

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ
ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

FACULTY OF INFORMATION TECHNOLOGY
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

DETEKCE OHNĚ A KOUŘE VE VIDEOSEKVENCI

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. ROBERT HAVELKA

BRNO 2010



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA INFORMAČNÍCH TECHNOLOGIÍ
ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

FACULTY OF INFORMATION TECHNOLOGY
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

DETEKCE OHNĚ A KOUŘE VE VIDEOSEKVENCI

SMOKE AND FIRE DETECTION IN VIDEO SEQUENCES

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. ROBERT HAVELKA

VEDOUCÍ PRÁCE
SUPERVISOR

Ing. MICHAL ŠPANĚL

BRNO 2010

Vysoké učení technické v Brně - Fakulta informačních technologií

Ústav počítačové grafiky a multimédií

Akademický rok 2009/2010

Zadání diplomové práce

Řešitel: **Havelka Robert, Bc.**

Obor: Počítačová grafika a multimédia

Téma: **Detekce ohně a kouře ve videosekvenci**
Smoke and Fire Detection in Video Sequences

Kategorie: Počítačová grafika

Pokyny:

1. Prostudujte základy zpracování obrazu. Zaměřte se na problematiku extrakce příznaků z obrazu a zpracování videosekvencí.
2. Zorientujte se v současných metodách vizuální detekce kouře a ohně v obraze.
3. Vyberte vhodnou metodu a navrhnete jednoduchý detektor kouře/ohně.
4. Experimentujte s vaší implementací a případně navrhnete vlastní modifikace metod.
5. Porovnejte dosažené výsledky a diskutujte možnosti budoucího vývoje.
6. Vytvořte stručný plakát prezentující vaši diplomovou práci, její cíle a výsledky.

Literatura:

- Dle pokynů vedoucího.

Při obhajobě semestrální části diplomového projektu je požadováno:

- Splnění prvních tří bodů zadání.

Podrobné závazné pokyny pro vypracování diplomové práce naleznete na adrese
<http://www.fit.vutbr.cz/info/szz/>

Technická zpráva diplomové práce musí obsahovat formulaci cíle, charakteristiku současného stavu, teoretická a odborná východiska řešených problémů a specifikaci etap, které byly vyřešeny v rámci ročníkového a semestrálního projektu (30 až 40% celkového rozsahu technické zprávy).

Student odevzdá v jednom výtisku technickou zprávu a v elektronické podobě zdrojový text technické zprávy, úplnou programovou dokumentaci a zdrojové texty programů. Informace v elektronické podobě budou uloženy na standardním nepřepisovatelném paměťovém médiu (CD-R, DVD-R, apod.), které bude vloženo do písemné zprávy tak, aby nemohlo dojít k jeho ztrátě při běžné manipulaci.

Vedoucí: **Španěl Michal, Ing.**, UPGM FIT VUT

Datum zadání: 21. září 2009

Datum odevzdání: 26. května 2010

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
Fakulta informačních technologií
Ústav počítačové grafiky a multimédií
612 66 Brno, Božetěchova 2
L.S.

doc. Dr. Ing. Jan Černocký
vedoucí ústavu

Abstrakt

Tato diplomová práce se zabývá detekcí ohně ve videosekvenci. Pozornost je věnována známým charakteristikám ohně a nastiňuje principy existujících řešení, které se zabývají touto problematikou. Práce také popisuje návrh, implementaci a testování detektoru ohně, který je založen na rozpoznání podezřelých oblastí podle barvy, kombinovaném se sledováním pohybových a světelných vlastností.

Abstract

This master's thesis deals with fire detection in videosequences. Attention is paid to the known characteristics of fire and basic principles of existing solutions which deal with this issue. The thesis also describes design, implementation and testing of a fire detector that is based on the recognition of suspicious areas by fire color modeling, combined with detection of motion and light intensity variations.

Klíčová slova

Detekce ohně, video sekvence, texturní analýza, barevné modely, OpenCV, segmentace, detekce pohybu, počítačové vidění.

Keywords

Fire detection, video sequence, texture analysis, color models, OpenCV, segmentation, motion detection, computer vision.

Citace

Robert Havelka: Detekce ohně a kouře ve videosekvenci, diplomová práce, Brno, FIT VUT v Brně, 2010

Detekce ohně a kouře ve videosekvenci

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně pod vedením pana Ing. Michala Španěla. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

.....
Robert Havelka
25. května 2010

Poděkování

Děkuji panu Ing. Michalu Španělovi za čas, který mi věnoval při řešení této diplomové práce.

© Robert Havelka, 2010.

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

Obsah

1	Úvod	3
2	Přístupy k detekci ohně	4
2.1	Barevné prostory	4
2.2	Změna pixelů v čase	5
2.3	Vyhledávání a analýza kontur	6
2.4	Segmentace a vyhodnocení pomocí rozpoznávacích algoritmů	7
2.5	Přehled existujících řešení	7
3	Počítačové vidění	11
3.1	Barevné prostory	11
3.2	Detekce pohybu	12
3.3	Filtrace obrazu	12
3.4	Dilatace a eroze	12
3.5	Diskrétní Fourierova transformace	13
4	Návrh	14
4.1	Přehled	14
4.2	Předpokládaný postup vyhodnocení	15
4.3	Detektor	15
4.4	Vyhodnocovací proces	18
5	Implementace	20
5.1	Použité knihovny a programovací jazyk	20
5.2	Popis oblastí	20
5.3	Třídy	20
5.4	Funkce	21
5.5	Postup vyhodnocení	22
6	Nastavení parametrů aplikace a testování	24
6.1	Nastavení aplikace	24
6.2	Vzorová videa	25
6.3	Výkon	25
6.4	Porovnání barevných modelů	26
6.5	Variety detekce	27
6.6	Úspěšnost	36
6.7	Možnosti přizpůsobení	37

7 Závěr	38
A Výsledky detekcí	41
B Ovládání	48
C Obsah CD	49

Kapitola 1

Úvod

Proč chceme automaticky detekovat oheň ve videu? Již samotná otázka nabízí odpověď. Chceme tento proces zautomatizovat a zdokonalit tak, aby dovedl detekovat oheň ve videu s minimálním či žádným zásahem lidské složky a s co nejnižším počtem falešných detekcí. Toho pak může být úspěšně využito v automatizovaných bezpečnostních systémech. Některé kvalitní a nejméně chybné metody však mohou mít při zpracování videí větší výpočetní nároky. Detekční systémy však je vhodné nasazovat v kombinaci s lidskou složkou, čímž se sníží požadavek na jejich přesnost a systém funguje jako alarm, který zajistí pozornost lidí. Obsluha již vyhodnotí situaci a učiní potřebné kroky k zastavení požáru či minimalizaci škod. Falešný alarm lidská složka lehce odhalí.

Diplomová práce pojednává o základních přístupech k detekci ohně. Cílem je prostudovat existující řešení a zjistit jaké vlastnosti ohně jsou směrodatné pro jeho detekci. Na základě zjištěných poznatků a existujících řešení navrhnout detektor vlastní, který bude implementován. Implementaci je nezbytné řádně otestovat. Zvýšená pozornost bude věnována chybnému chování a možnostem jeho eliminace.

Navržený a implementovaný detektor je založen na charakteristických znacích ohně, mezi které řadíme především jeho barvu a pohyb. Další důležitý rozhodovací krok je založen na známém faktu, že pulzování ohně je v oblasti 1–10Hz bez ohledu na hořící materiál.

Kapitola 2 pojednává o vlastnostech ohně, na které se při detekci zaměřujeme. V druhé části předkládá přehled zlomku zpracovaných prací, které nabízí určité formy postupů detekce. V kapitole 3 jsou stručně objasněny pojmy, které se objevují v souvislosti s detekcí ohně. Návrh detektoru je uveden v kapitole 4 jehož implementace je popsána v následující kapitole 5. Dosažené výsledky a zhodnocení práce jsou popsány v kapitole 6 a 7.

Kapitola 2

Přístupy k detekci ohně

Obvyklé způsoby detekce ohně vychází z jeho charakteristických vlastností a z chování jeho plamenů. Jedná se především o barvu, tvar a jeho dynamické vlastnosti jako například nepřetržitý pohyb, který je omezen na oblast požáru.

Uvedené příklady se mezi sebou obvykle kombinují pro dosažení co nejpřesnějších výsledků. Také se aplikují různé alternativní přístupy odvozené od uvedených. Rozhodující kritéria pro použití následujících možností vyhledávání jsou barevnost zdroje, zda se jedná o jeden obraz či video sekvenci a zda je kamera stacionární nebo se pohybuje.

2.1 Barevné prostory

Jak je známo každý standardní oheň má svoji obvyklou barvu, která je vždy víceméně stejná. Barvu můžeme označit jako směs barev od červené, přes oranžovou až po žlutou či jasně bílou. Zmínil jsem standardní oheň, protože požáry, při kterých hoří chemikálie¹, mohou být zbarveny například do modra nebo zelena. To pak musí být zohledněno v případě, že detektor při hledání inkriminovaných míst v obraze používá barevnou informaci. Barevná informace se obvykle vyhodnocuje technikami, které mohou využívat buď jednoduché intervalové vymezení, nebo „chytrý“ trénovaný model.

Pokud bychom uvažovali šedotónové obrazy, metody musí použít sofistikovanějších metod pro rozlišení ohně. Barevná, respektive jasová informace je zpracována především pro vyhledání centra předpokládaného výskytu požáru. Je zřejmé, že za centra požáru budou označena místa s vysokou intenzitou jasu. Po nalezení potenciálních center je nezbytné využít dalších technik pro ohraničení oblasti plamenů, které již nemusí jednoznačně vykazovat vysokou hodnotu jasu.

Intervalové vymezení v barevném modelu

Intervalové vymezení znamená, že barva pixelu, která je reprezentována v určitém barevném modelu (např. RGB, HSV, CIE LAB), musí spadat do definovaného rozmezí hodnot, nebo určitého intervalu jejich poměrů. Obrazové pixely, jsou pak při zpracování jednotlivě testovány na příslušnost k těmto intervalům. Limitní hodnoty jsou obvykle získány statisticky zpracováním velkého množství obrazových dat.

¹Například při hoření dusičnanu barnatého se plamen barví do zelena. Při hoření solí mědi získáváme plamen modrý. Více informací o změnách barev plamene lze nalézt například na <http://www.jergym.hiedu.cz/canovm/vybusnin/PXD/cl/color.htm>.

U RGB reprezentace se barevné modely především zaměřují na hodnotu červené barvy s následným rozšířením o porovnání ostatních dvou složek ve vztahu k červené. Jeho aplikace je zpracována například v [8, 7]. Další model, který je pro tento účel využíván, je HSV. Je využit například v práci [15, 9]. Tento model má vhodnou distribuci barev pro vymezení intervalů jednotlivých složek. V pracích [2, 13, 6] jsou využity i barevné modely YCbCr a CIE LAB. Obrázek 2.1 znázorňuje extrakci podezřelých míst na základě jednoho barevného modelu RGB a obrázek 2.2 při použití barevného prostoru I1I2I3.



Obrázek 2.1: RGB barevný prostor. Převzato z [6]



Obrázek 2.2: I1I2I3 barevný prostor. Převzato z [6]

Natrénované barevné prostory

Trénované modely, vzhledem k diskrétní reprezentaci barevných modelů, také vnitřně obsahují intervaly, ale jejich počet je v řádu desítek až stovek a jsou vytvářeny automatizovaným postupem. Před vlastním použitím je nezbytné vytvořit rozsáhlou trénovací sadu, kterou je nutno ručně anotovat. To znamená, že skupiny pixelů musí být označeny, zda se jedná o ohňové pixely nebo o pixely obyčejného prostředí. Z takto označené trénovací sady poté klasifikátory extrahují barevnou informaci a natrénují se pro rozpoznání požadovaných barev.

Využívají se například neuronové sítě, které zmiňují práce [11, 14], skryté Markovovy modely² nebo vyhledávací tabulka dominantních barev ohně, která je využita v práci [4]. Pozadu nezůstává ani využití modelů Gaussova rozložení.

