

# **Algoritmus pro rychlou detekci ohně v obrazovém toku**

Ing. Peter Janků, Ph.D.

Teze disertační práce



# Univerzita Tomáše Bati ve Zlíně

## Fakulta aplikované informatiky

Teze disertační práce

### Algoritmus pro rychlou detekci ohně v obrazovém toku

### Algorithm for Fast Fire Detection in Video Stream

Autor: **Ing. Peter Janků, Ph.D.**

Studijní program: Inženýrská informatika

Studijní obor: Inženýrská informatika

Školitel: doc. Ing. Bronislav Chramcov, Ph.D.

Oponenti: prof. Dr. Ing. Pavel Zemčík  
prof. Ing. Petr Dostál, CSc.  
doc. Mgr. Milan Adámek, Ph.D.

Zlín, prosinec 2019

© Peter Janků

Vydala **Univerzita Tomáše Bati ve Zlíně** v edici **Doctoral Thesis Summary** v roce 2019.

Klíčová slova: *detekce ohně, počítačové vidění, sensorové systémy, inteligentní senzory, neuronové sítě, vyčlenění markantů*

Key words: *fire detection, computer vision, sensor systems, smart sensors, neural networks, feature extraction*

Plná verze dizertační práce je dostupná v Knihovně UTB ve Zlíně.

ISBN 978-80-7454-886-4

# ABSTRAKT

Tato disertační práce se zabývá algoritmy pro detekci ohně v obrazovém toku. Při požáru nebo při krizové události způsobené hořením je vždy velké riziko vzniku škod na zdraví a majetku osob. Principy funkce u standardně používaných detektorů ohně vykazují určitá omezení, kvůli kterým je možnost jejich použití v několika specifických prostředích omezená. Například v průmyslových areálech se mohou nacházet procesy podobné hoření nebo procesy, ve kterých je hoření jejich přímou součástí. Přestože vývoj algoritmů detekce ohně za pomoci počítačového vidění je velmi dobře publikován, vhodný algoritmus pro detekci ohně v obrazovém toku v reálném čase stále chybí. Tato práce se zaměřila na vývoj nového algoritmu založeného na počítačovém vidění, který je vhodný pro detekci ohně s využitím standardních bezpečnostních kamer. Výsledkem je návrh nového algoritmu schopného detekovat oheň s využitím jednoduché neuronové sítě a extrakce markantů v čase. Speciální pozornost při vývoji byla věnována výpočetní náročnosti algoritmu a dosažené přesnosti detekce.

# ABSTRACT

This thesis deals with algorithms of fire detection in a video stream. Each unmanaged fire or emergency event caused by the fire has a significant potential to inflict extensive damage on a property or human lives. Moreover, widely used standard fire detectors have some principle limitations, and therefore their usage is restricted in specific scenarios. Especially in industrial areas, processes similar to combustion or processes containing combustion can be found. Even if the development of the fire-detection computer vision algorithms is well-published, there are no suitable algorithms for fire-detection in the video stream in real-time. This thesis is aimed to develop a new computer vision algorithm which is suitable for fire detection by using standard surveillance camera. The main result is a new algorithm specification suitable for fire detection in video stream by using simple feed-forward neural network and feature extraction. The special attention is devoted to decrease the computational complexity and improve the reliability of detection.

# OBSAH

1	ÚVOD	4
2	SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY	5
2.1	Detekce kouře	6
2.2	Možnosti vyhodnocení barev v obraze	7
2.3	Detekce pohybu v obraze	7
2.4	Další možné přístupy	9
2.5	Neuronové sítě a softcomputing	10
3	CÍLE PRÁCE	10
4	ZVOLENÉ METODY ZPRACOVÁNÍ	11
4.1	Použité technologie	11
4.2	Architektura algoritmu	11
4.3	Detekce podezřelých oblastí	14
4.4	Zpracování markantů	16
4.5	Ověření výsledků	21
5	ZHODNOCENÍ CÍLŮ PRÁCE	23
6	HLAVNÍ VÝSLEDKY PRÁCE	24
7	PŘÍNOS PRÁCE PRO VĚDU A PRAXI	25
8	ZÁVĚR	26
	POUŽITÁ LITERATURA A ZDROJE	29
	PUBLIKAČNÍ AKTIVITY AUTORA	34
	SEZNAM OBRÁZKŮ	37
	SEZNAM TABULEK	38
	SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK	39

# 1 ÚVOD

Tématem disertační práce bylo sestavení kontextově senzitivního sensorového systému. Kontextově senzitivní sensorový systém lze v obecné rovině chápat jako systém, který svou činnost nepodmiňuje konkrétními podmínkami. Takový systém se na zkoumaný objekt dívá jako na soustavu dějů - událostí, které jsou na sobě příčinně závislé a jako takové je vyhodnocuje.

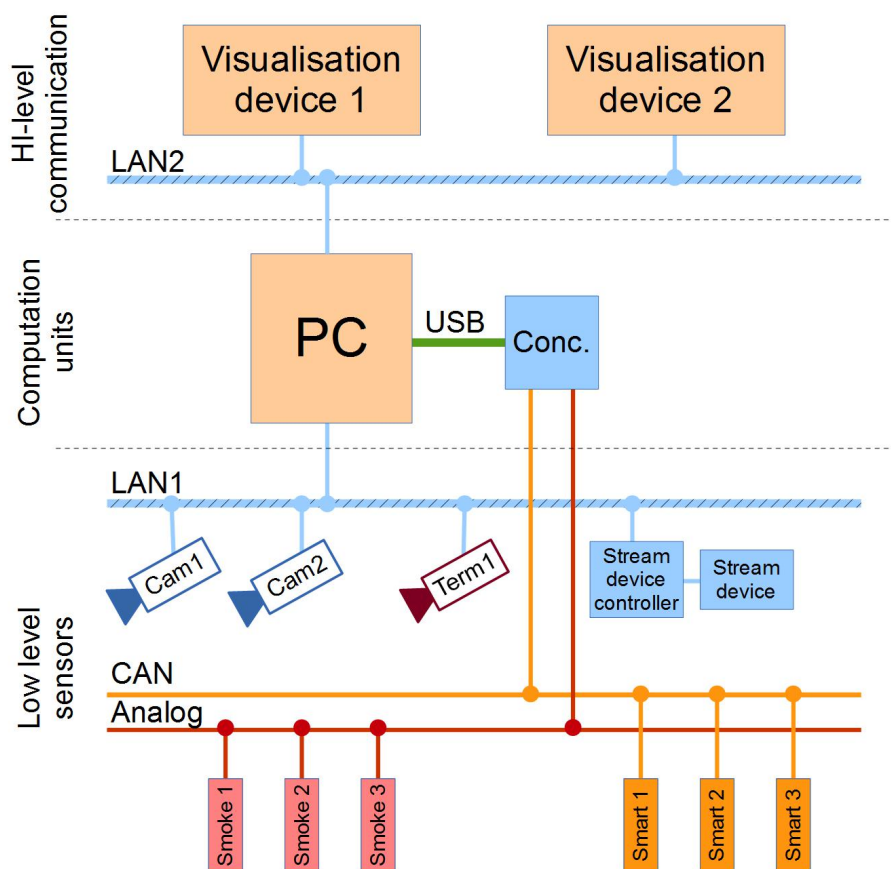
Jako kontextově senzitivní lze pojmut i systémy protipožární ochrany. Například v některých průmyslových prostorech je velmi těžké rozlišit jednotlivé projevy požáru od projevů dějů, které jsou součástí běžného výrobního procesu např. svařování. V uvedených provozech je někdy nemožné instalací konvenčních separátních sensorů řešit detekci požáru s dostatečnou kvalitou.

V počátku práce na tomto tématu byla navrhnutá architektura kontextově sensorového systému pro detekci požáru, který pro svou funkci využíval sadu různých sensorů a detekčních metod. Jeho podoba je zobrazena na obr. 1.1. Při hlubším studiu dané problematiky bylo zjištěno, že i přes intenzivní vývoj v oblasti zpracování obrazu nejsou dostupné vhodné algoritmy/zařízení, které by bylo možné využít pro detekci požáru v obraze. Veškeré dostupné algoritmy byly limitovány jednak výpočetním výkonem a také omezenou použitelností vzhledem k okolním podmínkám. Díky tomu jejich použití v rozsáhlejších systémech bylo značně problematické. Z tohoto důvodu se zbývající část práce zaměřila právě na algoritmy pro detekci ohně v obrazovém toku.

Samotnou detekci požáru v obraze lze s výhodou pojmut jako kontextově senzitivní systém. V naprosté většině případů se plameny požáru odlišují od okolního prostředí svou barvou a svým pohybem - v rámci kontextu daného prostředí jsou rozeznatelné. Mimo to z pohledu časové osy je detekce požáru v obraze typická tím, že se většinou jedná o kontinuální děj nabírající na intenzitě.

Oblast zpracování obrazu a počítačového vidění má i svá specifická omezení. Tato omezení primárně plynou z velkého množství zpracovávaných dat a množství nesené informace. Sestavování algoritmů pro počítačové vidění dále ztěžují velmi rozdílné vlastnosti získávaných obrazů. Díky tomu, že téměř každá kamera je specifická svým rozlišením, obrazovou kvalitou, citlivostí a pod., je současně s množstvím různých snímaných prostředí velmi obtížné sestavit uni-

versální algoritmus pracující s vysokou mírou úspěšnosti za všech okolností.



Obr. 1.1 Návrh architektury kontextově senzitivního protipožárního systému

## 2 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY

S rostoucím výkonem počítačů a klesající cenou digitálních kamer se značným způsobem rozšiřuje výzkum v oblasti detekce ohně v obraze. Daný trend ilustruje mimo jiné počet článků publikovaných v uznávané databázi IEEE. Například pro klíčová slova *"fire detection computer vision"* tato databáze vrátí přibližně 200 výsledků, z čehož jednu třetinu tvoří články publikované v posledních 4 letech. Obdobná situace je v databázích Scopus a Web Of Science. Tyto databáze jsou velmi často propojeny a je tedy možné totožné publikace nalézt ve více databázích.

