenia [16]. Viditeľná časť je daná vlnovými dĺžkami tohto žiarenia na úrovni približne od 380 nm do 740 nm (Obr. 2.7). Žiarenia s vlnovou dĺžkou pod 380 nm a nad 740 nm už nepatria do viditeľného svetla, no stále sa jedná o rôzne typy elektromagnetického žiarenia, ako napríklad ultrafialové alebo infračervené, ktoré je možné zachytávať rôznymi inými spôsobmi, nie však ľudským okom alebo bežne dostupnou kamerou.

Viditeľné spektrum svetla, ako je vidieť na Obr. 2.7, však neobsahuje vlnovú dĺžku, ktorá by predstavovala bielu farbu, respektíve biele svetlo. Biele svetlo je totiž dané žiarením v celom viditeľnom spektre a videnie farby ľudskými bytosťami, ako aj zvieratami, má podstatu

v odraze tohto viditeľného žiarenia od okolitých objektov [16]. Každý z povrchov objektov má iné odrazové vlastnosti, t.j. odráža alebo pohlcuje určité vlnové dĺžky λ . Týmto spôsobom sa vytvára vnem farby. Biele slnečné svetlo v podobe elektromagnetického žiarenia, dopadajúce na povrch objektu, ako napríklad listu stromu, sa po odraze tohto žiarenia javí ako zelená farba, pretože od objektu sa odrazila väčšina žiarenia s vlnovými dĺžkami okolo 580 nm, a väčšina ostatných vlnových dĺžok bola pohltaná daným objektom. Biele svetlo je potom definované odrazovými vlastnosťami objektu, ktoré zapríčinia že tento objekt odráža, respektíve pohlcuje, každé vlnové dĺžky približne v rovnakom množstve. Funkciu odrazového spektra budeme označovať ako $S(\lambda)$, ktorá je závislá od vlnovej dĺžky λ .



Obr. 2.7: Viditeľné spektrum elektromagnetického žiarenia *

„Väčšina senzorov, zachytávajúcich farbu, ako napríklad v kamerách, nemá priamy prístup k farbe; výnimkou je fotospektrometer... Intenzity [†] sú merané vo viacerých zúžených pásmach vlnových dĺžok a sú zhromaždené vo vektore, popisujúci každý pixel[‡].“ [12] Vo väčšine prípadov je farba zachytávaná v hrubom rozlíšení, použitím iba troch pásiem (kanálov). Jedno pre červenú farbu, jedno pre zelenú farbu a jedno pre modrú farbu (bližšie ozrejmené v nasledujúcich odsekoch).

Oči, respektíve ich čapíky, sú senzorom zodpovedným za zachytávanie farby pre ľudí [12]. V ľudskom oku sú prítomné čapíky, citlivé na rôzne vlnové dĺžky svetla. Kategorizované sú na tri druhy na základe ich maximálnej citlivosti a často sú označované ako čapíky typu B, G a R (angl. *Blue, Green, Red*). Citlivosť čapíkov je daná funkciou $R(\lambda)$, ktorá je závislá od vlnovej dĺžky λ . Relatívna citlivosť čapíkov B, G, alebo R je pre rôzne vlnové dĺžky rôzna, pričom pre každý typ čapíka dosahuje maximum v určitej vlnovej dĺžke, zodpovedajúcej približnej farbe

* Lena Lighting S.A. - <http://www.lenalighting.pl/en/knowledge/spectrum-of-visible-radiation/>

[†] elektromagnetického žiarenia


[‡] zachyteného obrázka

označenia čapíka. Výsledná vnímaná farba pozorovaného objektu je teda závislá od citlivosti senzorov $R(\lambda)$, teda čapíkov, a spomínaného odrazového spektra $S(\lambda)$. Rovnako dôležitá je pri výslednej farbe aj iluminantná zložka žiarenia $I(\lambda)$, ktorá reprezentuje spektrum zdroja svetla. Celková výsledná vnímaná farba každého i -teho senzora, označeného ako q_i , je daná integráciou nad súčinom všetkých troch zložiek v intervale vlnovej dĺžky λ_1 až λ_2 (Rov. 2.5).

Rov. 2.5: Vnem farby povrchu objektu pre senzor q [12]

$$q_i = \int_{\lambda_1}^{\lambda_2} I(\lambda) R(\lambda) S(\lambda) d(\lambda)$$


Z dôvodu rôznych možností reprezentácie pozorovanej farby a rôznych citlivostí senzorov v roku 1931 zaviedla CIE (International Commission on Illumination) štandardizovaný farebný priestor XYZ [12]. Tento štandardný priestor modeluje farbu pomocou troch štandardizovaných funkcií $\bar{x}$, $\bar{y}$ a $\bar{z}$ (podobne ako tri typy čapíkov v ľudskom oku) závislých od vlnovej dĺžky žiarenia λ . Priebeh zodpovedajúcich funkcií je naznačený na Obr. 2.8.



Obr. 2.8: Priebeh funkcií zodpovedajúcej farby štandardu CIE 1931 [17]

Pozorovaná „štandardizovaná“ farba je teda reprezentovaná kombináciou troch výsledných hodnôt. Pri vynesení možných hodnôt na 2D priestor vzniká tzv. *chromatický diagram* (Obr. 2.9) [12]. Tento „podkovitý“ tvar obsahuje farby, ktoré sú ľudia schopný vidieť. Rôzne zobrazovacie zariadenia sú však schopné zobrazíť iba časť z tohto priestoru farieb. Takáto časť, respektíve výsek, farebných odtieňov na chromatickom diagrame sa nazýva *gamut*.

Štandardizovaný farebný priestor XYZ sa považuje za absolútny priestor. Existujú aj rôzne kvantizované relatívne priestory [12], ktoré sú prezentované v nasledujúcej časti. Aplikácie počítačového videnia, a teda aj rôzne detekcie objektov, pracujú práve s týmito priestormi.



Obr. 2.9: Chromatický diagram (po obvodě zobrazeného tvaru sa nachádzajú zodpovedajúce vlnové dĺžky žiarenia v nm) [17].

2.2.2 Farebné priestory


Štandardná reprezentácia farby bola priblížená v predošlej časti. Pre účely zobrazovania farby v komerčnom prostredí, alebo pre účely manipulácie s farbou používateľom však boli zavedené aj ďalšie priestory [12]. „Vo všeobecnosti môžeme chápať farebné priestory ako špecifikáciu súradnicového systému a podprieštoria v tomto systéme, kde je každá farba reprezentovaná jedným bodom.“ [16]. Pre účely tejto práce sú z mnohých existujúcich farebných priestorov uvedené iba relevantné ako RGB alebo HSI. Perceptuálne uniformné priestory ako CIE L^*u^*v neuvádzame, pretože: „Nedáva zmysel používať tieto priestory v aplikáciách, ktoré nemajú priame prepojenie na ľudské videnie, ako napríklad stereo, alebo detekcia pohybu. V týchto prípadoch nie je zrovna efektívne vykonávať časovo náročný nelineárny prevod z RGB.“ [17]. Každý z uvedených priestorov využíva tri dimenzie na reprezentáciu farby.

2.2.2.1 RGB

Pôvod RGB (angl. *Red, Green, Blue*) priestoru vychádza z nástupu televízie s použitím technológie CRT a je založený na karteziánskej súradnicovej sústave [12], [16]. Farba je reprezentovaná vektorom troch súradníc, kde každej zo súradníc zodpovedá jedna z troch základných farieb červená, zelená alebo modrá (Obr. 2.10). Hodnoty každej súradnice (kanálu) sú normalizované v intervale $[0, 1]$, no môžu byť, a často aj sú kvantizované v rozsahu 8 bitov pre kanál. Každý kanál teda môže nadobúdať 256 hodnôt. Celkový počet farieb v tomto diskretnom priestore je rovný $256^3 = 16\,777\,216$ farieb. Obrázok, ktorý je reprezentovaný pomocou 24-bitového modelu RGB, pozostáva z troch obrazových komponentov, každý pre

jeden 8-bitový kanál modelu. Výsledný obraz na monitore počítača vzniká skombinovaním všetkých komponentov.

Zaujímavá je telesová uhlopriečka zo začiatku súradnicovej sústavy (0,0,0) do bodu (1,1,1), ktorá vymedzuje všetky vektory, ktoré majú každú z troch hodnôt jeho súradníc rovnakú. Body na tejto priamke reprezentujú postupne od bielej do čiernej rôzne stupne šedej farby (angl. *gray scale*). Vychádza to z faktu, popisovaného vyššie, kedy je žiarenie v každej vlnovej dĺžke konštantné (rovnaké), a teda nie je pozorovaný žiaden farebný odtieň.



Obr. 2.10: Farebný priestor RGB (modifikovaný obrázok z [16])

Farbu, modelovanú v štandardizovanom priestore XYZ možno transformovať na RGB pomocou transformačnej matice (Rov. 2.6) [12]. Hodnoty tejto matice však môžu byť z dôvodu viacerých inštancií RGB stanovenými rozličnými organizáciami rôzne. Príkladom sú modely sRGB, Adobe RGB alebo Adobe Wide Gamut RGB.

Rov. 2.6: Príklad transformácie farby medzi priestormi XYZ a RGB [12]

$$\begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} 3.24 & -1.54 & -0.50 \\ -0.98 & 1.88 & 0.04 \\ 0.06 & -0.20 & 1.06 \end{bmatrix} * \begin{bmatrix} X \\ Y \\ Z \end{bmatrix}$$

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.41 & 0.36 & 0.18 \\ 0.21 & 0.72 & 0.07 \\ 0.02 & 0.12 & 0.95 \end{bmatrix} * \begin{bmatrix} R \\ G \\ B \end{bmatrix}$$


RGB model je užitočný hlavne pri použití v hardvérových implementáciách a jeho výhodou je fakt, že ľudské oko je primárne citlivé práve pre červenú, zelenú a modrú zložku farby [16]. „Môžeme zhrnúť, že RGB je ideálny pre generovanie farby (ako napríklad zachytávanie obrazu farebnou kamerou alebo zobrazovanie obrazu na displeji)...“ [16].

2.2.2.2 HSI

Predchádzajúca reprezentácia farby pomocou RGB modelu má svoje výhody, avšak pre ľudí vnímateľnejší popis farby a praktickejšiu manipuláciu s farbou je vhodnejší práve model HSI (angl. *Hue, Saturation, Intensity*) [16]. Predstava farby na základe percentuálnej hodnoty o každom z troch farebných kanálov RGB obrázka nie je zrovna jednoduchá. Oveľa prirodzenejší spôsob pre ľudí je popis odtieňa (angl. *hue*), sýtosti (angl. *saturation*) a jas (angl.

brightness) pozorovanej farby. Základnými zložkami priestoru HSI práve z pohľadu farby je *odtieň* a *sýtosť*. *Odtieň* definuje čistý farebný odtieň (teda napríklad červená, oranžová alebo modrá) a *sýtosť* udáva stupeň zriedenia daného odtieňa farby s bielym svetlom. Poslednou zložkou, ale už viac podstatnou z pohľadu jasu ako samotnej farby je zložka *intenzita*. Práve táto zložka je najpoužiteľnejšou v prípade potreby pozeráť sa na obrázok iba v úrovni šedej farby (intenzita teda sama o sebe predstavuje „čierno-biely“ obrázok).

Z bodu obrázka reprezentovaného modelom RGB je možné jednoducho extrahovať každú zo zložiek HSI. Ak by sme si zobrali ľubovoľný bod z priestoru RGB, jeho intenzitu by sme získali ako prienik uhlopriečky stupňa šedej (pozri časť 2.2.2.1 RGB) a kolmice na túto uhlopriečku, ktorá prechádza daným bodom. Túto uhlopriečku môžeme na základe tejto vedomosti nazývať uhlopriečkou intenzity. Sýtosť farby je následne vzdialenosť daného bodu od uhlopriečky intenzity. Spomínaný bod tvorí spolu s vrcholmi uhlopriečky trojuholník, ktorého rotáciou okolo uhlopriečky intenzity sa získava výsledný odtieň farby (Obr. 2.11).



Obr. 2.11: Farebný model HSI [16]

Model HSI sa zvykne označovať aj ako HSL (angl. *Hue, Saturation, Lightness*), respektíve HLS [12]. Existuje aj mierne odlišná verzia modelu s názvom HSV (angl. *Hue, Saturation, Value*), respektíve HSB (angl. *Hue, Saturation, Brightness*), ktorá na rozdiel od zložky intenzity, nazývanej aj *svetlosť* (angl. *lightness*), používa zložku s názvom *hodnota* (angl. *value*), nazývanú aj *jas* (angl. *brightness*). Rozdiely medzi týmito modelmi teda spočívajú v rozdiely medzi jasom a svetlosťou. „Jas čistej farby je rovný jas bielej farby, zatiaľ čo svetlosť čistej farby je rovná svetlosti stredne sivej.“ [12]. Jas je fyzikálna veličina meraná v kandelách (cd) a svetlosť iba vizuálny vnem [18].

Na záver uvádzame citát, ktorý predurčuje použitie tohto používateľsky orientovaného modelu pre účely našej práce: „HSI model je ideálny nástroj pre vývoj algoritmov spracovania

obrazu založených na popise farby, ktorý je prirodzený a intuitívny pre ľudí, ktorý sú koniec koncov vývojári a používatelia týchto algoritmov.“ [16].

2.3 Detekcia pohybu

Ako názov tejto časti napovedá, v nasledujúcich odsekoch sú priblížené základné prístupy a znalosti týkajúce sa nie len samotnej detekcie pohybu, ale aj jeho analýzy. S príchodom cenovo prístupnejšieho a zároveň postačujúceho výpočtového výkonu aj pre bežného človeka sa viac otvorila možnosť využitia analýzy časových závislostí sekvencie obrázkov napríklad v oblasti bezpečnostných a sledovacích systémov [12], kam prakticky spadá aj detekcia ohňa a dymu. Ďalšími oblasťami, ktoré priamo aj nepriamo profitujú z analýzy pohybu sú detekcie, a najmä následné sledovanie,

- ľudských tvárí alebo chodcov vo všeobecnosti,
- dopravných prostriedkov
- alebo akékoľvek iné získavanie komplexných informácií o pohyblivých objektoch.

Vstupom pre analýzu pohybu je sekvencia minimálne dvoch obrázkov [12]. Komplexnosť a náročnosť samotnej analýzy býva a často aj musí byť znížená zakomponovaním dodatočných informácií a ohraničení riešeného problému, ktoré okrem iného ovplyvňujú aj následný výber vhodnej metódy analýzy. Príkladom je informácia o použití v mnohých prípadoch prijateľnejšej, statickej kamery, oproti použitiu pohyblivej nestatickej kamery.

Podľa [12] existujú vo všeobecnosti tri hlavné skupiny problémov využívajúcich analýzu pohybu, a to:

1. Detekcia pohybu.
2. Detekcia a lokalizácia pohyblivých objektov.
3. Extrahovanie 3D vlastností objektov (na základe ich pohybu).


Detekcia pohybu v rámci sekvencie obrázkov, bez potreby dodatočnej informácie o pohybe alebo ďalšej analýzy, je jednoduchou záležitosťou [12] a v tejto časti nebude ďalej rozoberaná.* Rovnako extrahovanie 3D vlastností objektov nie je pre potreby tejto práce predmetné, preto bude v nadchádzajúcich častiach účelne opomenuté. Pod detekciu pohybu objektov (nie len pohybu samotného) a ich lokalizáciu spadá viacero konkrétnejších prístupov a metód. Jednoduchá detekcia pohybu objektov zahŕňa segmentačné metódy založené na pohybe (angl. *motion-based segmentation methods*), a spomínaná detekcia na základe pozadia v časti 2.1 podľa rôznych literatúr, vrátane [12], spadá medzi ne. Ďalej môžu byť skúmané trajektórie pohybu, spolu s predikciou budúcej trajektórie; potrebné sú aj zachytávanie rôznych črt objektov, ako

* jedná sa o detekciu v zmysle: “Je v rámci sekvencie obrázkov pozorovaný nejaký pohyb?”

aj špecifických reprezentatívnych bodov objektov (*lokálne príznaky*); alebo pohyblivé objekty môžu byť zachytávané na základe ich grafovej reprezentácie.

Analýza pohybu môže byť univerzálne definovaná ako „hľadanie zhôd medzi párami bodov záujmu v sekvenčných obrázkoch“ [12]. Každému z iníciaľných bodov je po identifikácii pohybu priradený zistený vektor rýchlosti, opisujúci charakteristiky pohybu ako jeho smer, vzdialenosť alebo rýchlosť.

Špecifickou metódou analýzy je výpočet *optického toku* (angl. *optical flow*) [12]. Jej hlavnou charakteristikou a výsledkom je relatívne malý vektor pohybu, avšak teoreticky každého bodu, resp. časti obrázka (Obr. 2.12). Má však viacero ohraničení, na ktoré je potrebné myslieť pred jeho použitím, ako napríklad nutnosť veľmi malého pohybového rozdielu medzi dvoma za sebou „idúcimi“ obrázkami ako aj podmienka, že do sekvencie nevstupuje žiadna rozsiahla zmena. Jeho nevýhodou je detegovanie aj zmien osvetlenia ako pohyb, často je však optický tok vstupnou podmienkou ďalších vyšších metód analýzy.



Obr. 2.12: (1) iníciaľny obrázok, (2) nasledujúci obrázok, (3) výsledný optický tok. [12]

2.3.1 Lokálne príznaky

„Analýza pohybu a sledovanie objektov sú jednými z najpokrokovejších aplikačných oblastí strojového videnia.“ [12]. Pri detekciách pohybu v sekvenciách s výraznejšou zmenou medzi nasledujúcimi obrázkami je možné využiť takzvané *lokálne príznaky* alebo *lokálne body záujmu* (angl. *local feature points*) [12]. Určenie vhodných bodov záujmu je najdôležitejšou časťou metód založených na tomto princípe spolu s nájdením zhodných bodov v nasledujúcej inštancii. Zobrazenie príslušných vektorov pohybu je už triviálne. Najvhodnejšie body na sledovanie v obrázkoch sú vo všeobecnosti napríklad rôzne rohy objektov alebo ich hrany. Rovnako môžu byť použité iné špecifické informácie o objekte, ktoré je možné sledovať v čase.

Základy jednej z úspešných súčasných metód hľadania lokálnych príznakov, *Harrisovho detektora* [14], boli publikované v roku 1980 prácou [13]. Princíp spočíva v sledovaní rozdielov v priemernej intenzite bodov, ktoré sú dané posúvaním malého okna v čiernobiely obrázku o veľmi malú vzdialenosť, rôznymi smermi. Zmena intenzity E posunutia (x, y) je daná rovnicou Rov. 2.7, kde I je intenzita bodu a w je funkcia zvoleného okna, ktorá sa rovná 1 ak daný bod (u, v) patrí do okna, a 0 ak nepatrí.

Rov. 2.7: Zmena intenzity E posunutia (x, y) [14]


$$E(x, y) = \sum_{u,v} w_{u,v} [I_{x+u,y+v} - I_{u,v}]^2$$

V prípade homogénnej oblasti sú zmeny intenzít blízke nule. V prípade hrany budú posunutia po hrane blízke nule a posunutia kolmo na hranu naopak vysoké. Zmeny pri posunutí do každého smeru budú vysoké iba pri rohoch. Ak je minimum spomedzi všetkých zmien E väčšie ako stanovený prah, jedná sa o lokálny príznak na báze rohu.

Rov. 2.8: Rovnica odozvy [14]

$$R = \alpha\beta - k(\alpha + \beta)^2$$

Harrisov detektor rieši viacero nedostatkov tohto prístupu. Prvým z nich je odstránenie obmedzenia posunutia iba o 45 stupňov. Ďalším je použitie prirodzenejšej funkcie zvoleného binárneho obdĺžnikového okna, teraz už v podobe gaussovej funkcie. V neposlednom rade *Harrisov detektor* zavádza rovnicu odozvy (Rov. 2.8), ktorá vychádza z rovnice zmeny intenzity E (Rov. 2.7). Rovnica odozvy nahrádza prosté hľadanie minima zmeny E , ktorého výsledkom bolo (v istých prípadoch) nájdenie stále bodu hrany a nie rohu. Premenné α a β sú vlastné čísla (angl. *eigenvalues*) matice, ktorá vychádza z maximalizácie rozdielu intenzít pomocou Taylorovho rozšírenia (angl. *Taylor expansion*).



Obr. 2.13: Znázornené prípady na základe závislosti vlastných čísel α a β [14]. Podstatné sú oblasti, ktoré oddeľujú hrubé čiary. V ľavom dolnom rohu sú homogénne oblasti, v pravom dolnom a ľavom hornom rohu sú oblasti hrán. Ostatná časť prislúcha oblasti nájdeného rohu.

Na základe veľkostí vlastných čísel α a β sa určuje typ oblasti zvoleného okna, pričom vlastné čísla úzko súvisia s autokoreláciou maximalizovanej matice intenzít (Obr. 2.13). Odlíšené sú znovu tri rôzne prípady, kedy sa v oblasti zvoleného okna nachádza iba homogénna oblasť,

hrana alebo roh. Ideálny lokálny príznak má vysoké obe vlastné čísla, čo značí, že sa jedná o roh. V prípade jednej veľkej eigenhodnoty, a druhej malej, sa jedná o hranu.