2.2 Změna pixelů v čase

Jedná se o způsob detekce ve videosekvenci, kdy je sledována změna pixelů. Tyto změny jsou vyhodnocovány a v případě ohně, kdy jsou změny neustálé, je pak pixel označen za pixel ohně. Je zřejmé, že tato metoda musí zohlednit přístup využívající barevných modelů. Bez toho by docházelo k falešným detekcím například v úseku videa se stromem s třepotajícími se listy a podobně.

Jedna z variant je použití vlnkové transformace, kdy je každý samostatný pixel na stejné pozici v sérii obrazů zohledněn jako jednorozměrný signál. V barevném modelu RGB se pracuje pouze s červenou složkou, jako je uvedeno v práci [5]. Tento signál je analyzován a je určena jeho frekvence. Pokud se jedná o stacionární pixel, jeho frekvence bude nulová nebo blízká nule. Pokud se bude jednat o pixel ohně, jeho barva se bude měnit, a tedy jeho frekvence bude výrazně vyšší. Obrázky níže znázorňují rozdíl vlnkové transformace

²Využité v práci [5]

mezi ohněm na obrázku 2.3 a červeným tričkem na obrázku 2.4. Vyšší frekvence je znázorněna světlejším odstínem pro příslušný pixel. Jak je z obrázků zřejmé, oblast ohně má nepravidelné rozložení dílčích frekvencí pixelů v označené oblasti.



Obrázek 2.3: Zobrazení vlnkové transformace ve výřezu, kde se nalézá oheň. Převzato z [12]



Obrázek 2.4: Zobrazení vlnkové transformace ve výřezu, kde se nalézá chlapec s červeným tričkem. Převzato z [12]

2.3 Vyhledávání a analýza kontur

Předpokládá se, že po barevném zpracování obrazu, lze ohraničit oblasti s ohněm. Ohraničení je dále analyzováno. Analýza probíhá na dvou úrovních. První úroveň je sledování statických vlastností tvaru, mezi které patří například zakřivení. Druhá úroveň je sledování dynamických vlastností. To zahrnuje změny v po sobě jdoucích snímcích. Pokud se jedná o oheň, bude se ohraničení náhodně měnit v čase. Využívá se například tvorba Fourierova deskriptoru. To znamená, že pro jednu oblast se v každém snímku vypočítávají koeficienty Fourierovy transformace z hranice oblasti, ze kterých je vhodně sestaven její popis. Pokud se oblast tvarově mění, budou se měnit i koeficienty deskriptorů oblasti. Pokud hodnota změn přesáhne stanovený práh, lze oblast označit za oheň. Jak je v práci [15] uvedeno, k detekci postačuje sledování prvních 32 koeficientů Fourierovy transformace vyjma nulového. Metoda dokáže odlišit pohybující se objekt, který nemění svůj tvar od objektů, jejichž ohraničení se v sekvenci snímků mění.

2.4 Segmentace a vyhodnocení pomocí rozpoznávacích algoritmů

U tohoto přístupu je obraz rozdělen do malých bloků, které jsou následně klasifikovány pomocí rozpoznávačů. Tyto rozpoznávače jsou naučeny na množství malých vzorků ohňů. Jedná se opět o metodu, která vyžaduje učení. Před použitím je třeba sestavit trénovací množinu dat, která bude obsahovat vhodné výřezy částí ohňů a opačné příklady, které ohněm nejsou. Tato metoda může být úspěšně aplikována i na šedotónové obrazy.

2.5 Přehled existujících řešení

V této části uvedu výtahy z několika prací. Popíší implementaci a zmíním uváděné úspěšnosti detekcí.

Vision Based Fire Detection [9]

Autory práce jsou Che-Bin Liu a Narendra Ahuja. Postup implementované detekce vychází z vlastností barvy, geometrie a pohybu.

Prvním stupněm zpracování je nalezení vysoce jasových oblastí v obraze, které jsou označeny za semínko regionu. Označení je provedeno v šedotónovém modelu. Regiony jsou následně rozšiřovány tak aby pokryly okolní barvy, které jsou barvami ohně. Pro rozhodování, zda se barva považuje za barvu ohně, jsou použity Gaussovy modely. Zpracování probíhá v barevné reprezentaci HSV. Tím vzniknou podezřelé regiony. Hranice těchto regionů jsou zkontrolovány na obsah ohňových a jasně bílých pixelů, aby se předešlo pouhému ohrazení velkých bílých oblastí. Oblasti, které splní podmínku, pokračují ve zpracování. Jsou zkoumány na tvar a náhodnou změnu tohoto tvaru v čase. Ohrazení je bráno jako jednorozměrný komplexní signál, kde souřadnice x je brána jako reálná složka a y souřadnice představuje komplexní část $\{z_i | z_i = x_i + jy_i\}$. Tvar tedy může být popsán Fourierovým deskriptorem, který je vytvořen z koeficientů získaných pomocí DFT³. Podmínkou je, že hranice oblasti musí být vždy čtena ze stejné nebo nejbližší pozice a vždy stejným směrem. To si lze představit tak, že každá hranice má například počátek čtení v nejhornější středové části a hodnoty jsou čteny po směru hodinových ručiček. Kdyby byla stejná hranice rozdělena pokaždé na jiném místě, hodnoty deskriptoru by byly pro stejnou oblast odlišné.

Implementace byla testována na různorodých videích, které zahrnovaly hoření obytných domů, skladišť a požáry v přírodě. Videá byla zaznamenána za denního světla, za soumraku i v nočních hodinách. Uváděná úspěšnost je uváděna okolo 99% při detekci kontur ohně a zhruba 95% při rozpoznání kontur oblastí, které nejsou oheň.

Omezení jsou v detekci minimální velikosti ohně. Vzdálené požáry tedy nebudou detekovány. Uvedená implementace také interně ignoruje oblasti tenké.

Image Based Forest Fire Detection Using Dynamic Characteristics With Artificial Neural Networks [15]

Uvádění autoři Dengyi Zhang, Shizhong Han, Jianhui Zhao, Zhong Zhang, Chengzhang Qu, Youwang Ke, Xiang Chen. Jak název práce naznačuje, je zaměřena na detekci ohně v lesích. Práce využívá extrakci barevných pixelů podezřelých na oheň, extrakci dynamických příznaků a neuronové sítě pro vyhodnocení skupiny příznaků.

³DFT – diskrétní Fourierova transformace

Prvním stupněm zpracování je separace barev. Zpracování je prováděno v barevné reprezentaci HSV. Barva podezřelých ohňových pixelů je vymezena pomocí intervalů, do kterých musí jednotlivé složky H a S spadat.

$$V_x = x|x(H) \in [0, 36] \cup [345, 359], x(S) \in [69, 255] \quad (2.1)$$

Po separaci je možné ohraničit spojité regiony, které budou považovány za oblasti s vyskytující se ohněm. Jako další přichází na řadu zpracování v podobě extrakce příznaků nalezených oblastí. Prvním příznakem je změna velikosti oblasti, protože se předpokládá zvětšování nekontrolovaného požáru. Druhým příznakem je složitost ohraničení. To je zjištěno jako celková délka hranice nalezeného tvaru v poměru k ohraničené ploše. Je zřejmé, že bude-li mít hranice složitý tvar s různými zákruty a zvlněním bude délka hranice velká i když bude ohraničovat oblast, která bude plošně shodná například s čtvercem, kde hranice jsou přímé linky, a tento poměr bude vyšší. Třetím příznakem je sledování změn kontur ohraničené oblasti. Složitý tvar nemusí jednoznačně představovat oheň, pokud se nemění v čase. Kontura je popsána deskriptorem obdobně jako v předchozím přístupu. Hodnota jejich rozdílnosti je vypočítána jako suma absolutních hodnot rozdílů koeficientů se stejným indexem ve dvou po sobě jdoucích deskriptorech, které se vztahují ke stejné oblasti.

$$D_i = \sum_{w=1}^{32} \left| \|F_w^i\|_2 - \|F_w^{i-1}\|_2 \right| \quad (2.2)$$

Jak je z rovnice vidět, ignorován je nulový koeficient, který je označován jako centrum gravitace, tedy těžiště zpracovávaných bodů. K samotnému vyhodnocení postačuje prvních 32 koeficientů.

Tímto je vytvořeno množství příznaků, které jsou uchovávány a je vypočtena jejich průměrná hodnota a hodnota kvadratické odchylky. Příznaky jsou nadále zpracovány neuronovou sítí se zpětným šířením⁴ chyby. To znamená, že v případě chybného výstupního výsledku při učebním postupu je zpětně upravována váha jednotlivých koeficientů u vstupních uzlů jednotlivých neuronů, aby se dosáhlo co nejvyšší úspěšnosti.

Podle zprávy bylo testováno 27 videoklipů s ohněm, z nichž jeden nebyl rozpoznán. Pro testování falešných alarmů bylo použito 349 klipů s vlající vlajkou a pohybujícím se autem, kde byl třikrát spuštěn falešný alarm. Výsledky testování uvádí 98,94% úspěšnost.

Computer vision based method for real-time fire and flame detection [12]

Autoři B. Uğur Töreyn , Yiğithan Dedeoğlu, Uğur Güdükbay, A. Enis Çetin. Detektor využívá detekce pohybujících se regionů, barevný model pro separaci podezřelých oblastí a vlnkovou analýzu.

Detektor nalezne pohybující se oblasti obrazu, které následně zkontroluje na přítomnost ohňových barev. Rozhodovací model je realizován pomocí natrénovaného Gaussova modelu v reprezentaci barev pomocí RGB. Následuje zpracování pomocí vlnkových transformací. Pomocí časové vlnkové analýzy se zjišťuje, zda je přítomno pulzování ohně na frekvenci do 10Hz. Z toho vyplývá kritérium minimálního počtu snímků za sekundu ve sledovaném videu, kterých nesmí být méně než 20 snímků za sekundu. Pomocí prostorové vlnkové analýzy je pak rozhodnuto, zda se jedná o obyčejný pohyb nebo o neuspořádaný pohyb ohně.

Údajná úspěšnost detekce ohně na testovacích datech byla téměř 100%. Data zahrnovala různorodá prostředí, ve kterých se pohybovali lidé, prostředí dálnice, přírodní scény jako například zahrada s výskytem ohně a mnoho dalších.

⁴BP - Back propagation

Early fire detection method in video for vessels [13]

Autory metody jsou Shuenn-Jyi Wang, Dah-Lih Jeng, Meng-Tsai Tsai. Návrh detektoru je specializován pro plavidla. Metoda se zaměřuje na detekci ohně podle barvy a následně i na detekci kouře, který předchází nebo provází hoření a může signalizovat blížící se nebezpečí.

Klíčovým prvkem je vytvoření takzvané vyhledávací tabulky dominantních barev ohně označenou jako DFCLT⁵. Vytvoření tabulky probíhá ze sbírky hořících materiálů. Jako vybrané materiály uvádí papír, piliny, polštáře, benzín a motorovou naftu. Vyjmenované materiály se běžně vyskytují na plavidlech a jsou nejčastějším zdrojem ohně. Každý materiál byl při hoření snímán za různých světelných podmínek. Příklad záběrů hořícího polštáře je na obrázku 2.5.



Obrázek 2.5: Ukázka vzorku trénovacích dat - hořící polštář. Převzato z [13].

Barvy byly zpracovávány v barevných prostorech RGB, HSV, CIE LAB. Pro všechny byla vytvořena za pomoci fuzzy clusteringu barevné informace výřezů ohňů tabulka nebezpečných barev. Pokud barevný prostor obsahuje přímo informaci o hodnotě světlosti, byla tato informace ignorována. Tím tedy vznikla tabulka nebezpečných barev pro RGB, HS a CIE AB. Samotná detekce poté obsahuje sledování pohybu odečítáním od referenčního snímku. Poté následuje shlukování (clusterizace) pixelů snímku a nalezení dominantní barvy pro porovnání s tabulkou. Podle vyhodnocení je detektor schopen signalizovat několik úrovní alarmu. Vyhodnocení provází detekce kouře, kterou zde nebudu rozebírat.