Doposud zveřejněné vědecké články využívají velké škály různých přístupů a metod. Některé popisují metody pro detekci kouře v obraze [29], jiné využívají možností hlubokých neuronových sítí [9, 5] a nebo jednodušších rozhodovacích mechanismů na základě pohybu [28, 7]. V následujících kapitolách je uveden základní nikoliv však vyčerpávající přehled doposud publikovaných metod a přístupů.

Oheň jako fyzikální jev generuje sadu vnějších projevů. Tyto projevy jsou buď projevy přímo viditelné - např. světlo, kouř, nebo projevy přímo neviditelné - např. teplo, některé zplodiny hoření a podobně. Z pohledu počítačového vidění se lze zabývat pouze projevy, které lze zaznamenat běžnou nebo speciální digitální kamerou (např. termokamerou). Vzhledem k zaměření této práce je nutné detekované projevy limitovat pouze na ty, které jsou viditelné běžnou digitální kamerou. Mezi tyto bez pochyby patří světlo (plamen) a kouř (viditelné zplodiny hoření).

## 2.1 Detekce kouře


Jedna z oblastí počítačového vidění se zabývá detekcí kouře, nebo detekcí ohně na základě detekce kouře. Tyto přístupy vychází z představy, že kouř jako takový je projevem hoření a tudíž velmi často i jeho přímým důsledkem. Stejně jako oblast detekce ohně v obraze je i oblast detekce kouře v obraze velmi progresivní, což lze doložit velkým množstvím odborných publikací ve vědeckých databázích.

Zásadní problém a limitace detekce požáru pomocí kouře ale spočívá ve skutečnosti, že kouř může být např. v průmyslových prostředích důsledkem i jiných dějů - nejen hoření. Typickým příkladem je proces svařování. Jen na základě kouře velmi obtížné rozlišit, jde-li o výsledek žádaného nebo nežádoucího procesu.

K detekci kouře je možné využít velmi podobné přístupy, které se používají pro detekci ohně v obraze. Příkladem mohou být algoritmy založené na principu sledování množství energie v popředí a pozadí, sledování tvaru kouře a jeho změny a také sledování úrovně rozostření pozadí. [29]

Na obrázku 2.1 jsou zobrazeny výsledky algoritmu založeného na zpracování obrazu v blocích s využitím detekce barev a detekce míry a směru pohybu. [6].





Obr. 2.1 Postup detekce ohně. a) originální snímek, b) výsledek detekce pohybu, c) výsledek detekce barvy, d) kombinace předchozích parametrů. [6]

## 2.2 Možnosti vyhodnocení barev v obraze

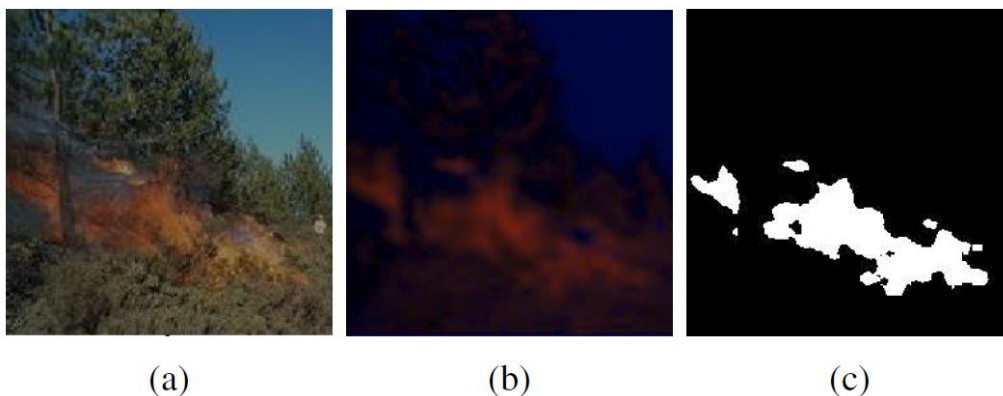
Doposud publikované algoritmy pro detekci ohně v obraze z velké části využívají jako jeden z kroků (někdy i hlavní krok) analýzu barevného spektra obrazu. Tyto algoritmy vycházejí z předpokladu, že za běžných okolností dosahuje plamen ohně barvy v rozsahu od bílé přes žlutou, oranžovou až po tmavší červenou. Cílem je tedy vybrat z daného obrazu pouze tyto barvy a jiné eliminovat. Další možností je analyzovat disperzi, rozptyl, intenzitu nebo rozložení barev v rámci obrazu, jak uvádí ve svém článku např. Wang a kolektiv [32].

Pro analýzu barev v obraze je možné využít velkou škálu barevných prostorů. Za základní barevný model využívaný v oblasti počítačového vidění je možné považovat aditivní barevný model RGB. Každá barva v rámci tohoto modelu je složena ze tří barevných složek (červená, zelená, modrá), které se navzájem sčítají. Na jednotlivé barevné složky lze poté aplikovat různá pravidla [1, 32].

Kromě základního barevného modelu RGB využívají publikované studie i další modely. Mezi tyto patří YUV[18], YCbCr[35], HSV[30]. Mimo zmíněných standardních barevných prostorů lze k detekci ohně využít i barevné prostory, které jsou přímo za tímto účelem vyvinuté [14]. Příklad aplikace takového cíleně vyvinutého barevného prostoru je na obrázku 2.2.

## 2.3 Detekce pohybu v obraze

Dalším běžným krokem v již publikovaných algoritmech je detekce nebo přímo analýza pohybu v obraze. Tento přístup vychází z předpokladu, že plameny ohně nejsou statickým prvkem, ale v čase se vyvíjejí a tím generují typický



Obr. 2.2 Aplikace barevného prostoru FCS na obrázek. a) originální obraz, b) FCS barevný prostor, c) FCS barevný prostor po aplikaci Otsu. [14]

pohyb, který z velké části směřuje nahoru.

Algoritmy založené na zpracování pohybu vycházejí z několika základních principů. První přístup vychází z výpočtu vektoru pohybu dílčích částí obrazu - makrobloků[6]. Autoři zpracovávají obraz v makroblocích. U každého makrobloku analyzují jeho pohyb v čase. Získají tím dva pohybové vektory - pro osu  $x$  a  $y$ . Na základě obdržných vektorů následně určí rozsah pohybu a směr, což jim slouží jako jedno ze základních rozhodovacích pravidel [6].

Velmi často publikovaný princip detekce je založený na principu určení optického toku (optical flow) v obraze [7], který může spočívat v jednoduché analýze směru nebo také v různých principech statistického zpracování [33, 18]. Na obrázku 2.3 jsou znázorněny výsledné získané pohybové vektory pro bloky 5x5 pixelů.



Obr. 2.3 Dynamická textura ohně s vyznačenými vektory optického toku (optical flow) [33]

Kromě zpracování vektorů optického toku využívají některé publikované algoritmy metod frekvenční analýzy, konkrétně vlnkové transformace. Jako vstupem pro tuto transformaci slouží vektory vycházející ze změny intenzity jednotlivých pixelů nebo například změnou intenzity konkrétních složek barevného modelu RGB [28]. Součástí zpracování pohybu za pomoci vlnkové transformace může být v některých případech i předzpracování obrazu v podobě detekce popředí a pozadí, nebo také predikce pohybu některých částí obrazu [35]. V neposlední řadě se publikované algoritmy zabývají oscilací intenzity v rámci jednotlivých pixelů ohně, kdy metoda detekce vychází z předpokladu vysokých frekvencí v případě pixelů náležícím ohni [30].

Jinou možností, jak využít analýzu pohybu v obraze, je zaměřit se na změnu a chování kontur plamene [32]. Další možné metody pro detekci ohně využívají zpracování pouze modré složky obrazu [13], zpracování pohybu pomocí GMM (Gaussian mixture model) [8] a nebo jednoduchého průměrování rozdílů následujících snímků a jasů okolních pixelů [22].

## 2.4 Další možné přístupy

Mimo přístupů uvedených v předchozích kapitolách lze v publikovaných článcích nalézt různorodé metody detekce ohně. Přístup zabývající se tvarem kontury plamene publikovali Zainab Suleiman Abdullahi a kolektiv [1]. K detekci ohně je možné také využít kromě standardních kamerových systémů i stereovizní kamery [16], kdy stereovize pomáhá mimo detekci i k lokaci detekovaného plamene.

Součástí detekce ohně mohou být také různé úrovně kombinace detekce ohně v obraze společně s použitím dalších snímacích technologií např. spektroskopie [24]. Mezi publikovanými vědeckými pracemi lze nalézt i takové, které se zaměřují na implementaci detekce ohně za použití integrovaných zařízení postavených na Digital Signal Processing (DSP) [36]. Vzhledem k tomu, že oblast protipožární ochrany je velmi důležitá, probíhá vývoj nejen v rámci detekce ohně v obraze, ale také za využití nových materiálů a nových detektorů na fyzikální bázi [34].

## 2.5 Neuronové sítě a softcomputing

Další velká část doposud publikovaných algoritmů využívá jako jeden z kroků detekce nebo přímo jako základní princip detekce neuronové sítě, konvoluční neuronové sítě a principy hlubokého učení. Obecně lze aplikaci těchto softcomputingových metod rozdělit do dvou základních přístupů.

První z nich spočívá ve vydefinování a nalezení jednoznačných specifických znaků v obraze (dále jen markantů). Výsledný algoritmus může být tvořen klasickou dopřednou neuronovou sítí, metodou podpůrných vektorů (Support Vector Machines - SVM) a podobnými technikami [19, 2, 23, 12, 11, 4].

Druhý přístup využívá konvoluční neuronové sítě a metody hlubokého učení. V obou případech není nutné vyhledávat speciální markanty v obraze, ale jako vstup do dané metody slouží celý zpracovávaný obraz [5, 26, 10, 9, 37, 20].

## 3 CÍLE PRÁCE

Základním cílem disertační práce je vyvinout kontextově senzitivní sensorový systém v podobě algoritmu pro detekci ohně v obraze, který bude umožňovat brzkou detekci požáru za použití standardních průmyslových kamerových systémů. Vzhledem k plánované oblasti použití je zvláštní pozornost věnována výpočetní náročnosti algoritmu tak, aby detekce mohla probíhat v několika obrazových proudech současně. Oproti konvenčním požárním detektorům bude systém umožňovat detekci požáru i v průmyslových prostorech a tam, kde se běžně nacházejí procesy podobné hoření.