Harrisov detektor podľa práce [15] vyhľadáva intuitívne správne príznaky, avšak pre algoritmy sledujúce pohyb príznakov sa nemusí vždy jednať o najvhodnejší bod. Práca pre dosiahnutie lepších výsledkov detekcie pohybu v prípade konkrétnych algoritmov navrhuje zjednodušenie rovnice odozvy (Rov. 2.1) je na tvar $R = \min(\alpha, \beta)$. Metódu detekcie bodov podľa tejto práce budeme ďalej nazývať podľa jej *Shi-Tomasi detektor*, alebo podľa jej názvu *GoodFeaturesToTrack*.

2.4 Existujúce riešenia

Táto časť obsahuje prieskum publikácií zameraných na detekciu ohňa a dymu, či už spoločne alebo každého zvlášť, a je nutnou podmienkou pre začiatok hľadania (a vôbec pre začiatok uvažovania) vlastného riešenia. Základný prehľad danej problematiky v tejto práci je získaný z publikácie z roku 2013 [3], ktorá sumarizuje 30 z doterajších významných a často odkazovaných publikácií. Okrem hlavných myšlienok zo spomínanej práce obsahuje táto časť aj popis postupov a dosiahnutých výsledkov priamo z konkrétnych článkov. Metódy detekcie sa rozdeľujú na detekcie na základe viditeľného spektra žiarenia a na základe infračerveného žiarenia. V našej práci sa zameriavame na detekciu iba na základe viditeľného spektra žiarenia, ktoré je možné pomerne lacno zachytávať bežnými bezpečnostnými kamerami.

„V literatúre počítačového videnia v posledných rokoch narastá počet publikácií o vizuálnej detekcii ohňa exponenciálne. Síce sa jedná o relatívne nový predmet vo výskume videnia, už teraz prináša nádejné výsledky.“ [3]. Klasickým problémom, ako u viacerých podobných oblastí počítačového videnia, je rôznorodosť podmienok v podobe odlišného osvetlenia a rôznych parametrov snímajúcich senzorov, ako aj existencia rôznych špecifických podôb ohňa a dymu [3]. Techniky detekcie je možné rozdeliť do viacerých kategórií, respektíve oblastí počítačového videnia. V našej práci sú rozdelené na tri všeobecné oblasti:

- detekcie farby,
- detekcia pozadia
- a detekcia pohybu.

V iných prácach sa ešte zvyknú využívať detekcie *textúr* alebo *nerovnomerností* (angl. *disorder*) a detekcia pohybu sa ešte zvykne deliť na detekciu *pohyblivých objektov* a detekciu pohybu v zmysle *trepotania* (angl. *flicker*).

Najčastejšou citovanou prácou podľa [3] je pre detekciu aj ohňa aj dymu práca [28], pre detekciu samotného ohňa sú to práce [23] a [24] a pre detekciu dymu [26] a [29]. Tieto práce sú teda akýmsi etalónom na súčasnej scéne detekcie požiaru. Práca [3] uvádza porovnanie každej z týchto metód, a to tak, že práca [28], je prvou porovnávanou metódou, práca [23]


spolu s prácou [26] druhou metódou a [24] spolu s [29] treťou. Výsledky sú porovnávané na 9-tich rôznych videách a je z nich možné usúdiť, že všetky metódy sú vo všeobecnosti rovnako úspešne. Každá v niektorých prípadoch viac a v niektorých menej, s priemernou mierou úspešnosti 82 %.

2.4.1 Detekcia ohňa

Práca autorov Celik a Demirel [23] využíva na detegovanie ohňa iba informáciu z farebného priestoru YCrCb (na rozdiel od predošlých prác využívajúcich RGB priestor). Práca uvádza, že model RGB nepostačuje na úspešnú klasifikáciu pixelov ohňa z dôvodu veľkého rozptylu intenzity jasů ohňa. Normalizovaný priestor RGB, navrhnutý v [22] tieto nedostatky znižuje, avšak použité YCrCb sa vďaka jeho oddeleným zložkám jasů a farby (angl. *luminance* a *chrominance*) javí ako lepšia voľba. Ďalšou výhodou tohto priestoru je, že je možné ho získať lineárnym prevodom z RGB priestoru, na rozdiel od iných priestorov, ktoré rovnako oddeľujú zložku jasů od zložiek farby. Základným poznatkom o pixeloch ohňa v priestore RGB je, že hodnota červeného kanálu R je väčšia ako hodnota zeleného kanálu G, a hodnota zeleného kanálu G je väčšia ako hodnota modrého kanálu B, teda $R > G > B$. Tento poznatok je využívaný vo viacerých prácach detegujúcich na základe farby v priestore RGB tak, že sú porovnávané priemerné hodnoty každého z kanálov daných oblastí obrázku. Toto pravidlo je v priestore YCrCb formované ako $Y > Cb$ a $Cr > Cb$. Ďalším poznatkom, ktorý práca uvádza je, že hodnota zložky Y pixela ohňa je väčšia ako priemerná hodnota Y celého obrázku, hodnota zložky Cb je vo všeobecnosti menšia ako priemerná hodnota zložky Cb celého obrázku a hodnota zložky Cr je vo všeobecnosti väčšia ako priemerná hodnota zložky Cr celého obrázku (Rov. 2.9). Toleranciu výslednej detekcie je možné korigovať zmenou parametra T , ktorý stanovuje závislosť medzi reálnym poplachom (*true positive*) a falošným poplachom (*false positive*) (Obr. 2.14). Spolu s použitím ešte ďalšieho pravidla, založeného na štatistickej analýze farebných zložiek manuálne vymedzených oblastí ohňa pomocou polynomických funkcií, uvádza práca 99.0 % úspešnosť detekcie ohňa pri 31.5 % falošných detekciách.

Rov. 2.9: Farebné pravidlá [23]

$$\begin{aligned}
 &Y(x, y) > Cb(x, y) \wedge Cr(x, y) > Cb(x, y) \\
 &Y(x, y) > Y_{mean} \wedge Cb(x, y) < Cb_{mean} \wedge Cr(x, y) > Cr_{mean} \\
 &|Cb(x, y) - Cr(x, y)| \geq T
 \end{aligned}$$



Obr. 2.14: ROC krivka [23]


Ďalšia práca, publikovaná autormi Borges, Mayer a Izquierdo [24] prezentuje metódu na určenie prítomnosti ohňa na danej snímke videa sledovaním viacerých náhodných charakteristík ohňa v reálnom čase. Jej cieľom ale nie je presne klasifikovať konkrétne pixely ohňa. V prvom rade sa opiera o vytvorenie iniciálnej masky pixelov ohňa na základe farby. Využíva všeobecné pravidlá z predošlej opisovanej práce [23] o priestore RGB a normalizovaného RGB z [22]. Práca uvádza, že detekcia na základe farby je najsilnejšou charakteristikou pre hľadanie ohňa vo videu a práve preto je výsledná maska vytvorená na základe tolerantného práhovania pravidiel s cieľom pokryť každý pixel ohňa, aj za cenu väčšieho počtu falošných detekcií. Falošné detekcie sú následne eliminované pomocou sledovania viacerých náhodných charakteristík. Prvou z nich je náhodné správanie veľkosti plochy výsledných oblastí masky ohňa. Do úvahy berie zmenu medzi aktuálnou a predošlou snímku kamery. V tomto, a aj v ďalšom popisovanom prístupe teda analyzuje pohyblivú zložku ohňa v čase. Ďalšou sledovanou charakteristikou je nerovnosť hraníc oblastí ohňa (angl. *boundary roughness*), ktoré sú porovnávané nie pomocou účinných, avšak výpočtovo náročných *fourierových deskriptorov*, ale pomocou jednoduchého konvexného obalu (Obr. 2.15), vytvoreného nad oblasťou ohňa, ktorý je údajne pre tieto účely rovnako účinným a nenáročným deskriptorom tvaru ako fourierov deskriptor. Nerovnosť hraníc je daná rozdielom medzi obvodom oblasti ohňa a obvodom konvexného obalu oblasti ohňa. Rovnako ako v predošlej charakteristike porovnáva aktuálny a predošlá snímka videa.



Obr. 2.15: Konvexný obal oblasti ohňa [24]

Ďalším sledovaným znakom je textúrová charakteristika ohňa, ktorá je jednoduchým a výpočtovo nenáročným spôsobom identifikovaná na základe rozptylu podozrivej oblasti. Posledná charakteristika je šikmosť distribučného súboru, ktorý predstavuje histogram červeného a zeleného kanálu RGB. Ako sa ukázalo, oblasti ohňa majú v týchto kanáloch výraznú negatívnu šikmosť so strednou hodnotou blízko maxima kanálu. V práci autori uvádzajú približné hodnoty koeficientov jednotlivých charakteristík rozhodujúcich o klasifikovaní snímky, respektíve oblasti ako oheň. Tieto koeficienty boli získané empiricky pomocou Bayesovho klasifikátora na rozsiahlych tréningových záznamoch z [25]. Celkový pohľad na metódu je zobrazený na Obr. 2.16.

Pri použití iba detekcie na základe farby dosahuje metóda až 11.2 % falošných detekcií a s použitím všetkých štyroch spomínaných charakteristík iba 0.9 % falošných detekcií. Hlavnou výhodou tejto metódy je jej použiteľnosť aj pri nestacionárnych kamerách.



Obr. 2.16: Klasifikácia snímok ohňa na základe prítomnosti ohňa podľa [24]



Obr. 2.17: Príklad oblasti podobnej ohňu [24]

2.4.2 Detekcia dymu

Autori Toreyin, Dedeoglu a Cetin v publikácii [26] predstavili inovatívnu metódu pre vizuálnu detekciu dymu v reálnom čase. Keďže sa v prvom rade odráža od segmentovania dymu pomocou detekcie pozadia, je možné ju využiť iba pri stacionárnych kamerách. Detekcia pozadia je implementovaná podľa [27]. Po segmentácii objektov popredia sleduje 4 špecifické charakteristiky dymu, na základe ktorých úspešne vymedzuje lokalizované časti. Prvou z nich je jeho transparentnosť, ktorú je možné detegovať sledovaním zjemňovania ostrosti hrán segmentovanej oblasti. Hrany sú reprezentované pomocou *priestorovej vlnkovej transformácie* (angl. *spatial wavelet transform*), kde sa zjemňovanie hrán prejaví znížením časti ich energie, avšak nie až na nulu. Zistené hodnoty energie aktuálnej snímky sú porovnávané s aktuálnym modelom pozadia (ktoré musí byť pre tieto účely uchovávané). Transformácie sú vyhodnocované v blokoch veľkosti 8×8 pixelov v jasovej zložke priestoru YUV (Obr. 2.18). Rozdelenie na bloky umožňuje v prípade potreby lokalizovať konkrétnu oblasť dymu v obrázku.



Obr. 2.18: Snímka videa pri zisťovaní zjemňovania ostrosti hrán pozadia dymom [26]

Ďalšou sledovanou a špecifickou charakteristikou pre dym je zníženie intenzity farebných zložiek U a V (priestoru YUV) segmentovanej časti popredia. Rovnakú vlastnosť majú však aj napríklad tieň objekto. Nasledujúcou sledovanou charakteristikou je trepotanie (angl. *flicker*) okrajových oblastí dymu, najmä pri začiatku dymenia, resp. horenia. Viaceré pixely okrajov dymu môžu niekoľko krát za sekundu byť pixelmi pozadia alebo pixelmi dymu.


Frekvencia miznutia nie je sledovaná na základe predpokladaných hodnôt, ale je trénovaná pomocou trojstavových Markových modelov. Trepotanie dymu však môže byť nebadateľné pri rýchlo šíriacich sa požiaroch, a teda rýchlo zväčšujúcich sa oblastiach dymu. Poslednou sledovanou, avšak rovnako dôležitou charakteristikou, je kontúra hraníc oblastí dymu (pozri Obr. 2.19). Hranica je reprezentovaná jedno-dimenziálnou krivkou vzdialenosti okraja od stredu danej oblasti. Predpokladom je, že po vlnkovej transformácii bude mať krivka hraníc dymu väčšiu frekvenciu, ako iné oblasti. Overenie metódy nezaznamenalo žiadne falošné detekcie pri 100 %-nej úspešnosti detekcie dymu. Pri porovnaní s metódou na detekciu ohňa dosiahla táto metóda v niektorých prípadoch skoršiu detekciu vzniknutého (respektíve ešte len začínajúceho) požiaru. Nevýhodou tejto metódy je však jej predpoklad, ktorým je aspoň čiastočná transparentnosť dymu pred začatím horenia.



Obr. 2.19: Porovnanie kontúr hraníc segmentovaných oblastí [26]. Na spodnom videu vodič úmyselne mení intenzitu stretávacích svetiel, čím sú splnené požiadavky všetkých charakteristík dymu okrem poslednej predstavenej – kontúry.

2.4.2.1 Zhodnotenie

Zadanie diplomového projektu vzniklo na podnet nemenovanej spoločnosti so záujmom o detekciu ohňa a dymu. Po analýze existujúcich riešení dymu a ujasnení požiadaviek spoločnosti, bolo prijaté rozhodnuté vynechať detekciu dymu z celkového riešenia projektu. Téma vizuálnej detekcie dymu pri použití statickej kamery sa javí byť viac menej uzatvorená, čo je v rozpore s výskumným zámerom záverečného projektu. Plánovaný koncept riešenia detekcie dymu v práci je dokonca takmer zhodný s postupom analyzovanej publikácie [26]. Navrhovanú detekciu pohybu ohňa je možné teoreticky jednoducho prispôbiť aj na detekciu dymu, avšak vzhľadom na existujúce riešenia nie je tento prístup perspektívny. Na Obr. 2.20 je možné vidieť ukážku úspešnej komerčnej detekcie dymu.



Obr. 2.20: Komerčné riešenie detekcie dymu *

* ORR Protection Systems - <http://www.orrprotection.com/detection/video-smoke-detection/>

3 Návrh riešenia

Cieľom tejto práce je úspešne detegovať oheň metódami počítačového videnia. Ako aj vyplýva z *Kapitoly 2*, o žiadaný výsledok sa táto práca usiluje použitím troch hlavných prístupov spracovania a analýzy obrazu (2.1 *Detekcia na základe pozadia*, 2.2 *Detekcia na základe farebného modelu*, 2.3 *Detekcia pohybu*). V priebehu riešenia práce bola však z plánovaného postupu detekcie vynechaná detekcia farby a tým pádom aj detekcia pozadia. Dôvody sú ozrejmene v časti 3.3 *Postup riešenia*.

Analyzované sú hlavné znaky prístupov alebo základný predstavitelia daného prístupu, avšak pre dosiahnutie čo najlepších výsledkov je potrebné experimentovať až za úrovňou analyzovaných prístupov, keďže oblasť počítačového videnia je rozsiahlou a rýchlo rozvíjajúcou sa oblasťou, a rôznymi existujúcimi prístupmi nepriamo ponúka pomocnú ruku pri hľadaní riešení rôznych špecifických problémov reálneho sveta. Vizualne rozpoznávanie ohňa patrí medzi ne. Pomocné prístupy nemusia pochádzať iba z oblasti počítačového videnia, ktorá už sama o sebe zasahuje do viacerých ďalších disciplín. Kľúčom k úspechu je potrebné prístupy nájsť, vhodne skombinovať, v prípade potreby modifikovať pre účely daného problému, a dostatočne overiť.


Hlavným ohraničením stanoveného cieľa práce je použiteľnosť riešenia v bežných podmienkach, teda za použitia bežných bezpečnostných priemyselných alebo domácich kamier. Pri využití detekcie farby je samozrejme potrebná farebná kamera. Keďže najperspektívnejšie využitie sa ponúka v podobe zlepšenia zabezpečenia proti škodám eliminovaním rizika vzniku požiarov, navrhnutá metóda musí byť aplikovateľná v reálnom čase. V našom ponímaní to znamená, že živý záznam z kamery môže byť pri prehrávaní doplnený o aktuálnu informáciu o detegovanom objekte, bez narušenia plynulosti prehrávania.

Ďalším dôležitým predpokladom, ktorý výrazne zjednoduší daný problém a teda umožní jeho vyriešenie v reálnom čase, je použitie statickej kamery. Dôvod je ozrejmene v nasledujúcich častiach, spolu s popisom navrhovaných metód na detekciu samotného ohňa. Predstavený je koncept postupu riešenia s popisom použitých prístupov a výsledky prvotných experimentov implementovaných metód. Ďalej je priblížený detailný pohľad na detekciu pohybu a v závere je popísaná implementácia celkového riešenia spolu s používateľským rozhraním. V práci sú vyžívané viaceré rôzne súbory videozáznamov, získané z [33], [34], [35], [36], [37].

3.1 Koncept postupu riešenia

Spomínaný predpoklad použitia statickej kamery, umožňuje využiť metódy detekcie pozadia, ktoré nenáročným spôsobom dokážu úspešne segmentovať nové alebo akékoľvek pohybujúce

sa objekty vo výhlade kamery. Takýmto objektom je aj oheň, a detegovaním popredia môžeme v reálnom čase získať z aktuálnej snímky videa oblasti, ktoré už môžu reprezentovať samotný oheň. Jedná sa o dobrý začiatok a vstup pre ďalšie metódy, ktoré následne vymedzia konkrétne oblasti, spĺňajúce špecifické charakteristiky ohňa. Celkový prehľad navrhovaného konceptu riešenia je znázornený na Obr. 3.1.



Obr. 3.1: Prehľad konceptu metódy detekcie ohňa

Naša navrhovaná metóda teda v prvom rade využíva detekciu pozadia, ktorej výstupom je maska popredia, teda maska nových objektov, ktoré sa objavili na sledovanej scéne. Získaný medzivýsledok dáva veľmi dobré predpoklady pre ďalšie rozpoznávanie, avšak za predpokladu použitia statickej kamery, ktorá ale je v mnohých existujúcich sledovacích video-systémoch samozrejmou.

Maska popredia je následne vstupom pre ďalší implementovaný prístup detekcie na základe farby. Cieľom tohto prístupu je ďalej vymedziť podozrivé oblasti ohňa pomocou známych pravidiel o pixeloch farby oblastí ohňa. Využitie sú pravidlá pri použití farebného priestoru YCrCb, predstavené v práci [23] (analyzované v časti 2.4.1). Pravidlá sú zostavené tak, aby tolerantným spôsobom vymedzili z aktuálnych oblastí iba také, ktoré na základe farebných vlastností pripomínajú oheň. Je možné využívať aj vlastné pravidlá, napríklad s použitým farebného priestoru HSI, avšak tréning vlastných pravidiel môže byť z dôvodu existencie už overených výsledkov v minulosti zbytočné. Výsledkom tohto prístupu je teda podmnožina vstupujúcej masky popredia. V prípadoch, kedy do záberu kamery nevstupuje okrem ohňa iný objekt, ktorý tiež spĺňa stanovené farebné podmienky, oheň je úspešne detegovaný. V reálnych prípadoch však do záberu kamery prichádza veľa ďalších, ohňu farebne podobných objektov. Je teda potrebné skúmať aj ďalšie charakteristiky ohňa.

Podstatnou charakteristikou, ktorú sme sa ďalej v tejto práci rozhodli sledovať, je pohybová vlastnosť plameňov. Plamene ohňa kmitajú s určitou frekvenciou a toto kmitanie je možné

pozorovať známymi metódami detekcie pohybu. Plamene obsahujú dostatočné množstvo záchytných bodov, ktoré možno detegovať ako lokálne body záujmu pre algoritmy sledujúce pohyb týchto bodov. Použitý algoritmus Lucas-Kanade [30] tieto body následne sleduje, čím vznikne vektorový priestor detegovaného pohybu plameňov. Vektorový priestor je následne analyzovaný s ohľadom na stanovené pohybové charakteristiky ohňa a aktuálne segmentované podozrivé oblasti sú na základe splnenia týchto charakteristík prehlásené za oblasti ohňa. Výstupom je konečná maska oblastí ohňa.

Na záver postupu je potrebné podotknúť, že cieľom práce nie je určiť aj pozíciu ohňa vo videu. Vo výsledku stačí prehlásiť, či sa oheň danej snímke nachádza, alebo nenachádza. Metódy, ktoré však sú pri postupe zvolené, už priamo pracujú s konkrétnou analyzovanou oblasťou. Ich výstupom teda je aj pozícia ohňa.

3.2 Experimenty s navrhovanými prístupmi

V tejto časti sú popísané prvotné skúmania navrhnutých metód, ktoré boli vykonané v úvodnej časti riešenia projektu. Jedná sa hlavne o oboznámenie sa s prístupmi detekcie farby a pozadia, od ktorých následne závisí komplexnejší prístup detekcie pohybu.

3.2.1 Detekcia pozadia a farby

Táto časť obsahuje popis a ukážky vykonaných experimentov s existujúcimi prístupmi počítačového videnia za účelom detekcie ohňa. Metódy sú implementované v jazyku C++ pomocou knižnice OpenCV. Pokusy s navrhovanými aj nenavrhovanými metódami sú nevyhnutným predpokladom pre úspešné riešenie problému, najmä z dôvodu existencie veľkého množstva teoreticky použiteľných metód s rovnako obsiahlymi možnosťami nastavenia ich parametrov.