Jako výhoda je uvedeno použití DFCLT, kterou je možno jednoduše přetrénovat podle prostředí, osvětlení a použité kamery. Z toho vyplývá, že jedna DFCL tabulka by neměla být použita v rozdílném prostředí či dokonce s jiným technickým vybavením.

Celkové zhodnocení metody není zcela jednoznačné, protože měření, která jsou shrnuta v tabulkách, uvádí stupně nebezpečnosti.

Efficient visual fire detection applied for video retrieval [10]

Autoři Paulo Vinicius Koerich Borges, Joceli Mayer, Ebroul Izquierd. Tato implementace se zaměřuje jako předchozí na barevnou informaci, náhodné změny ohraničených oblastí a jejich náhodnost a hrubost. Všechny informace nakonec zpracovává Bayesovský klasifikátor.

Proces zpracování je započat eliminací barevných pixelů, které nemají barvu ohně. Barevné zpracování je pouze v prostoru RGB. Pro zvýšení přesnosti bylo využito rovnic, které zohledňují i množství jasu v obraze pomocí poměru jednotlivých kanálů spojených s empirickými horními a dolními hranicemi. Tím vznikne maska obrazu, která dvojicí hodnot true/false koresponduje s pixely v obraze. Na základě této masky jsou vytvořeny a ohraničeny spojitě oblasti, které obsahují podezřelé barvy. Následuje paralelní zpracování, při kterém jsou nalezené oblasti vyhodnoceny na změnu tvaru a velikosti oblasti, odchylku hranice, šikmost hranice a hrubost hranice. Všechny tyto vyhodnocené parametry jsou jako vstup Bayesova klasifikátoru, který vyhodnotí podmínky a označí u jednotlivých oblastí, zda jsou ohněm nebo ne.

⁵ DFCLT - dominant flame color lookup table

Výsledky měření uvádí 0.9% nevygenerovaných alarmů a 0.4% falešných alarmů.

Fire detection using statistical color model in video sequences [1]

Autoři Turgay Celik , Hasan Demirel, Huseyin Ozkaramanli, Mustafa Uyguroglu. Metoda se silně zaměřuje na barevný model v kombinaci s detekcí pohybu.

Implementace realizuje detekci pohybu pomocí natrénovaného modelu. To se může jevit jako omezení metody na jeden typ naučeného prostředí. Autoři uvádí, že model je schopný samostatné aktualizace v případě vzniku trvalejších změn. Druhou podstatnou částí je barevný model pro rozhodování, zda barva pixelu je podezřelá na výskyt ohně nebo ne. Vytvořený statistický model pracuje s barevným modelem RGB. Model je vytvořen na základě velkého množství dat. Výsledkem je 5 porovnávacích rovnic, které reflektují i jas pixelu přes poměrné vyhodnocení jednotlivých kanálů mezi sebou. Výsledná detekce je spojení výsledků sledování změn pohybu a označených ohňových pixelů.

Úspěšnost metody je 98,89%. Chyba je způsobována náhlými změnami osvětlení a nelinearitou snímání zapříčiněné kamerou.

Kapitola 3

Počítačové vidění

Tato kapitola stručně uvádí především pojmy a metody počítačového vidění, které jsou využity při návrhu detektoru v kapitole 4 nebo jsou zpracovávány v pracích, z nichž tato práce čerpala.

3.1 Barevné prostory

Barevné prostory definují barvy při zpracování ve výpočetní technice. Existuje mnoho modelů¹, které reflektují jednoduchost použití či vlastnosti lidského oka. Modely, které byly použity v této práci, jsou následující

RGB

Toto je nejrozšířenější a nejznámější reprezentace barevného prostoru. Prostor je rozdělen na tři složky² (R – červená, G – zelená, B – modrá). Tyto složky obvykle nabývají hodnot 0-255 při reprezentaci jedné složky osmi bity. Hovoříme-li o vyzařovacím zařízení (např. monitor), je výsledná barva získána aditivním skládáním. Dále tohoto modelu vychází rovnice, které zajišťují převod do ostatních barevných modelů.

HSV

Je velmi rozšířeným modelem. Skládá se ze tří složek³: H – odstín, S – saturace, V – jas. Jeho výhodou je oddělení jasové složky od barevného tónu. Zjednodušuje práci při separaci barvy určitého odstínu nebo separaci barvy určité světlosti. Rovnice, kterými je tento model získán z modelu RGB jsou následující.

¹<http://www.couleur.org/index.php?page=transformations>

²Red, Green, Blue.

³Hue, Saturation, Value.

$$h = \begin{cases} \text{nedefinován,} & \text{jestliže } max = min \\ 60^\circ \times \frac{g-b}{max-min} + 0^\circ, & \text{jestliže } max = r \text{ a } g \geq b \\ 60^\circ \times \frac{g-b}{max-min} + 360^\circ, & \text{jestliže } max = r \text{ a } g < b \\ 60^\circ \times \frac{b-r}{max-min} + 120^\circ, & \text{jestliže } max = g \\ 60^\circ \times \frac{r-g}{max-min} + 240^\circ, & \text{jestliže } max = b \end{cases} \quad (3.1)$$

$$s = \begin{cases} 0, & \text{jestliže } max = 0 \\ \frac{max-min}{max} = 1 - \frac{min}{max}, & \text{jinak} \end{cases} \quad (3.2)$$

$$v = max \quad (3.3)$$

Šedotónový model

Tento model není přímo modelem barevným. Obsahuje pouze odstíny šedé, což nám dává paletu od černé po bílou. Je odvozen z modelu RGB empirickým vztahem, který reflektuje vlastnosti lidského oka a jeho zvýšenou citlivost na rozpoznání zelené barvy a nižší citlivost na barvu modrou. Výhoda modelu je v úspoře místa v případě, že není nutné uchovávat barevnou informaci.

$$V_{\text{gray}} = 0.3 * R + 0.59 * G + 0.11 * B \quad (3.4)$$

3.2 Detekce pohybu

Algoritmů pro detekci pohybu existuje mnoho. Pro účely detekce ohně nám postačí jednoduché metody, o kterých pojednává například [3]. Jedná se o metodu odečítání vyhodnocovaných snímků od referenčního snímku neboli metodu odečítání pozadí. Referenční snímek je aktualizován, aby bylo možné zaznamenat pohyb a zároveň nebylo vyhodnocení ovlivněno změnou osvětlení (střídání dne a noci). Odečítání probíhá po jednotlivých pixelech.

3.3 Filtrace obrazu


Při zpracování videosignálu musíme počítat s tím, že videozáznamy budou obsahovat nadbytečné informace jako je šum. Ten je nežádoucí při jakékoliv práci v podobě diferencování snímků a je vhodné ho co jen výrazněji redukovat. Mezi známou metodu patří aplikace mediánového filtru. Více informací o použití vhodných filtrů při detekci pohybu můžeme nalézt v práci [3]. Tato operace však sebou nese pouze výhody. Z obrazu se nám mohou vytratit sledované informace jako jsou například náhlé změny v malém úseku obrazu, které se vlivem filtrace zredukuje nebo úplně ztratí. Proto je nezbytné před použitím dobře zvážit dopad na postup práce.

3.4 Dilatace a eroze

Dilatace i eroze patří mezi morfologické operace nad obrazem. Morfologické operace jsou nelineární funkce, které se provádí nad šedotónovým nebo černobílým⁴ obrazem. Funkce

⁴Černobílý obraz je také nazýván binární a může být reprezentován jako směs 0 a 1, kde 0 udává černý pixel a 1 bílý pixel.

dilatace prochází zdrojový obraz po jednotlivých pixelech a do výstupního obrazu se přenáší nejvyšší nalezená hodnota ze zvoleného okolí. Velikost okolí je libovolná v praxi se používá například velikost okolí 3x3. Dilatace je často používána po operaci eroze, která naopak do výsledného obrazu přenáší nejnižší nalezenou hodnotu. To způsobí odstranění šumu v podobně osamocených pixelů. Názorná ukázka je na obrázku 3.1 a 3.2



Obrázek 3.1: Ukázka výsledku operace dilatace. Převzato z [3].



Obrázek 3.2: Ukázka výsledku operace eroze. Převzato z [3].

3.5 Diskrétní Fourierova transformace

Fourierova transformace slouží k vyjádření signálu pomocí harmonických funkcí sinus a cosinus. První algoritmy pro výpočty měly kvadratickou složitost a nebyly vhodné pro aplikace pracující v reálném čase. Postupem času byl vytvořen algoritmus⁵, který výrazně zjednodušil výpočet a umožnil nasazení do reálných systémů. Jednorozměrná DFT je definována následujícím vztahem

$$X_k = \sum_{n=0}^{N-1} x_n e^{-\frac{2\pi i}{N} k n} \quad k = 0, \dots, N-1 \quad (3.5)$$

Nyquistův teorém pojednává o minimální hodnotě vzorkovací frekvence, která musí být minimálně dvojnásobkem sledovaného signálu. V případě detekce ohně ve videu je třeba tuto podmínku splnit ve formě minimálního počtu snímků za sekundu ve zpracovávaném videu. Jak uvádí zdroje, oheň kmitá v rozmezí 1–10Hz. Po aplikaci tohoto pravidla je tedy nutné pro zajištění správné funkčnosti zpracovávat videozáznamy s minimální hodnotou 20 snímků za sekundu.

⁵FFT - Fast Fourier Transform

Kapitola 4

Návrh

Cílem je sestavení detektoru na základě známých charakteristik ohně. Mezi ně patří jeho barva, pohyb a frekvence jeho pohybu. Myšlenkou je vyhnout se metodám, které obsahují algoritmy, vyžadující trénování, před vlastním nasazením. Výsledky úspěšnosti vyhodnocování navrženého detektoru budou dále shrnuty v kapitole 6.

4.1 Přehled

Detektor musí obsahovat části, které budou schopny sledovat a vyhodnocovat následující charakteristiky ohně.

Barva

Barva je velmi důležitým prvkem pro rozpoznání ohně. Ve většině popisovaných prací v části 2.5 je extrakce a vyhodnocení barevné informace klíčovým prvkem správné funkčnosti. Proto tento krok bude jako první a umožní eliminovat převážnou část irelevantních informací v obraze. V rozebíraných pracích je uvedeno několik empirických vztahů, podle kterých je možné rozhodnout, zda vybraný pixel je nebo není podezřelý na barvu ohně. Vyhodnocení bude probíhat v barevných modelech RGB a HVS na základě existujících rovnic. Pravidla jsou však pro standardní oheň a tedy nepočítají s hořením chemikálií, které mohou změnit barvu plamenů. Pokud by se tak stalo, plameny by byly odfiltrovány barevným zpracováním a k detekci by nemohlo dojít.

Pohyb

Oheň není statická záležitost. Protože je zpracováváno video, je nezbytné sledovat změnu oblastí. To zajistí eliminaci nepohyblivých předmětů, které však mají barvy podezřelé na výskyt ohně. Problém se vyskytne v případě, že kamera není statická a nepohyblivé předměty budou vykazovat pohyb a naopak pohyb nemusí být odhalen. Pohyb ohně je naštěstí neuspořádaný a riziko nenalezení pohybu plamenů je minimální.

Frekvence

Frekvence je podstatným ukazatelem, zda oblast nalezená pomocí výše uvedených technik, může být opravdu ohněm. Oblasti je tedy nutné vhodně sledovat a v průběhu času vyhodnocovat fluktuaci intenzity. Pokud bude splněno kritérium, můžeme sledovanou oblast označit za oblast s vyskytující se ohněm.

4.2 Předpokládaný postup vyhodnocení

Detektor bude zpracovávat snímek po snímku a ukládat nezbytné informace o oblastech a vyhodnocovat podezřelé chování. Pokud chování ve sledovaných částech splní sadu podmínek, oblast se označí za oheň.