K dosažení hlavního cíle disertační práce jsou definovány následující dílčí cíle:

- rešerše stávajících metod a řešení pro detekci ohně s využitím zpracování obrazu
- návrh a ověření nového algoritmu pro detekci požáru v obrazovém toku
- integrace algoritmu do podoby výsledné aplikace/knihovny vhodné pro reálné nasazení

## 4 ZVOLENÉ METODY ZPRACOVÁNÍ

Jak již bylo zmíněno dříve, hlavní částí této práce je sestavit algoritmus pro detekci ohně v obraze, který by za dosažení dostatečné úrovně kvality detekce byl schopný detekovat oheň v různých videích. Důraz je tedy kladen nejen na spolehlivost detekce, ale také na výpočetní náročnost celého algoritmu. V jeho reálném nasazení tedy nepůjde o nahrazení konvenčních protipožárních zařízení, ale o doplnění stávajících kamerových systémů o možnost detekce požáru.

V následujících kapitolách jsou popsány jednotlivé kroky algoritmu a popis detekce požáru. Některé kroky jsou převzaty z již publikovaných studií, rozšířeny nebo doplněny o další činnosti. Některé části algoritmu jsou navrženy nově a následně ověřeny v ukázkové implementaci. Princip navržené detekce vychází ze snahy najít ve video-obraze plameny požáru a tyto jednoznačně označit a to se zaměřením na pohyb plamenů v čase.

### 4.1 Použité technologie

Pro ukázkovou a testovací implementaci algoritmu byl využit programovací jazyk C++ ve standardu c++11. Společně s ním tvořili základ aplikace dvě komplexní knihovny. Základem pro zpracování, ukládání a manipulaci s obrazovými daty je knihovna OpenCV ve verzi 3.xx. Jako další stavební prvek byla využita knihovna Qt 5. Jedná se o multiplatformní knihovnu pro jazyk C++, která zapouzdřuje velkou sadu běžných operací. Poslední použitou knihovnou je knihovna FFTW, která zapouzdřuje výpočet Diskrétní Fourierovy transformace.

### 4.2 Architektura algoritmu

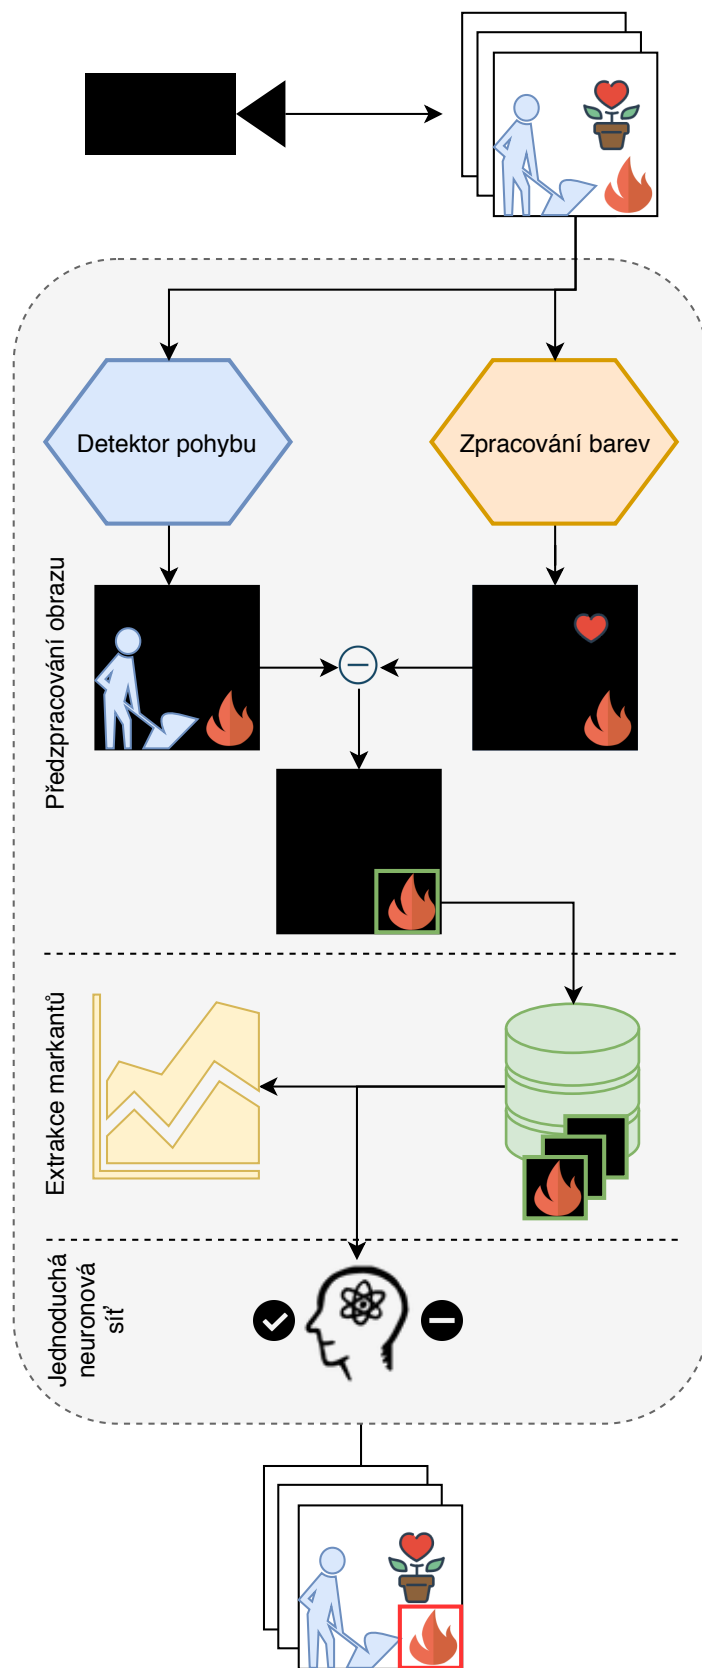
Algoritmus byl navržen jako klasický sekvenční postup, který jako vstup přebírá časovou posloupnost obrazových snímků  $F = (F_1, F_2, \dots, F_n, \dots, F_N)$  o jednoznačně definované frekvenci v rozmezí 25 - 30 snímků za sekundu. Zdrojem těchto snímků může být obrazový tok vysílaný přímo z kamery nebo získaný načtením ze souboru. Algoritmus tyto snímky postupně v daném pořadí zpracovává jeden po druhém aplikováním jednotlivých sekvenčních kroků. Ar-

chitektura algoritmu je znázorněna na obrázku 4.1. Jak je z tohoto diagramu zřejmé, zpracování každého snímku probíhá ve třech základních fázích.

V první fázi algoritmu probíhá předzpracování obrazových dat. Součástí tohoto předzpracování jsou detektory pohybu a detektor barev. Cílem detekce pohybu je snaha nalézt v po sobě jdoucích obrazových snímcích pohybující se části. Toto vychází z předpokladu, že oheň je děj dynamický a jeho sledovaný projev - plamen se neustále pohybuje. Detekce barev následně vyhledává oblasti v obraze, které svým barevným podáním odpovídají nejčastějším barvám plamenů. Výsledkem části předzpracování je bitová maska, která reprezentuje podezřelé oblasti, ve kterých by se mohl nacházet plamen.

Druhá fáze algoritmu si klade za cíl z podezřelých oblastí vyextrahovat markanty, které by bylo možné zpracovat jednoduchou dopřednou neuronovou sítí. Postupuje tak, že jednotlivé podezřelé oblasti na základě pevně daných pravidel sjednotí a jako sjednocené sleduje jejich vývoj v čase. Na takto získané časové posloupnosti následně aplikuje statistické metody, jejichž výstup využívá jako charakteristické markanty pro vyhodnocení neuronové sítě.

Poslední fáze algoritmu využívá jednoduchou dopřednou neuronovou síť, jejímž vstupem je vektor předem získaných markantů. Výstupem je pak rozhodnutí, zda daná podezřelá oblast obsahuje plameny nebo ne. Na základě tohoto rozhodování je možné vykreslit do původního obrazového toku informaci o výsledku detekce a upozornit tak obsluhu na nebezpečí požáru. Jak je uvedeno dále, učení této neuronové sítě probíhalo na sadě různých videí, kdy při výběru byl kladen důraz na různorodost a také na nalezení objektů podobných plamenům, které však s hořením nesouvisí (tančící lidi v oranžových barvách, západ slunce, pohybující se vozidla aj.).



Obr. 4.1 Struktura algoritmu

### 4.3 Detekce podezřelých oblastí

První fází detekce plamenů je předzpracování obrazu za účelem výběru podezřelých oblastí. Podezřelou oblastí se pro účely tohoto algoritmu uvažuje jednoznačně určená obdélníková plocha, ve které je zvýšená pravděpodobnost výskytu plamenů.

Celá fáze předzpracování začíná konverzí barevného prostoru obrazového snímku. Původní barevný model je převeden do barevného modelu HSL, který byl experimentálně určen jako nejvhodnější pro další zpracování. Barva obrazového bodu v rámci barevného modelu HSL je definována třemi složkami H - hue - odstín, S - saturation - sytost a L - lightness - světlost barvy. K tomuto účelu je využita vestavěná funkce knihovny OpenCV [21].

Takto zkonvertovaná posloupnost obrazových snímků  $F$  je následně v rámci fáze předzpracování zkoumána za účelem detekce pohybu a detekce barev odpovídajících plamenům.

#### Detekce pohybu v obraze

Krok algoritmu spočívající v detekci pohybu vychází z předpokladu, že hoření je dynamický děj. Tato dynamika se projevuje jednak změnou velikosti oblasti zasažené plameny, ale také změnou barevné struktury jednotlivých ploch plamenů. Z pohledu počítačového vidění, je možné detekci pohybu provádět různými metodami. Pro potřeby popisovaného algoritmu byla vybrána jednoduchá metoda detekce pohybu, která využívá rozdílů po sobě jdoucích obrazových snímků.

$$F_n = \begin{pmatrix} p_n^c(0, 0) & \dots & p_n^c(w, 0) \\ \vdots & \ddots & \vdots \\ p_n^c(0, h) & \dots & p_n^c(w, h) \end{pmatrix} \quad (4.1)$$
$$p_n^c(x, y) = \{H, S, L\}$$

Mějme snímek  $F_n$ , který je složený z pixelů  $p_n^c(x, y)$ , kdy  $n$  je pořadí snímku v obrazovém toku a  $c$  značí originální barevný pixel. Jednotlivé pixely tohoto výchozího snímku jsou zastoupeny složkami barevného modelu HSL. Tato matice je znázorněna rovnicí (4.1).