Prvotné experimenty boli vykonané s dvoma bežne používanými metódami detekcie pozadia:

- **Základné modelovanie pozadia:** Použité je jednoduché, nenáročné modelovanie pozadia pomocou priemeru (teória uvedená v časti 2.1.2 *Základné modelovanie pozadia*). Na tieto účely je v OpenCV dostupná funkcia *accumulateWeighted()*. Model pozadia je uchovávaný ako priemerný obrázok, ktorý je na základe učiaceho koeficientu prispôbovaný každou novou snímku videa. Na Obr. 3.2 je znázornené segmentovanie na príkladnej snímke menej kvalitného záznamu, obsahujúci oheň, dym a ďalší pohyblivý objekt. Učiaci koeficient je v tomto prípade nastavený na hodnotu 0.005.
- **Štatistické modelovanie pozadia:** Na účely štatistického modelovania je použitá OpenCV trieda *BackgroundSubtractorMOG2* (teória uvedená v časti 2.1.3 *Štatistické*

modelovanie pozadia). Rovnaká snímka, ako v predošlom prístupe je znázornená na Obr. 3.3.



Obr. 3.2: Základné modelovanie pozadia; a) Originálna snímka videa s aplikovaným mediánovým filtrom; b) Rozdiel aktuálnej snímky a modelu pozadia v absolútnej hodnote; c) Prah rozdielu aktuálnej snímky a pozadia; d) Popredie snímky po aplikovaní morfológických operácií na masku popredia




Obr. 3.3: Štatistické modelovanie pozadia; a) Originálna snímka; b) Maska popredia; c) Maska popredia po morfológických operáciách; d) Popredie snímky

Na zvolenom zázname dosahujú obe z metód postačujúce a zároveň porovnateľné výsledky (Obr. 3.4). Výhody štatistického prístupu sa dostavujú v prípade scén s dynamicky meniacim sa pozadím. Medzi oboma metódami sú badateľné rozdiely, ktoré však je možné

minimalizovať použitím morfológických operácií. Na ukážkach sú zobrazené prípady s použitím iba troch normálových rozdelení. V neskorších fázach riešenia nechávame algoritmus voliť maximálny počet normálových rozdelení automaticky.




Obr. 3.4: Porovnanie základného a štatistického prístupu modelovania pozadia; a) základný; b) štatistický



Obr. 3.5: Odtieň a sýtosť pixelov manuálne zvolených oblastí ohňa


Prvotné výsledky skúmania farebných vlastností ohňa sú zobrazené na Obr. 3.5, ktorý obsahuje graf sýtosti pixelov manuálne zvolených oblastí ohňa v závislosti od odtieňa farebného priestoru HLS. Na samotnú detekciu farby sú aplikované pravidlá z práce [23] (pozri časť 2.4.1). Tretia polynomická rovnica posledného pravidla sa však javí ako chybná, preto je toto pravidlo vynechané. Deklarovaná úspešnosť funkčných pravidiel, pri použití prahu $T = 40$, sa javí na vybraných videách s ohňom ako pravdivá. Pri experimentoch však boli pri rozumných nastaveniach parametra pozorované rôzne falošné detekcie a rovnako aj nedetegované prípady (pozri príloha A.1 Experimenty). Väčšina týchto prípadov je ale

problémová na rozpoznanie aj pre človeka. V bežných svetelných podmienkach a bežne sfarbených plameňoch, je tento prístup úspešný (Obr. 3.6).



Obr. 3.6: Príklad vstupnej snímky videa, detekcie pozadia a úspešnej detekcie farby (zľava)


V druhej fáze komplexnejších experimentov s detekciou farby na vlastnom datasete (pozri 4.1 *Vlastný dataset*) boli dosiahnuté prekvapivo výrazne lepšie výsledky ako uvádza samotná publikácia. Pri 91 %-ných úspešných detekciách sa objavilo iba 7 % falošných detekcií. Prekvapivé je najmä to, že tieto výsledky boli dosiahnuté iba s detekciou farby, bez využitia detekcie pozadia, pričom často boli na zázname prítomné oranžové a žlté objekty. Do istého bodu zvoleného prahu sa metóde darí vylúčiť tieto objekty z detekcie, pri zachovaní vysokej úrovni úspešných detekcií ohňa. Porovnanie našich výsledkov s publikovanou ROC krivkou je možné vidieť na Obr. 3.7.



Obr. 3.7: Porovnanie úspešnosti detekcie ohňa na základe farby

3.2.2 Detekcia pohybu

Pokusy boli rovnako vykonané aj s algoritmom detekcie pohybu. Využitá funkcia knižnice OpenCV sa nazýva *calcOpticalFlowPyrLK()*, ktorá pomocou metódy Lucas-Kande sleduje pohyb lokálnych bodov záujmu. Použité sú iba jednakanálové snímky v odtieni sivej. Pre porovnanie výsledkov detekcie pri rôznych pomeroch konverzie RGB obrázka do odtieňov sivej pozri časť 4.5 *Zhodnotenie výsledkov*. Tieto body sú funkcii dodané manuálne, a sú zvolené tak aby rovnomerne pokrývali celý obrázok. Zaznamenaný pohyb je znázornený pomocou vektorov, ktorých farba je závislá od dĺžky vektora, postupne od zelenej, cez žltú, až po červenú farbu (Obr. 3.8). Ako je vidieť, predpoklady o náhodnom pohybe plameňov boli správne. Pri nekvalitných záznamoch bolo viac pohybu pozorovaného pri použití iba červeného kanála snímok, namiesto použitia konverzie trojkanálových snímok do jednakanálových.



Obr. 3.8: Pohybové vlastnosti ohňa

3.2.2.1 Vyhľadanie bodov záujmu


Základom detekcie pohybu sú body záujmu (resp. lokálne príznaky), ktorých pohyb je sledovaný vo videu. Zvoliť sledované body je možné jednoducho a rýchlo vytvorením rastra rovnomerne rozložených bodov. Čím je raster hustejší, tým môže byť výpočet pohybu pomalší. Výsledkom detekcie pohybu je v tomto prípade optický tok objektov. Pri sledovaní homogénnych objektov, kde je problém s vyhľadaním lokálnych príznakov, je tento prístup veľmi výhodný. Jeho nevýhodou však je časté strácanie bodov pri sledovaní. Tento nedostatok je možné riešiť prispôbením každého bodu blízkeho, lepšie detegovateľnému príznaku, avšak tým sa môžu stratiť podstatné informácie o toku objektov, a možno je už v tomto prípade vhodnejšie použiť niektorú zo sofistikovanejších metód vyhľadania, ako *Shi-Tomasi detektor* alebo *Harrisov detektor* (2.3.1 *Lokálne príznaky*). Raster je najlepšie použiť, ak nás zaujíma optický tok sekvencie dvoch snímok, a nie je potrebné sledovať konkrétny bod záujmu viac snímok. Pre každú snímku sa vytvorí nový raster bodov, a vypočítané body z predošlej snímky sa zahodia.

Ďalším spôsobom vyhľadania bodov je využitie spomínaného Harrisovho alebo Shi-Tomasi detektora. Knižnica OpenCV ponúka pre oba detektory združenú funkciu

GoodFeaturesToTrack(). Výsledok hľadania bodov je možné ovplyvniť nasledovnými parametrami algoritmu:

- maximálny počet nájdených bodov,
- najmenšia akceptovateľná kvalita bodu (závislá od kvality najlepšieho nájdeného bodu),
- minimálna vzdialenosť susedného bodu,
- veľkosť prehľadávaného bloku
- a maska prehľadávaných oblastí.


Pri využití detekcie pozadia je možné získať masku oblastí, ktorú je následne možné použiť na hľadanie bodov záujmu. Bolo predpokladom, že použitie masky zvýši rýchlosť hľadania bodov, avšak tento predpoklad nebol splnený. Výpočet kvality bodov je vykonávaný pre celú snímku videa, a špecifikovaná maska iba určuje, ktoré z už nájdených bodov majú byť vrátené. Samotné vyhľadanie bodov aj na celej snímke videa však nie je nijako výrazne časovo odlišné od ostatných algoritmov, použitých v implementácii. Porovnanie spôsobov je možné vidieť na Obr. 3.9.



Obr. 3.9: Porovnanie spôsobov vyhľadania bodov záujmu
(hore rovnomerný raster, dole Shi-Tomasi detektor)

3.2.2.2 Porovnanie pohybu objektov

Potrebné informácie o pohybe objektov máme. Otázkou však je, ako zistiť, či sa jedná o oheň. Na Obr. 3.10 je znázornený rovnomerný pohyb bežných objektov, v tomto prípade osôb na stavbe, v porovnaní s náhodným, až chaotickým, pohybom plameňov ohňa. Oblasti osôb obsahujú viaceré vektory podobného smeru, podobnej dĺžky, pričom oblasti ohňa rôzne smery a dĺžky vektorov



Obr. 3.10: Porovnanie pohybu bežných objektov vľavo s pohybom ohňa vpravo (ideálny prípad)

Na prvý pohľad sa vzájomné odlišenie týchto dvoch tried pohybov z pohľadu počítačového videnia a klasifikácie javí iba nenáročný problém zvolenia vhodných metrík. Rovnako však ako pri iných problémoch v tejto oblasti, aj v tomto prípade je na obrázku možné vidieť iba ideálny pozorovanie. Ľahko môže nastať aj opačný prípad, kedy bežný objekt vykazuje náhodný pohyb, a oheň pohyb rovnomerný. Dôvodom môže z časti byť nízke FPS alebo nízke rozlíšenie, no artefakty podobného charakteru je možné pozorovať aj pri kvalitnejších záznamoch.



Obr. 3.11: Porovnanie pohybu bežného objektu vľavo s pohybom ohňa vpravo (neideálny prípad)


3.2.3 Klasifikácia pomocou Support Vector Machine

Po zvolení vhodných príznakov je práci na rozpoznanie pohybu ohňa využívaný klasifikátor Support Vector Machine (SVM) [31]. Dôvodom zvolenia je jeho popularnosť a úspešnosť pri súčasne skúmaných problémoch počítačového videnia. Pred použitím klasifikátora pri trénoch na reálnych dátach sme sa však rozhodli preveriť jeho účinnosť na modelových prípadoch. Pre tieto účely bola využitá implementácia SVM v knižnici OpenCV. Implementácia v OpenCV vychádza z implementácie LIBSVM, publikovanej v [32].

Pri experimentovaní už boli dostupné prvotne namerané hodnoty jednotlivých tried problému (pozri 3.4.1.1 *Príznaky*) a tým pádom sme mali predstavu o probléme, ktorý sa klasifikátor pokúsi vyriešiť. Už na prvý pohľad je vidieť, že naše prvotné trénovacie dáta sú výrazne zašumené, obsahujú teda veľké množstvo neseparovateľných meraní.

Fiktívne modelové dáta sme sa rozhodli pri experimente rozdeliť na dve triedy v 2D priestore, ktoré nie je možné úspešne separovať lineárnou rovinou. Pre dosiahnutie čo najlepších výsledkov predikcie, je teda potrebné použiť polynomicke jadro klasifikátora. Dáta sú však modelované tak, že aj v tomto prípade sa klasifikátoru nemusí podať oddeliť triedy so 100 %-nou úspešnosťou. Vzhľadom na charakter dát bol zvolený druhý stupeň polynómu, a následne bolo skúmané správanie vytvorenej hranice medzi triedami pri použití rôznych hodnôt parametra C a ukončovacích výpočtových kritérií algoritmu SVM.

Parameter C je veľmi dôležitou súčasťou klasifikácie, najmä pri zašumených dátach. Pri zvolení nízkej hodnoty nie sú chybné klasifikácie príliš trestané, a tým pádom sa klasifikátor orientuje na intuitívne oddelenie čo najväčšieho množstva dát. Pri zašumených dátach je toto správna cesta, avšak nízke hodnoty C majú za následok nutnosť použitia viacerých podporných vektorov, ktorých počet negatívne ovplyvňuje rýchlosť predikcie. Pri trénovaní na modelových a aj na reálnych, niekoľko desaťtisícových vzorkách však rozdiel v rýchlosti predikcie nebol podstatný. Hodnotu parametra C je možné meniť po mocninách desiatky v rozmedzí napríklad 10^{-8} až 10^8 . Ukážky výsledkov experimentu sú znázornené na Obr. 3.12. Cieľom experimentu bolo overenie, či klasifikátor dokáže oddeliť triedy na základe výrazne zašumených dát. Pri vhodnom nastavení parametrov boli očakávania splnené.



Obr. 3.12: Vrchný rad znázorňuje výsledky klasifikácie s postupným znižovaním hodnoty parametra C (zľava). Ľavý obrázok v spodnom rade znázorňuje podporné vektory (zakrúžkované pozorovania) a pravý obrázok prezentuje výsledky pri zhutnení trénovacích dát najmä v problematickej oblasti.

3.3 Postup riešenia

Po vykonaní experimentov na základe navrhovaného konceptu postupu riešenia bol finálny postup riešenia práce upravený (*Obr. 3.13*). Podnet na úpravu pramenil od nemenovanej spoločnosti, ktorá prejavila záujem o navrhovaný systém detekcie ohňa. Novou podmienkou detekcie sa stala nezávislosť na farbe plameňov ohňa. V praxi je totiž napríklad v prípade sledovania výrobných procesov, využívajúcich rôzne chemické látky, očakávaný výskyt rôzne sfarbených plameňov. Celková detekcia ohňa je teda v konečnom dôsledku závislá iba od detekcie pohybu. Detekcia farby je z finálneho postupu vynechaná, avšak jej implementácia ostáva využitá na porovnanie s výsledkami detekcie pohybu a rovnako je využitá aj ako výpomoc pri vymedzení tried trénovacích dát z neanotovaných záznamov.

Využitie detekcie pozadia v postupe bez detekcie farby stráca zmysel. Hlavným dôvodom využitia detekcie pozadia bolo zníženie výskytu falošných detekcií farby, ktorej úlohou by bolo sledovať iba nové objekty v zázname. Oranžový objekt pozadia záznamu by bol v tomto prípade ignorovaný, a falošnú detekciu by mohol spôsobiť iba nový oranžový objekt popredia. Oranžovú farbu je však potrebné brať s rezervou a je uvedená iba ako príklad, pretože detekcia farby sofistikovaným spôsobom porovnáva hodnoty červeného kanála celého obrázka, a nemusí vyslovene detegovať iba čisto oranžový oheň. Úspešná môže byť aj pri odtieňoch smerujúcich ku žltej, červenej alebo aj zelenej farbe. Vzdialenejšie odtiene by však už boli problémom. Ďalším dôvodom využitia detekcie pozadia môže byť vymedzenie masky pre vyhľadávanie bodov záujmu pre algoritmus sledovania pohybu iba na objekty popredia, avšak ako bolo zistené, rýchlosť vyhľadania bodov sa tým nezvýši. Okrem iného je detekcia pohybu tiež formou detekcie pozadia, pretože pohyb je aj tak nájdený iba na objektoch popredia. Pokiaľ sú pri detekcii pozadia využité aj morfológické operácie, je v porovnaní s detekciou pohybu výrazne pomalšia. Detekcia pozadia môže byť ešte perspektívna pri sledovaní zhľuku vektorov pohybu, avšak v tejto práci nie je na tieto účely využitá (pozri 3.4.2 METÓDA 2: *Zhluk vektorov pohybu*).



Obr. 3.13: Upravený postup riešenia detekcie ohňa.
Použitie detekcie farby a detekcie pozadia je voliteľné.

Samotná detekcia ohňa na základe pohybu predstavuje novátorský prístup, ktorý prináša táto diplomová práca. Bez detekcie pozadia a farby je však problémová oblasť výrazne rozsiahlejšia a detekcia pohybu o to náročnejšia. Postup detekcie pohybu je priblížený v nasledujúcej časti. Predpoklad statickej kamery ostáva platný aj bez využitia detekcie pozadia, pretože je rovnako podstatný aj pri samotnej detekcii pohybu.


3.4 Detekcia pohybu

Pre úspešné detegovanie ohňa na základe pohybu je potrebné nájdený pohyb analyzovať za účelom odhalenia vzorov v špecifickom správaní plameňov. Výstupom detekcie, respektíve výpočtu pohybu z jedného bodu záujmu je bod záujmu na inej pozícii. Tieto dva body záujmu tvoria jeden vektor pohybu a cieľom práce je analyzovať pozorovaný pohyb z dvoch rôznych uhlov pohľadu ktorými sú:

- METÓDA 1:** Bod záujmu
METÓDA 2: Zhluk vektorov pohybu

Prvým zrejým a zároveň nenáročným z nich je analýza pohybu z pohľadu jedného bodu záujmu, ktorého zmena pozície je sledovaná v čase. Druhým, možno intuitívnejším avšak náročnejším, je analyzovanie pohybu z pohľadu zhľuku viacerých blízkyh vektorov pohybu. V ďalších častiach dokumentu budú navrhnuté prístupy nazývané aj ako *metóda 1* a *metóda 2*. V oboch metódach sa v konečnom dôsledku pozerá na vektory pohybu. Jedným z hlavných rozdielov je, že pri metóde 1 sa jedná o usporiadanú množinu vektorov, a pri metóde 2 o neusporiadanú. Na Obr. 3.14 je načrtnutý postup oboch metód pričom podrobne vysvetlené sú v nasledujúcich častiach. Napriek tomu, že sa jedná o dve nezávislé metódy, je možné ich spojiť do jedenej dvojfázovej metódy, kedy je výstup z metódy 1 vstupom pre metódu 2.

V ďalej práci sú analyzované rôzne možnosti určenia vstupných oblastí (zhlukov) pre metódu 2, avšak využívaná je práve výsledná oblasť ohňa z metódy 1. V tomto prípade je potrebné nastaviť čo najvyššiu citlivosť metódy 1, pričom metóda 2 zastáva úlohu odfiltrovaná čo najväčšieho počtu falošných detekcií.




Obr. 3.14: Postup detekcie pohybu

3.4.1 METÓDA 1: Bod záujmu

V sekvencii obrázkov je vektor pohybu daný začiatočnou polohou bodu záujmu na predošlom obrázku a koncovou polohou bodu záujmu aktuálneho obrázka. Koncová poloha bodu aktuálneho obrázka môže byť zároveň začiatočnou polohou bodu vektora pohybu získaného na nasledujúcom obrázku. Okrem samotnej sekvencie obrázkov pozorujeme teda aj istú (v prípade nájdienia pohybu) pod-sekvenciu bodov záujmu, ktoré určujú sekvenciu vektorov

pohybu, pričom počet vektorov $n = \text{počet_bodov_záujmu} - 1$. V konkrétnom čase analyzovanej sekvencie, napríklad $t = 4$, môžu byť v obrázku prítomné viaceré vektory pohybu, pričom tieto vektory sú v aktuálnom obrázku reprezentované iba koncovým bodom vektora, ktorý môže byť súčasťou sekvencie viacerých vektorov (Obr. 3.15).



Obr. 3.15: Sekvencia vektorov pohybu je daná sledovaním bodu záujmu v čase t

Vektor, znázornený na obrázku prerušovanou čiarou, reprezentuje výsledný pohyb sledovaného bodu záujmu od jeho inicializácie až po aktuálnu snímku, respektíve až po jeho „vymretie“. O vymretie bodu záujmu sa jedná v prípade, že na nasledujúcej snímke nebola nájdená nová poloha tohto bodu, poprípade táto poloha nebola vzdialená od začiatočnej viac ako stanovené minimum (predvolené na 1 pixel). V rámci jednej sekvencie pozícií bodov môže byť bod na tom istom mieste viac ako jeden krát, nie však bezprostredne za sebou. Pozície bodov sú reprezentované celočíselnými hodnotami dvoj-dimenzionálnej karteziánskej súradnicovej sústavy.

Na Obr. 3.14 je načrtnutý priebeh činností metódy 1. Tento priebeh je rovnaký pre každú snímku videa. Začiatok metódy je daný získaním prvej snímky videa. Na snímke sú vyhľadané body záujmu pomocou *goodFeaturesToTrack* algoritmu. Využitie rovnomerného rastra bodov pri metóde 1 nie je rozumné, pretože pri rastri sa body rýchlo strácajú, keďže nie sú prispôsobené lepšie detegovateľným príznakom, raster musí byť na každej snímke obnovovaný, a pre účely tejto metódy je potrebné, aby body záujmu vydržali živé čo najdlhšie (pozri 2.3.1 *Lokálne príznaky* a *Vyhľadanie bodov záujmu*).