Prvním stupněm zpracování, bude separace podezřelých pixelů, které mají barvy ohně. Tím se oddělí nadbytečná informace v obraze. A vznikne nám maska, která bude korespondovat s místy podezřelými na přítomnost ohně. Z masky je nutné extrahovat jednotlivé oblasti (nejlépe obdélníkové ohraničení). Tyto oblasti se nadále vyhodnotí na přítomnost pohybu. Předpokládáme, že plameny ohně, který chceme detekovat, jsou v neustálém pohybu. Oblasti, které nebudou vykazovat pohyb, mohou být vyřazeny ze zpracování. Tyto oblasti budou tvar a velikost. Pro sledování frekvenční složky ohně bude obraz rozdělen do sítě vzájemně se překrývajících čtverců, ve kterých bude sledována intenzita jasu. Na základě změn této intenzity bude probíhat vyhodnocení s cílem určit dominantní frekvenci změn a na základě této informace dodatečně rozhodnout, zda oblast obsahuje oheň. Následně se provede průnik samostatně nalezených oblastí a oblastí z obrazové sítě, které splní vyhodnocovací kritéria. Samostatné oblasti, které budou obsahovat pozitivní oblasti z obrazové sítě, budou zachovány. Pro vyhlazení výstupu detektoru a eliminaci skokových mylných nebo vynechaných detekcí bude výstup předcházejících stupňů zpracovávat sledovač podezřelých oblastí (tracker). Ten zajistí označení a aproximaci místa kde byly nalezeny podezřelé oblasti.

4.3 Detektor

Barevné zpracování

Prvním stupněm zpracování snímku bude vytvoření masky, která bude označovat pixely s barvou plamenů. Vstupem bude jeden snímek z videa a výstupem matice označující podezřelé pixely. Pro implementaci budou použity tři rozhodovací modely. Jejich vhodnost a přesnost bude vyhodnocena v části testování.

První bude statistický barevný model, který je uveden v práci [1] a pracuje pouze s barevným modelem RGB. Rovnice obsahují jednoduchá pravidla jako je minimální hodnota červené složky a vzájemný vztah jednotlivých barevných kanálů. Složitější částí jsou rovnice, které byly získány zpracováním několika milionů pixelů, jak uvádí zdroj. Rovnice reflektují hodnotu jasu, kterou barevný model RGB přímo neobsahuje. Vytvoření masky bude možné dvojím způsobem. První bude jednoduché porovnání pixelů a jejich ohodnocení podle rovnic. Druhým způsob bude částečně realizovat myšlenku uvedenou v práci, ze které jsou rovnice čerpány. Každý pixel bude kromě vyhodnocení barevnosti také vyhodnocen na změnu oproti předchozímu snímku.

$$R(x, y) > R_{mean} \quad (4.1)$$

$$R_{mean} = \frac{1}{K} \sum_{i=1}^K R(x_i, y_i) \quad (4.2)$$

$$R(x, y) > G(x, y) > B(x, y) \quad (4.3)$$

$$\begin{aligned}
0.25 &\leq G(x, y)/(R(x, y) + 1) \leq 0.65 \\
0.05 &\leq B(x, y)/(R(x, y) + 1) \leq 0.45 \\
0.20 &\leq B(x, y)/(G(x, y) + 1) \leq 0.60
\end{aligned}
\tag{4.4}$$

Druhým model vychází ze dvou rovnic uvedených v práci [6] a jedné experimentálně vytvořené. Pracuje s RGB i HSV barevným prostorem. Model RGB je použit pro zjištění poměrů jednotlivých kanálů barev. Druhá rovnice udává poměr červené barvy a poslední rovnice určuje minimální hranici hodnoty součtu intenzity a saturace barvy. Tento model bude výpočetně náročnější, protože vyžaduje převod snímku do barevného modelu HSV.

$$R(x, y) > G(x, y) > B(x, y) \tag{4.5}$$

$$S(x, y) \geq (255 - R(x, y) * S_T/R_T) \tag{4.6}$$

$$S(x, y) + V(x, y) \geq 350 \tag{4.7}$$

Třetí barevný model je převzat z práce [6]. Pracuje nad barevnými prostory RGB a HSV. Obsahuje tři pravidla, podle kterých jsou klasifikovány barvy ohně.

$$R(x, y) > R_T \tag{4.8}$$

$$R(x, y) > G(x, y) > B(x, y) \tag{4.9}$$

$$S(x, y) \geq (255 - R(x, y) * S_T/R_T) \tag{4.10}$$

Jak je z rovnic názorně vidět, většina modelů obsahuje podobné podmínky.

Separace podezřelých oblastí

Plameny ohně můžeme pokládat za spojité. Jejich lokalizace tedy znamená nalezení spojitých ploch, které mají specifické barvy ohně. Jako vstup bude vhodné použít masku získanou barevným zpracováním. Nalezneme ohraničení těchto oblastí, které bude potřeba nadále sledovat a vzájemně porovnávat v časové ose. Ideální případ je znázorněn na obrázku 4.1. Bohužel tohoto výsledku těžko dosáhneme. Jak je vidět, i lampička a stěna mají stejnou paletu barev jak plameny samotné.

Protože maska nemusí být spojitá a může obsahovat osamocené pixely, bude na místě využít morfologických operací eroze a dilatace. Tím budou odstraněny osamocené pixely a zároveň zaplněny drobné díry v masce.


Detektor pohybu

Detektor musí zpracovávat každý snímek a být schopný určit množství pohybu (změn) v daném výřezu. Zjištěné množství změn nazvěme pohybovým momentem, který bude udávat rozsáhlost změn ve sledované oblasti. Bude vhodné realizovat detektor, který si bude uchovávat referenční snímek. Tento referenční snímek bude aktualizován váhovým přičítáním nově přichozích snímků. To zajistí postupnou aktualizaci a zároveň historii. Aby



Obrázek 4.1: Vlevo je ideální maska s vyznačením oblastí, která byla ručně upravena. Vpravo je originální snímek.

byl detektor odolný na změnu osvětlení, bude si udržovat informaci o průměrné hodnotě všech kanálů referenčního snímku, které může porovnávat s průměrnou hodnotou získanou ze snímku, který je vyhodnocován. Využití detektoru pohybu však nese nevýhodu. Jelikož jsou odečítány snímky od referenčního, který je postupně aktualizován, bude se pohybovat vše jakmile se posune kamera a tím celý snímaný obraz. Situaci vystihuje obrázek 4.2 dvou diferenčních snímků.



Obrázek 4.2: Vlevo je diferenční snímek, kde je názorně vidět pouze pohybující se plameny. Vpravo je snímek, který vznikl při pohybu kamery.


Vyhodnocení oblastí

Všechny nalezené oblasti musí být analyzovány. Informace by měly obsahovat množství ohňových pixelů, celkovou hodnotu jasu, zjištěné množství pohybu (změn) a směrodatnou odchylku těchto změn. Na základě těchto informací se vytvoří historie pro následné vyhodnocování.

Sledování segmentů obrazu

Chceme-li sledovat pulzování ohně, je potřeba obraz zpracovávat po pevně daných oblastech. Každá oblast bude mít konstantní velikost. Oblasti se budou vzájemně překrývat a budou

tvořit síť, která bude rozdělovat snímek. Tím bude docíleno toho, že každou dílčí oblast bude možné v čase sledovat a vyhodnocovat pulzování intenzity. Historii takového sledování je možné zobrazit obrázkem 4.3. I přes jeho zvětšení jsou vidět pomyslné linky (řádky), které odpovídají jedné oblasti. Jejich délka (počet sloupců) je pak zmiňovaná historie.




Obrázek 4.3: Zvětšený obrázek možné reprezentace vývoje historie intenzit oblastí.

Tato část bude velmi náchylná na pohyb kamery.

Sledovač podezřelých oblastí

Tento sledovač, jinak označen taky jako sledovač ohně, bude výstupním stupněm celého detektoru. Jeho úkolem bude shromažďovat informace o detekcích, které budou založeny na výstupech předchozích bloků. Tyto dílčí detekce budou v čase vzájemně spojovány (klíčovány) v případě existující návaznosti, aby mohlo dojít k celkovému vyhodnocení, zda je možné označit oblast za oheň. Vytvoření návaznosti mezi oblastmi v posloupnosti snímků bude na základě procentuálního překryvu s historií. Plameny se mohou pohybovat a je tedy žádoucí, aby byly vyhodnocovány jako jedna oblast. Ilustrační obrázek 4.4 znázorňuje myšlenku přesunu (kmitu) plamene v sekvenci snímků.



Obrázek 4.4: Ilustrační obrázek pohybu plamene se zvýrazněnou detekcí podezřelé oblasti v každém snímku.

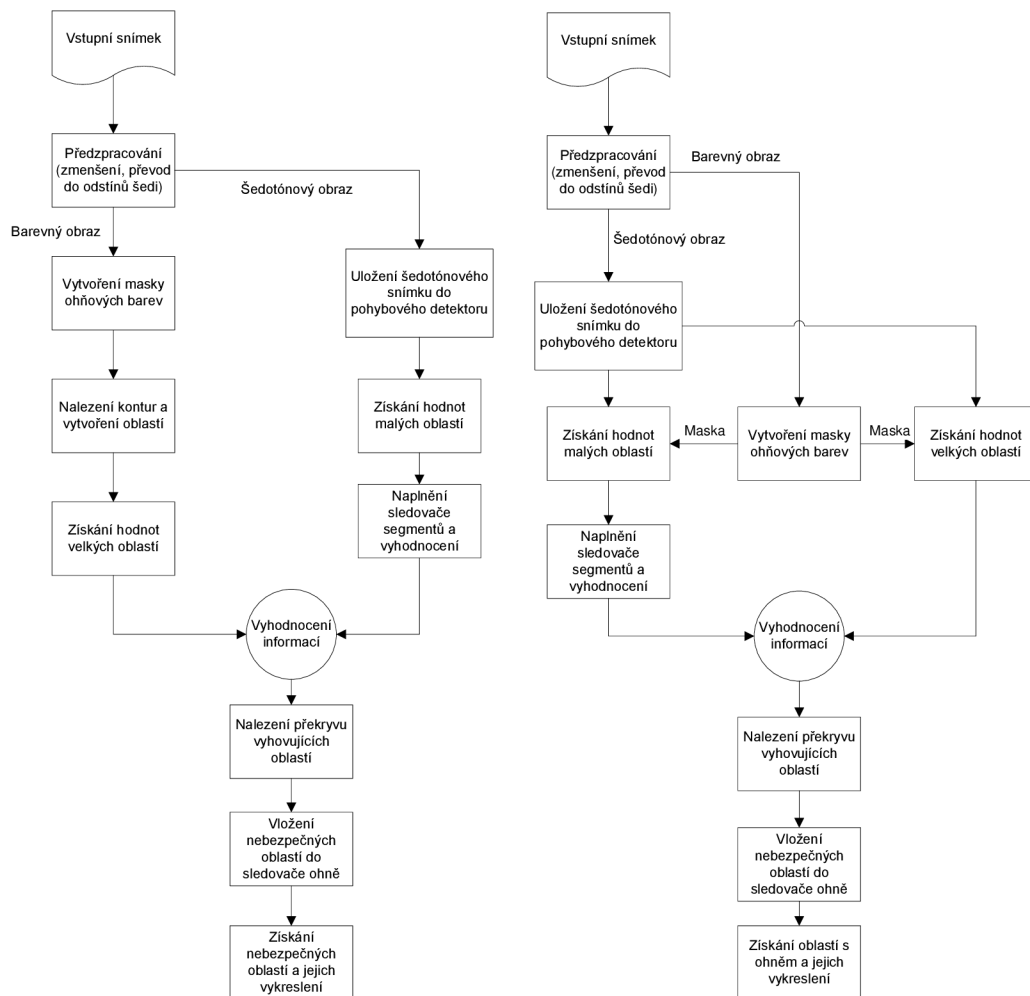
Přenos informací mezi bloky

Oblasti se budou přenášet v podobě obdélníkových oblastí. Uchovávaná informace musí být jejich pozice a rozměry. Další informace potřebné pro vyhodnocování je průměrná intenzita, množství naměřeného pohybu, směrodatná odchylka jednotlivých pixelů od průměru a dominantní frekvence zjištěná pomocí Fourierovy transformace.