Tento snímek je po jednotlivých pixelech převeden do monochromatického provedení. Monochromatické snímky jsou následně ukládány a porovnávány. Za účelem redukce vlivu obrazového šumu popisovaný algoritmus využívá více po sobě jdoucích snímků. Jejich počet reprezentuje konstanta  $n\_max$ . Pro každý pixel je spočítána absolutní diference mezi všemi po sobě jdoucími snímky v dané posloupnosti. Pokud není k dispozici dostatečné množství snímků (v brzkých fázích algoritmu), jsou čísla v této masce nahrazena 0. Konečný výsledek detekce pohybu je poté tvořen maskou  $M_n^M$ , kdy každému bodu masky  $m_n(x, y)$  je přiřazena hodnota 0 resp. 255 podle toho, jestli je absolutní hodnota po sobě jdoucích snímků vyšší než předem definovaný práh.

### Zpracování barev v obraze

Souběžně s detekcí pohybu je každý obrazový snímek zpracováván za účelem detekce barev odpovídajících plamenům. Zdrojový snímek reprezentovaný barevným modelem HSL je rozložen do tří dílčích snímků dle jednotlivých složek a následně zpracováván po pixelech. Výsledkem této operace je maska  $M_n^C$  kde  $n$  značí pořadí snímku v sekvenci. Každý prvek masky  $m_n = (x, y)$  je nastaven na hodnotu 0 nebo 255 podle toho, jestli jednotlivé složky zdrojového snímku na dané pozici odpovídají předem definovaným prahům.

### Aplikace maskování a vyhledávání podezřelých oblastí

Výsledkem zpracování barev v obraze je maska  $M_n^C$  a pro zpracování pohybu maska  $M_n^M$ . Obě masky jsou matice reprezentující jednoznačnou hodnotu pro konkrétní pixel obrazového snímku a to v rozsahu 0 - 255. Jak je patrné z pravidel tvorby těchto matic, ve skutečnosti každý prvek této matice může nabývat pouze hodnoty 0 nebo 255. Ve výsledku se tedy jedná o binární masky, které jsou v dalším kroku sjednoceny pomocí operace průniku, čímž vznikne výsledná maska  $M_n$ , matematicky vyjádřena ve tvaru (4.2).

$$M_n = M_n^M \cap M_n^C \quad (4.2)$$

Tato výsledná maska je pak aplikována na odpovídající obrazový snímek. Výsledný snímek obsahuje černou barvu (hodnoty 0) v místech, kde aplikovaná

maska obsahovala hodnoty 0 a originální barevnou informaci v místech, kde aplikovaná maska obsahovala hodnoty 255. Popis vzniku výsledného snímku je znázorněn v rovnicích (4.3)

$$F_n^M = \begin{pmatrix} p_n^M(0,0) & \dots & p_n^M(w,0) \\ \vdots & \ddots & \vdots \\ p_n^M(0,h) & \dots & p_n^M(w,h) \end{pmatrix} \quad (4.3)$$

$$p_n^M(x,y) = \begin{cases} p_n(x,y), & \text{if } m_n(x,y) \\ 0, & \text{jinak} \end{cases}$$

V takto upraveném snímku probíhá hledání oblastí, ve kterých zůstala barevná informace - tzv. blobů [27]. Tato místa lze označit za místa podezřelá, tedy místa, kde je velká pravděpodobnost výskytu plamene. Pro každý takovýto blob je nalezena submatice originálního snímku  $F_{n,k}$ , kde  $k$  znamená pořadí submatice nalezené v rámci snímku  $n$ . V závěrečném kroku této fáze předzpracování jsou vzniklé submatice redukovány na základě velikosti a polohy.

#### 4.4 Zpracování markantů

První fáze algoritmu zpracovávala posloupnost obrazových snímků  $F$  a tuto pomocí jednotlivých kroků transformovala v posloupnost různě velikých fragmentů těchto snímků. Výsledné fragmenty označila za podezřelé oblasti, ve kterých je zvýšená pravděpodobnost výskytu plamenů. Toto předzpracování samo o sobě nedosahuje dostatečné přesnosti detekce požáru. Z tohoto důvodu jsou podezřelé oblasti zpracovávány za účelem přesnější detekce požáru.

#### Sestavení historie podezřelých oblastí

Jak bylo popsáno v předchozí kapitole, výsledkem fáze předzpracování je pro každý obrazový snímek  $F_n$  sada submatic  $F_{n,k}$ , kde  $n$  znamená pořadí snímku v obrazovém toku a  $k$  pořadí submatice detekované v daném snímku. Z principu detekce je zřejmé, že každá takto předzpracovaná matice může nabývat různých rozměrů, které se navíc z důvodu náhodného pohybu plamenů mohou v průběhu obrazového toku měnit.

Z časového hlediska se v krátkodobé historii plameny jeví jako objekty se stabilní polohou a typickým plápoláním. Z tohoto důvodu je pro každou submatici  $F_{n,k}$  založena časová řada tak, jak je daná submatice detekována v jednotlivých snímcích. Nebo v případě opakování v po sobě jdoucích snímcích je tato přiřazena do existující časové řady.

Pro každou podezřelou oblast je před jejím uložením do časové posloupnosti sestaven histogram jednotlivých složek modelu HSL. Výsledné normované kvanta z daného histogramu jsou ukládány v časové řadě o  $m$  prvních. Z těchto záznamů lze následně složit matici  $HV$  obsahující jednotlivé historické hodnoty. Složení matice lze zapsat ve tvaru (4.4).

$$HV = \begin{bmatrix} H^{HV} & S^{HV} & L^{HV} & B^{HV} \end{bmatrix} \quad (4.4)$$

$$HV = \begin{bmatrix} hv_{n,0}, & hv_{n,1} & \dots & hv_{n,(3*c+1)} \\ \vdots & \vdots & \vdots & \vdots \\ hv_{n-m,0}, & hv_{n-m,1}, & \dots & hv_{n-m,(3*c+1)} \end{bmatrix} \quad (4.5)$$

Jak je z popisu matice  $HV$  patrné, tato je složena ze tří dílčích matic  $H^{HV}$ ,  $S^{HV}$ ,  $L^{HV}$  a vektoru  $B^{HV}$ . Pro další popis algoritmu je vhodné k matici  $HV$  přistoupit jako ke komplexní matici s globálním indexováním definovaným v (4.5). V tomto případě  $hv$  reprezentuje jeden prvek matice,  $n$  pořadí posledního snímku v obrazové sekvenci,  $m$  maximální počet uložených snímků a  $c$  počet kvant v rámci dílčích histogramů. Matice  $H^{HV}$ ,  $S^{HV}$  respektive  $L^{HV}$  obsahují hodnoty dílčích histogramů pro jednotlivé složky barevného modelu HSL. Prvky  $h$ ,  $s$ ,  $l$  těchto matic obsahují normovanou hodnotu daného kvanta v rámci histogramu. Vektor  $B^{HV}$  obsahuje normovanou hodnotu odpovídající černým pixelům v podezřelé oblasti pro daný snímek  $n$ .

Při sestavování historické matice  $HV$  dochází ke změnám její velikosti. Při prvním vložení hodnot histogramu do matice obsahuje tato pouze jeden řádek. Následně při zpracování dalších obrazových snímků za výše popsaných podmínek se další řádky do matice přidávají. Při plném obsazení historických záznamů proces sestavování historické matice funguje jako paměť typu *fronta* o pevně dané velikosti.

Po zpracování kompletního obrazového snímku (všech detekovaných pode-

zřelých oblastí) je provedena kontrola všech uložených historických řad za účelem odstranění těch, které již nejsou v rámci obrazového toku aktivní (plamen z dané oblasti dlouhodobě zmizel). Tohoto je dosaženo počítáním parametru *RTL* (right to life). Jedná se o parametr, který se pro každou historickou řadu upravuje při zpracování každého snímku videa (inkrementuje/dekrementuje). Při limitní hodnotě je celá řada z dalšího zpracování vyřazena.

## Vyčlenění markantů

Jak je patrné z předchozího popisu a obrázku 4.1, součástí poslední fáze algoritmu je aplikace jednoduché dopředné neuronové sítě. Důvodem této volby je snaha o snížení výpočetního výkonu společně s dosažením maximální spolehlivosti detekce. Výhodou dopředné neuronové sítě je také možnost jednoduché paralelizace výpočtu - každý neuron v rámci jedné vrstvy sítě může být počítán souběžně s ostatními z dané vrstvy.

Základní dopředná neuronová síť (dále jen NS) jako svůj vstup vyžaduje vektor hodnot, které budou jako celek dostatečně charakterizovat zpracovávaný signál tak, aby jej bylo možné klasifikovat. Vycházíme-li z toho, že zpracovávaným signálem pro potřeby tohoto algoritmu je posloupnost historických hodnot podezřelých oblastí, je nutné z této posloupnosti sestavit vstupní vektor pro použitou neuronovou síť. Samotné zřetězení jednotlivých řádků historické matice *HV* by znamenalo vytvoření rozsáhlého vstupního vektoru a tedy i velké vstupní vrstvy neuronové sítě. Z tohoto důvodu je přistoupeno před samotným zpracováním k vyčlenění hodnot - markantů z této matice. Hlavním cílem vyčlenění markantů je kondenzace informace umožňující klasifikaci daných signálů.

Vyjdeme-li z předpokladu, že děj zaznamenávaný kamerou je spojitý signál v čase, pak jednotlivé zaznamenané snímky obrazového toku  $F$  definovaného ve tvaru (4.1) lze chápat jako jednotlivé hodnoty získané vzorkováním tohoto signálu. Posloupnost snímků  $F$  tedy reprezentuje diskretizovaný signál o frekvenci vzorkování  $f_s$ , která odpovídá hodnotě *FPS* daného videa. Sestavený algoritmus pracuje a byl testován s videi o hodnotě  $FPS = 25$  a  $FPS = 30$ .