Na nájdenie pohybu je samozrejme potrebné získať ďalšiu snímku videa. Z bodov na predošlej snímke sú nájdené nové pozície bodov. Na tieto účely je využitý *Lucas-Kanade Tracker* (pozri 2.3 *Detekcia pohybu* a 3.2.2 *Detekcia pohybu*). Predpokladom je, že každý bod záujmu prislúcha objektu a že tento bod aj nasleduje pohyb časti objektu, ktorá je v okolí sledovaného bodu. Ďalším predpokladom je, že sekvencia vektorov plameňov má odlišné vlastnosti v porovnaní s vektormi iných objektov. Na porovnanie týchto vlastností je potrebné zaviesť

vhodné metriky (predstavené v nasledujúcej časti 3.4.1.1 *Príznamy*).^{*} História pozície aktuálnych bodov je uchovávaná, a na základe tejto histórie sú vypočítané príznaky každého z aktuálnych bodov. Jedno pozorovanie je reprezentované jedným z aktuálnych bodov záujmu. Následne je pre každé pozorovanie vykonaná predikcia pomocou SVM klasifikátora. Od predikcie z pohľadu jedného bodu záujmu nie je možné očakávať, že všetky body ohňa budú označené pozitívne a body na ostatných objektoch budú označené negatívne. Po vykonaní prvotných experimentov s metódou 1 je zrejmé, že na určenie finálnych oblastí musí byť výstup predikcie analyzovaný na základe viacerých snímok. Z tohto dôvodu je pre celkové vyhodnotenie výsledkov predikcie zavedené modelovanie heat-mapy. Podrobne je popísané v nasledujúcej časti 3.4.1.2 *Vyhodnotenie predikcie*, vrátane ukážky prvotných experimentov s metódou 1. Práhouvaním heat-mapy a analýzou kontúr sú získané výsledné oblasti ohňa. Celkový proces navrhutej metódy sa opakuje s každou ďalšou snímkou videa.

Vyhľadanie bodov na novej snímke berie do úvahy už získané nové pozície bodov z predošlej snímky. Vyhľadanie je vykonané najskôr na celej snímke, bez ohľadu na už existujúce body. K existujúcim bodom sa však pridajú z novo-vyhľadaných iba tie, ktoré spĺňajú podmienku minimálnej vzdialenosti susedného bodu. Cieľom je, aby sa v blízkom okolí nenachádzalo zbytočne veľa rovnakých vektorov pohybu, ktoré by spomaľovali celkovú detekciu. Rovnaká minimálna vzdialenosť je dodržiavaná aj pri vyhľadaní bodov pomocou algoritmu *goodFeaturesToTrack*. Týmto spôsobom sa zabezpečí, aby bola podmienka splnená pre všetky aktuálne body záujmu.

Na záver uvádzame najdôležitejšie parametre vyhľadania bodov, ktorými je možné ovplyvniť celkový výsledok detekcie:

- metóda vyhľadania bodov (*Shi-Tomasi / Harris*),
- *minimálna vzdialenosť susedného bodu*
- a najnižšia povolená *kvalita bodov*.

Pri definovaní *minimálnej vzdialenosti susedného bodu* alebo najnižšej povolenej *kvality bodov* je *maximálny počet nájdených bodov* zbytočne obmedzovať.

3.4.1.1 Príznamy

V prvom rade sa pre účely analýzy pohybu ponúka využiť bežné štatistické charakteristiky ako stredná hodnota náhodnej veličiny, poprípade jej štandardná odchýlka. Počiatočne navrhnuté metriky pre sekvenciu vektorov pohybu sú nasledovné:

- *počet vektorov*,
- *stredná hodnota smeru*,

^{*} metrika je v práci označovaná aj ako príznak (dimenzia) vstupných údajov pre trénovaný klasifikátor

- *odchýlka zmeny smeru*,^{*}
- stredná hodnota dĺžky,
- *odchýlka dĺžky*,^{*}
- pomer dominantných smerov k počtu vektorov,[†]
- výsledný smer pohybu
- a výsledná dĺžka pohybu.

Po prvotných meraniach (pozri časť 4 *Overenie riešenia*) sa však ako smerodajné javia iba tie zvýraznené kurzívou. Sledovať strednú hodnotu dĺžky alebo výslednú dĺžku pohybu pre účely tejto práce nie je zaujímavé, pretože sa predpokladá využitie jej výsledkov pre detegovanie rôzne veľkých objektov pri použití kamier s rôzne veľkým rozlíšením. Trénovanie klasifikátora, citlivého na chyby merania, môže byť na základe týchto hodnôt kontraproduktívne.

Počet vektorov môže byť nazvaný aj ako doba existencie bodu, respektíve jeho vek. *Stredná hodnota smeru* je daná priemernou hodnotou uhla. Použitie konvenčného prístupu na získanie priemeru však v prípade veličiny neeuklidovského priestoru, akým je v tomto prípade smer daný uhlom, nie je správne. Uhol 0° je rovnaký ako uhol 360° , čo je pri výpočte priemeru potrebné zohľadniť. Korektné uhlové štatistiky sú predstavené a využívané pri metóde 2 v časti 3.4.2.1 *Príznaky*. Pri metóde 1 *stredná hodnota smeru* nie je využívaná.

Odchýlka zmeny smeru je daná bežným vzorcom štandardnej odchýlky (Rov. 3.1), s tým, že rozdiel medzi aktuálnou hodnotou uhla a strednou hodnotou nie je umocnený a neskôr odmocnený, a výsledná hodnota je normalizovaná predelením hodnotou π . Hodnota n je rovná počtu vektorov, δ_t je rovné uhlu v radiánoch medzi vektorom v čase t a vektorom v čase $t + 1$ (pozri Obr. 3.15). *Stredná hodnota* je v tomto prípade rovná nule, pretože nás zaujíma odchýlka zmeny smeru vzhľadom na smer aktuálneho vektora v čase t . Rozdiely nie sú umocňované, pretože sú vždy rovné nule, a zaujíma nás iba normalizovaná hodnota z intervalu $[0; 1]$. Pre lepšie pochopenie významu parametra uvádzame, že hodnotu 1, by nadobúdali sekvencie, ktorých uhol každej zmeny smeru je rovný 180° a hodnote 0 by odpovedali sekvencie bez zmeny smeru.

Rov. 3.1: Normovaná odchýlka zmeny smeru

$$\sigma_1' = \frac{1}{\pi} \frac{1}{n-1} \sum_{t=1}^{n-1} (\delta_t - 0)$$

Stredná hodnota dĺžky je daná priemernou hodnotou veľkosti každého vektora. *Odchýlka dĺžky* je pre naše účely tiež normalizovaná predelením strednou hodnotou dĺžky (Rov. 3.2). Hodnota

^{*} metrika je prispôsobená

[†] pre každý smer (hore, dole, doľava a doprava) sa jedná o inú hodnotu a teda zvlášť metriku

n je rovná počtu vektorov, d_t je rovné veľkosti vektora v čase t a $\bar{d}$ je stredná hodnota veľkosti vektorov.

Rov. 3.2: Normovaná odchýlka dĺžky

$$\sigma_2' = \frac{1}{\bar{d}} \sqrt{\frac{1}{n} \sum_{t=1}^n (d_t - \bar{d})^2}$$

Pomer dominantných smerov k počtu vektorov je vypočítaný pomer pre každý zo štyroch základných smerov *hore*, *dole*, *dol'ava* a *doprava* k celkovému počtu vektorov danej sekvencie. Jedná sa teda o štyri rôzne, ale vzájomne závislé metriky, každá pre jeden zo smerov *hore*, *doprava*, *dole* alebo *dol'ava*. Z pohľadu klasifikátora sa však jedná o nezávislé metriky. Smer *hore* je daný rozsahom $\left(\frac{\pi}{4}; \frac{3}{4}\pi\right)$ a ostatné smery analogicky. Ako príklad je možné sa pozrieť na sekvenciu vektorov na Obr. 3.15. Metrika pre smer *hore* je rovná $\frac{3}{4}$, pre smer *dole* rovná $\frac{1}{4}$ a pre *dol'ava* a *doprava* rovná 0.

Výsledný smer pohybu je rovný uhlu výsledného vektora, ktorého začiatkový bod je prvý bod sekvencie a koncový bod posledný bod sekvencie, s jednotkovým vektorom osi x . Výsledná dĺžka pohybu je rovná veľkosti dĺžky výsledného vektora.

3.4.1.2 Vyhodnotenie predikcie

Na každej snímke videa sú pomocou SVM predikcie ohodnotené aktuálne body záujmu. Pozitívne ohodnotené reprezentujú oheň a negatívne ohodnotené bežne pohybujúci sa objekt. Po vykonaní prvotných experimentov s SVM predikciou sa ukázali perspektívne výsledky. Body záujmu v oblastiach ohňa obsahujú väčšinové množstvo pozitívnych bodov, zatiaľ čo bežné objekty väčšinové množstvo negatívnych bodov (Obr. 3.16). Pozitívne body na bežných objektoch vo väčšine prípadov nie sú v danej oblasti dlhú dobu. Pre určenie výsledných oblastí, bez potreby využitia metód zhlukovania, a zároveň pre odfiltrovanie častých falošných detekcií bola zavedená heat-mapa pozitívnych bodov. Cieľom heat-mapy je vymedzenie takých oblastí, na ktorých sa už dlhšiu dobu objavujú pozitívne body.

Princíp modelovania heat-mapy spočíva v tom, že:

- heat-mapa aktuálnej snímky videa obsahuje kumulované informácie z niekoľkých predošlých snímok
- a výskyt každého pozitívneho bodu je na tejto heat-mape reprezentovaný pomerne veľkou „gauss-ovkou“.

Gauss-ovka je výstupom dvojdimenzionálnej funkcie normálového rozdelenia pre stanovenú štvorcovú oblasť. Hodnoty gauss-ovky sú v rozsahu $[0; \text{gauss max value}]$. V prípade, že sa gauss-ovky na jednej snímke prekrývajú, ich hodnoty sú sčítané, avšak iba v rámci rozsahu $[0; 1]$. Gauss-ovky na jednotlivých snímkach sú následne sčítané, čím je vytvorená celková

heat-mapa. Rozsah hodnôt heat-mapy je tým pádom v rozmedzí $[0; \text{heat-map size}]$. Výsledná oblasť ohňa je určená práhovaním hodnôt heat-mapy na aktuálnej snímke a analýzou kontúr. Detekcia ohňa je týmto spôsobom mierne oneskorená, vzhľadom na určenú veľkosť heat-mapy a pomeru práhovania. Modelovanie je možné ovplyvniť nasledovnými parametrami:

- **Heat-map size** (20 snímok): Parameter vyjadruje počet sledovaných snímok, resp. rozsah heat-mapy. V prípade, že heat-mapa obsahuje informácie zo stanoveného počtu sledovaných snímok, získaním novej snímky videa sa odstránia z heat-mapy informácie najstaršej snímky.
- **Gauss kernel size** (81 px): Celková veľkosť gauss-ovky v pixeloch.
- **Gauss sigma** (40 px): Rozptyl gauss-ovky v pixeloch.
- **Gauss increase ratio** (30 %): Parameter udáva pomer zvýšenia hodnôt gauss-ovky. Jeho účelom je zvýšenie viacerých hodnôt až na stanovenú maximálnu hodnotu (parameter *gauss max value*). Čím je tento pomer väčší, tým väčšia časť gauss-ovky obsahuje od jej stredu hodnoty rovné maximálnej hodnote.
- **Gauss max value** (30 %): Maximálna hodnota jednej gauss-ovky v rozsahu $[0; 1]$. Účelom parametra je určiť, koľko pozitívnych bodov na jednej snímke je potrebných v blízkosti seba, aby vznikla sčítaním ich gauss-oviek oblasť, ktorá má časť hodnôt rovné jednej.
- **Threshold** (50 %): Pomer práhovania celkovej heat-mapy.

Predvolené hodnoty (empiricky odvodené) parametrov sú uvedené v zátvorkách. V prípade nastavenia parametra *heat-map size* = 20, *gauss max value* = 0.3 a *threshold* = 0.5 je na prehlásenie danej oblasti za oheň potrebné, aby na minimálne 10-tich snímkach boli aspoň tri pozitívne body v tesnej blízkosti. Ukážku vyhodnotenia predikcie pomocou heat-mapy a určenie oblasti ohňa je možné vidieť na Obr. 3.17.



Obr. 3.16: Výsledok SVM predikcie bodu.
Pozitívne body sú označené fialovou farbou, negatívne zelenou.



Obr. 3.17: Modelovanie heat-mapy.
Vrchný rad reprezentuje stav po získaní troch snímok videa, spodný rad po získaní 13-tich snímok.

3.4.2 METÓDA 2: Zhluk vektorov pohybu

Podstatou metódy 1 je usporiadaná sekvencia pozícií jedného bodu záujmu na viacerých snímkach. Metóda 2 sleduje na rozdiel od metódy 1 neusporiadanú množinu (zhluk) vektorov v podstate iba na jednej snímke. V konečnom dôsledku je samozrejme aj v prípade metódy 2 potrebné sledovať zhluk viacerých snímok, avšak smerodajné pozorovanie môže byť samo o sebe aj na jednej snímke, čo pri metóde 1 nie je možné prehlásiť. Metóda 1 sleduje teoreticky pohyb iba jednej časti objektu, v našom prípade napríklad jeden plamienok. Pohyb plamienka môže

byť síce špecifický, v zmysle, že sa hýbe zo strany na stranu v rôznych smeroch, no z pohľadu jedného bodu objektu sa takýto náhodný pohyb môže vyskytovať aj na bežných objektoch, ktoré sa celé hýbu zo strany na stranu. Pri detegovaní náhodného pohybu bodu bežného objektu je väčšia pravdepodobnosť, že aj susedné body budú mať na danej snímke podobný smer pohybu. Naopak pri plameňoch ohňa, ako je možné vidieť na Obr. 3.8, majú susedné body výrazne odlišné smery pohybu. Pre zachytenie tohto javu metóda 2 sleduje susedné vektory pohybu v danom čase.

Na Obr. 3.14 je znázornený celkový postup metódy 2. Problémovou časťou metódy je hneď jej úvodná časť, a to určenie záujmovej oblasti. V práci je nakoniec pre tieto účely využitá priamo metóda 1, avšak zvažované sú aj rôzne ďalšie možnosti ako:

- detekcia pozadia + morfológické operácie + hľadanie kontúr,
- (detekcia pozadia $\cap$ detekcia farby) + morfológické operácie + hľadanie kontúr,
- zhľukovanie blízkyh vektorov pohybu,
- alebo pohyblivé okno.

V prípade získania oblasti pomocou metódy 1 sú vstupné kontúry oblasti ohraničené prislúchajúcim obdĺžnikom, následne je obdĺžnik mierne zväčšený. Výsledný sledovaný zhľuk je daný týmto obdĺžnikom, a nie vstupnou kontúrou.

Zhľuk oblastí ohňa nemusí na každej snímke vykazovať „chaotický“ pohyb (pozri Obr. 3.11). Z tohto dôvodu je potrebné sledovať určenú oblasť niekoľko snímok za sebou. Ak je už zhľuk sledovaný určený počet snímok, vypočítajú sa príznaky zhľuku, na základe ktorých je následne využitá SVM predikcia zhľuku. Pozitívne označené oblasti reprezentujú oblasti ohňa. Zhľuky, ktoré na viac ako 90-tich percentách sledovaných snímok neobsahujú aspoň 3 vektory pohybu, nie sú predikované a nie sú považované za oblasť ohňa.

Detekcia ohňa metódou 2 je vzhľadom na určený počet sledovaných snímok oneskorená. V prípade určenia záujmových oblastí pomocou metódy 1 je toto oneskorenie ešte zvýšené. Z postupu metódy 2 na Obr. 3.14 sú pre prehľadnosť vynechané kroky vyhľadanie bodov a nájdenie nových pozícií bodov, keďže už vychádza z metódy 1, ktorá tieto kroky obsahuje. V prípade využitia metódy 2 ako samostatnej detekcie (respektíve v prípade využitia iného spôsobu určenia zhľuku), sú samozrejme tieto kroky potrebné.

Výsledky predikcie je pri metóde 2 možné ovplyvniť spomínaným parametrom

- sledovaný počet snímok,
- parametrami vyhľadania bodov záujmu
- a v prípade využitia metódy 1 môže byť ovplyvnená aj jej parametrami vyhodnotenia predikcie.

3.4.2.1 Príznaky

Pre účely analýzy zhľuku vektorov sa rovnako ako pri metóde 1 ponúkajú bežné štatistické charakteristiky. S ohľadom na stanovený cieľ práce sú pri metóde 2 zvolené tri príznaky:

- priemerná normovaná *odchýlka dĺžky vektorov*,
- priemerná normovaná *odchýlka smeru vektorov*
- a priemerná *stredná hodnota smeru*.

Vzhľadom na určený počet sledovaných snímok, sa každá sledovaná oblasť skladá z viacerých zhľukov vektorov. Stále sa jedná o tú istú sledovanú oblasť, ktorá však na každej snímke obsahuje inú množinu vektorov. Pri výpočte príznakov jednej sledovanej oblasti sú v prvom rade vypočítané *odchýlky* a *stredná hodnota smeru* pre každú množinu vektorov zvlášť, a následne sú výsledky priemerované pre celú „históriu“ oblasti.

Pri výpočte *strednej hodnoty smeru* nie je možné využiť konvenčný spôsob výpočtu priemeru. Keďže sa jedná o kruhový rozsah $[0^\circ, 360^\circ)$, na vzdialenosť dvoch uhlov je možné sa pozeráť z dvoch smerov (v protismere, resp. v smere hodinových ručičiek). Priemer dvoch uhlov je v tomto prípade rovný polovici tej vzdialenosti, ktorá je z nich kratšia. Ak sú obe vzdialenosti rovnaké, výsledkom priemeru sú bohužiaľ dve rôzne, avšak rovnako správne hodnoty. Pre účely práce je v tomto prípade volená iba jedna z hodnôt.

Smer vektora je daný uhlom tohto vektora s jednotkovým vektorom osi y . Uhol vektora v smere dohora, ktorý je rovnobežný s osou y , je teda rovný 0° , resp. 360° . Vzorec normovanej *odchýlky smeru vektorov* je daný vzorcom *Rov. 3.3*. Vzorec *odchýlky dĺžky vektorov* je rovnaký ako v prípade metódy 1 (*Rov. 3.2*).

Rov. 3.3: Normovaná odchýlka smeru n vektorov zhľuku. Vstupné uhly sú v radiánoch.

$$\sigma_1' = \frac{1}{\pi} \frac{1}{n} \sum_{v=1}^n (uhol\ vektora\ v - stredná\ hodnota\ smeru)$$


3.4.2.2 Vyhodnotenie predikcie

Na rozdiel od metódy 1, nie je nutné výstup z predikcie SVM ďalej analyzovať. Kumulované informácie viacerých snímok už sú zakomponované priamo v príznakoch zhľuku. Ďalšie analyzovanie pozitívne ohodnotených oblastí však nie je zbytočné. Po viacerých krokoch a pohľadoch na pohyb objektov je predpokladom, že získaná oblasť naozaj reprezentuje oheň. Intenzita a pohyb ohňa sú však variabilné, a ľahko sa môže stať, že oheň výrazne zoslabne a prestane byť detegovaný. Pri predpoklade, že oheň nemení svoju polohu (minimálne zdroj horenia), by bolo vhodné získanú oblasť sledovať aj na ďalej, pričom už by nemusela spĺňať tak isto prísne kritériá, ako v úvodných krokoch detekcie.

3.5 Popis implementácie

Knižnica OpenCV ponúka prostredníctvom rozhrania Qt* jednoduchú možnosť na vizualizáciu a manipuláciu obrázkov.† Manipulácie zahŕňajú približovanie a oddiaľovanie obrázka alebo jeho uloženie, pričom je možné pridať vlastné ovládacie prvky, napríklad pre prispôbenie rôznych parametrov použitých algoritmov. Pri vizualizovaní rôznych obrázkov súčasne je potrebná inštancia dialógového okna pre každý obrázok zvlášť. V prípade potreby sledovať viacero rôznych obrázkov súčasne nastáva problém s udržiavaním rozmiestnenia jednotlivých inštancií. Problém sa objavuje najmä pri spúšťaní aplikácie na monitoroch s rôznym rozlíšením.

Najmä pre zefektívnenie práce s viacerými výstupmi, ktoré zdieľajú ovládacie prvky, je navrhnuté vlastné grafické používateľské rozhranie. Na Obr. 3.18 sú zobrazené základné prípady použitia. Pomocou rozhrania je možné meniť rôzne parametre detekcie a sledovať jej priebeh.




Obr. 3.18: Diagram základných prípadov použitia

* multiplatformové aplikačné a grafické rozhranie pre jazyk C++ – <http://qt-project.org/>

† pod obrázkom sa rozumie aj snímka videa

Podrobný diagram prípadov použitia, ktorý je výrazne rozsiahlejší oproti základnému, je možné nájsť v prílohe na Obr. B.2. Používateľom rozhrania je najmä vývojár riešenia, od čoho sa odvíjajú aj navrhnuté ovládacie prvky a výstupy detekcie. Súčasťou implementácie je aj anotátor videí. Podrobný popis používateľského rozhrania a celkovej funkcionality je obsiahnutý v prílohe B.3 *Používateľská príručka*. Náhľad rozhrania je na Obr. 3.19. Detailnejší pohľad je možné nájsť v Prílohe A.4. Podrobný technický popis implementácie je uvedený v prílohe B.1 *Implementácia*.