4.4 Vyhodnocovací proces

Obraz bude rozdělen do dvou úrovní vyhodnocovaných oblastí (velké a malé oblasti). První úrovní budou malé oblasti. Ty budou sloužit především pro sledování změn intenzit a jejich

vyhodnocení v čase. Druhá úroveň bude tvořena buď většími oblastmi s pevně danou velikostí, nebo oblastmi, které se získají z oblastí nalezených v masce ohňových pixelů. Tyto větší oblasti, ať už se jedná o oblasti s pevně danou velikostí a nebo oblasti vytvořené z masky, budou vyhodnocovány na úroveň pohybu a směrodatnou odchylku. Vyhodnocení však bude prováděno pouze pro pixely, které mají podezřelou barvu. Směrodatná odchylka bude v případě výskytu plamenů vykazovat vyšší hodnoty než v případě výskytu jednobarevné skvrny (např. barevná stěna). Důvod je takový, že plameny při pulzování a pohybu rychle mění barevné odstíny a jednotlivé pixely se budou od průměrné hodnoty lišit. U konstantně barevné plochy budou jednotlivé pixely blízké průměrné hodnotě a hodnota bude nižší. Následující obrázek 4.5 ukazuje dvě možnosti logiky vyhodnocení podle volby tvorby velkých oblastí.



Obrázek 4.5: Diagram vlevo znázorňuje princip zpracování při získávání velkých oblastí z masky ohňových barev. Diagram vpravo nastiňuje postup vyhodnocení v případě použití konstantně velkých ploch, které jsou vyhodnocovány.

Kapitola 5

Implementace

V této kapitole je popsána implementace navržených částí detektoru a popis použitých knihoven.

5.1 Použité knihovny a programovací jazyk

Program je psaný v jazyce C++ s využitím IDE Microsoft Visual Studio 2008, které poskytuje dobré a jednoduché zázemí pro ladění programu, zjišťování výkonu a výpočetní náročnosti psaných funkcí.

Jelikož se jedná o grafickou aplikaci, je využito knihovny OpenCV 2.1, která je populární a hojně využívána při tvorbě aplikací zaměřených na zpracování obrazu. Tato knihovna obsahuje stovky praktických funkcí a tříd, které jsou optimalizovány a poskytují co nejvyšší výkon. Implementuje například rozhraní a funkce pro práci s video soubory, jednoduché zpracování a zobrazování snímků a poskytuje praktickou strukturu `cv::Mat`, která je vhodná pro ukládání obrazových dat i dat, které jsou používány pro výpočet.

Pro zvýšení výkonu na víceprocesorových systémech je využito OpenMP, které přináší možnost vícevláknového zpracování v místech, kde jsou prováděny výpočty nad maticemi s různorodými operacemi a vyhodnocováním. Pokud při překladu není OpenMP dostupné, kód je přeložen standardním způsobem ve formě aplikace pro jeden procesor a není nutný zásah do kódu. Při programování je však nutná pozornost při práci se sdílením úseků paměti.

5.2 Popis oblastí

Pro popis oblastí jsou vytvořeny dvě struktury. První (**Area**) je pro přenos a uložení obecných informací o oblastech. Obsahuje souřadnice s rozměry oblasti a dále informace které jsou využívány pro statistické vyhodnocování. Druhá (**AreaState**) je pro uložení oblastí ve třídě **FireTracker** jelikož obsahuje informace, které jsou nezbytné pro správnou funkčnost této třídy a již neobsahuje ostatní dodatečné informace.

5.3 Třídy

MotionDetector

Třída zpracovává jednotlivé snímky a poskytuje informace o určených oblastech. Mezi ně patří množství zjištěného pohybu s odchylkou změn, průměrná intenzita a její standardní

odchylka od průměru a počet pixelů, které jsou podezřelé na barvu ohně.

Po inicializaci je objektu přidáván každý snímek pomocí `addFrame()`, ten je pokaždé uložen do vnitřní paměti. Referenční snímek je aktualizován předchozím vloženým, který se nachází v interní paměti, a až poté se na jeho místo zkopíruje nový. Z toho vyplývá, že parametr metody `addFrame()`, který určuje váhu přičítaného snímku, ovlivňuje předchozí snímek.

Jak bylo řečeno, hlavní funkcí této třídy je výpočet informací o oblastech. Tato funkcionality je poskytnuta metodou `computeAreaInformationMasked()` a `computeAreaInformation()`. Obě metody mají obdobnou funkčnost, pouze první uvedená zahrnuje do vyhodnocení pixely, které odpovídají zadané masce.

Pomocí metody `createFireMask_Color()` je implementována tvorba masky podle podezřelých pixelů na barvu ohně, která zohledňuje změnu jednotlivých pixelů snímku od referenčního. Tato myšlenka byla popsána v 4.3.

SegmentAnalyzer

Podle zadané vstupní mapy oblastí sleduje jednotlivé segmenty obrazu.

Inicializace probíhá pomocí metody `init()`, která obsahuje jeden parametr určující hloubku historie. Poté je nezbytné vložit schéma kontrolovaných oblastí pomocí funkce `insertScheme()`. Objekt si vytvoří paměťovou strukturu nezbytnou pro ukládání zpracovávaných informací. Mapa segmentů s vypočítanými informacemi se vkládá pomocí metody `step()`, které je předán vektor oblastí popsaných strukturou `Area`.

Klíčovou úlohou je udržování historie vývoje intenzit jednotlivých oblastí. Tuto historii objekt vrací pomocí metody `getIntensity()` do struktury `cv::Mat`, která je součástí `OpenCV`.

FireTracker

Má za úkol vyhodnocovat množství podezřelých oblastí, spojovat je vzájemně mezi jednotlivými snímky a podle jednoduchých pravidel určovat, zda oblast splňuje podmínky a může být označena za oheň.

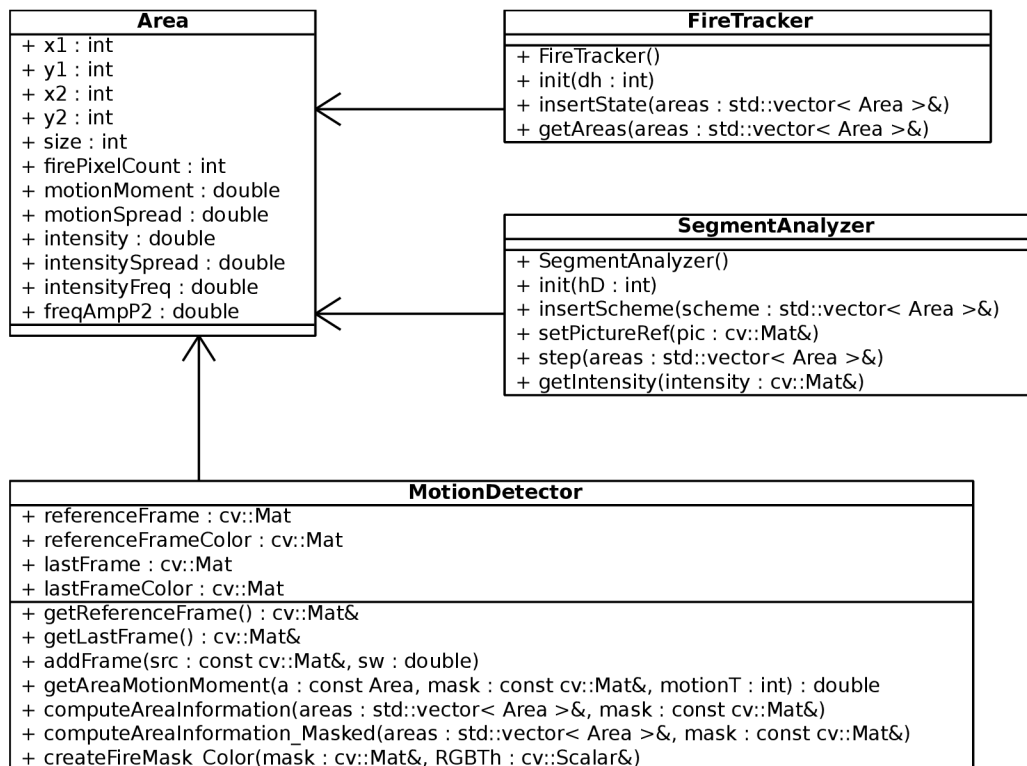
Inicializace probíhá pomocí metody `init()`, která přebírá parametr nastavující hloubku historie. Každý krok výsledků je vkládán pomocí metody `insertState()`. Obdobně jako `SegmentAnalyzer` přebírá vektor oblastí uložených ve struktuře `Area`. Tyto oblasti jsou jednotlivě zpracovávány tak, že se hledá překryv s již existujícími oblastmi, které objekt obsahuje a v případě pozitivního nálezu přiřadí porovnávanou oblast ke korespondující oblasti v historii. Nejdůležitější je pak funkce `getAreas()`. Ta vrací oblasti z historie, které byly vloženy několikrát po sobě v časovém úseku třetiny historie.

5.4 Funkce

Některé funkce bylo praktické implementovat samostatně.

K rozdělení obrazu na jednotlivé segmenty slouží `createSegmentsOL()`. Podle zadaných parametrů (rozměry obrazu a požadovaná délka hrany segmentu) vytvoří množinu oblastí popsaných strukturou `Area`, která je uložena do vektoru. Návrátová hodnota odpovídá počtu sloupců.

Tvorbu masky podle barvy pixelů provádí funkce `createFireColorMaskBGR()`, `createFireColorMask()` a `createFireColorMaskBGRS()`. Ty realizují výběr pixelů podle



Obrázek 5.1: Diagram tříd.

principů uvedených v části 4.3. Všechny tři funkce také jako jeden z parametrů přebírají strukturu `cv::Scalar`, ze které čtou uloženou průměrnou hodnotu kanálu červené barvy a následně tuto hodnotu i aktualizují.

Práce s oblastmi je realizována pomocí funkcí `findAreas()`, `joinOverlapAreas()`, `divideAreas()`, `removeWithoutSegment()` a `computeDominantFrequency()`. První z uvedených nalezne ohraničení z vektoru kontur, který je vrácen funkcí OpenCV pro nalezení kontur v obraze. Ignorovány jsou oblasti, jejichž plocha nepokrývá zadané minimum. Druhá funkce zajišťuje spojení oblastí, které se překrývají. Interně vypočítá překryv oblastí vzhledem k oblasti s menší plochou, a pokud je tento překryv větší než zadaná hodnota, sloučí tyto oblasti do jedné. Třetí funkce `divideAreas()` je pro zajištění maximální velikosti jednotlivých oblastí v předané množině. Uplatnění je popsáno v kapitole 6. Předposlední funkce je důležitá pro vytvoření průniku výsledku. Ze dvou vektorů oblastí ponechá v prvním vektoru pouze ty, jež jsou překryty alespoň částečně jednou oblastí z vektoru druhého. Nejdůležitější z vyjmenované pětky je `computeDominantFrequency()`, která z výstupu metody `getIntensity()` třídy `SegmentAnalyzer` extrahuje informaci o dominantní frekvenci změny intenzity a uloží ji do korespondujícího vektoru oblastí.

5.5 Postup vyhodnocení

Aplikace po spuštění otevře zdroj video souboru. Pokud jsou rozměry videa příliš velké, bude se zpracovávat s poloviční velikostí. Podle této informace jsou vytvořeny segmenty pro zpracování dílčích částí obrazu. Pokud je zapnuto vyhledávání ohňových oblastí podle konstantně velkých segmentů, jsou vytvořeny i ty. Dále jsou provedeny inicializace a začíná

samotné zpracování jednotlivých snímků. Po načtení snímků je v případě potřeby provedeno jeho zmenšení na poloviční velikost. Z barevného snímku je vytvořena maska, která označuje podezřelé pixely. Barevný snímek je nadále převeden do odstínů šedi a vložen do pohybového detektoru. Následující část se liší v případě, zda hledáme velké oblasti na základě barevné masky. Pokud chceme velké oblasti nalézt pomocí masky, upravíme ji funkcemi eroze a dilatace, abychom odstranili osamocené pixely a vyplnili drobné nespojitosti. Na takto upravenou masku použijeme funkci OpenCV, která vrátí vektor kontur nalezených oblastí. Z nich jsou pomocí funkce `findAreas`, nalezena ohraničení spojitých oblastí. Může se však stát, že oblast bude příliš velká z důvodu přsvětlení a odrazů. Z toho důvodu je použita funkce `divideAreas`, která rozdělí rozsáhlé oblasti do menších. O nevýhodách velkých spojitých oblastí je pojednáno v kapitole 6.