Zpracováním každého snímku zvláště vznikne z obrazového snímku  $F_n$  pro každou nalezenou submatici podezřelé oblasti  $F_{n,k}$  jeden vektor hodnot. Jak bylo popsáno výše, tento vektor je v podobě nového řádku zapsán do historické

matice  $HV$  pro danou oblast, kde  $n$  reprezentuje index posledního zpracovaného snímku,  $m$  počet historických záznamů a  $i$  index sloupce v historické matici. Z toho plyne, že řádky matice  $HV$  lze považovat také za jednotlivé vzorky vzniklé vzorkováním spojitého signálu. Jeden sloupec této matice reprezentuje vektor hodnot  $hv(i)$  definovaný v (4.6), což je diskrétní posloupnost vzorků spojitě funkce jedné proměnné. Tato funkce v rámci obrazového toku reprezentuje změnu hodnoty histogramu podezřelé oblasti v čase pro jednu konkrétní barvu/skupinu barev.

$$hv(i) = \{hv_{n,i}, hv_{n-1,i}, hv_{n-2,i}, \dots, hv_{n-m,i}\} \quad (4.6)$$

Původní návrh algoritmu v tomto kroku vycházel z představy, že plápolání ohně v obraze představuje periodický signál v podobě změny barev a tvaru plamene. Bylo předpokládáno, že změna tvaru plamene společně s jeho barevnou reprezentací se projeví v rámci histogramu změnou obsažení jednotlivých barev v podezřelé oblasti. Na základě tohoto předpokladu byl využitý princip diskrétní Fourierovy transformace. Pro každý sloupec historické matice  $HV$  respektive pro každý vektor hodnot  $hv$  definovaný v (4.6) je pomocí Fourierovy transformace vypočítaná sada koeficientů  $X(i)$  odpovídajících jednotlivým nalezeným frekvencím. Na základě provedených experimentů nebyly nalezeny reprezentativní frekvence. Z důvodu není zpracování pomocí FFT dále využito.

Použitá metoda vychází ze statistického zpracování vstupního signálu. Na číselnou řadu v podobě jednoho sloupce historické matice  $HV$  definovanou jako (4.6) je nahlíženo jako na náhodnou veličinu. Pro každou tuto náhodnou veličinu (každý sloupec historické matice  $HV$ ) je vypočítána výběrová směrodatná odchylka. Způsob výpočtu je znázorněn na (4.7). V tomto vzorci reprezentuje  $hv$  jeden prvek sloupce historické matice,  $m$  je aktuální počet uložených historických záznamů a  $\overline{hv(0)}$  průměr hodnot v daném sloupci. Výpočet průměru  $\overline{hv(0)}$  je vyjádřen v (4.8).

$$s_{O^{hv(0)}} = \sqrt{\frac{1}{m-1} \left( \sum_{k=1}^m hv_{k,0}^2 - m * \overline{hv(0)}^2 \right)} \quad (4.7)$$

$$\overline{hv(0)} = \frac{1}{m} \left( \sum_{k=1}^m hv_{k,0} \right) \quad (4.8)$$

Výpočtem hodnot směrodatné odchylky pro každý sloupec matice  $HV$  získáme vektor hodnot  $so$  definovaný ve tvaru (4.9). Odstraněním vypočtených prvků, které trvale nabývají nulových hodnot získáme vektor markantů. Jednotlivé dílčí prvky vektoru nejsou samy o sobě dostatečně charakteristické pro detekci ohně.

$$so = \{so^{hv(0)}, so^{hv(1)}, \dots, so^{hv(3*c+1)}\} \quad (4.9)$$

Součástí testování bylo sestavení velkého počtu výše zmíněných vstupních vektorů pro neuronovou síť. Tyto vektory byly vygenerovány na základě videí obsahujících oheň, i videí obsahujících procesy podobné hoření. Graf 4.2 zobrazuje náhodně vybranou sadu vektorů z obou testovacích množin. Červené křivky představují vektory z oblastí obsahujících oheň, zelené křivky reprezentují vektory z oblastí obsahující procesy podobné hoření, které však ohněm nejsou.



Obr. 4.2 Vybrané průběhy hodnot jednotlivých markantů.

## Využití neuronové sítě

Vzhledem k výrazným rozdílným markantům (Obr. 4.2) lze jako vhodnou metodu pro klasifikaci použít umělé neuronové sítě (NS) [3, 15, 31, 25, 17]. Umělé

neuronové sítě jsou inspirovány neuronovými systémy v přírodě. NS transformují signál ze vstupních údajů na výstupní odezvu sítě.

V rámci této práce bylo využito neuronových sítí s učitelem, mělkých neuronových sítí s jednou skrytou vrstvou. V rámci testování bylo použito 1 až 20 neuronů v dané skryté vrstvě.

Neuronová síť je tzv. data-driven metodou. Musí mít k dispozici vhodná data, na kterých může být naučena. Data bývají nejdůležitější součástí učení a závisí na nich z velké části úspěšnost učení. Soubor dat je tedy rozdělen na trénovací skupinu a testovací skupinu. Smyslem učení je eliminovat chybu na výstupní vrstvě v trénovací sadě dat. Následně na testovací skupině se vyzkouší, zda se neuronová síť naučila vstupy správně klasifikovat. V tomto případě, zda daný vstupní vektor popisující podezřelou oblast je pozitivní na oheň či je to oblast bez ohně.

## 4.5 Ověření výsledků

Jak je patrné z předchozího popisu algoritmu, součástí jeho vývoje bylo velké množství experimentálního testování. Za tímto účelem bylo nutné získat dostatek vstupních dat: pro pozitivní detekci - videa obsahující oheň, ale i pro negativní detekci - videa obsahující děje podobné ohni, nikoliv však hoření. V již publikovaných odborných článcích autoři ve velké míře používají blíže nspecifikovaná vlastní videa pro testování, která velmi často nejsou dostupná pro stažení.

Byly nalezeny i publikace, kdy autor společně s algoritmem publikuje i dataset použitý pro jeho ověření, nebo udává jeho zdroj. Toto je případ například článku publikovaném Mao et al. [19], kdy autor přímo odkazuje na použitý dataset. Po bližším zkoumání bylo však zjištěno, že tento dataset je značně nekvalitní - obsahuje velmi malé množství videí s velmi nízkou kvalitou navíc obsahující oheň už ve velmi pokročilém stádiu. Z tohoto důvodu byl autorem práce sestaven vhodný dataset videí, který je vhodný pro učení neuronové sítě i testování algoritmů na detekci ohně. Dataset je kombinací nahrávek získaných z různých dostupných datasetů a z volně dostupných zdrojů na internetu. Výsledná podoba datasetu obsahuje 120 videí s ohněm a 50 videí s procesy podobnými hoření.

Pro potřeby vyhodnocení jednotlivých přístupů a struktur neuronové sítě

bude použita metoda sledující úspěšnost algoritmu nikoliv na základě obrazových snímků, ale na základě jednotlivých vstupních vektorů neuronové sítě. Výsledné hodnoty úspěšnosti neuronové sítě tedy nerepresentují množství správně detekovaných obrazových snímků, ale množství správně rozřazených vstupních vektorů neuronové sítě.

Pro vyčíslení úspěšnosti učení a testování neuronových sítí je nutné definovat další parametry. Parametr *Accuracy* (v tabulkách označeno jako *Acc*) uvádí poměr správně detekovaných vzorků oproti všem testovaným vzorkům. Tento parametr reprezentuje úroveň natrénování daného modelu a udává obecně přehled o úspěšnosti metody. Parametr *Precision* udává poměr mezi správně detekovanými vzorky a všemi pozitivně detekovanými snímky. Udává tedy úspěšnost pozitivní detekce, respektive zohledňuje úroveň falešných alarmů. Hodnota *Recall* oproti předchozím parametrům uvažuje vliv chybně negativně označených vzorků. Kombinací předchozích parametrů lze získat hodnotu *F1score*, která vyjadřuje úspěšnost algoritmu s ohledem na množství false positive (*FP*) i false negative (*FN*) vzorků.

Tabulka 4.1 uvádí nejlepší zjištěné počty neuronů ve skryté vrstvě pro jednotlivé kombinace přenosových funkcí. Jak je z této tabulky patrné, v oblasti trénování a testování dosahují všechny nejlepší kombinace úspěšnosti vyšší než 99.8 %.

Tab. 4.1 Nejlepší kombinace struktury neuronové sítě

	Sigmoid Tanh 15	Tanh Tanh 18	Sigmoid Sigmoid 17	Tanh Sigmoid 12	SaturatedLin SaturatedLin 19
Acc-train	99.9811	99.9244	99.9433	99.8865	99.8865
F1-train	99.9721	99.8884	99.9163	99.8325	99.8327
Acc-test	100.	99.9432	99.9811	99.9243	99.9054
F1-test	100.	99.9161	99.972	99.8881	99.8604

Na základě tabulky 4.1 byla jako nejlepší kombinace určená pro implementaci ve výsledné podobě algoritmu vybrána kombinace 15 skrytých neuronů a přenosových funkcí Logistická Sigmoida a Hyperbolický tangens. Výsledky v podobě trénovací konfúzní matice jsou uvedeny v tabulce 4.2 a v podobě testovací konfúzní matice v tabulce 4.3.



*Tab. 4.2 Training confusion matrix -  
15 Sigmoid Tanh*

		P	N
True predicted	TP	1790	0
False predicted	FN	1	3497
	TPR	100.	99.9714
	FPR	0.	0.0285878
Accuracy		99.9811	
Precision		100.	
F1 score		99.9721	

*TPR-Sensitivity TNR-Specificity  
FPR-False positive rate FNR-False negative rate*

*Tab. 4.3 Testing confusion matrix -  
15 Sigmoid Tanh*

		P	N
True predicted	TP	1788	0
False predicted	FN	0	3496
	TPR	100.	100.
	FPR	0.	0.
Accuracy		100.	
Precision		100.	
F1 score		100.	

*TPR-Sensitivity, TNR-Specificity,  
FPR-False positive rate, FNR-False negative rate*

## 5 ZHODNOCENÍ CÍLŮ PRÁCE

Základním cílem disertační práce bylo vyvinout kontextově senzitivní senzorový systém v podobě algoritmu pro detekci ohně v obraze, který umožňuje brzkou detekci požáru za použití standardních průmyslových kamerových systémů. Zvláštní pozornost byla věnována výpočetní náročnosti algoritmu tak, aby detekce mohla probíhat v několika obrazových proudech současně. Princip algoritmu umožňuje detekci požáru i v průmyslových prostorech tam, kde se běžně nacházejí procesy podobné hoření.