Obr. 3.19: Náhľad používateľského rozhrania

4 Overenie riešenia

4.1 Vlastný dataset

Na overovanie výsledkov riešenia je v práci využívaný vlastný dataset obsahujúci približne dve hodiny záznamov ohňa aj dymu v exteriéry (nie je možnosť využiť fyzické detektory dymu). Celková dĺžka video-záznamov existujúcich datasetov ohňa a dymu je iba zlomkom z celkovej dĺžky nášho datasetu, pričom vzhľadom na kvalitu je použiteľná iba časť záznamov [33], [34], [35], [36], [37]. Rozlíšenie existujúcich je štvornásobne nižšie ako dnes bežné 720p HDReady rozlíšenie a FPS je v niektorých pod úrovňou 10 snímok za sekundu.

Vlastný dataset obsahuje záznamy v rozlíšení aj 1080p FullHD pri 20 FPS aj 720p HDReady pri 30 FPS. Nahrávané sú digitálnou zrkadlovkou Canon EOS 500D so statívom ako aj so zapožičanou priemyselnou bezpečnostnou IP kamerou Dahua. Oheň rôznej intenzity na dvoch rôznych miestach je pozorovaný z rôznych uhlov a vzdialeností. Jeden zdroj ohňa je otvorený, druhý uzatvorený. Popri horiacom ohni je prítomný aj rôznorodý pohyb dvoch až troch osôb pri špecifických činnostiach, ako napríklad pílenie vianočného stromčeka. Často je oheň prekrytý pohybom osoby, alebo sa osoba pohybuje za plameňmi, alebo priamo niečo vkladá do ohňa. Zámerne je na niektorých záberoch traseť vetvičkou stromu, alebo otáčané kusom kartónu na jednom mieste. Ukážky vybraných snímok je možné vidieť na *Obr. 4.1*.



Obr. 4.1: Ukážka vlastného datasetu

4.2 Spôsob vyhodnotenia úspešnosti

Výstupom oboch navrhnutých metód detekcie ohňa je oblasť daná jej kontúrou alebo prislúchajúcim obdĺžnikom. Skutočné oblasti ohňa sú vo videu anotované vo forme mierne väčšieho obdĺžnika ako je samotná oblasť ohňa. Za úspešnú detekciu je považovaná taká oblasť, ktorej prienik s anotovanou skutočnou oblasťou ohňa je neprázdny. V prípade, že viacero oblastí v rámci jednej snímky zasahuje do anotovanej oblasti, stále sa jedná o jednu úspešnú detekciu. Ak získaná oblasť nezasahuje do žiadnej anotácie, jedná sa o falošnú detekciu. Na jednej snímke videa je možné dosiahnuť iba jednu falošnú detekciu, bez ohľadu na počet získaných oblastí, ktoré nezasahujú do anotácie. Jedna snímka môže obsahovať viacero anotácií ohňa a počet možných úspešných detekcií na snímkach s viacero anotáciami je rovný počtu anotácií.

Na vizualizovanie pomeru úspešných detekcií (angl. *true positive rate*, *TP rate*) voči falošným detekciám (angl. *false positive rate*, *FP rate*) pri rôznych hodnotách parametra ovplyvňujúceho toleranciu detekcie je využívaná ROC krivka (angl. *Receiver Operating Characteristic*). Vzorce pre výpočet *TP rate* a *FP rate* sú uvedené v Rov. 4.1. Konkrétne pozícia na krivke prislúcha konkrétnej hodnote parametra ovplyvňujúceho toleranciu.

Rov. 4.1: Vzorec pre výpočet *TP rate* a *FP rate*. *TP* = počet úspešných detekcií,
P = počet anotácií ohňa, *FP* = počet falošných detekcií, *N* = počet snímkov

$$TP\ rate = \frac{TP}{P}, \quad FP\ rate = \frac{FP}{N}$$

4.3 METÓDA 1: Bod záujmu

4.3.1 Trénovacie dáta

Táto časť obsahuje výsledky meraní analýzy pohybu v podobe grafov závislostí medzi navrhnutými metrikami, popriprade v podobe histogramov hodnôt konkrétnych metrík. Každému pozorovaniu a zisteniu je venovaná zvlášť pozornosť. Analýza pohybu je vykonaná z pohľadu jedného bodu záujmu, popísaného v časti 3.4.1 METÓDA 1: *Bod záujmu*.

Jeden bod na grafe reprezentuje jedno meranie. Meraním je sekvencia vektorov pohybu, ktoré sú dané sledovaním polohy jedného bodu záujmu v čase. Jedno pozorovanie na aktuálnej snímke môže byť v prípade nevymretia bodu pozorovaním aj na nasledujúcej snímke s tým rozdielom, že je obohatené o ďalšiu pozíciu bodu. Nejedná sa o nežiadany jav, no pri najmä pri analýze trénovacích dát je vhodné si túto skutočnosť uvedomovať.


V úvode tejto časti sú predstavené výsledky reprezentatívneho pozitívneho prípadu (ohňa), následne je predstavený reprezentatívny negatívny prípad (iný pohyblivý objekt) a v závere je uvedený problémovjší pozitívny prípad ohňa, ktorý je zaťažený prvkami negatívneho.

4.3.1.1 Oheň z menšej vzdialenosti


Merania nekontrolovaného ohňa, zaznamenaného z menšej vzdialenosti, kamerou v rozlíšení aspoň 1 megapixel, sú v tejto práci považované za ideálne. Pri záberoch z väčšej vzdialenosti je identifikovanie náhodného pohybu plameňov problémovjšie. Pod nekontrolovaným ohňom je myslené horenie bežného materiálu v bežných podmienkach, ako napríklad papier alebo drevo, pričom množstvo horiaceho materiálu je v takom rozsahu, aby bolo možné pozorovať náhodný pohyb plameňov. Prúdenie vzduchu v okolí plameňov by malo byť obmedzené na minimum. Príklad záberu s ideálnym ohňom je na *Obr. 3.8*. Merania obsahujú vyše 24 tisíc inštancií získaných zo sekvencie 75-tich snímok.

Pre vyhodnocovanie náhodného pohybu plameňov sa po prvotných meraniach javí ako najpodstatnejšia závislosť odchýlky zmeny smeru od počtu vektorov sekvencie, ktorá je zobrazená na *Obr. 4.2*. Z grafu sa dá vyčítať, že čím viac snímok daný bod nevymrie, tým je väčšia pravdepodobnosť, že pokiaľ sa jedná o oheň, bude mať polovičnú hodnotu odchýlky. V prípade polovičnej odchýlky je v priemere každý vektor sekvencie vychýlený od predošlého o 90° , čo je jasným dôkazom náhodného pohybu. Po porovnaní s meraniami bežného pohybu (v ďalšej časti) vyplýva, že smerodajné budú práve sekvencie s väčším počtom vektorov.



Na *Obr. 4.3* sú zobrazené ďalšie 4 príznaky, udávajúce pomer daného smeru v celej sekvencii vektorov v závislosti od počtu vektorov. Zaujímavé na tomto príznaku je, že žiaden zo smerov nie je pri záberoch ohňa z blízka výrazne dominantnejší. Práve naopak, každý zo štyroch smerov postupne konverguje k štvrtinovému pomeru. Smer *hore* sa však predsa ukazuje ako mierne dominantnejší, čo je pri plameňoch očakávané. Treba však ešte podotknúť, že horizontálne smery sú náchylné na vplyv prúdenia vzduchu na plamene, resp. vetra. V týchto prípadoch budú príznaky podobné bežným pohybom iných objektov. Zmena príznaku jedného smeru navyše ovplyvní príznaky iných smerov. Pri trénovaní klasifikátora tento príznak nie je využitý.




Obr. 4.2: Závislosť odchýlky zmeny smeru ideálneho ohňa od počtu vektorov danej sekvencie.



Obr. 4.3: Pomer smeru (hore, doprava, dole, doľava) ku počtu vektorov

Obr. 4.4: Histogram hodnôt príznaku *stredná hodnota smeru*.Obr. 4.5: Histogram hodnôt príznaku *odchýlka dĺžky*.



Obr. 4.6: Histogram hodnôt príznaku *stredná hodnota dĺžky*.

Sledovanie strednej hodnoty smeru (Obr. 4.4) konvenčným spôsobom nie je smerodajné (pozri časť 3.4 *Detekcia pohybu*) a je v tejto časti uvedené iba pre úplnosť s navrhnutou analýzou pohybu. Podľa tohto príznaku má najviac sekvencií priemerný smer vektorov v rozsahu $(0 \text{ rad}; 1 \text{ rad})$ čo je približne 0° až 60° . Toto zistenie však nie je metodicky správne. Pri tréningu klasifikátora metódy 1 stredná hodnota nakoniec nie je využívaná. Kruhovú štatistiku je korektne počítaná a využívaná pri metóde 2. Pri metóde 1 je žiadané, aby sledovala iba náhodný pohyb, bez ohľadu na dominantný smer sekvencie.


Normovaná odchýlka dĺžky vektorov vykazuje už použiteľnejšie výsledky (Obr. 4.5). Väčšina sekvencií je zložená z vektorov, ktorých odchýlka dosahuje hodnoty takmer rovné strednej hodnote dĺžky (zobrazená na Obr. 4.6), pričom sa objavujú aj odchýlky veľké takmer 1,5-násobok strednej hodnoty. Väčší rozptyl dĺžky je v prípade ohňa očakávaný. Ostatné objekty vykazujú menšie hodnoty rozptylu. Normálové rozdelenie histogramu narúšajú hodnoty menšie ako 0,2, ktoré možno považovať za šum, zrejme nepodstatných bodov záujmu, ktoré rýchlo vymreli. Jedná sa o podobnú situáciu nezaujímavých meraní s nízkym vekom, ako v prípade príznakov *odchýlka zmeny smeru* a *pomer smeru vektorov*, ktoré boli porovnávané práve v závislosti od počtu vektorov.

Stredná hodnota dĺžky je ďalší z príznakov, ktorý ako samostatná jednotka nemá veľkú váhu pri odhalení správania ohňa. Je totiž ovplyvnený rôznym rozlíšením snímajúcej kamery a vzdialenosťou od jej objektívu (Obr. 4.6). V tejto časti je rovnako uvedený iba pre úplnosť a lepšiu predstavu o veľkosti skúmaných vektorov. Pre pripomenutie uvádzame, že sa jedná o euklidovskú vzdialenosť v pixeloch.


4.3.1.2 Bežné objekty

Táto časť je zameraná na porovnanie meraní pohybu bežných objektov s meraniami ohňa z menšej vzdialenosti v predošlej časti. Za bežný pohyb, ktorý je zároveň aj primerane komplexný, bol zvolený pohyb osôb na stavenisku. Príklad záberu s bežným pohybom je na Obr. A.3. Merania obsahujú takmer 30 tisíc inštancií.

Závislosť odchýlky zmeny smeru od počtu vektorov sekvencie je zobrazená na Obr. 4.7. S narastajúcim počtom vektorov konverguje odchýlka k hodnote 0,15. Meranie dokazuje, že bežný pohyb nemá tendenciu výrazne meniť smer a znovu je možné pozorovať tento jav najmä pri sekvenciách s väčším počtom vektorov, kde sa prípadné chyby merania strácajú. V porovnaní s ohňom z menšej vzdialenosti sa jedná o najzásadnejší rozdiel.




Obr. 4.7: Závislosť odchýlky zmeny smeru od počtu vektorov danej sekvencie.



Obr. 4.8: Pomer smeru (hore, doprava, dole, doľava) ku počtu vektorov.

Na Obr. 4.8 sú zobrazené príznaky, udávajúce pomer daného smeru v celej sekvencii vektorov v závislosti od počtu vektorov. Oproti ohňu z menšej vzdialenosti je možné pozorovať, že v tomto prípade sa objavuje viacero sekvencií, ktoré obsahujú iba jeden dominantný smer. Jedná sa najmä o početnejšie inštancie s pomerom väčším ako 0,5.

Normovaná odchýlka dĺžky vektorov (Obr. 4.9) je v prípade bežného pohybu vo väčšine meraniach menšia ako 0,6. V prípade ideálneho ohňa je odchýlka rozmiestnená viac-menej až v okolí hodnoty 0,8. Jedná sa teda o nezanedbateľný príznak, ktorý určite môže dopomôcť k úspešnej detekcii ohňa.




Obr. 4.9: Histogram hodnôt príznaku *odchýlka dĺžky*.


4.3.1.3 Oheň z väčšej vzdialenosti

Pre lepšiu predstavu o náročnosti problému uvádzame výsledky meraní pohybu ohňa, ktorý je nasnímaný z väčšej vzdialenosti kamerou s nižším rozlíšením. Príklad záberu ohňa, ktorého výsledky meraní nie sú ideálne, je na Obr. 3.6. Scéna je dokonca situovaná tak, že plamene ohňa majú svetlé pozadie s podobným odtieňom ako samotné plamene.

V prípade nádejného príznaku *odchýlka zmeny smeru* už teraz nie je možné pozorovať výrazné zmeny oproti bežnému pohybu iných objektov (Obr. 4.10). Pri pozornejšom zahľadnutí na najtmavšie body grafu je však možné vidieť prítomnosť normálového charakteru so strednou hodnotou na úrovni odchýlky 0,4. Náhodnosť pohybu neideálneho ohňa nie je tak výrazná ako ideálneho, no stále je možné ju pozorovať. Merania sú však do istej miery zaťažené aj charakteristickými pohybmi pre bežné objekty.




Obr. 4.10: Závislosť odchýlky zmeny smeru od počtu vektorov danej sekvencie.



Obr. 4.11: Pomer smeru (hore, doprava, dole, doľava) ku počtu vektorov.

Príznaky, udávajúce pomer daného smeru v celej sekvencii vektorov v závislosti od počtu vektorov je možné rovnako subjektívne zaradiť medzi ideálny oheň a bežné objekty (Obr. 4.11). Smer *doprava* je v tomto prípade dominantný aj pri viacpočetných sekvenciách. Ostatné smery nie sú až také dominantné, ako v prípade bežných objektov, no o zhode s ideálnym ohňom nie je možné hovoriť.

Potešujúcejším zistením je, že histogram *odchýlky dĺžky* je veľmi podobný histogramu ohňa z menšej vzdialenosti (Obr. 4.12). V tomto prípade je ale prítomné väčšie množstvo meraní s veľmi malou odchýlkou pod 0,2. Stále je však možné na istej podmnožine meraní pozorovať špecifické správanie plameňov ohňa.



Obr. 4.12: Histogram hodnôt príznaku *odchýlka dĺžky*.

4.3.2 Trénovanie klasifikátora

Pre odbremenenie klasifikátora od snahy oddeliť neseparovateľné dáta, sú na trénovanie využité iba smerodajné merania s počtom vektorov ≥ 4 (pozri 4.3.1 *Trénovacie dáta*).

V Tab. 4.1 sú uvedené parametre trénovaného SVM klasifikátora. Pomer pozitívnych ku negatívnym inštanciam je približne 1:1. Pri trénovaní bolo využitých 10 rôznych hodnôt parametra C. Každá hodnota parametra je trénovaná a overovaná s využitím cross-validácie. Trénovacie dáta sú rozdelené na tri podmnožiny. Trénovanie je vykonané na každej kombinácii dvoch z týchto množín pričom zvyšná tretia je využitá na overenie úspešnosti predikcie. Výsledná úspešnosť klasifikátora pre daný parameter C je určená priemernou úspešnosťou cross-validácie. Použité príznaky sú *počet vektorov*, *odchýlka zmeny smeru* a *odchýlka dĺžky*. Najlepšie výsledky dosahuje klasifikátor pri hodnote parametra $C = 10^{-3}$ (pozri Tab. 4.2). Pri vyšších hodnotách je možné vidieť príklad typického pretrénovania klasifikátora, kedy je úspešnosť zhodná s úspešnosťou pri náhodnej predikcii.

Tab. 4.1: Parametre SVM pre metódu 1

Počet inštancií:	~ 60 tis.
Počet príznakov:	3
Cross-validácia:	3 podmnožiny
Parameter C:	$10^{-10} - 10^{-1}$
Typ jadra:	polynomicke 2. stupňa

Tab. 4.2: Porovnanie úspešnosti trénovania SVM pri rôznej citlivosti na chyby.

PS = Pozitívne body – Skutočnosť, PP = Pozitívne body – Predikcia,

U = Úspešnosť predikcie (priemerná)


Parameter C	1.pokus			2.pokus			3.pokus			Trvanie h:m:s	Úspešnosť
	PS	PP	U	PS	PP	U	PS	PP	U		
10^{-10}	48%	0%	50%	49%	0%	52%	49%	0%	51%	00:01:20	51,17 %
10^{-9}	48%	3%	54%	49%	3%	55%	49%	3%	54%	00:01:20	54,36 %
10^{-8}	48%	12%	59%	49%	11%	59%	49%	12%	59%	00:01:02	58,91 %
10^{-7}	48%	17%	60%	49%	16%	61%	49%	17%	60%	00:01:02	60,34 %
10^{-6}	48%	19%	62%	49%	17%	62%	49%	18%	61%	00:01:21	61,63 %
10^{-5}	48%	23%	69%	49%	22%	69%	49%	23%	69%	01:32:00	68,81 %
10^{-4}	48%	30%	72%	49%	28%	72%	49%	29%	72%	02:43:00	72,06 %
10^{-3}	48%	34%	73%	49%	33%	73%	49%	34%	73%	03:15:00	73,06 %
10^{-2}	48%	100%	49%	49%	100%	48%	49%	100%	49%	02:21:00	48,99 %
10^{-1}	48%	100%	49%	49%	100%	49%	49%	100%	49%	02:03:00	48,90 %

4.3.3 Výsledky predikcie

Podstata metódy 1 spočíva najmä v SVM predikcii bodu. Tolerancia SVM klasifikátora je však zvolená pevne, vzhľadom na najvyššiu dosiahnutú úspešnosť pri trénovaní. Variabilné sú však parametre modelovania heat-mapy (pozri 3.4.1.2 *Vyhodnotenie predikcie*). Najpodstatnejším z nich z pohľadu tolerancie je *threshold*. Jeho zmena najvýraznejšie ovplyvňuje pomer medzi úspešnými a falošnými detekciami. Jeden bod na ROC krivke prislúcha konkrétnej hodnote *threshold*-u (pozri 4.2 *Spôsob vyhodnotenia úspešnosti*). Na porovnanie sú uvedené tri rôzne prístupy:

- (1) Pri prvom pokuse sú využívané predvolené hodnoty parametrov heat-mapy. Keďže použitý klasifikátor je trénovaný na inštanciách s počtom vektorov ≥ 4 , predikcia je tiež vykonávaná iba na takýchto bodoch. Merania sú vykonané s troma rôznymi hodnotami *threshold*-u. S postupným znižovaním *threshold*-u až na úroveň 10 %, sa podarilo metóde 1 dosiahnuť iba 79 %-ný *TP rate*. Pre doplnenie vývoja ROC krivky tolerantnejším smerom sú vykonané dodatočné merania pri zvýšených hodnotách parametra *gauss max value* na úroveň 0,5 a 0,7. Týmto spôsobom je pre dosiahnutie maximálnej hodnoty heat-mapy pre jednu snímku potrebných menej pozitívnych bodov v tesnej blízkosti seba. Posun k vyšším hodnotám *TP rate* je však stále nevýrazný. Z tohto dôvodu bol vykonaný nasledovný pokus (2).
- (2) Pre zvýšenie celkovej úspešnosti detekcie sú v tomto prípade všetky sekvencie s počtom vektorom < 4 rovno prehlásené ako pozitívne (bez vykonávania SVM predikcie). Vykonané sú merania s piatimi rôznymi hodnotami *threshold*-u, pričom pri 10 %-ách dosiahla metóda 1 úspešnosť detekcie 98 % avšak až pri 53 %-ách falošných detekcií. Pri použití 70 %-ného *threshold*-u je dosiahnutá úspešnosť 72 % pri 8 %-ách falošných detekcií. Úspešnosť tohto merania na konkrétnych analyzovaných videách je možné porovnať v Tab. 4.3. Spomedzi všetkých prístupov metódy 1 sa javí byť prístup (2) ako najúspešnejší.
- (3) Pokus vychádza z pokusu (2). Za účelom zníženia pomeru falošných detekcií popri zachovaní úrovne úspešných detekcií je pri pokuse (3) zväčšená veľkosť heat-mapy na 60 snímok. Oblasť bežných objektov by pri dlhšom sledovaní mala obsahovať menej pozitívnych bodov. Toto tvrdenie je potvrdené; pri rovnakej hodnote *threshold*-u je nižšia úroveň falošných detekcií, avšak priamo úmerne sú znížené aj úspešné detekcie. Výsledná ROC krivka ma teda rovnaký charakter ako pri prístupe (2).

ROC krivky prislúchajúce jednotlivým prístupom sú zobrazené na Obr. 4.13. Ukážky úspešných, neúspešných aj falošných detekcií je možné nájsť v prílohe A.2.