Nyní přichází fáze výpočtu vlastností sledovaných oblastí. Hodnoty do struktury `Area` vyplní pohybový detektor pomocí metody `computeAreaInformationMasked` (pro malé i velké oblasti). Stav malých oblastí je nyní možné předat analyzátoru oblastí, který do historie uloží stav intenzit a metodou `getIntensity` získat historii intenzit zpět. Pomocná funkce `computeDominantFrequency` vypočítá a doplní hodnoty, které určují dominantní frekvenci a velikost s jakou se intenzita oblasti mění.

Následuje vyhodnocení všech oblastí. Malé oblasti jsou vyhodnoceny na existenci dominantní frekvence v rozsahu 1–10Hz, minimální hodnoty množství pohybu a průměrné odchylky pohybu jednotlivých pixelů. Velké oblasti jsou vyhodnocovány pouze v rámci hodnot množství pohybu a průměrné odchylky změn jednotlivých pixelů. Tímto vzniknou nejpravděpodobnější oblasti na výskyt ohně. Informace jednotlivých množin oblastí je nutné sloučit. To provede funkce `removeWithoutSegment`, která nám z velkých oblastí eliminuje ty, které nemají překryv s žádnou malou oblastí.

Velké oblasti jsou nyní předány komponentě na sledování ohně. Ta oblasti zpracuje tak, že přiřadí korespondující oblasti z předchozích kroků k sobě a aktualizuje svou historii. Ve výsledku je podstatná množina oblastí, kterou komponenta vrátí pomocí metody `getAreas`. Ta vrací oblasti, které byly vloženy vícekrát, a nejedná se o jednorázovou detekci, která je pokládána za chybu vyhodnocovacího procesu. Vrácený vektor oblastí tedy obsahuje místa s detekovaným ohněm. Ty je možné označit ve zpracovávaném videu.

Kapitola 6

Nastavení parametrů aplikace a testování

Tato kapitola se zabývá výsledky, které byly dosaženy při testování navrženého detektoru. Také je zde uveden rozbor případů, ve kterých detektor selhává.

6.1 Nastavení aplikace

I přes snahu vytvořit aplikaci nezávislou na předchozím učení, je potřeba určit hranice pro rozhodování, které se týká minimálního pohybu v určených oblastech. Pro tento účel bylo analyzováno několik částí videí s ohněm a bez ohně. Z hodnot, jakých dosahovali jednotlivé sledované vlastnosti, byl vypočítán průměr a zohledněna odchylka z čehož vyšla následující nastavení. Která jsou rozdílná pro segmenty malé, segmenty velké a oblasti získané z masky ohňových barev.

Minimální hodnoty malých segmentů jsou následující

- `intensitySpread` > 7.2
- `motionMoment` > 6.47
- `motionMoment/motionSpread` > 1.5
- `firePixelCount` > délka hrany segmentu¹

Minimální hodnoty velkých segmentů jsou následující

- `intensitySpread` > 1.2
- `motionMoment` > 0.74
- `motionMoment/motionSpread` > 1.2
- `firePixelCount` > délka hrany segmentu²

Minimální hodnoty velkých oblastí získaných z masky

- `intensitySpread` > 9

¹V aplikaci `#define SEGMENT_SIZE 16`.

²V aplikaci `#define SEGMENT_SIZE_BIG 32`.

- motionMoment > 8

Ostatní hodnoty jsou ignorovány, protože oblast je vytvořena na základě masky a tedy obsahuje pixely podezřelé na oheň.

Další nastavení je délka historie jednotlivých částí, které se starají o zpracování a vyhodnocení. Jako optimální byla zvolena jedna sekunda³ u sledovače ohně a dvě sekundy u sledovače segmentů. Tato nastavení ovlivňují prodlevu před označením oblasti, která obsahuje oheň.

6.2 Vzorová videa

Jak bylo na začátku práce zmíněno, detektory musí počítat s mnoha vlivy, které jsou zapříčiněné snímacím zařízením. Při testování bylo k dispozici několik videí, která bychom mohli v základu rozdělit následovně.

Venkovní prostory – kde je oheň například v lese, požáry domů a podobně. Tyto videa pak nadále lze rozlišit podle působení větru, protože to může značně ztížit podmínky detekce. I v případě dostatečné snímací kapacity kamery může být pohyb plamenů téměř skokový. Uvážíme-li nasazení detektoru ve spolupráci s přenosem po síti a levnějším snímacím zařízením, nemusí se detektoru dostávat dostatečného množství snímků, aby byly tyto skokové pohyby co nejvíce aproximovány.

Vnitřní prostory – oheň vyskytující se v místnostech či jiných uzavřených prostorech. Tyto videa mají výhodu eliminace povětrnostních podmínek. To však nezaručuje hladký průběh plamenů požáru, protože při velmi živém ohni, který zachvátí obrovskou plochu a stává se nekontrolovatelným, může být obraz znehodnocen množstvím kouře. Dalším ztíženým parametrem je odraz. Jelikož je oheň světelný zdroj, jsou předměty v jeho blízkosti osvětleny a přebírají jeho odstíny. Tím se do procesu zpracování dostávají stěny a dalších předměty, které jsou tímto osvětlením ovlivněny.

Obě skupiny videí obsahují další vlastnosti, podle kterých lze určovat kritéria detekce. Na obrázku 6.1 je příklad ohně, který je velmi živý, ale jeho detekce je ztížena absencí dostatečné viditelnosti plamenů. Samotný oheň je možné s jistotou detekovat až o několik desítek sekund později, kdy plameny začnou vlivem rozsáhlosti požáru pronikat přes hustý kouř a je možné je zaznamenat.

Vzorová videa byla nalezena na internetu a z důvodu uniformity byly použity dva zdroje⁴. To zajistilo dvě množiny obdobně kvalitních videí pro testování.

6.3 Výkon

Výsledná aplikace byla testována PC s následující konfigurací: CPU Intel Core 2 Duo⁵ 2.13GHz, 4 GB RAM, Windows Vista 64bit. Použit byl druhý barevný model, který dosahoval nejlepších výsledků při zpracování.

³1 sekunda odpovídá hodnotě FPS

⁴Zdroje: www.ultimatechase.com - Stock Footage and Storm Video Production Services; www.fire.gov - National Institute of Standards and Technology

⁵Překlad s OpenMP byl pro dvou-procesorový systém.



Obrázek 6.1: Vlevo jsou plameny ohně skryty množstvím kouře. Vpravo pronikají ven.

Vzhledem k množství použitých funkcí z repertoáru OpenCV je výkon velmi uspokojivý pro videa do velikosti 400 x 400 a lze je zpracovávat v reálném čase. Měření rychlosti zpracování probíhalo na dvou videích, z nichž jedno bylo převáděno na poloviční velikost z důvodu rozměrů. První video má rozměry 360 x 288 a druhé 720 x 480 (360 x 240 po interním převodu). Výkon s OpenMP byl mírně vyšší. Nízký nárůst výkonu je ale zapříčiněn použitím mnoha vysoce náročných funkcí, které zajišťuje knihovna OpenCV. Knihovna nebyla přeložena s podporou paralelního zpracování.

- Průměrné zpracování snímku prvního (menšího) videa s využitím OpenMP – 15,12ms.
- Průměrné zpracování snímku prvního videa bez OpenMP – 14,11ms.
- Průměrné zpracování snímku druhého videa s využitím OpenMP – 21,37ms.
- Průměrné zpracování snímku druhého videa bez OpenMP – 21,04ms.

Jak je vidět, nárůst výkonu tedy není příliš razantní. V případě menšího videa, u kterého nebylo třeba převádět velikost obrazu, je procentuální nárůst uspokojivý okolo 7%. U rozměrnějšího videa hovoříme pouze zhruba o 1,5%.



6.4 Porovnání barevných modelů

Jak bylo v návrhu zmíněno, aplikace obsahuje tři metody pro separaci barev. Pro názornou ukázkou byly vybrány dva snímky na obrázku 6.2, na kterých byla vytvořena maska. Výsledky jsou uvedeny na obrázcích níže s patřičným komentářem.

Původní očekávání bylo, že první model, bude dosahovat sám o sobě velmi dobrých výsledků. Bohužel i přes dobré separační vlastnosti a úsporu výpočetního času, protože nemusel být prováděn převod do jiného barevného modelu, se ukázalo, že pro některé situace není zcela vhodný. Jak je vidět na obrázku 6.3, zahrnuje oblohu a velkou část ploch, které obsahují pouze odraz. Jak ukazují konkrétní ukázky, oblasti, které bychom měli pokládat barvou za klíčové, naprosto ignoruje. To je daň za univerzalitu modelu. Vynecháním přepálených míst ulehčuje zpracování, protože při nasazení ve venkovním prostředí může obraz obsahovat velké množství jasných odlesků od slunce a v mnoha případech i celou oblohu jak je příkladu vidět.



Obrázek 6.2: Snímky, na kterých je provedena ukázka tvorby masky jednotlivými modely.




Obrázek 6.3: Použití první metody na vzorových snímcích.

Druhý model, který je vytvořen z převzatých podmínek a přidává jednu experimentální dosahuje obdobných výsledků jako model první. Na obrázku 6.4 je vidět, že separuje přepálené oblasti (tedy i oblohu), ale zachovává více barev, které se opravdu shodují s oblastí ohně v obrázku hořícího stromu.

Třetí model, jehož výsledek je možné sledovat na obrázku 6.5, se jeví jako nevhodný. Zahrnuje velké množství oblastí, které je třeba analyzovat. To v této implementaci znamená, že v případě výskytu prudkých či chaotických pohybů může způsobovat zvýšené množství falešných detekcí.

6.5 Varianty detekce

Výsledky a testy jsou provedeny s druhým barevným modelem, protože rozdíl výsledných detekcí oproti modelu prvnímu je minimální a třetí model byl pro použití zavržen. Jelikož je využito principu sledování intenzit malých oblastí, jsou uváděné testy prioritně prováděny na videích, která byla zaznamenána nepohyblivou kamerou.



Obrázek 6.4: Použití druhé metody na vzorových snímcích.



Obrázek 6.5: Použití třetí metody na vzorových snímcích.

Oheň


Jak z návrhu a implementace vyplývá, detekce vyžaduje několikasekundový běh videa, díky kterému se naplní historie, ze kterých jsou prováděny analýzy. To však bohužel neznamena, že plameny ohně jsou detekovány okamžitě. Kvůli sledování pulzování musí být plameny ve stejné oblasti určitý čas. Korektní vyhodnocení je uvedeno na obrázku 6.6. Vidět můžeme vytvořenou masku, ze které byly odvozeny velké oblasti (modré obdélníky). Malé segmenty obrazu (zelené čtverce) jsou vyhodnoceny na podezřelé chování v časové oblasti.

Nalezení velkých oblastí z masky

Obrázek 6.6 také ukazuje, že modré obdélníky byly záměrně vytvořeny rozdělením jednoho většího. Při porovnání masky a velkých oblastí, které prošly kontrolou, je jasně vidět, že dělba velkých ploch je na místě. Více situaci znázorňuje následující obrázek 6.7, kde je vidět množství detekcí pulzujících oblastí, ale velká oblast, která splňuje podmínky změny je opravdu pouze uprostřed. Osvícená stěna je tedy z větší části v detekci eliminována, což je požadovaná vlastnost detektoru. Malé oblasti nemusíme považovat za chybu, protože oblasti opravdu splňují podmínky. Při sledování bychom pozorovali pulzování intenzity jasu



Obrázek 6.6: Korektní detekce - nahoře maska ohňových barev. Uprostřed vykreslení interních zpracovávaných oblastí. Dole korektní výstup.



Obrázek 6.7: Nalezení oblastí v masce - vykreslení interních oblastí, kde je viditelná účinnost segmentace a ponechání pouze střední části.

na frekvenci hořícího ohně, který tento odraz způsobuje.