Jednotlivé dílčí cíle práce byly naplněny takto:

- rešerše stávajících metod a řešení pro detekci ohně s využitím

## **zpracování obrazu**

V rámci tohoto dílčího cíle byly prostudovány odborné články publikované ve vědeckých databázích. Na základě těchto článků byl sestaven obsáhlý přehled metod a principů uvedený v kapitole 2.

- **návrh a ověření nového algoritmu pro detekci požáru v obrazovém toku**

Na základě provedené rešerše byl navržen algoritmus, jehož princip je popsán v kapitole 4, kdy architektura algoritmu je popsána kapitolou 4.2. Výsledné testování proběhlo na testovací sadě videí a jeho kompletní průběh je demonstrován kapitolou 4.5. Algoritmus byl také přijatý vědeckou komunitou. Byl publikovaný v časopise [P.18].

- **integrace algoritmu do podoby výsledné aplikace/knihovny vhodné pro reálné nasazení**

Za účelem ověření možností praktického nasazení algoritmu byl tento sestaven a naprogramován za použití technologií programovacího jazyka C++ a knihoven Qt 5 a OpenCV do podoby výsledné aplikace, která je vhodná pro reálné nasazení v cílovém prostředí.

## **6 HLAVNÍ VÝSLEDKY PRÁCE**

Hlavním výsledkem práce je nový algoritmus pro detekci ohně v obraze. Navržený algoritmus je kombinací dříve publikovaných a běžně využívaných postupů v počítačovém vidění (detekce barev v obraze, detekce pohybu v obraze, aj.) a nových postupů pro zpracování podezřelých oblastí včetně jejich sledování v čase. Jak bylo popsáno v předchozích kapitolách, závěrečná fáze algoritmu využívá jednoduché dopředné neuronové sítě. Díky této navržené struktuře je možné velkou část kroků algoritmu paralelizovat.

Algoritmus byl vyvíjen s konkrétním aplikačním zaměřením - podpůrný nástroj do stávajících kamerových systémů. Z tohoto aplikačního zaměření vycházely i požadavky pro návrh algoritmu. Tím základním, který byl splněn v plné míře, byl požadavek na běh algoritmu v reálném čase. Vyvinutý algoritmus je schopen zpracovávat hned několik obrazových toků - videí v reálném čase na standardním stolním počítači. Díky tomu s využitím výkonného serveru

je možné jeho nasazení na dostatečném množství obrazových toků z běžných průmyslových kamer.

Metodika použitá pro detekci ohně v rámci vyvinutého algoritmu umožňuje modifikací některých vnitřních parametrů změnit objekt detekce například na kouř, tok kapaliny aj.

Mimo samotný návrh algoritmu byla provedena testovací implementace navržených postupů. Tato implementace je ve fázi testovacího nasazení a po drobných optimalizacích kódu je možné ji využít pro reálné nasazení. Výsledná aplikace získaná optimalizací kódu testovací implementace je dalším výstupem této práce.

## 7 PŘÍNOS PRÁCE PRO VĚDU A PRAXI

Jak je patrné z kapitoly popisující současný stav problematiky, otázka detekce ohně je aktuálním tématem. Z množství publikovaných odborných článků ve vědeckých databázích lze usuzovat, že zájem odborné veřejnosti o toto téma zásadně roste.

Přínos práce lze spatřovat v rovině vědecké a zejména pak v rovině praktického využití při konkrétních aplikacích. Předložená práce představuje ve srovnání s doposud publikovanými výstupy nový přístup (algoritmus) pro detekci ohně v obraze. Navrhovaný přístup ukazuje, že i s využitím jednoduché neuronové sítě a vhodného extrahování markantů pro tuto síť lze získat dostatečně robustní algoritmus pro detekci ohně a to s relativně vysokou úspěšností. Výsledný přístup a jádro algoritmu je navíc možné využít při konstrukci algoritmů i pro jiné úlohy (např. detekce kouře, detekce jiných objektů s typickou strukturou a pohybem). Práce ale nabízí svým charakterem i další možnosti vědecké práce. Navržený algoritmus lze určitě, s ohledem na zvýšení úspěšnosti výsledné detekce, dále zdokonalovat. Jedním z příkladů může být využití optimalizačních metod pro stanovení interních parametrů algoritmu.

Praktický přínos práce je zřejmý z prezentovaných výsledků a také z výsledků, které byly publikovány v minulosti jinými autory. Nepříliš vysoké nároky na hardware umožňují nasadit tento navrhovaný algoritmus jako podpůrný nástroj do kamerových systémů, které běží v reálném čase. Vzhledem k tomu, že bylo při sestavování algoritmu použito standardního programovacího

jazyka C++ a knihoven pro počítačové vidění, je jeho reálné nasazení jednodušší. Praktický přínos dokresluje také úzká spolupráce s komerčním subjektem již při vývoji navrhovaného algoritmu. Lze tedy s vysokou pravděpodobností předpokládat využití tohoto algoritmu minimálně v rámci obchodních aktivit tohoto komerčního subjektu.

## 8 ZÁVĚR

Primárním cílem disertační práce bylo sestavení algoritmu pro detekci ohně v obrazovém toku. Tento cíl byl definován zúžením původního tématu disertační práce a to vývoje kontextově senzitivního sensorového systému. Původně navržená struktura takového systému obsahovala velké množství komponent určených pro detekci jednotlivých příznaků hoření, přenos signálů a jejich zpracování. V průběhu řešení dané problematiky bylo zjištěno, že oblast detekce ohně v obraze nebo videosekvencích i přes velké množství publikovaných článků nenabízí dostatečně robustní a zároveň rychlý algoritmus. Samotná detekce ohně v obraze navíc může být považována jako kontextově senzitivní aplikace.

Protipožární systémy využívají běžně jako základní prvek detekce detektory kouře založené na principu ionizační komory, fotoelektrických nebo teplotních sensorů. Základním předpokladem je, že detekovaný kouř je produktem nežádoucího hoření tedy požáru. Pro běžné vnitřní prostory je tento předpoklad dostatečný, existují ale prostředí, kde tyto detektory nelze použít. Typickým příkladem jsou průmyslové prostory, kde oheň nebo jemu podobné jevy produkující kouř jsou součástí výrobních procesů. Také použití detektorů ve venkovních nebo velkých otevřených prostorech je velmi problematické. Z tohoto důvodu možnost detekce ohně v obraze představuje důležitou a progresivní oblast vývoje.

V první fázi návrhu algoritmu byly definovány základní požadavky na jeho funkcionalitu. Zvláštní důraz byl při vývoji kladen na výpočetní náročnost tak, aby byl algoritmus schopen fungovat v reálném čase. Algoritmus byl vyvíjen pro implementaci do běžných bezpečnostních kamer, které jsou používány ve většině průmyslových prostorech a budovách. Předpokladem byla pak aplikace algoritmu ve stávajících systémech průmyslových kamer bez nutnosti jejich zásadní modifikace.

Před samotným návrhem algoritmu byly prostudovány publikace indexovány v odborných vědeckých databázích. Z jejich přehledu vyplývá, že naprostá většina stávajících algoritmů pracuje ve dvou základních fázích a to fází předzpracování a fází následného rozhodování. Detekce popsaná v publikovaných algoritmech využívá různých modifikací metod pro detekci barev v obraze, detekci pohybu v obraze a zpracování informací o tomto pohybu. Oblast softcomputingu je zastoupena klasifikačními metodami typu Support vector machines, jednoduchými dopřednými neuronovými sítěmi a dalšími klasifikátory. Moderním a také často publikovaným přístupem je využití hlubokých neuronových sítí. Společným jmenovatelem publikovaných metod je slabé testování výsledků nebo vysoká výpočetní náročnost.

Na základě těchto zjištění byl sestaven obsáhlý dataset s 170 videi o různém rozlišení. Následně byl sestaven algoritmus pro detekci ohně v obrazovém toku využívající statistické metody a jednoduchou dopřednou neuronovou síť. Stejně jako publikované metody i navržený algoritmus obsahuje několik fází. V první fázi předzpracování provádí generování masky na základě detekce pohybu v několika po sobě jdoucích snímcích videosekvence a detekování barev podobných ohni s využitím barevného modelu HSL. Na základě této masky se posléze vyberou podezřelé oblasti. V těchto oblastech je zvýšená pravděpodobnost výskytu plamenů. Druhá fáze algoritmu jako vstup přebírá jednotlivé podezřelé oblasti a tyto zpracovává v čase. Provádí jejich sledování mezi jednotlivými snímky a výpočet histogramu složek barevného modelu HSL. Pokud je daná oblast v obraze dostatečně dlouhá, je tato předmětem zpracování histogramů statistickým výpočtem. Výsledkem je vektor hodnot, který je ve třetí a závěrečné fázi algoritmu vstupem pro jednoduchou dopřednou neuronovou síť.

Ze sestaveného datasetu bylo vybráno 5288 reprezentativních vzorků z různých videí, na kterých bych výsledný algoritmus testován. Pro výslednou klasifikaci byla učena dopředná neuronová síť s pěti kombinacemi přenosových funkcí a s jedním až dvaceti neurony ve vnitřní skryté vrstvě. Na základě trénování a testování byla vybrána jako nejlepší kombinace 15 skrytých neuronů a kombinace logistické sigmoidy a hyperbolického tangetu jako přenosových funkcí. Výsledná síť dosáhla přesnosti 99.9811% pro trénování a 100% při testování. Celý algoritmus včetně naučené neuronové sítě byl implementován do

podoby funkční aplikace a zpětně ověřen na sestaveném datasetu.

V posledních letech se na trhu s průmyslovými kamerami objevilo několik zařízení, které jsou schopné detekovat oheň nebo kouř ve videu. Typickým příkladem jsou kamery Bosch Aviotec IP starlight 8000, SigniFire nebo Smoke-Catcher. Společným jmenovatelem těchto systémů je specifický výběr kamery, která je přímo svázaná s daným software nebo skutečnost že detekci provádí interně v kameře. Základní nevýhodou je však v porovnání s navrženým algoritmem fakt, že při jejich využití je nutné vyměnit stávající bezpečnostní kamery za specifické pro daný systém, což je velmi finančně nákladné. Výhodou je naopak bezpečnostní certifikace, kterou tyto systémy disponují.