Obr. 4.13: Porovnanie úspešnosti metódy 1 pri použití rôznych parametrov

Vzhľadom na sledované príznaky pohybu jedného bodu je možné považovať metódu 1 za pomerne úspešnú. SVM predikcia bodu slúži naozaj dobre na odhalenie náhodného pohybu. Slabinou metódy 1 v zmysle falošných detekcií je fakt, že aj bežné objekty môžu vzhľadom na jeden bod záujmu ľahko vykazovať nerovnomerný pohyb. Stačí iba sa nejaká časť objektu hýbala na jednom mieste rôznymi smermi. Príkladom môže byť trasúca sa vetvička stromu, ba dokonca aj stojaca osoba, ktorá je teoreticky v klude, no málokedy bez mierneho kolísania napríklad. Rovnako nerovnomerné otáčanie nejakého objektu na menšom priestore predstavuje z pohľadu jedného bodu sekvenciu s vysokou *odchýlkou zmeny smeru* a *odchýlkou dĺžky vektorov*. Nedostatky algoritmu nájdenia novej pozície bodu môžu byť rovnako veľkým problémom, pretože napríklad nohavica pohybujúcej sa osoby síce môže mať na jej okrajoch dobre detegovateľné lokálne príznaky, no pri pohybe sa vlnením látky mení poloha týchto príznakov, čím sa pôvodný rovnomerný pohyb mení na pohyb s väčšou odchýlkou smeru.

Slabinou metódy 1 v zmysle neúspešných detekcií, je v prvom rade fakt, že aj plamene ohňa môžu bez pomoci prúdenia vzduchu vykazovať rovnomerný pohyb napríklad iba dohora. V extrémnych prípadoch nemusia plamene vykazovať žiaden pohyb. Na testovanom datasete sa objavuje tento jav pri malých plameňoch napríklad v kotlíku, ktorý tak vytvára mierne závetrie. Celkovo je ale pri menších plameňoch problém detegovať akýkoľvek pohyb. Na Obr. A.8 je možné vidieť príklad. Nejedná sa dokonca v tomto prípade o výrazne malý oheň, avšak pozitívne predikované body nevykazuje takmer žiadne, sekvencie nemajú dostatočný

počet vektorov lebo sa body ľahko strácajú, a ak je aj nájdený nejaký vektor pohybu, je veľmi malý. Problém na tomto obrázku je však riešený v prístupe (2).

Tab. 4.3: Úspešnosť detekcie vybraného merania prístupu (2) na konkrétnych videách.

Názov videa	N (# snímok)	P (# anotácií)	TP	FP	TP rate	FP rate
<i>Fire_001.mp4</i>	344	344	329	0	96 %	0 %
<i>Fire_002.mp4</i>	3752	3752	2601	0	69 %	0 %
<i>Fire_003.mp4</i>	270	270	255	11	94 %	4 %
<i>Fire_004.mp4</i>	1132	1132	1117	0	99 %	0 %
<i>Fire_Non-Fire_001.mp4</i>	446	446	382	174	86 %	39 %
<i>Fire_Non-Fire_002.mp4</i>	1120	1120	786	40	70 %	4 %
<i>Fire_Non-Fire_004.mp4</i>	7547	7243	4034	316	56 %	4 %
<i>Fire_Non-Fire_005.mp4</i>	4674	4273	3805	549	89 %	12 %
<i>Fire_Non-Fire_006.mp4</i>	2721	992	805	745	81 %	27 %
<i>Fire_Non-Fire_007.mp4</i>	222	242	207	0	86 %	0 %
Celkovo	22228	19814	14321	1835	72 %	8 %

Pri porovnaní úspešnosti na konkrétnych videách (Tab. 4.3) je možné vidieť na niektorých z nich výrazný rozdiel oproti väčšine. Videá s názvom *Fire_XXX* obsahujú iba oheň, bez pohybu iných objektov, avšak vzniknutý dym môže byť tiež falošne detegovaný ako oheň. Na troch z týchto videí je dosiahnutá úspešnosť tesne pod 100 %. Oheň nie je detegovaný iba na úvodných 10-20 snímkach z dôvodu modelovania heat-mapy. Video *Fire_002*, na ktorom je dosiahnutá úspešnosť iba 69 %, je už zaznamenané z väčšej vzdialenosti, pričom intenzita horenia je niekedy veľmi nízka (pozri Obr. A.9 a Obr. A.10). Na niektorých záberoch sú plamienky dokonca prekryté viacerými vetvičkami stromu. V prípade, že oheň zaberá aspoň 10 % snímky, je možné subjektívne konštatovať úspešnosť detekcie až 99 %. Úspešnosť detekcie menších ohňov je nižšia a závisí od rôznych už spomínaných faktorov.

Videá s názvom *Fire_Non-Fire_XXX* obsahujú okrem ohňa aj pohyb iných objektov, no nie na každej snímke videa. Neúspešné detekcie sú znova väčšinou iba v prípade malých ohňov, niekedy dokonca problémové na detekciu aj pre človeka (pozri Obr. A.12), pričom pár výpadkov detekcie je zaznamenaných aj na väčších ohňoch. Vyše 700 falošných detekcií obsahuje video *Fire_Non-Fire_006*. Spôsobuje ich zväčša silný dym z zaznamenaný z veľkej blízkosti, plus priamo pred záberom stojí nie v úplnom pokoji osoba, ktorá na malom priestore hýbe vetvičkami stromu alebo vlní na nej látka nohavíc (pozri Obr. A.11).

4.4 METÓDA 2: Zhluk vektorov pohybu


4.4.1 Trénovacie dáta

Táto časť obsahuje výsledky meraní analýzy pohybu v podobe histogramov hodnôt navrhnutých metrík. Analýza pohybu je vykonaná z pohľadu zhľuku vektorov, popísaného v časti 3.4.2 *METÓDA 2: Zhluk vektorov pohybu*. Jedno meranie predstavuje jeden analyzovaný zhľuk 50 snímok za sebou. Zhľuk je získaný na základe metódy 1 s úspešnosťou detekcie 95 % pri falošných detekciách na úrovni 49 %. V prípade metódy 2 však bola znížená hodnota najnižšej povolenej *kvality bodov* záujmu na úroveň 0,01. Tým pádom sledovaný zhľuk obsahuje viac vektorov pohybu, a teda viac užitočných informácií.


Každý sledovaný príznak je priemerovaný pre zhľuk v celom jeho sledovanom rozsahu. V úvode tejto časti sú predstavené výsledky pozitívneho prípadu (ohňa) a následne sú predstavené negatívne prípady (iný pohyblivý objekt). Trénovacie dáta sú získané z vlastnej anotovanej časti datasetu.

4.4.1.1 Oheň

Predpokladaná vysoká odchýlka vektorov oblastí ohňa je potvrdená na *Obr. 4.14* a *Obr. 4.15*. Obe odchýlky majú charakter normálneho rozdelenia. Hodnota *odchýlky smeru* väčšiny meraní ohňa je nad 0,2, pričom najviac meraní je pozorovaných v rozsahu odchýlky 0,3 – 0,4. Hodnota *odchýlky dĺžky* väčšiny meraní je nad 0,4, pričom najviac meraní je v rozsahu odchýlky 0,6 – 0,8.




Obr. 4.14: Histogram priemernej odchýlky smeru vektorov



Obr. 4.15: Histogram priemernej odchýlky dĺžky vektorov

V porovnaní s metódou 1 je už z pohľadu zhluku vektorov možné pozorovať očakávaný priemerný smer vektorov ohňa nahor (Obr. 4.16). Strená hodnota smeru je znázornená kruhovým histogramom uhlov v rozsahu 36° . Najväčší počet meraní je možné pozorovať v rozsahu okolo uhla 0° , ktorý zodpovedá uhlom $(342^\circ; 360^\circ)$ v $(0^\circ; 18^\circ)$. Veľký počet meraní je možné pozorovať aj v rozsahu $(18^\circ; 54^\circ)$. Keďže sa v sledovanej oblasti ohňa môže často vyskytovať aj dym, merania sú čiastočne ovplyvnené aj jeho pohybom.


Histogram priemernej strednej hodnoty smeru




Obr. 4.16: Histogram priemernej strednej hodnoty smeru vektorov

4.4.1.2 Bežné objekty

Predpokladaná nižšia odchýlka vektorov bežných objektov oproti vektorov ohňa je potvrdená na Obr. 4.17 a Obr. 4.18. Obe odchýlky majú charakter normálového rozdelenia, pričom stredná hodnota rozdelenia je v prípade bežných objektov nižšia približne o 0,2. Hodnota *odchýlky smeru* väčšiny meraní ohňa je v tomto prípade pod 0,2, pričom najviac meraní je pozorovaných v rozsahu odchýlky 0,1 – 0,2. Hodnota *odchýlky dĺžky* väčšiny meraní je v tomto prípade pod 0,8, pričom najviac meraní je v rozsahu odchýlky 0,2 – 0,4. Na rozdiel od *odchýlky smeru* má *odchýlka dĺžky* bežných objektov mierne viac meraní s rovnakou odchýlkou ako merania ohňa.




Obr. 4.17: Histogram priemernej odchýlky smeru vektorov



Obr. 4.18: Histogram priemernej odchýlky dĺžky vektorov

Priemerný smer vektorov bežných objektov vykazuje najmä horizontálny pohyb v oboch smeroch, vyplývajúci najmä z pohybu osôb. Je však pozorované aj nezanedbateľné množstvo vertikálneho pohybu, najmä smerom nahor, zrejme z dôvodu prítomnosti dymu v záberoch (Obr. 4.19). Strená hodnota smeru je znázornená kruhovým histogramom uhlov v stupňoch.

Histogram priemernej strednej hodnoty smeru



Obr. 4.19: Histogram priemernej strednej hodnoty smeru vektorov

4.4.2 Trénovanie klasifikátora

Použité trénovacie dáta sú popísané v predchádzajúcej časti. V Tab. 4.5 sú uvedené parametre trénovaného SVM klasifikátora. Pomer pozitívnych ku negatívnym inštanciam je približne 1:3. Pri trénovaní bolo využitých 13 rôznych hodnôt parametra C. Každá hodnota parametra je trénovaná a overovaná s využitím cross-validácie. Trénovacie dáta sú rozdelené na tri podmnožiny. Trénovanie je vykonané na každej kombinácii dvoch z týchto množín pričom zvyšná tretia je využitá na overenie úspešnosti predikcie. Výsledná úspešnosť klasifikátora pre daný parameter C je určená priemernou úspešnosťou cross-validácie. Použité príznaky sú *odchýlka zmeny smeru*, *odchýlka dĺžky* a *stredná hodnota smeru*. Najlepšie výsledky dosahuje klasifikátor pri hodnote parametra $C = 1$ (pozri Tab. 4.5). Pri vyšších hodnotách je znovu možné vidieť príklad typického pretrénovania klasifikátora, kedy je úspešnosť zhodná s úspešnosťou pri náhodnej predikcii.

Tab. 4.4: Parametre SVM pre metódu 1

Počet inštancií:	~ 70 tis.
Počet príznakov:	3
Cross-validácia:	3 podmnožiny
Parameter C:	$10^{-10} - 10^2$
Typ jadra:	polynomicke 2. stupňa

Tab. 4.5: Porovnanie úspešnosti trénovania SVM pri rôznej citlivosti na chyby.

PS = Pozitívne body – Skutočnosť, PP = Pozitívne body – Predikcia,

U = Úspešnosť predikcie (priemerná)


Parameter C	1.pokus			2.pokus			3.pokus			Trvanie h:m:s	Úspešnosť
	PS	PP	U	PS	PP	U	PS	PP	U		
10^{-10}	33%	0%	66%	34%	0%	66%	34%	0%	67%	00:01:20	66,82 %
10^{-9}	33%	0%	66%	34%	0%	66%	34%	0%	67%	00:01:30	66,82 %
10^{-8}	33%	0%	66%	34%	0%	66%	34%	0%	67%	00:01:30	66,82 %
10^{-7}	33%	0%	66%	34%	0%	66%	34%	0%	67%	00:01:30	66,82 %
10^{-6}	33%	0%	66%	34%	0%	66%	34%	0%	67%	00:01:30	66,82 %
10^{-5}	33%	0%	66%	34%	0%	66%	34%	0%	67%	00:01:30	66,82 %
10^{-4}	33%	5%	70%	34%	6%	71%	34%	5%	71%	01:00:00	70,54 %
10^{-3}	33%	21%	80%	34%	23%	81%	34%	23%	82%	02:55:00	81,12 %
10^{-2}	33%	31%	86%	34%	31%	86%	34%	31%	85%	02:55:00	85,54 %
10^{-1}	33%	30%	86%	34%	30%	86%	34%	30%	86%	02:55:00	85,85 %
10^0	33%	29%	86%	34%	30%	86%	34%	29%	86%	04:14:00	85,93%
10^1	33%	62%	48%	34%	60%	48%	34%	35%	55%	02:58:00	48,18%
10^2	33%	35%	56%	34%	58%	50%	34%	38%	55%	01:48:00	53,75%

4.4.3 Výsledky predikcie

Pri vyhodnocovaní je využívaný SVM klasifikátor, ktorý dosiahol najväčšiu úspešnosť (85,93 %). Pri využití metódy 1, ktorá dodáva metóde 2 oblasti s úspešnosťou detekcie ohňa 95 %, nie je možné od metódy 2 očakávať celkovú úspešnosť viac ako 82 % (0.8593×0.95). Cieľom je znížiť falošné detekcie z pôvodných 49 % na čo najnižšiu úroveň, ktorá je teoreticky 7 % ($(1 - 0.8593) \times 0.49$).

Celkový priebeh ROC krivky v tomto prípade nie je možné určiť bez zmeny citlivosti klasifikátora. Pri metóde 1 je dostupný napríklad parameter *threshold*, ktorým je možné dosiahnuť rôzne pomery medzi úspešnou detekciou a falošnou detekciou. Pri metóde 2 je ale dostupný iba parameter *počet snímok*, v rámci ktorých je zhluk sledovaný (okrem parametrov metódy 1 a vyhľadania bodov záujmu). Na znázornenej ROC krivke je možné vidieť v obmedzenom rozsahu pomer medzi *TP rate* a *FP rate* pri rôznych hodnotách parametra *počet snímok* (Obr. 4.20). Na grafe je pre porovnanie uvedená aj ROC krivka najúspešnejšieho prístupu metódy 1 a červenou farbou je zaznačené meranie, z ktorého vychádza metóda 2. Na porovnanie sú uvedené dva prístupy:

- (1) Prvý prístup vychádza z *kvality bodov* = 0,01. Metóda 2 je overená pri použití *počtu snímok* = {10,20,60,100}. Najvyššia úspešnosť detekcie 76 % je dosiahnutá pri hodnote 60. Použitie vyšších alebo nižších hodnôt už má za následok znižovanie úspešnosti detekcie. Pri porovnaní prístupu (1) s krivkou metódy 1 je možné pozorovať zlepšenie približne o 4 %.
- (2) Pre zvýšenie počtu vektorov sledovaného zhluku je znížená hodnota najnižšej povolenej *kvality bodov* na úroveň 0,001. Sledovaná oblasť obsahuje tým pádom viac informácií o pohybe, no rýchlosť detekcie sa tým zníži približne o 50 %. Na metódu 1 nemá zvýšenie počtu bodov záujmu badateľný vplyv, pretože tieto body sa rýchlo strácajú. Pre metódu 2 však stačí, aby nový bod vydržal živý aspoň jednu snímku. Pri tomto prístupe metóda 2 dosiahla predpokladanú úspešnosť detekcie ohňa až 82 %, pri falošných detekciách na úrovni iba 9 % (pri *počte snímok* = 50). Úspešnosť tohto merania na konkrétnych analyzovaných videách je možné porovnať v Tab. 4.6. Oproti metóde 1 je tak možné pozorovať celkovo až 10 %-né zlepšenie. Falošné detekcie sú pre danú úspešnosť 82 % až o približne 15 % nižšie, ako v prípade metódy 1.



Obr. 4.20: Porovnanie úspešnosti metódy 2

Tab. 4.6: Úspešnosť detekcie vybraného merania prístupu (2) na konkrétnych videách


Názov videa	N (# snímok)	P (# anotácií)	TP	FP	TP rate	FP rate
Fire_001.mp4	344	344	289	28	84%	8 %
Fire_002.mp4	3752	3752	2894	0	77%	0 %
Fire_003.mp4	270	270	219	0	81%	0 %
Fire_004.mp4	1132	1132	1081	0	95%	0 %
Fire_Non-Fire_001.mp4	446	446	392	0	88%	0 %
Fire_Non-Fire_002.mp4	1120	1120	1023	1	91%	0 %
Fire_Non-Fire_004.mp4	7547	7243	5342	525	74%	7 %
Fire_Non-Fire_005.mp4	4674	4273	3952	604	92%	13 %
Fire_Non-Fire_006.mp4	2721	992	865	844	87%	31 %
Fire_Non-Fire_007.mp4	222	242	192	0	79 %	0 %
Celkovo	22248	19824	16249	2002	82 %	9 %

Metóda 2 je rovnako ako v prípade metódy 1 neúspešná pri menších ohňoch, kde nie je dostupný dostatok informácií o jeho pohybe. Na falošné detekcie má v prípade metódy 2 už väčší vplyv oneskorenie detekcie. Ak na nejakom mieste je 50 snímok detegovaný oheň a následne zhasne, alebo ho nejaký objekt prekryje, stále bude ďalších 50 snímok oheň na tomto mieste detegovaný, avšak anotácia ohňa sa na danom mieste už nenachádza. Pre smerodajnejšie výsledky falošných detekcií by bolo vhodné brať za úspešnú detekciu aj prípad, kedy sa na detegovanom mieste nachádza aspoň na jednej snímke anotácia ohňa. Týmto spôsobom by bola hodnota falošných detekcií ešte nižšia. Na druhej strane by rovnako mali byť označené aj ako úspešné detekcie, ktoré sú oneskorené o sledovaný počet snímok. Použité vyhodnocovanie je však z pohľadu vyhodnocovania klasifikácie správne a pre

porovnanie s inými metódami detekcie by malo vychádzať zo zaužívaného spôsobu. Zo subjektívneho pohľadu sú však dosiahnuté výsledky ešte lepšie.

4.5 Zhodnotenie výsledkov


V prvom rade uvádzame na Obr. 4.21 porovnanie úspešnosti detekcie bežne sfarbeného ohňa navrhnutými metódami detekcie pohybu (pozri 3.4 *Detekcia pohybu*) voči existujúcej detekcii na základe farby (pozri 3.2.1 *Detekcia pozadia a farby*). Je možné vidieť, že v tomto smere je úspešnosť navrhovaných metód nižšia ako nameraná úspešnosť existujúcej detekcie farby, avšak stále je vyššia ako jej publikovaná úspešnosť.



Obr. 4.21: Porovnanie výsledkov pri bežne sfarbenom ohni

Následne uvádzame porovnanie na odlišne sfarbených plameňoch ohňa, kedy už má navrhnutá detekcia pohybu výhodu oproti existujúcej detekcii farby. Vyhodnocovať detekciu farby je v tomto prípade zbytočné, pretože jej obmedzenia s ohľadom na odlišnú farbu ohňa sú zrejmé. Úspešné detekcie na základe farby môžu byť ale pozorované aj v prípade iného objektu, ktorý spĺňa farebné podmienky bežne sfarbeného ohňa a nachádza sa v oblasti anotácie ohňa. Pre úplnosť ale uvádzame jej výsledky pri tolerantnej hodnote prahu $T = 40$. Odlišné farby ohňa sú získané vzájomnou výmenou RGB kanálov vstupnej snímky videa (ukážka detekcie zeleného ohňa je na Obr. A.15). Parametre oboch metód detekcie pohybu sú rovnaké pre každé meranie, pričom pri metóde 1 sú schválne (pre účely metódy 2) zvolené


parametre s vysokým pomerom úspešnosti detekcie a teda aj s vysokým pomerom falošných detekcií (pozri 4.4.3 *Výsledky predikcie*).



Obr. 4.22: Porovnanie úspešnosti detekcie farby s detekciou pohybu na rôzne sfarbených ohňoch

Navrhnutá metóda detekcie pohybu je pri odlišne sfarbených plameňoch mierne horšia ako pri bežne sfarbených plameňoch. Ako je možné vidieť, navrhované metódy sú však schopné úspešne detegovať aj rôzne sfarbené plamene ohňa popri nízkom výskyte falošných detekcií. Oproti existujúcej detekcii farby sú výsledky navrhovaných metód neporovnateľne lepšie.

Dôvodom horších výsledkov pri iných farbách je konverzia vstupného troj-kanálového farebného RGB signálu do jedno-kanálového signálu v odtieňoch sivej pre potreby detekcie pohybu (pozri 3.2.2 *Detekcia pohybu*). Pri konverzii dochádza k strate informácie, čo sa aj negatívne odzrkadľuje vo výsledkoch. Na Obr. 4.23 uvádzame porovnanie výsledkov detekcie pohybu pri rôznych pomeroch farebných kanálov konverzie z RGB do odtieňov sivej. Úspešnosť detekcie bežne sfarbených plameňov je priamo úmerne závislá od množstva zachovanej informácie červeného kanála. Pre čo najlepšie výsledky detekcie bežne sfarbených plameňov ohňa je teda využívaný iba červený kanál, pričom je metóda stále schopná detegovať aj odlišne sfarbené ohne (pozri predošlý graf na Obr. 4.22).