Použití pevně daných velkých oblastí

Obrázek 6.8 zobrazuje stejnou scénu jak je na obrázku 6.6. Při vyhodnocení jsou však použity pevně dané velké oblasti (modré čtverce). Tato metoda je náročnější, protože se vždy vypočítávají vlastnosti všech oblastí v obraze. Jsou případy, kdy tento přístup zlepšuje detekci malých plamenů. Jak je však na obrázku vidět, přístup způsobuje značnou segmentaci celkové plochy ohně, protože ne vždy jsou v jednotlivých částech splněny podmínky. Pro další testování bylo prioritně využíváno detekce oblastí z masky ohňových barev.

Tvorba masky


Problém při detekci nastává v případě intenzivního ohně. Zde selhávají barevné modely, které eliminují přepálená místa. Tímto se z ucelených plamenů stává vysoce segmentovaná oblast, u které je detekce ztížena. Při výpočtu intenzity s použitím maskování nastávají rapidní změny a mezery. Situace na obrázku 6.9 je takovým případem. Je vidět, že pro lidské oko ucelená plocha ohně se vlivem zhoršené kvality masky stává množinou oblastí, z nichž některé jsou příliš malé a nejsou dále zpracovávány. Další případ zobrazený na obrázku 6.10 znázorňuje nezachycený oheň, z důvodu špatné masky. Zde je vidět, že detektor zaznamenal vyhledávané změny intenzit v oblasti, kde se opravdu oheň nalézá. Ale nebyly nalezeny žádné relevantní velké oblasti, které by označovali podezřelé místo výskytu ohně.

Efekt rozmazání


Jsou-li oblasti, které obsahují oheň přesvětleny nebo vlivem kamery rozmazány, je detekce ztížena až znemožněna. Obrázek 6.11 odpovídá takovému případu. Můžeme si povšimnout, že oblasti neobsahují výrazné změny sousedních pixelů a oblasti jsou velké plochy příbuzné barvy, která při šedotónovém zpracování nebude vykazovat vysokou hodnotu změn. To



Obrázek 6.8: Pevně daná velikost oblastí - vlevo vykreslení oblastí, kde je názorná segmentace ucelené oblasti ohně. Vpravo výstup detektoru s roztroušenou detekcí.



Obrázek 6.9: Tvorba masky - vlevo zobrazení masky, která je velmi členitá. Vpravo vykreslení interních zpracovávaných oblastí.



Obrázek 6.10: Tvorba masky - vlevo vykreslení masky. Vpravo zpracovávané oblasti, které obsahují pouze malé segmenty.



Obrázek 6.11: Efekt rozmazání - detekované oblasti, které neobsahují žádnou velkou oblast z důvodů malých změn.

způsobí nesplnění podmínek a vyřazení oblastí ze zpracování. Z toho vyplývá, že je nevhodné používat pro předzpracování filtry, které obrazy vyhlazují.

Malý oheň

Detekce pochopitelně také závisí na velikosti ohně. Obrázek 6.12 zobrazuje případ, kdy je zjištěna přítomnost hledaných změn intenzit, ale velké oblasti nebyly z důvodu rozměrů detekovány nebo byly odstraněny, kvůli nedostatečným změnám. Pokud by tato chyba byla fatální, bylo by nezbytné zmenšit minimální velikost hledaných oblastí.

Odolnost a falešné detekce


V případě zdroje videa z nepohyblivé kamery detektor ignoruje stacionární objekty, které mají barvu ohně. Toho je pochopitelně dosaženo použitím pohybové detekce. Více nás tedy zajímají pohybující se oblasti. Obrázek 6.13 ukazuje scénu, u které je nezbytné směřovat pozornost na procházející pořadatele v oranžových vestách. Oba se pohybují směrem doprava. U vzdálenějšího pořadatele je vidět, že jedna malá oblast prošla sérií kontrol, ale nekoresponduje s žádnou existující velkou oblastí. Toto je opět očekávané a žádané chování. Oranžové vesty mají téměř konstantní barvu po celé jejich ploše a jsou eliminovány z důsledku nedostačující hodnoty průměrné odchylky.

Obrázek 6.14 ukazuje, že detekce ohně je v určitých případech možná i za silných povětrnostních podmínek. Zde jsou plameny i s kouřem po celou dobu hoření unášeny větrem vpravo, ale i přes tuto skutečnost bylo rozpoznáno kmitání intenzity malých oblastí a změna oblastí velkých.


Problém nastává v případě existence chaotického pohybu. Obrázek 6.15 a 6.16 zobrazují případ, kdy do scény vchází hasiči. Jejich oblečení není zcela eliminováno barevným rozpoznáním což je jasně vidět na korespondující masce obrázku 6.15. První obrázek zachycuje případ, kdy hasiči vykazují minimální pohyb a velké oblasti byly eliminovány z důvodu nízké hodnoty pohybu v celé oblasti. Posléze je však vidět, že detektor označil větší množství malých oblastí a oblast velkou několikrát po sobě a to se projevilo i na celkovém výstupu detektoru. Z toho vyplývá, že frekvenční analýza oblastí není zcela dostatečná.




Obrázek 6.12: Malý oheň - nahoře nalezené oblasti, které neobsahují žádnou korespondující velkou oblast. Dole originální snímek.



Obrázek 6.13: Vlevo maska, kde je vidět označení vest. Vpravo vykreslení interních zpracovávaných oblastí, kde je jedna skoková detekce malé oblasti, která však nezpůsobí falešnou detekci na výstupu.



Obrázek 6.14: Vlevo vykreslení interních zpracovávaných oblastí. Vpravo korektní výstup i za nepříznivých povětrnostních podmínek.



Obrázek 6.15: Vlevo maska, které zachycuje i oblečení. Vpravo vykreslení interních malých oblastí, které bez korespondující velké oblasti neprodukují detekci.



Obrázek 6.16: Špatná detekce - Vlevo zpracovávané oblasti, které již zahrnují i velkou oblast. Vpravo výstup obsahující falešnou detekci.

6.6 Úspěšnost

Detektor byl otestován v popsané konfiguraci na některých videích, které je možné nalézt na přiloženém DVD. Nebyl proveden test na všech z důvodů rozporuplnosti požadovaného výsledku. Bylo nezbytné rozhodnout jakým způsobem videa vyhodnocovat, protože některá videa obsahují mnoho stříhů a nebo jsou zaznamenána pohyblivou kamerou. Videá, která obsahovala velký pohyb kamery nebyly do testů zahrnuty, protože jejich výsledky by byly naprosto zcestné. Jak z principu návrhu vychází, detektor potřebuje vyhodnocovat oblasti, které jsou fixně dané a prudký pohyb kamery tento přístup zcela naruší. Výsledky detekce by tedy byly náhodné.

Problém se vyskytuje u rozhodnutí, kdy oheň považovat za dostatečný. Malé plamínky jsou z důvodů popsaných v předchozí části nedetekovatelné. Je také nutné zohlednit potřebu detektoru naplnit příslušné paměti pro vyhodnocení v čase. Proto se bude měření odvíjet vždy dvě sekundy⁶ po začátku relevantní části videa nebo stříhu mezi scénami.

Analyzované scény dohromady obsahovaly 25860 snímků. Z toho 19950 snímků obsahovalo oheň a tedy zbývajících 5910 snímků bylo bez ohně. Detektor na výstupu korektně označil aproximovaná místa výskytu ohně u 15575 snímků. Na 236 snímcích bez ohně byly vyznačeny oblasti, které byly detekovány jako oheň, což je chybná detekce.

$$\frac{\text{detekované snímky ohně}}{\text{celkový počet snímků ohně}} * 100\% = \frac{15575}{19950} * 100\% = 78.07\% \quad (6.1)$$

$$\frac{\text{detekované snímky bez ohně}}{\text{celkový počet snímků bez ohně}} * 100\% = \frac{236}{5910} * 100\% = 3.99\% \quad (6.2)$$

$$\frac{\text{správně detekované snímky}}{\text{celkový počet snímků}} * 100\% = \frac{15575 + (5910 - 236)}{25860} * 100\% = 82.19\% \quad (6.3)$$

Z jednoduchého výpočtu 6.1 a 6.2 tedy vychází, že detektor detekoval 78.07% ohně a chybná detekce se vztahovala na 3.99% snímků, ve kterých se oheň nevyskytoval. Z celkového počtu vyhodnocených snímků podle rovnice 6.3 je přesnost detekce 82.18%. V porovnání s metodami, které byly uvedeny v kapitole 2, je tento výsledek neuspokojivý. Nejde

⁶Nastavená hloubka paměti pro sledování pulzování intenzit oblastí odpovídá dvou sekundám záznamu.

však provést objektivní srovnání bez stejných sad shodně anotovaných videí. Snížená přesnost je také daní za univerzálnost detektoru.

6.7 Možnosti přizpůsobení

I když je detektor navržen a nastaven jako univerzální. Je možné změnit jeho nastavení na přísnější nebo mírnější způsoby vyhodnocování. To znamená, že v případě sledování videozáznamu, kde je nezbytné detekovat veškeré podezřelé chování se mohou parametry zvolnit čímž se však zvýší i procento falešných detekcí. Opačná varianta přináší možnost zpřísnění podmínek a tím snížení počtu detekcí s možností rizika chybějících detekcí.

Možnost jednoduché náhrady funkce, která klasifikuje jednotlivé pixely a vytváří masku ohňových barev, dovoluje přizpůsobit detektor na vyhledávání požárů s nestandardní barvou plamenů. Je však nezbytné mít statistický model barev, který je možné vložit do funkcí.

Kapitola 7

Závěr

Po dohodě s vedoucím práce bylo rozhodnuto, že práce bude zaměřena pouze na detekci ohně. Detekce kouře byla kvůli rozdílným technikám přístupu vynechána. Součástí zadání bylo nastudování existujících řešení. Práce byla rozdělena na dvě hlavní části. První část obsahuje výtahy z vybraných prací. V druhé části je pozornost věnována návrhu a implementaci jednoduchého detektoru. Následuje testování a identifikace hlavních problémů včetně návrhu jejich možných řešení.

Vlastní detektor je založen na známých vlastnostech ohně jako je pohyb, frekvence pulzování a barva. Byl navržen s myšlenkou na vytvoření obecného detektoru a vyhnutí se trénovacím procesům, přizpůsobujícím detektor na konkrétní prostředí. Nezbytné bylo pouze stanovit vhodné parametry. Postup vyhodnocení koncepčně vychází z klasifikátoru, který produkuje výstup na základě vyhodnocení spojením výstupů několika slabých klasifikátorů, které zpracovávají různé vlastnosti vzorku. Implementace je zaměřena na přehlednost kódu s možností jednoduchých úprav.

Hlavní nevýhodou použité metody jsou občas se vyskytující chybné detekce, které byly v kapitole věnované testování detailněji rozebrány. Pro jednotlivé druhy chyb byl proveden rozbor a případně navržena možná řešení. Při testování bylo také zjištěno, že úspěšnost použitých metod detekce barev je silně problematická. Některé barevné modely produkuje velké množství falešných detekcí nebo naopak nedetekují určité zabarvení plamenů. Slabým článkem metod založených na časové závislosti a statistickém vyhodnocení plochy je, že vyžadují minimální velikosti ohně.

Budoucí vývoj pro zlepšení přesnosti detekce by mohl obsahovat zlepšení stávajících barevných modelů nebo jejich úplnou náhradu za trénovaný model. Stejně tak vyhodnocení segmentů a oblastí by mohlo být prováděno například Bayesovským klasifikátorem jako je tomu v práci [10]. Prostor se naskýtá i pro přidání dalšího vyhodnocovacího procesu, který by za cenu snížení výkonu zmenšil množství falešných detekcí.