Výsledkem práce je tedy návrh algoritmu primárně určeného pro detekci ohně v obrazovém toku v reálném čase. Z použitého principu detekce vyplývá možnost adaptace algoritmu na další děje podobné svým charakterem plamenům, tedy na děje s typickým pohybem a barvou. Na základě dosažených výsledků lze předpokládat, že algoritmus je vhodný pro nasazení jako doplňková detekce tam, kde je již instalován stávající kamerový systém. Budoucí pokračování ve vývoji navrženého algoritmu je možné zejména v optimalizaci jednotlivých kroků algoritmu a také v rozšířeném testování a testovacím nasazení na různé lokace.

# LITERATURA

- [1] ABDULLAHI, Z. S., DALHATU, S. H. and ABDULLAHI, Z. H. Development of Fire Detection Algorithm at Its Early Stage Using Fire Colour and Shape Information. *IOP Conference Series: Materials Science and Engineering*. 2018, 344, 1, pp. 012021. ISSN 1757-899X. doi: 10.1088/1757-899X/344/1/012021. Dostupné z: <<http://stacks.iop.org/1757-899X/344/i=1/a=012021>>. done.
- [2] CORTES, C. and VAPNIK, V. Support-vector networks. *Machine Learning*. September 1995, 20, 3, pp. 273–297. ISSN 1573-0565. doi: 10.1007/BF00994018. Dostupné z: <<https://doi.org/10.1007/BF00994018>>.
- [3] FAUSETT, L. V. *Fundamentals of Neural Networks: Architectures, Algorithms And Applications*. Pearson, 1 edition edition, December 1993. ISBN 978-0-13-334186-7.
- [4] FILONENKO, A. and JO, K. Fast fire flame detection on videos using AdaBoost and parallel processing. In *2018 IEEE Industrial Cyber-Physical Systems (ICPS)*, pp. 645–650, May 2018. doi: 10.1109/ICPHYS.2018.8390782. done.
- [5] FRIZZI, S., KAABI, R., BOUCHOUICHA, M., GINOUX, J., MOREAU, E. and FNAIECH, F. Convolutional neural network for video fire and smoke detection. In *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*, pp. 877–882, October 2016. doi: 10.1109/IECON.2016.7793196. done.
- [6] HA, C., JEON, G. and JEONG, J. Vision-Based Smoke Detection Algorithm for Early Fire Recognition in Digital Video Recording System. In *2011 Seventh International Conference on Signal Image Technology Internet-Based Systems*, pp. 209–212, November 2011. doi: 10.1109/SITIS.2011.23.
- [7] HA, C., HWANG, U., JEON, G., CHO, J. and JEONG, J. Vision-Based Fire Detection Algorithm Using Optical Flow. In *2012 Sixth International Conference on Complex, Intelligent, and Software Intensive Systems*, pp. 526–530, July 2012. doi: 10.1109/CISIS.2012.25.

- [8] HAN, X.-F., JIN, J., WANG, M.-J., JIANG, W., GAO, L. and XIAO, L.-P. Video fire detection based on Gaussian Mixture Model and multi-color features. *Signal, Image and Video Processing*. 2017, 11, 8, pp. 1419–1425. doi: 10.1007/s11760-017-1102-y. done.
- [9] HÜTTNER, V., STEFFENS, C. R. and BOTELHO, S. S. d. C. First response fire combat: Deep learning based visible fire detection. In *2017 Latin American Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR)*, pp. 1–6, November 2017. doi: 10.1109/SBR-LARS-R.2017.8215312. done.
- [10] HU, Y. and LU, X. Real-time video fire smoke detection by utilizing spatial-temporal ConvNet features. *Multimedia Tools and Applications*. 2018, 77, 22, pp. 29283–29301. doi: 10.1007/s11042-018-5978-5. done.
- [11] HUANG, M., WANG, Y. and HU, Y. Smoke identification of low-light indoor video based on support vector machine. In *2017 3rd IEEE International Conference on Computer and Communications (ICCC)*, pp. 2045–2049, December 2017. doi: 10.1109/CompComm.2017.8322896. done.
- [12] JIN, L. and LI, L. Research on fire image detection technology base on RBF. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 2018, 11067 LNCS, pp. 670–681. doi: 10.1007/978-3-030-00018-9\_59. done.
- [13] KHAN, R. A., UDDIN, J. and CORRAYA, S. Real-time fire detection using enhanced color segmentation and novel foreground extraction. In *2017 4th International Conference on Advances in Electrical Engineering (ICAEE)*, pp. 488–493, September 2017. doi: 10.1109/ICAEE.2017.8255405. done.
- [14] KHATAMI, A., MIRGHASEMI, S., KHOSRAVI, A. and NAHAVANDI, S. A New Color Space Based on K-Medoids Clustering for Fire Detection. In *2015 IEEE International Conference on Systems, Man, and Cybernetics*, pp. 2755–2760, October 2015. doi: 10.1109/SMC.2015.481.
- [15] KŘIVAN, M. *Úvod do umělých neuronových sítí*. přepřac. Praha: Oeconomica, vyd. 3. edition, 2014. ISBN 978-80-245-2024-7.



- [16] KO, B., JUNG, J.-H. and NAM, J.-Y. Fire detection and 3D surface reconstruction based on stereoscopic pictures and probabilistic fuzzy logic. *Fire Safety Journal*. 2014, 68, pp. 61–70. doi: 10.1016/j.firesaf.2014.05.015. done.
- [17] LAM, H. K., LING, S. S. H. and NGUYEN, H. T. (Ed.). *Computational Intelligence and Its Applications: Evolutionary Computation, Fuzzy Logic, Neural Network and Support Vector Machine Techniques*. Imperial College Pr, July 2012. ISBN 978-1-84816-691-2.
- [18] LI, S., LIU, W., MA, H. and FU, H. Multi-attribute based fire detection in diverse surveillance videos. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 2017, 10132 LNCS, pp. 238–250. doi: 10.1007/978-3-319-51811-4\_20. done.
- [19] MAO, W., WANG, W., DOU, Z. and LI, Y. Fire Recognition Based On Multi-Channel Convolutional Neural Network. *Fire Technology*. 2018, 54, 2, pp. 531–554. doi: 10.1007/s10694-017-0695-6.
- [20] MUHAMMAD, K., AHMAD, J., MEHMOOD, I., RHO, S. and BAIK, S. Convolutional Neural Networks Based Fire Detection in Surveillance Videos. *IEEE Access*. 2018, 6, pp. 18174–18183. doi: 10.1109/ACCESS.2018.2812835.
- [21] OPENCV. OpenCV, 2019. Dostupné z: <<https://opencv.org/>>.
- [22] PHILLIPS, W., SHAH, M. and LOBO, N. D. V. Flame recognition in video. In *Proceedings Fifth IEEE Workshop on Applications of Computer Vision*, pp. 224–229, December 2000. doi: 10.1109/WACV.2000.895426. done.
- [23] PUNDIR, A. S., BUCKCHASH, H., RAJPUT, A. S., TANWAR, V. K. and RAMAN, B. Fire Detection Using Dense Trajectories. In CHAUDHURI, B. B., KANKANHALLI, M. S. and RAMAN, B. (Ed.) *Proceedings of 2nd International Conference on Computer Vision & Image Processing*, Advances in Intelligent Systems and Computing, pp. 211–221. Springer Singapore, 2018. ISBN 978-981-10-7898-9, done.

- [24] QIU, X., XI, T., SUN, D., ZHANG, E., LI, C., PENG, Y., WEI, J. and WANG, G. Fire Detection Algorithm Combined with Image Processing and Flame Emission Spectroscopy. *Fire Technology*. 2018, 54, 5, pp. 1249–1263. doi: 10.1007/s10694-018-0727-x. done.
- [25] RUSSELL, S. J., DAVIS, E. and NORVIG, P. *Artificial Intelligence: A Modern Approach*. Pearson Education India, 3rd edition edition, 2010. ISBN ISBN 978-0-13-604259-4.
- [26] SHEN, D., CHEN, X., NGUYEN, M. and YAN, W. Q. Flame detection using deep learning. In *2018 4th International Conference on Control, Automation and Robotics (ICCAR)*, pp. 416–420, April 2018. doi: 10.1109/ICCAR.2018.8384711. done.
- [27] SUZUKI, S. and ABE, K. Topological Structural Analysis of Digitized Binary Images by Border Following. *Compture vision, graphics, and image processing*. 1985, 30, 30, pp. 32–46.
- [28] TÖREYİN, B. U., DEDEOĞLU, Y., GÜDÜKBAY, U. and ÇETİN, A. E. Computer vision based method for real-time fire and flame detection. *Pattern Recognition Letters*. January 2006, 27, 1, pp. 49–58. ISSN 0167-8655. doi: 10.1016/j.patrec.2005.06.015. Dostupné z: <<http://www.sciencedirect.com/science/article/pii/S0167865505001819>>.
- [29] TRIPATHI, A. and SWARUP, S. Visual smoke detection. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 2017, 10116 LNCS, pp. 128–142. doi: 10.1007/978-3-319-54407-6\_9.
- [30] VIJAYALAKSHMI, S. R. and MURUGANAND, S. Fire alarm based on spatial temporal analysis of fire in video. In *2018 2nd International Conference on Inventive Systems and Control (ICISC)*, pp. 104–109, January 2018. doi: 10.1109/ICISC.2018.8399002. done.
- [31] VOLNÁ, E. *Umělá inteligence : rozpoznávání vzorů v dynamických datech*. BEN - technická literatura,, 1. vyd. edition, 2014. ISBN 978-80-7300-497-2.