Obr. 4.23: Porovnanie výsledkov detekcie pohybu pri rôznych pomeroch konverzie RGB do odtieňov sivej

Počas riešenia projektu bolo potrebné experimentovať aj mimo dokumentované výsledky. Pri experimentovaní s rôznymi kombináciami parametrov metód sú uvádzané, resp. aj ďalej analyzované, iba perspektívne a najzaujímavejšie z nich. Na druhej strane sú samozrejme dostupné ďalšie nepreskúmané parametre a možnosti detekcie.

Pri využití oboch navrhnutých metód detekcie na základe pohybu na komprimovaných záznamoch v HDReady rozlíšení 1280x720 px je rýchlosť detekcie na úrovni približne dvoch až troch snímok za sekundu (pri neobmedzenom počte bodov záujmu, najnižšej povolenej kvalite bodov na úrovni 0,001 a minimálnej vzdialenosti bodov 5 px na nízkonapäťovom procesore 2,4 GHz Intel Core i5-4258U). Približne 7 snímok za sekundu dosahuje metóda pri obmedzenom počte a vzdialenosti bodov. Pri nasadení detekcie v reálnom čase je možné:

- zachytiť prvých napríklad 50 snímok videa,
- analyzovať pohyb,
- prehlásiť či sa na daných snímkach nachádza oheň
- a znovu zachytiť 50 aktuálnych snímok videa.

5 Záver

Výsledkom diplomovej práce je úspešne navrhnutý a implementovaný systém detekcie ohňa metódami počítačového videnia. V priebehu riešenia projektu boli z pohľadu výskumného zámeru, aj pre potreby praxe a záujmu externej firmy, upravené požiadavky na detegovanie iba ohňa, avšak pri rôzne sfarbených plameňoch (pozri 3.3 *Postup riešenia*). Po analýze existujúcich riešení sa detekcia dymu javí byť ako uzatvorená a je z implementácie vynechaná (pozri 2.4.2 *Detekcia dymu*). Navrhnutú analýzu pohybu ohňa však je možné v prípade potreby ľahko aplikovať aj na pohyb dymu.

Po analýze navrhovaných metód a existujúcich riešení práca okrem prvej implementácie a experimentov s metódami detekcie pozadia a farby preskúmala závislosti medzi navrhnutými metrikami analýzy pohybu. Pohyb je analyzovaný z pohľadu jedného sledovaného bodu záujmu a z pohľadu zhľuku vektorov pohybu (pozri 3.2.2 *Detekcia pohybu*). Výsledky detekcie ohňa sú vyhodnocované iba s ohľadom na detekciu pohybu, bez využitia detekcie farby a pozadia. Detekcia farby a pozadia je však súčasťou implementácie a je možné pomocou používateľského rozhrania všetky navrhnuté metódy pohybu, farby a pozadia počas behu detekcie rôzne kombinovať a sledovať ich vzájomný vplyv na základe zobrazených medzi-výstupov metód.

Detegovanie pohybu ohňa iba z pohľadu jedného bodu sa javí byť odvážne, no ako ukazujú samotné výsledky, jednoduchosť tohto prístupu prináša pozitívne výsledky (pozri 4.3.3 *Výsledky predikcie*). Komplexnejším a metodicky správnejším prístupom je však analyzovanie pohybu z pohľadu zhľuku viacerých blízkych vektorov pohybu, ktorý už je robustnejší s ohľadom na chyby merania. Výstup určených oblastí detekcie na základe bodu záujmu je vstupom detekcie na základe zhľuku vektorov. Tolerancia detekcie na základe bodu záujmu je v tomto prípade nastavená vysoko a získané podozrivé oblasti ohňa sú následne ďalej analyzované detekciou na základe zhľuku vektorov. Kombinácia oboch prístupov priniesla oproti prvému prístupu zvýšenie úspešných detekcií o 10 % a zníženie falošných detekcií o 15 %. Výhodou navrhutej detekcie je jej použiteľnosť aj pri nezvyčajne sfarbených plameňoch ohňa (pozri 4.5 *Zhodnotenie výsledkov*).

Práca sa snaží kriticky poukázať na možné problémy detekcie, avšak pri odmyslení krajných prípadov a nutnosti detegovať každý nevýrazný, málo pohybujúci sa oheň, je navrhnutá metóda naozaj úspešná, dokonca aj pri rôzne sfarbených plameňoch, aj pri využití čierne-bielych kamier. Pri vhodnej kombinácii existujúcej detekcie farby a uvedenej detekcie pohybu môžu byť získané výsledky naozaj veľmi blízko výsledkom detekcie dosiahnutej človekom. Nehovoriac o kombinácii s informáciou o infračervenom žiarení.

Zoznam použitej literatúry


- [1] K-SPACE - Knowledge Space of Semantic Inference for Auto-matic Annotation and Retrieval of Multimedia Content – European Commission Project - IST 6th Framework Programme.
- [2] HOGAN, J.: Your Every Move Will Be Analyzed. In: *New Scientist*, 2006.
- [3] ÇETIN, E., et al.: Video fire detection–Review. *Digital Signal Processing*, 2013, 23.6: 1827-1843.
- [4] BOUWMANS, T.: Recent advanced statistical background modeling for foreground detection - a systematic survey. *Recent Patents on Computer Science*, 2011, 4.3: 147-176.
- [5] BAUMBERG, A., HOGG, D.: An efficient method for contour tracking using active shape models. In: *Proceedings of the IEEE Workshop on Motion of Non-Rigid and Articulated Objects*, 1994. p. 194-199.
- [6] BENEZETH, Y., et al.: Review and evaluation of commonly-implemented background subtraction algorithms. In: *19th International Conference on Pattern Recognition*, 2008. p. 1-4.
- [7] LI, L., HUANG, W., GU, I., TIAN Q.: Statistical Modeling of Complex Background for Foreground Object Detection. In: *IEEE transactions on Image Processing*, Volume 13, Issue 11, p. 1459-1472, November 2004.
- [8] TOYAMA, K., KRUMM, J., BRUMITT, B., MEYERS, B.: Wallflower: Principles and Practice of Background Maintenance. In: *The Proceedings of the Seventh IEEE International Conference on Computer Vision*, 1999. p. 255-261.
- [9] NASCIMENTO, J., MARQUES, J.: Performance Evaluation of Object Detection Algorithms for video Surveillance. In: *IEEE Transaction on Multimedia*, August 2006, p. 761-774.
- [10] BHASKAR, H., MIHAYLOVA, L., MASKELL, S.: Automatic Target Detection Based on Background Modeling Using Adaptive Cluster Density Estimation. In: *German Workshop on Sensor Data Fusion: Trends, Solutions, Applications*, Universität Bremen, Germany, September 2007.
- [11] CELIK, T.: Fast and Efficient Method for Fire Detection Using Image Processing. *ETRI Journal*, 2010, 32.6.
- [12] SONKA, M., HLAVAC, V., BOYLE, R.: Image processing, analysis, and machine vision (Third Edition). Toronto: Thomson, 2008.

-
- [13] MORAVEC, H.: Obstacle avoidance and navigation in the real world by a seeing robot rover. Tech Report CMU-RI-TR-3, Carnegie-Mellon University, Robotics Institute, 1980.
 - [14] HARRIS, C., STEPHENS, M.: A combined corner and edge detector. In: *Alvey vision conference*, 1988. p. 50.
 - [15] SHI, J., TOMASI, C.: Good features to track. In: *Computer Vision and Pattern Recognition*, 1994. p. 593-600.
 - [16] GONZALEZ, R., WOODS, R.: Digital image processing (Second Edition). New Jersey: Prentice Hall Press, 2002.
 - [17] GEVERS, T., et al.: Color in Computer Vision (Fundamentals and Applications). New Jersey: Wiley, 2012.
 - [18] ŠIKUDOVÁ, E., ČERNEKOVÁ, Z., BENEŠOVÁ, W., et. al.: Počítačové videnie. Detekcia a rozpoznávanie objektov. Praha: Wikina, 2014. 397 s. ISBN 978-80-87925-07-2
 - [19] POWER, W., SCHOONEES, A.: Understanding Background Mixture Models for Foreground Segmentation. In: *Proceedings Image and Vision Computing*, New Zealand, 2002.
 - [20] ZLACKÁ, A.: Charakteristika jednorozmerných štatistických súborov. Katedra geografie a geoekológie, FHPV PU v Prešove.
 - [21] STAUFFER, C., GRIMSON, W.: Adaptive background mixture models for real-time tracking. In: *CVPR '99: Computer Society Conference on Computer Vision and Pattern Recognition*, Ft. Collins, USA, volume 2, 1999, pp. 246-252.
 - [22] CELIK, T., DEMIREL, H., OZKARAMANLI, H.: Automatic fire detection in video sequences. In: *Proceedings of European Signal Processing Conference (EUSIPCO 2006)*, Florence, Italy, September 2006.
 - [23] CELIK, T., DEMIREL, H.: Fire detection in video sequences using a generic color model. In: *Fire Safety Journal*, 2008, 44.2: 147-158.
 - [24] BORGES, P., MAYER, J., IZQUIERDO, E.: Efficient visual fire detection applied for video retrieval. In: *Proceedings of 16th European Signal Processing Conference (EUSIPCO)*, August 2008.
 - [25] MESH - Multimedia Semantic Syndication for Enhanced News Service - European Commission Project - IST 6th Framework Programme.
 - [26] TOREYIN, U., DEDEOGLU, Y., CETIN, E.: Contour based smoke detection in video using wavelets. In: *Proceedings of European Signal Processing Conference (EUSIPCO)*, September 2006. p. 123-128.


-
- [27] COLLINS, R., LIPTON, A., KANADE, T.: A system for video surveillance and monitoring. In: *8th Int. Topical Meeting on Robotics and Remote Systems*. 1999, American Nuclear Society.
- [28] VERSTOCK, S.: Multi-modal Video Analysis for Early Fire Detection. Universiteit Gent, 2011. Ph.D. thesis.
- [29] XIONG, Z.: Video-based smoke detection. Possibilities, techniques, and challenges. In: *Proceedings of Suppression and Detection Research and Applications (SUPDET)*, A Technical Working Conference, 2007.
- [30] LUCAS, B., KANADE, T.: An Iterative Image Registration Technique with an Application to Stereo Vision. In: *Proc. of 7th International Joint Conference on Artificial Intelligence (IJCAI)*, Vol. 81, 1981. pp. 674-679.
- [31] BURGESS, C.: A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 1998, 2.2: 121-167.
- [32] CHANG, C., LIN, C.: LIBSVM: a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2011, 2.3: 27.
- [33] FIRESSENSE Project. Specific Targeted Research Project of the European Union's 7th Framework Programme Environment. 2009. FP7-ENV-2009-1-244088-FIRESSENSE. <http://www.firesense.eu/>
- [34] CETIN, E.: Computer Vision Based Fire Detection Software. <http://signal.ee.bilkent.edu.tr/VisiFire/Demo/SampleClips.html>
- [35] KO, B., CHEONG, K., NAM, J.: Fire detection based on vision sensor and support vector machines. In: *Fire Safety Journal*, 2009, 44.3: 322-329.
- [36] KMU CVPR Lab. KMU Fire & Smoke Database. 2009. <http://cvpr.kmu.ac.kr/Dataset/Dataset.htm>
- [37] VEZZANI, R., CUCCHIARA, R.: Video Surveillance Online Repository (ViSOR): an integrated framework. In: *Multimedia Tools and Applications*, vol. 50, 2010, n. 2, Kluwer Academic Press, pp. 359-380. <http://www.openvisor.org>

Príloha A: Ukážky


A.1 Experimenty



Obr. A.1: Príklad nedetegovaného ohňa pri použití prahu $T = 40$ (bežná prípustná hodnota) a príklad falošne detegovaného ohňa pri použití prahu $T = 10$. Jedná sa o detekciu iba na základe pozadia a farby.




Obr. A.2: Príklad bežnej prípustnej hodnoty prahu $T = 30$, ktorá v tomto prípade falošne deteguje aj žlté pole v okolí plameňov. Mierne zvýšenie prahu nad bežne prípustnú hodnotu $T = 60$ už je k farbe plameňov menej tolerantnejšie a plamene sú segmentované korektne. Jedná sa o detekciu iba na základe pozadia a farby.




Obr. A.3: Pohyb osôb s oranžovými prilbami na stavenisku. Vpravo hore je ukážka falošného poplachu pri použití iba detekcie farby a pozadia. Pre úplnosť sú vpravo dole zobrazené nájdené vektory pohybu.

A.2 METÓDA 1: Bod záujmu



Obr. A.4: Úspešné detekcie ohňa




Obr. A.5: Neúspešná detekcia ohňa



Obr. A.6: Falošná detekcia ohňa s vektormi pohybu




Obr. A.7: Falošná detekcia ohňa



Obr. A.8: Príklad problémovej detekcie pohybu na vybranej sekvencii snímok. Vrchný rad znázorňuje výsledok SVM predikcie bodu. Pozitívne sú fialovou farbou, negatívne zelenou, a nepredikované, z dôvodu malého počtu vektorov, sivé. Spodný rad znázorňuje aktuálne vektory pohybu na danej snímke.



Obr. A.9: Problémový malý oheň vo videu *Fire_002.mp4* s jeho anotáciou.



Obr. A.10: Po miernom zväčšení ohňa vo videu *Fire_002.mp4* už metóda 1 úspešne detegovala oheň. Zelenou je farbou je označená anotácia ohňa a modrou detegovaná oblasť ohňa.




Obr. A.11: Falošné detekcie na videu *Fire_Non-Fire_006.mp4*




Obr. A.12: Nedetegovateľne malý oheň vo videu *Fire_Non-Fire_004.mp4* s jeho anotáciou.


A.3 METÓDA 2: Zhluk vektorov



Obr. A.13: Príklad úspešnej detekcie. Vrchný obrázok znázorňuje detegované podozrivé oblasti pomocou metódy 1 (iba na aktuálnej snímke). Prostredný obrázok obsahuje všetky aktuálne analyzované zhľuky (predikované z nich sú iba tie, ktoré už sú sledované 50 snímok). Úspešne predikovaný zhľuk je znázornený na spodnom obrázku modrým rámčekom. Anotácia ohňa je určená zeleným rámčekom.




Obr. A.14: Príklad falošnej detekcie. Vrchný obrázok znázorňuje detegované podozrivé oblasti pomocou metódy 1 (iba na aktuálnej snímke). Prostredný obrázok obsahuje všetky aktuálne analyzované zhľuky (predikované z nich sú iba tie, ktoré už sú sledované 50 snímok). Pozitívne predikovaný zhľuk je znázornený na spodnom obrázku modrým rámčekom. Anotácia ohňa je určená zeleným rámčekom.



Obr. A.15: Ukážka úspešnej detekcie ohňa odlišnej farby.

A.4 Používateľské rozhranie




Obr. A.16: Používateľské rozhranie

Príloha B: Technická dokumentácia

B.1 Implementácia

V tejto časti sú uvedené podrobnejšie informácie k implementácii riešenia ktoré je napísané v jazyku C++ na platforme Windows pomocou vývojového prostredia Microsoft Visual C++ 11.0 Update 4 (Microsoft Visual Studio 2012), pričom využíva knižnice OpenCV 2.4.8* a MFC†.



Obr. B.1: Diagram tried implementácie.
Balíky označené bielou farbou reprezentujú externé knižnice.

Knižnica OpenCV ponúka širokú škálu funkcií pre riešenie rôznych problémov v doméne počítačového videnia, pričom pri jej vyvíjaní je kladený dôraz práve na použitie v aplikáciách reálneho času. Knižnica je napísaná v jazykoch C a C++ a logicky teda ponúka rozhranie

* Open Source Computer Vision - <http://opencv.org/>

† Microsoft Foundation Class - <http://msdn.microsoft.com/en-us/library/d06h2x6e.aspx>

primárne pre jazyk C++. Existujú rozhrania aj pre ďalšie programovacie jazyky, no pre minimalizovanie problémov s kompatibilitou a maximalizovanie výkonu nášho riešenia bol zvolený pre našu implementáciu práve jazyk C++. Pre maximalizovanie výkonu ponúka OpenCV optimalizované funkcie pre viac-jadrové procesory a možné je využiť aj akceleráciu na grafickom jadre. Knižnica je voľne dostupná na akademické aj komerčné účely.

Grafické rozhranie aplikácie je implementované pomocou knižníc MFC, ktoré obaľujú natívne Win32 aplikačné rozhranie, pomocou ktorého je možné na platforme Windows dosiahnuť prirodzené vyzerajúce a funkčné ovládacie prostredie pre jazyk C++. Na diagrame (Obr. B.1) sú zobrazené triedy implementácie, pričom na najvyššej úrovni sa nachádzajú práve triedy knižnice MFC.

Trieda *MainDlg* obsahuje metódy pre spracovanie riadiacich udalostí hlavného dialógového okna aplikácie. Riadiaca funkcia aplikácie je implementovaná ako ďalšie vlákno hlavného dialógového okna priamo v triede *MainDlg*. Stará sa o získavanie snímok zo vstupného videa, o komunikáciu medzi ovládacími prvkami dialógového okna a navrhnutými triedami detekcie a riadi hlavný cyklus detekcie využitím napríklad tried na detekciu pozadia, farby a pohybu (*BackgroundSubtraction*, *ColorDetection*, *MotionTracker*). Knižnica OpenCV je využívaná vo všetkých navrhnutých triedach.

Celkové riešenie obsahuje takmer 4 tisíc riadkov zdrojového kódu bez prázdných riadkov, komentárov a externých knižníc (metrika LOC). Pri návrhu tried je kladený dôraz na efektivitu a rýchlosť implementácie. Výpočtovo najnáročnejšie časti implementácie sú morfologické operácie (ktoré sú z tohto dôvodu používané minimálne, resp. vôbec), sledovanie pohybu bodov a z časti aj modelovanie heat-mapy metódy 1. Ostatné časti implementácie sú náročné približne rovnako. Vývoj zdrojového kódu je udržiavaný pomocou verziovacieho systému Git na fakultnom repozitári.

Detekcia pohybu

Pre potreby detekcie pohybu ohňa metódou 1 bolo potrebné navrhnuť dátovú štruktúru, pomocou ktorej je možné rýchlo a efektívne získať na základe súradníc aktuálnej pozície bodu záujmu jeho históriu. Keďže s príchodom novej snímky videa sa aktuálne pozície bodov menia, resp. pre niektoré body nová pozícia nemusí byť nájdená vôbec, udržiavanie takejto štruktúry nie je jednoduché. Dátová štruktúra nazvaná *keyPoints* je definovaná ako dvojrozmerné pole ukazovateľov na triedu *MotionTrackerKeyPoint*, ktorá okrem iného obsahuje históriu pozícií bodu:

```
vector<vector<MotionTrackerKeyPoint*>> keyPoints;
```

Lucas-Kanade Tracker však vyhľadáva body s presnosťou na „tisíciny“ pixela, čo je pre účely práce zbytočné a pre navrhnutú dátovú štruktúru problémom. Pozície bodov sú teda zaokrúhľované na celé pixely, čo však môže zapríčiniť stretnutie viacerých bodov na

rovnakých súradniciach. Často sa to aj v praxi stáva a riešením je zahodiť bod s menšou históriou pozícií. Ďalší problém nastáva pri postupnom aktualizovaní nových pozícií bodov v dátovej štruktúre, ak sa novej pozícii nachádza nejaký bod. Ešte sa však nemusí vedieť, či tento bod náhodou nevymrel, alebo sa neposunul na novú pozíciu, preto je označený ako „otázny“. Po aktualizovaní všetkých nových bezproblémových pozícií bodov sa sú riešené otázne body, kde môžu nastať ďalšie problémové prípady. Ak pri postupnom prechádzaní otázných bodov nie je možné nastaviť novú pozíciu bodu, pretože sa na novej pozícii stále nachádza nejaký otázny bod, je tento bod posunutý na koniec zoznamu otázných bodov, a ak sa k nemu znovu dostane, možno už bude možné zmeniť jeho pozíciu. Celý proces sa opakuje až kým nie sú vyriešené všetky otázne body.

K aktuálnym bodom záujmu dátovej štruktúry sú pri získaní novej snímky videa pridané nové body pomocou metódy *goodFeaturesToTrack()*. Použité sú však iba tie, ktoré dodržia minimálnu vzdialenosť susedného bodu aj s ohľadom na pozície aktuálnych bodov v *keyPoints*. Zdrojové kódy vyhľadania bodov a udržiavania dátovej štruktúry sú uvedené v nasledujúcich častiach.