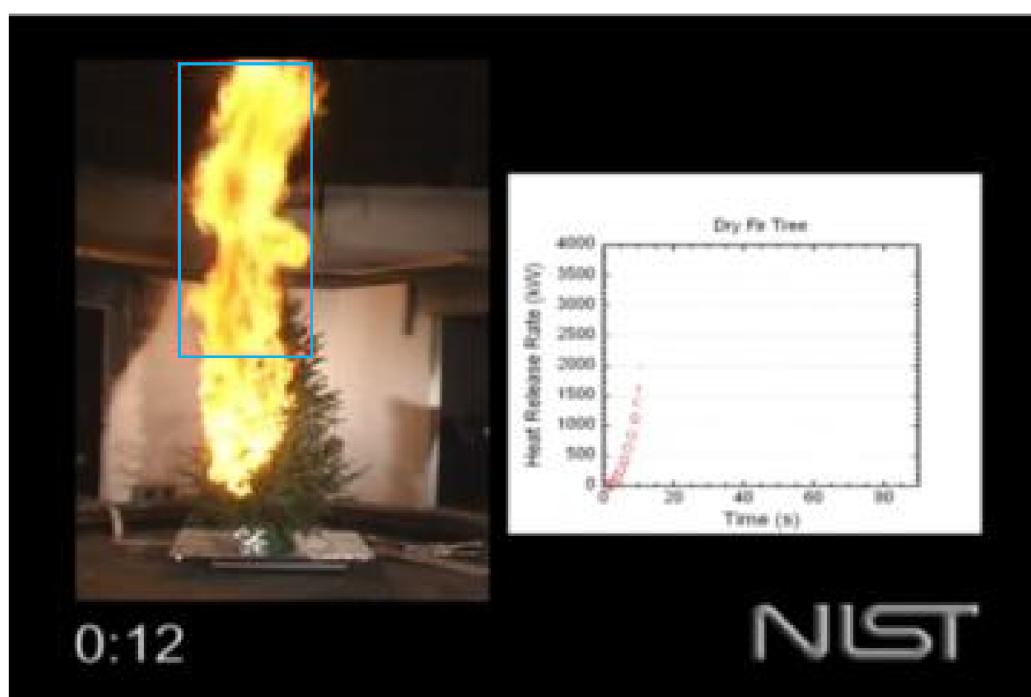
Literatura

- [1] Celik, T.; Demirel, H.; Ozkaramanli, H.; aj.: Fire detection using statistical color model in video sequences. *J. Vis. Comun. Image Represent.*, ročník 18, č. 2, 2007: s. 176–185, ISSN 1047-3203, doi:<http://dx.doi.org/10.1016/j.jvcir.2006.12.003>.
- [2] Celik, T.; Ozkaramanli, H.; Demirel, H.: FIRE AND SMOKE DETECTION WITHOUT SENSORS: IMAGE PROCESSING BASED APPROACH. In *15th European Signal Processing Conference (EUSIPCO 2007)*, September 2007, s. 1794–1798.
- [3] Chadim, P.: Detekce pohybu ve video sekvenci. Brno, bakalářská práce, FIT VUT v Brně, 2008.
- [4] Cui, Y.; Dong, H.; Zhou, E.: An Early Fire Detection Method Based on Smoke Texture Analysis and Discrimination. In *CISP '08: Proceedings of the 2008 Congress on Image and Signal Processing, Vol. 3*, Washington, DC, USA: IEEE Computer Society, 2008, ISBN 978-0-7695-3119-9, s. 95–99, doi:<http://dx.doi.org/10.1109/CISP.2008.397>.
- [5] Gunay, O.; Tasdemir, K.; Töreyn, B. U.; aj.: Fire Detection in Video Using LMS Based Active Learning. *Fire Technology*, 2009, ISSN 0015-2684 (Print), 1572-8099 (Online), doi:10.1007/s10694-009-0106-8.
- [6] Huang, P.-H.; Su, J.-Y.; Lu, Z.-M.; aj.: A Fire-Alarming Method Based on Video Processing. *Intelligent Information Hiding and Multimedia Signal Processing, International Conference on*, ročník 0, 2006: s. 359–364, doi:<http://doi.ieeecomputersociety.org/10.1109/IIH-MSP.2006.12>.
- [7] Jie, L.; Jiang, X.: Forest fire detection based on video multi-feature fusion. *Computer Science and Information Technology, International Conference on*, ročník 0, 2009: s. 19–22, doi:<http://doi.ieeecomputersociety.org/10.1109/ICCSIT.2009.5234862>.
- [8] Lee1, B.; Han, D.: Real-Time Fire Detection Using Camera Sequence Image in Tunnel Environment. *Advanced Intelligent Computing Theories and Applications. With Aspects of Theoretical and Methodological Issues*, ročník Volume 4681/2007, 2007: s. 1209–1220, doi:10.1007/978-3-540-74171-8_123.
- [9] Liu, C.-B.; Ahuja, N.: Vision Based Fire Detection. In *ICPR '04: Proceedings of the Pattern Recognition, 17th International Conference on (ICPR'04) Volume 4*, Washington, DC, USA: IEEE Computer Society, 2004, ISBN 0-7695-2128-2, s. 134–137, doi:<http://dx.doi.org/10.1109/ICPR.2004.979>.

- [10] Paulo Vinicius Koerich Borges, E. I., Joceli Mayer: EFFICIENT VISUAL FIRE DETECTION APPLIED FOR VIDEO RETRIEVAL. In *16th European Signal Processing Conference (EUSIPCO 2008)*, Lausanne, Switzerland: EURASIP, 2008.
- [11] Tipsuwanporn, V.; Krongratana, V.; Gulpanich, S.; aj.: Fire detection using neural network. *SICE-ICASE International Joint Conference*, ročník 0, 2006: s. 5474–5477, doi:<http://doi.ieeecomputersociety.org/10.1109/SICE.2006.315606>.
- [12] Töreyn, B. U.; Dedeoğlu, Y.; Gündükbay, U.; aj.: Computer vision based method for real-time fire and flame detection. *Pattern Recogn. Lett.*, ročník 27, č. 1, 2006: s. 49–58, ISSN 0167-8655, doi:<http://dx.doi.org/10.1016/j.patrec.2005.06.015>.
- [13] Wang, S.-J.; Jeng, D.-L.; Tsai, M.-T.: Early fire detection method in video for vessels. *Journal of Systems and Software*, ročník 82, č. 4, 2009: s. 656 – 667, ISSN 0164-1212, doi:DOI:10.1016/j.jss.2008.09.025, special Issue: Selected papers from the 2008 IEEE Conference on Software Engineering Education and Training (CSEET08). URL <http://www.sciencedirect.com/science/article/B6V0N-4TK476K-1/2/1d0acbdfef4104e8bd38ba95f709b74>
- [14] Xiong, Z.; Caballero, R. E.; Wang, H.; aj.: Video Fire Detection - Techniques and Applications in the Fire Industry. *Signals and Communication Technology*, 2009: s. 1–13, ISSN 1860-4862, doi:10.1007/978-0-387-76569-3.
- [15] Zhang, D.; Han, S.; Zhao, J.; aj.: Image Based Forest Fire Detection Using Dynamic Characteristics with Artificial Neural Networks. *Artificial Intelligence, International Joint Conference on*, ročník 0, 2009: s. 290–293, doi:<http://doi.ieeecomputersociety.org/10.1109/JCAI.2009.79>.

Dodatek A

Výsledky detekcí



Obrázek A.1: Detekce ve videu, které bylo pořízeno jak součást experimentu sledování hoření suchého stromu.



Obrázek A.2: Detekce ve videu ze studie požáru zaviněného suchým stromkem.



Obrázek A.3: Detekce ve videu ze studie požáru zaviněného suchým stromkem. V pokročilé fázi.



Obrázek A.4: Detekce ve videu, kde požár vznikl vznícením pohovky (např. nedopalek cigarety).



Obrázek A.5: Detekce ve videu, kde rozsáhlý oheň proniká dveřmi.



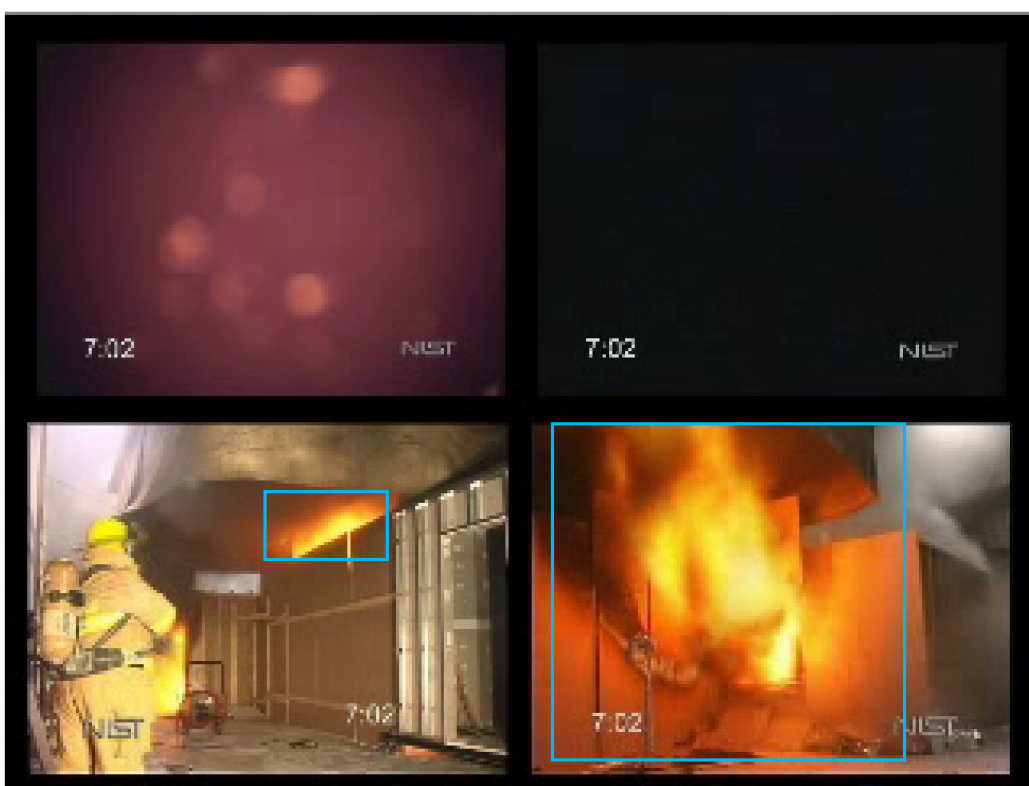
Obrázek A.6: Detekce ve videu, které zachycuje hořící stromek viditelný přes otevřené dveře.



Obrázek A.7: Detekce ve videu, které zachycuje hořící stromek viditelný přes otevřené dveře. Pokročilé stádium.



Obrázek A.8: Detekce při zpracování výstupu více kamer.



Obrázek A.9: Detekce při zpracování výstupu více kamer. Za přítomnosti hasičů.



Obrázek A.10: Detekce ve videu hořícího auta.



Obrázek A.11: Detekce ve videu řízeného podpalu lesa.



Obrázek A.12: Detekce ve videu pokročilého stádia hoření lesa.



Obrázek A.13: Detekce ve videu, které z dálky zachycuje lesní požár.

Dodatek B

Ovládání

Aplikace se spouští s jedním parametrem, kterým je cesta ke zdrojovému souboru videa.
`fireddetection.exe „název videosouboru“`

Zpracovávají jsou klávesy

r, R – spustí běh videa od začátku

s, S – posune video o jednu sekundu vpřed (lze držet jako přetáčení)

p, P – pozastaví zpracování

q, Q – ukončí zpracování

– – zvýší prodlevu zpracování mezi jednotlivými snímky (projeví se zpomalením běhu videa)

+ – sníží prodlevu zpracování mezi jednotlivými snímky (pokud to rychlost zpracování dovolí, projeví se zrychlením běhu videa)

Dodatek C

Obsah CD

Dokumentace

- `doc/xhavel25.pdf` – soubor obsahující dokumentaci
- `doc/dp_tex.zip` – zdrojové kódy pro L^AT_EX s obrázky

Zdrojové kódy aplikace

- `app/src` – adresář obsahuje projekt aplikace pro Visual Studio 2008

Knihovny

- `lib` – adresář obsahuje knihovny použité v aplikaci

Videa

- `movies` – adresář obsahuje původní verze videí, které byly použity (z důvodu nadměrné velikosti nebyly přiloženy nekomprimované a upravené verze)

Studijní texty

- `text` – adresář obsahuje kopie textů, ze kterých práce čerpala