- [32] WANG, T., SHI, L., YUAN, P., BU, L. and HOU, X. A new fire detection method based on flame color dispersion and similarity in consecutive frames. In *2017 Chinese Automation Congress (CAC)*, pp. 151–156, October 2017. doi: 10.1109/CAC.2017.8242754. done.
- [33] WATTANACHOTE, K., LI, L., LIN, Z., WANG, G., JIANG, M. and LIU, W. An investigation on motion periodic series for fire and smoke textures characteristic identification. In *2017 10th International Conference on Ubi-media Computing and Workshops (Ubi-Media)*, pp. 1–6, August 2017. doi: 10.1109/UMEDIA.2017.8074112.
- [34] XU, H. et al. Temperature-triggered sensitive resistance transition of graphene oxide wide-ribbons wrapped sponge for fire ultrafast detecting and early warning. *Journal of Hazardous Materials*. 2019, 363, pp. 286–294. doi: 10.1016/j.jhazmat.2018.09.082.
- [35] YE, S., BAI, Z., CHEN, H., BOHUSH, R. and ABLAMEYKO, S. An effective algorithm to detect both smoke and flame using color and wavelet analysis. *Pattern Recognition and Image Analysis*. 2017, 27, 1, pp. 131–138. doi: 10.1134/S1054661817010138. done.
- [36] YUAN, W., LI, J., FANG, J., HU, H. and ZHANG, Y. Design of a real-time video-fire-detection system based on DSP. *Applied Mechanics and Materials*. 2011, 52-54, pp. 1137–1141. doi: 10.4028/www.scientific.net/AMM.52-54.1137.
- [37] ZHONG, Z., WANG, M., SHI, Y. and GAO, W. A convolutional neural network-based flame detection method in video sequence. *Signal, Image and Video Processing*. 2018, 12, 8, pp. 1619–1627. doi: 10.1007/s11760-018-1319-4.

# PUBLIKAČNÍ AKTIVITY AUTORA

- [A.1] JANKŮ, Peter, BLIŽŇÁK, Michal. *DatabaseExplorer – Open Source Database Management Tool*. In Recent Researches in Applied Informatics & Remote Sensing. Penang : WSEAS press, 2011, s. 198-203. ISBN 978-1-61804-039-8.
- [A.2] JANKŮ, Peter, BLIŽŇÁK, Michal. Easy Database Management in C Applications by Using DatabaseExplorer Tool. *International Journal of Computers*, 2012, roč. 6, č. 1, s. 54-62. ISSN 1998-4308.
- [A.3] JANKŮ, Peter, VAŘACHA, Pavel, KOLEK, Jan. Database Explorer as an Effective Unifying Tool for Various Database Systems Management. In *Proceedings of the 3rd International Conference on Finance and Accounting*. Montreux : WSEAS Press, 2012, s. 218-221. ISBN 978-1-61804-148-7.
- [A.4] JANKŮ, Peter, DOŠEK, Roman, JAŠEK, Roman. Obstacle Detection for Robotic Systems Using Combination of Ultrasonic Sonars and Infrared Sensors. In *Advances in Intelligent Systems and Computing*. 285. Heidelberg : Springer-Verlag Berlin, 2014, s. 321-330. ISSN 2194-5357. ISBN 978-3-319-06739-1.
- [A.5] POHUBA, Daniel, DULÍK, Tomáš, JANKŮ, Peter. Automatic evaluation of correctness and originality of source codes. In *10th European Workshop on Microelectronics Education*. Piscataway : IEEE Operations Center, 2014, s. 49-52. ISBN 978-1-4799-4016-5.
- [A.6] JANKŮ, Peter, DOŠEK, Roman, DULÍK, Tomáš. Implementation and optimization of stereo matching algorithm on ARM procesors. In *Intelligent Systems in Cybernetics and Automation Theory*. Heidelberg : Springer-Verlag Berlin, 2015, s. 183-188. ISSN 2194-5357. ISBN 978-3-319-18502-6.
- [A.7] DOŠEK, Roman, JANKŮ, Peter, VAŘACHA, Pavel. Secure High Level Communication Protocol for CAN Bus. In *Annals of DAAAM International for 2015, Volume 26*. Vienna : DAAAM International Vienna, 2015, s. 1-8. ISSN 2304-1382. ISBN 978-3-902734-06-8.

- [A.8] JANKŮ, Peter, KAREL, Koplík, DOŠEK, Roman, DULÍK, Tomáš, BLIŽŇÁK, Michal, VAŘACHA, Pavel. Context sensitive fire protection systém.. In Annals of DAAAM International for 2015, Volume 26. Vienna : DAAAM International Vienna, 2015, s. 1-. ISSN 2304-1382. ISBN 978-3-902734-06-8.
- [A.9] JANKŮ, Peter, POSPÍŠILÍK, Martin, DULÍK, Tomáš. Construction of compact step down voltage converter in terms of EMC. In MATEC Web of Conferences. Les Ulis : EDP Sciences, 2016, s. "nestrankovano". ISSN 2261-236X.
- [A.10] JANKŮ, Peter, KOPLÍK, Karel, DULÍK, Tomáš, SZABO, Istvan. Comparison of tracking algorithms implemented in OpenCV. In MATEC Web of Conferences. Les Ulis : EDP Sciences, 2016, s. "nestrankovano". ISSN 2261-236X.
- [A.11] POSPÍŠILÍK, Martin, KORYTÁK, Zdeněk, JANKŮ, Peter, SILVA, Rui Miguel. RFID reader immunity test against electrostatic discharge. In MATEC Web of Conferences. Les Ulis : EDP Sciences, 2016, s. "nestrankovano". ISSN 2261-236X.
- [A.12] POSPÍŠILÍK, Martin, KORYTÁK, Zdeněk, JANKŮ, Peter, SILVA, Rui Miguel, NEUMANN, Petr. RFID reader's construction in terms of electromagnetic susceptibility. In Annals of DAAAM and Proceedings of the International DAAAM Symposium. Vídeň : DAAAM International, 2016, s. 0213-0218. ISSN 1726-9679. ISBN 978-3-902734-08-2.
- [A.13] JANKŮ, Peter, POSPÍŠILÍK, Martin, DULÍK, Tomáš. Compact Step Down Voltage Converter Constructed in Terms of EMC. In Annals of DAAAM and Proceedings of the International DAAAM Symposium. Vídeň : DAAAM International, 2016, s. 514-523. ISSN 1726-9679. ISBN 978-3-902734-08-2.
- [A.14] JANKŮ, Peter, LUBOŠ, Lorenc, DULÍK, Tomáš. Comparison of integrated and composed step-down converter in terms of EMC. In MATEC Web of Conferences. Les Ulis : EDP Sciences, 2017, s. nestrankovano. ISSN 2261-236X.

- [A.15] KAREL, Koplík, JANKŮ, Peter, VOZNYUK, Olga, DULÍK, Tomáš, SNOPEK, Petr. Detecting fire in video stream using statistical analysis. In MATEC Web of Conferences. Les Ulis : EDP Sciences, 2017, s. nestránkovano. ISSN 2261-236X.
- [A.16] KAREL, Koplík, JANKŮ, Peter, VOZNYUK, Olga, DULÍK, Tomáš, SNOPEK, Petr. Real-time fire detection in camera stream using statistical analysis. WSEAS Transactions on Environment and Development, 2017, roč. 13, č. 13, s. 387-393. ISSN 1790-5079.
- [A.17] KOUDELKOVÁ, Zuzana, ŽABČÍKOVÁ, Martina, FILIP, Michal, JAŠEK, Roman, CHRAMCOV, Bronislav, STRMISKA, Martin, ŠTĚPÁNEK, Vít, JANKŮ, Peter, VAŘACHA, Pavel, DAŇKOVÁ, Šárka, CHMELOVÁ, Irina, LINZER, Petr. Perspektivy využití technologie BCI (Brain Computer Interface) ve fyzioterapii. Trilobit, 2018, roč. Ne-  
uveden, č. 2, s. nestránkováno. ISSN 1804-1795.
- [A.18] JANKŮ, Peter, KOMÍNKOVÁ OPLATKOVÁ, Zuzana, DULÍK, Tomáš, SNOPEK, Petr, LÍBA, Jiří. Fire detection in video sequences using a simple neural network. Mendel, 2018, roč. 24, č. 2, s. 55-61. ISSN 1803-3814.

# SEZNAM OBRÁZKŮ

Obr. 1.1	Návrh architektury kontextově senzitivního protipožárního systému . . . . .	5
Obr. 2.1	Postup detekce ohně. a) originální snímek, b) výsledek detekce pohybu, c) výsledek detekce barvy, d) kombinace předchozích parametrů. [6] . . . . .	7
Obr. 2.2	Aplikace barevného prostoru FCS na obrázek. a) originální obraz, b) FCS barevný prostor, c) FCS barevný prostor po aplikaci Otsu. [14] . . . . .	8
Obr. 2.3	Dynamická textura ohně s vyznačenými vektory optického toku (optical flow) [33] . . . . .	8
Obr. 4.1	Struktura algoritmu . . . . .	13
Obr. 4.2	Vybrané průběhy hodnot jednotlivých markantů. . . . .	20

# SEZNAM TABULEK

Tab. 4.1	Nejlepší kombinace struktury neuronové sítě . . . . .	22
Tab. 4.2	Training confusion matrix - 15 Sigmoid Tanh . . . . .	23
Tab. 4.3	Testing confusion matrix - 15 Sigmoid Tanh . . . . .	23



# SEZNAM POUŽITÝCH SYMBOLŮ A ZKRA- TEK

SWA	Spatial Wavelet Analysis - prostorová vlnková analýza
GMM	Gaussian mixture model
PSO	Particle Swarm Optimization - Optimalizace hejnem částic
FCS	Fire-based color space
TPR	True positive rate - četnost správně pozitivních výsledků
TNR	True negative rate - četnost správně negativních výsledků
FPR	False positive rate - četnost nesprávně pozitivních výsledků
FNR	False neagive rate - četnost nesprávně negativních výsledků
DSP	Digital signal processing - integrované obvody pro zpracování signálů
GSM	Gaussian Membership Functions
RBF	Radial Basis Network - funkce s radiální bází
FPS	Frames per second - počet snímků za jednu sekundu
FFT	Fast Fourier Transformation - Rychlá Fourierova transformace

Peter Janků

# **Algoritmus pro rychlou detekci ohně v obrazovém toku**

Algorithm for Fast Fire Detection in Video Stream

Teze disertační práce

Vydala Univerzita Tomáše Bati ve Zlíně

nám. T. G. Masaryka 5555, 760 01 Zlín, the Czech Republic

Náklad: vyšlo elektronicky

Sazba: Peter Janků

Publikace neprošla jazykovou ani redakční úpravou.

První vydání

Rok vydání: 2019

ISBN 978-80-7454-886-4