Vyhľadanie bodov záujmu

```

if (compute){
    goodFeaturesToTrack(prevGray, points[0], MAX_GOOD_FEATURES, qualityLevel,
        nextPointMinDistance, mask, GOOD_FEATURES_BLOCK_SIZE,
        !goodFeatures, GOOD_FEATURES_FREE_PARAMETER);

    newInitialPointCounter = 0;
    for (u_int i = 0; i < points[0].size(); i++) {
        currentInitialPoint = keyPoints.at((u_int)points[0][i].y).at((u_int)points[0][i].x);

        // round decimal part (works only for positive numbers)
        points[0][i].x = static_cast<float>(floor(points[0][i].x + 0.5));
        points[0][i].y = static_cast<float>(floor(points[0][i].y + 0.5));

        if (hasCloseNeighbouringPoint((u_int)points[0][i].y, (u_int)points[0][i].x,
            nextPointMinDistance))
        {
            continue;
        }

        // new initial point[0][i] found
        if (currentInitialPoint == nullptr)
        {
            newInitialPointCounter++;
            keyPoints.at((u_int)points[0][i].y).at((u_int)points[0][i].x) =
                new MotionTrackerKeyPoint();
            currentInitialPoint = keyPoints.at((u_int)points[0][i].y).at((u_int)points[0][i].x);

            currentInitialPoint->addPosition(points[0][i]);

            lastComputedPoints.push_back(points[0][i]);
        }
    }
    //new initial points are now appended in lastComputedPoints
}
else {
    //erase keyPoints Matrix
    for(u_int i = 0; i < lastComputedPoints.size(); i++ )
    {
        currentInitialPoint =
            keyPoints.at((u_int)lastComputedPoints[i].y).at((u_int)lastComputedPoints[i].x);
        delete currentInitialPoint;
        keyPoints.at((u_int)lastComputedPoints[i].y).at((u_int)lastComputedPoints[i].x) = nullptr;
    }

    lastComputedPoints.clear();
}

points[0] = lastComputedPoints;
lastInitialPoints = points[0];

```

Výpočet nových pozícií bodov záujmu

```
//CALCULATE MOTION VECTORS AND UPDATE KEYPOINTS MATRIX
if( !points[0].empty() ){
    vector<uchar> status;
    vector<float> err;

    calcOpticalFlowPyrLK(prevGray, gray, points[0], points[1], status, err, winSize,
                        10, termcrit, 0, 0.001 );

    lastDeadPoints.clear();
    lastComputedPoints.clear();
    questionableKeyPoints.clear();

    //UPDATE keyPoints MATRIX
    for(u_int i = 0; i < points[0].size(); i++ )
    {
        currentInitialPoint = keyPoints.at((u_int)points[0][i].y).at((u_int)points[0][i].x);

        if (currentInitialPoint == nullptr) { //just a precaution, it shouldn't be nullptr
            AfxMessageBox(_T("currentPoint is nullptr!"));
            exit(1);
        }

        // round decimal part (works only for positive numbers)
        points[1][i].x = static_cast<float>(floor(points[1][i].x + 0.5));
        points[1][i].y = static_cast<float>(floor(points[1][i].y + 0.5));

        distance = euclideanDist(points[0][i], points[1][i]);
        //motion not found
        if (status[i] == 0 || distance < MIN_DISTANCE
            //check, if computed rounded points are still in the frame
            || points[1][i].x < 0 || points[1][i].y < 0 || points[1][i].x >= frame.cols
            || points[1][i].y >= frame.rows
        )
        {
            lastDeadPoints.push_back(points[0][i]);

            //delete dead keypoint
            delete currentInitialPoint;
            keyPoints.at((u_int)points[0][i].y).at((u_int)points[0][i].x) = nullptr;
        }
        //motion found
        else if (status[i] == 1 && distance >= MIN_DISTANCE){
            currentInitialPoint->addPosition(points[1][i]);

            //currentInitialPoint needs to be moved to a new location
            currentComputedPoint = keyPoints.at((u_int)points[1][i].y).at((u_int)points[1][i].x);
            if (currentComputedPoint != nullptr)
            {
                currentInitialPoint->questionable = true;
                questionableKeyPoints.push_back(currentInitialPoint);
                continue;
            }
            keyPoints.at((u_int)points[1][i].y).at((u_int)points[1][i].x) = currentInitialPoint;
            keyPoints.at((u_int)points[0][i].y).at((u_int)points[0][i].x) = nullptr;

            lastComputedPoints.push_back(points[1][i]);

            //DRAW MOTION VECTOR
            lineColor = computeColor(distance);
            line(image, Point(static_cast<int>(points[0][i].x), static_cast<int>(points[0][i].y)),
                Point(static_cast<int>(points[1][i].x),static_cast<int>(points[1][i].y)) ,
                lineColor, 1);
            circle(image, Point(static_cast<int>(points[1][i].x), static_cast<int>(points[1][i].y)),
                1, lineColor, -1);
        }
    }
}
```

Riešenie problémových nových pozícií bodov

```

//resolve questionable points
u_int cycle_size = 0;
u_int cycle_current = 0;
u_int difference;
for (u_int i = 0; i < questionableKeyPoints.size(); i++) {

    //due to swapping questionable points
    if ( ! questionableKeyPoints[i]->questionable ) continue;

    size1 = questionableKeyPoints[i]->size();
    if (size1 < 2) {
        AfxMessageBox("Size < 2 !");
        exit(1);
    }
    y0 = (u_int)questionableKeyPoints[i]->getPosition(size1-2).y; //last but one position
    x0 = (u_int)questionableKeyPoints[i]->getPosition(size1-2).x;
    y1 = (u_int)questionableKeyPoints[i]->back().y; //last postition
    x1 = (u_int)questionableKeyPoints[i]->back().x;

    keyPointOnNewPosition = keyPoints.at(y1).at(x1);

    // cycle detection
    if (questionableKeyPoints.size() > 1000000) {
        difference = questionableKeyPoints.size() - i - 1;
        //less than two should! be taken care of without cycle control
        if (difference > 2 && (cycle_current == 0 || difference != cycle_size)) {
            cycle_size = difference;
            cycle_current = 0;
        }

        //check it for two cycle periods
        if ( cycle_current < cycle_size * 2)
            ++cycle_current;

        //cycle detected
        if (cycle_current == cycle_size * 2) {
            //delete current point, and restore cycle detection, maybe it helps
            lastDeadPoints.push_back(questionableKeyPoints[i]->getPosition(size1-2));
            delete questionableKeyPoints[i];
            keyPoints.at(y0).at(x0) = nullptr;
            cycle_current = 0;
            cycle_size = 0;

            continue;
        }
    }

    if (keyPointOnNewPosition == nullptr) {
        questionableKeyPoints[i]->questionable = false;
        lastComputedPoints.push_back(questionableKeyPoints[i]->back());
        keyPoints.at(y1).at(x1) = questionableKeyPoints[i];
        keyPoints.at(y0).at(x0) = nullptr;
    }
    else if (keyPointOnNewPosition->questionable) {
        size2 = keyPointOnNewPosition->size();

        if (keyPointOnNewPosition->back().y == y0
            && keyPointOnNewPosition->back().x == x0) {
            //swap questionable points pointing to each other
            questionableKeyPoints[i]->questionable = false;
            keyPointOnNewPosition->questionable = false;

            keyPoints.at(y1).at(x1) = questionableKeyPoints[i];
            keyPoints.at(y0).at(x0) = keyPointOnNewPosition;

            lastComputedPoints.push_back(questionableKeyPoints[i]->back());
            lastComputedPoints.push_back(keyPointOnNewPosition->back());
        }
        else if (i < questionableKeyPoints.size() - 1 ){
            questionableKeyPoints.push_back(questionableKeyPoints[i]);
        }
        else {

```

```

        AfxMessageBox("Two questionable keypoints!");
        exit(1);
    }
}
//on new position is existing valid computed point...two different points are joined to one
//point with shorter history (life) is ditched
else { // note: point is already added to lastComputedPoint,
        doesn't matter wich (history) one wins now
        size2 = keyPointOnNewPosition->size();

        //replace existing computed point with this questionable one
        if (size1 >= size2) {
            questionableKeyPoints[i]->questionable = false;
            lastDeadPoints.push_back(keyPointOnNewPosition->getPosition(size2-2));
            delete keyPointOnNewPosition;
            keyPoints.at(y1).at(x1) = questionableKeyPoints[i];
            keyPoints.at(y0).at(x0) = nullptr;
        }
        //leave existing computed point as it is
        else {
            lastDeadPoints.push_back(questionableKeyPoints[i]->getPosition(size1-2));
            delete questionableKeyPoints[i];
            keyPoints.at(y0).at(x0) = nullptr;
        }
    }
}
}
}

```

B.2 Inštalačná príručka

Systémové požiadavky

Podporované operačné systémy:

Windows 7 Service Pack 1, Windows 8, Windows 8.1, Windows Server 2003, Windows Server 2008 R2 SP1, Windows Server 2008 Service Pack 2, Windows Server 2012, Windows Vista Service Pack 2, Windows XP

Hardvérové požiadavky:

900 MHz procesor

512 MB RAM

200 MB voľného miesta

5400 RPM pevný disk

DirectX 9 kompatibilná grafická karta pri 1024 x 768 rozlíšení

Pokyny k inštalácii

1. Nainštaluj "Visual C++ Redistributable for Visual Studio 2012 Update 4" zo súboru "`\Spustitelny subor\Poziadavky\vcredist_x86.exe`" na priloženom optickom médiu.
2. Skopíruj priečinok „Spustitelny subor“, obsahujúci súbor "FireDetectionMFC.exe", na zapisovateľný disk s aspoň 200MB voľného miesta.
3. Spusti "FireDetectionMFC.exe".

4. Pomocou tlačidla „Browse“ vyber niektoré z priložených videosúborov v priečinku "\\Spustitelny subor\\Vzorky videi".
5. Stlač tlačidlo "Start".

System requirements

Supported Operating System:

Windows 7 Service Pack 1, Windows 8, Windows 8.1, Windows Server 2003, Windows Server 2008 R2 SP1, Windows Server 2008 Service Pack 2, Windows Server 2012, Windows Vista Service Pack 2, Windows XP

Hardware Requirements:

900 MHz or faster processor

512 MB of RAM


50 MB of available hard disk space

5400 RPM hard drive

DirectX 9-capable video card running at 1024 x 768 or higher display resolution

Install instructions

1. Install "Visual C++ Redistributable for Visual Studio 2012 Update 4" from file "\\Spustitelny subor\\Poziadavky\\vcredist_x86.exe".
2. Copy directory, containing file "FireDetectionMFC.exe", on writeable hard drive with at least 200MB free space.
3. Run "FireDetectionMFC.exe".
4. Browse for included sample videos in folder "\\Spustitelny subor\\Vzorky videi".
5. Press "Start".



Používateľská príručka podrobne popisuje všetky prípady použitia s ohľadom na navrhnuté používateľské rozhranie. Je rozdelená podľa základných prípadov použitia a každá obsahuje popis daného prípadu spolu s jeho súvisiacimi prípadmi použitia. Kompletný diagram prípadov použitia je zobrazený na *Obr. B.2* a detailný náhľad používateľského rozhrania na *Obr. A.16*.

UC01 Detekcia ohňa

Detekcia ohňa pozostáva z *UC02 Prehrávanie videa*, kde je po zvolení požadovaného video-súboru možné spustiť prehrávanie, čím sa automaticky spustí aj detekcia ohňa, s ohľadom na zvolené parametre a povolené metódy (*UC15 Zmena parametrov*). Priebeh detekcie je možné sledovať priamo počas jej behu (pozri *UC12 Zobrazenie výstupov medzi-krokov a výsledkov predikcie*).

Vyhodnocovanie výsledkov detekcie ohňa je možné zapnúť tlačidlom „Evaluate results“. Po skončení prehrávania videa sú výsledky pridané do súboru „*detection_results.txt*“ vo formáte

„<cesta videosúboru> <dátum> <čas> <typ detekcie> <F = počet snímok>
<T = počet anotácií ohňa> <TP = úspešné detekcie> <FP = falošné detekcie>
<FN = neúspešné detekcie>“.

Typ detekcie môže byť:

- COLOR,
- MOTION METHOD1,
- alebo MOTION METHOD2.

UC02 Prehrávanie videa

Rozhranie umožňuje zvoliť vstupné video vyvolaním ďalšieho dialógového okna na prehľadávanie obsahu počítača (tlačidlo „Browse“). Po zvolení videa je možné spustiť vykonávanie programu (tlačidlo „Start“). V prípade, že nie je označené prehrávanie zvoleného videa v slučke (tlačidlo „Replay video“), vykonávanie programu je zastavené po prehraní celého videa. Vykonávanie je možné kedykoľvek zastaviť aj manuálne tlačidlom „Stop“. Na ovládanie prehrávania videa ponúka rozhranie možnosť preskočiť 5 sekúnd záznamu (tlačidlo „Skip 5s“), 60 sekúnd záznamu (tlačidlo „Skip 60s“), poprípade je možné pomocou tlačidla „Pause / Step fwd“ pozastaviť prehrávanie a posúvať sa po jednom snímku videa. Rýchlosť prehrávania je možné obnoviť tlačidlom „Play normal“. Rýchlosť spracovávanie snímkov videa však nie je automaticky obmedzená. Ľahko môžu teda nastať prípady, kedy je video prehrávané rýchlejšie. Rozhranie však umožňuje obmedziť počet prehraných snímkov za sekundu (FPS) v súlade s rýchlosťou zdrojového videa (tlačidlo „Limit FPS“). V ľavom dolnom rohu rozhrania je možné vidieť aktuálnu rýchlosť prehrávania v FPS a poradové číslo snímky videa.

UC06 *Krokovanie videa* dozadu je umožnené iba pri anotovaní videa (UC19). UC11 *Opakované prehrávanie videa* nie je pri anotovaní možné ani potrebné a rovnako ani UC07 *Preskočenie videa*, aby osoba, anotujúca videá, stále vizuálne kontrolovala označené oblasti.

UC12 Zobrazenie výstupov medzi-krokov a výsledkov predikcie

Originálna vstupná snímka prehrávaného videa je zobrazená v pravom hornom rohu rozhrania. Táto snímka je obohatená:

- o anotáciu videa v podobe svetlozeleného rámčeka,
- v prípade povolenej metódy 1 a zároveň nepovolenej metódy 2 o vyhodnotenú oblasť ohňa svetlomodrou kontúrou,
- a v prípade povolenej metódy 2 o pozitívny výstup SVM predikcie zhuku v podobe svetlomodrého rámčeka (čo predstavuje aj finálny výstup detekcie ohňa).

Okrem originálnej vstupnej snímky videa sú v rozhraní zobrazené ďalšie štyri pomocné snímky. Prvá zľava môže s ohľadom na povolené metódy zobrazovať:

1. výstup detekcie pozadia,
2. výstup detekcie farby,
3. alebo heat-mapu metódy 1.

Najväčšiu prioritu má prvý uvedený prístup, a ostatné majú analogicky nižšiu prioritu. Ak je teda povolená iba metóda 1 a detekcia farby, zobrazený bude výstup detekcie farby. Druhá snímka môže obsahovať:

1. výstup detekcie farby,
2. heat-mapu metódy 1,
3. alebo threshold heat-mapu metódy 1.

Znovu závisí od povolených metód detekcie farby, detekcie pozadia a metódy 1. Tretia snímka obsahuje živé body záujmu, pričom sú farebne odlíšené podľa ich veku (sivé = nízky vek, červené = vysoký vek), resp. ich počtu vektorov. V prípade povolenej metódy 1 sú tieto body zafarbené s ohľadom na výstup SVM predikcie bodu (fialová = pozitívne, zelená = negatívne, sivá = nepredikované) plus znázorňuje svetlomodrou kontúrou vyhodnotenú oblasť ohňa na základe threshold-u heat-mapy.

Štvrtá snímka obsahuje vektory pohybu vypočítané pre aktuálnu snímku, farebne odlíšené vzhľadom na ich veľkosť (zelené = najmenšie, červené = najväčšie). V prípade povolenej metódy 2 sú svetlomodrým rámčekom zobrazené všetky aktuálne analyzované zhuky.

Jednotlivé snímky majú ukotvenú pozíciu v rámci rozhrania, pričom ukotvenie každého z nich je v prípade potreby možné zrušiť pomocou tlačidla „Pop-up“. Ukotvené výstupy majú pevne zvolené rozmery, neukotvené je však možné ľubovoľne škálovať a rozmiestňovať po

obrazovke. Pre opätovné ukotvenie snímky je potrebné znovu použiť tlačidlo „Pop-up“, a nie tlačidlo „X“ okna snímky.

Pre lepšiu viditeľnosť bodov záujmu a vektorov pohybu je možné stlmiť jas pôvodnej snímky videa tlačidlom „Night mode“.

Súčasťou rozhrania je ešte časť pre zobrazenie pomocných údajov najmä pre ladenie programu. Ďalej je ešte možné v reálnom čase meniť toleranciu detekcie na základe farby, je možné povoliť detailnejšie prispôsobenie bodov záujmu lepšie detegovateľným príznakom a v neposlednom rade je v spodnej časti rozhrania zobrazené poradové číslo snímky videa a aktuálny pomer prehraných snímok za sekundu.

UC15 Zmena parametrov

Počas celého priebehu detekcie je možné povoliť alebo zakázať implementované metódy a je možné aj meniť ich parametre, bez ohľadu na to, či je metóda povolená alebo zakázaná. Pri vyhodnocovaní výsledkov samozrejme nie je rozumné meniť parametre metód. Pomocou používateľského rozhrania je teda možné povoliť / zakázať metódy:

- detekcia farby (tlačidlo „Color detection“),
- detekcia pozadia (tlačidlo „Background detection“),
- detekcia pohybu (tlačidlo „Motion“),
- detekcia pohybu ohňa – METÓDA 1 (tlačidlo „METHOD 1“)
- a detekcia pohybu ohňa – METÓDA 2 (tlačidlo „METHOD 2“).

Obe detekcie pohybu ohňa sú funkčné iba v prípade povolenej detekcie pohybu. METÓDA 2 je funkčná iba v prípade dodania oblastí niektorou z metód:

1. METÓDA 1,
2. detekcia farby,
3. alebo detekcia pozadia.

Využitá môže byť iba jedna z nich. V prípade, že sú povolené viaceré, najväčšiu prioritu má prvá uvedená metóda, a ďalšie majú postupne nižšiu prioritu. Detekcia farby v prípade povolenej detekcie pozadia pracuje iba na oblastiach popredia. Detekcia pohybu a detekcia pozadia sú nezávislé od ostatných metód. Parametre jednotlivých metód sú zoskupené podľa metódy. Výstupy medzi-krokov a výsledkov predikcie sú prispôsobené podľa povolených metód (pozri UC12).

UC11 Anotovanie videa

Po zvolení cesty videosúboru je možné tlačidlom „Annotate video“ vyvolať nové okno anotátora, obsahujúce prvú snímku zvolené ho videa. Prehrávanie videa je pri spustení pozastavené. Pri samotnom anotovaní je potrebné využívať aj myš aj klávesnicu a počas anotovania nie je umožnené spustiť detekciu ohňa.

Na každej snímke videa je možné stlačením a pridržaním ľavého tlačidla myši zvoliť začiatkový roh rámčeka anotácie. Posunutím myši a následným pustením stlačeného tlačidla je špecifikovaný ďalší roh rámčeka (po jeho uhlopriečke), čím vznikne požadovaný rámček anotácie. Počas posúvania myši je možné vidieť náhľad prípadného rámčeka. Ostatné úkony je anotovania potrebné ovládať klávesmi:

- MEDZERNÍK** - pozastavenie prehrávania videa / prejdenie na ďalšiu snímku pozastaveného videa
- B** - prejdenie na predchádzajúcu snímku videa (obmedzené na maximálne 100 snímok)
- P** - prehrávanie videa
- C** - vymazanie všetkých anotácií na aktuálnej snímke
- E** - vymazanie všetkých anotácií na aktuálnej a nasledujúcich snímkach
- ESC** - ukončenie anotovania

Pri prechádzaní na ďalšiu snímku videa, ktorá neobsahuje žiadnu anotáciu, anotátor automaticky skopíruje anotácie z aktuálnej snímky na ďalšiu. Pri prehraní celého videa alebo ukončení anotovania klávesom ESC sú anotácie uložené do súboru s názvom v tvare:

„<názov videosúboru>.annotation“.

Ak daný súbor už existuje, je možné určiť, či sa súbor prepíše, vytvorí sa ďalší, alebo sa zmeny zahodia. Každá anotácia je uložená vo formáte:

„<číslo snímky> <súradnice ľavého horného rohu> <súradnice pravého dolného rohu>“

Pri každom spustení anotátora sa automaticky načíta prvý súbor jeho anotácie, ak existuje, a následne je možné anotácie upravovať.

Príloha C: Obsah elektronického média

Priložené elektronické médium obsahuje adresárovú štruktúru podľa uvedeného zoznamu:

- **Elektronická verzia** – Elektronická verzia diplomovej práce v PDF.
- **Spustiteľný súbor** – Spustiteľný súbor *FireDetectionMFC.exe* spolu s potrebnými knižnicami OpenCV a pokynmi na spustenie programu a základné ovládanie programu.
 - **Vzorky videí** – Krátke videozáznamy ohňa, ktoré je možné použiť pri overení riešenia.
 - **Požiadavky** – Potrebné nástroje pre spustenie riešenia.
- **Zdrojové kódy** – Obsahuje zdrojové kódy programu v rámci projektového adresára vývojového prostredia (*Microsoft Visual Studio Solution*).