

UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Adriano Lages dos Santos

Detecção de fumaça em vídeos para
monitoramento de áreas ambientais

Belo Horizonte
2013

Adriano Lages dos Santos

Detecção de fumaça em vídeos para monitoramento de áreas ambientais

Dissertação apresentada ao Programa de pós-graduação em Engenharia Elétrica, da escola de engenharia da Universidade Federal de Minas Gerais, como requisito parcial para a obtenção do grau de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Hani Camille Yehia

Co-orientador: Dr. Douglas Alexandre Gomes Vieira

**Belo Horizonte
2013**

Santos, Adriano L.

66 páginas

Dissertação (Mestrado) - Escola de Engenharia -
Programa de pós-graduação em Engenharia Elétrica.

1. Detecção de fumaça
2. Visão computacional
3. Inteligência computacional

I. Universidade Federal de Minas Gerais. Escola de Engenharia. Programa de pós-graduação em Engenharia Elétrica.

Comissão Julgadora:

Prof. Dr.
Hani Camille Yehia

Dr. Douglas Alexandre Gomes Vieira

Prof. Dr.
Hermes Aguiar Magalhães

Dr. Carlos Alexandre Meireles Nascimento

Prof. Dr.
Adriano Vilela Barbosa

Dedico este trabalho à minha esposa e à minha filha.

Epígrafe

Não passe horas e horas criando um manual para ensinar ao usuário como usar o seu programa, gaste esse tempo deixando seu programa intuitivo o bastante para que o usuário não precise de um manual!

Jacob Nielsen

Agradecimentos

Agradeço ao meu orientador e co-orientador pelas orientações acerca da preparação deste trabalho, à CAPES, CEMIG e ANEEL que financiaram os meus estudos e minhas pesquisas, à minha família, a minha esposa e aos meus amigos por todo o suporte em momentos de dificuldade.

Resumo

Incêndios são uma das principais causas de desmatamento, destruindo um grande percentual das matas e florestas. São ainda responsáveis por produzir e emitir uma grande quantidade de CO₂ para a atmosfera, fazendo com que, juntamente com a destruição das florestas, haja desequilíbrio ambiental. Uma forma eficiente para prevenir e evitar os prejuízos causados por incêndios florestais está em detectar e extinguir os incêndios da forma mais rápida possível, evitando que estes evoluam rapidamente para um incêndio descontrolado e de grandes proporções. Uma das formas de atingir esse objetivo é criar sistemas que antecipem a detecção de fogo, nesse caso detectando a fumaça no estágio inicial do incêndio. O objetivo deste trabalho é desenvolver um sistema de detecção de fumaça através de sequências de vídeos, onde o alvo do sistema é a detecção de fumaça nos estágios iniciais da sua formação. A análise dos pontos de interesse candidatos a fumaça consiste em detectar objetos em movimento nos vídeos, através de técnica de subtração de fundo. Após seleção de objetos em movimento, eles são classificados quanto às suas cores e somente objetos com cor de fumaça são analisados pela última etapa, que realiza análise de movimento espacial, além de verificar a persistência temporal dos pixels de interesse nos quadros dos vídeos. Os pixels que satisfizerem as regras definidas nas três etapas são considerados pixels de fumaça. O sistema proposto neste trabalho é comparado com outros sistemas existentes na literatura, através de testes com uma base de dados com vídeos que contêm imagens de fumaça e vídeos que não contêm imagens de fumaça, mas que aparentam ser fumaça. A acurácia do método proposto obtida nos testes foi de 8 a 30% superior a métodos existentes na literatura que utilizam análise de cromaticidade, detecção de movimento e processamento de sinais. A acurácia do método proposto foi confirmada através de análise estatística.

Palavras-chave: detecção de fumaça, incêndios florestais, florestas.

Abstract

Fires are one of the main causes of deforestation, destroying a large percentage of the woods and forests. Moreover, they are responsible for producing and emitting a great amount of CO_2 into the atmosphere and, on the top of forest destruction, it also causes ambient unbalance. An efficient solution to reduce and to prevent the damages caused by forest fires, is to detect and extinguish fires as fast as possible, avoiding them to evolve quickly for an uncontrolled fire and of great proportions. One of the forms to reach this objective is to create systems that anticipate fire detection, in this case detecting smoke in the beginning period of the fire. This work aims to develop a smoke detection system by means of video sequences, where the purpose of the system is the smoke detection in early stages of formation. The analysis of the points of interest candidates to smoke consists of detecting objects in movement in the videos, through background subtraction. After detection of an object in movement, it is classified according to its color. Only objects with smoke color are analyzed by the last stage, that carries out analysis of space movement, besides verifying the temporal persistence of pixels of interest in the frames of the videos. Pixels that satisfy rules defined in the three stages are considered pixels of smoke. The system considered in this work is compared with other existing systems in literature. Through tests with a database with videos that contain smoke images and videos that do not contain smoke images, but contain objects that look like smoke. The accuracy of the proposed method obtained in the tests was 8%-30% over existing methods in the literature which relies on chromaticity analysis, motion detection and signal processing. The accuracy of the proposed method was confirmed by statistical analysis.

Keywords: smoke detection, forest fires.

Lista de Figuras

1.1	Fumaça, neblina ou nuvem?	3
3.1	Espaço de cor RGB	13
3.2	Diferentes tipos de fumaça	14
4.1	Fluxograma geral do sistema	19
4.2	Fluxograma subtração de fundo	23
4.3	Segmentação variando α	24
4.4	Segmentação variando τ	25
4.5	Pixels de cor de fumaça no espaço RGB	27
4.6	Segmentação manual	28
4.7	Fluxograma do algoritmo K-médias	29
4.11	Resultado segmentação retangular	29
4.8	Imagens do conjunto de treinamento	30
4.9	Resultado segmentação k-médias	31
4.10	Segmentação Retangular	31
4.12	Grupos obtidos na etapa de agrupamento	35
4.13	Exemplos da evaporação de grupos	41
4.14	Resultado final da persistência espacial e temporal	42
5.1	Exemplo de vídeos de teste para o primeiro experimento.	46
5.2	Exemplo de vídeos de teste para o segundo experimento.	47
5.3	Acurácia de detecção do método D383S versus algoritmos convencionais	50
5.4	Taxa de detecção de falsos positivos	51
5.5	Acurácia de detecção do método D383S versus algoritmo 3	52

5.6	Taxa de detecção de falsos positivos	53
5.7	Distribuição normal dos dados coletados no experimento 1	55
5.8	Ordem de coleta dos dados no experimento 1	56
5.9	Distribuição normal dos dados coletados no experimento 2	57
5.10	Ordem de coleta dos dados no experimento 1	58
5.11	Resultados do método proposto	58
5.12	Resultados do método proposto	59

Lista de Tabelas

4.1	Tabela de parâmetros utilizados no trabalho	43
5.1	Descrição dos vídeos do experimento 1.	45
5.2	Descrição dos vídeos do experimento 2.	46
5.3	Quantidade de quadros dos vídeos utilizados	47
5.4	Parte 1 resultados da detecção de fumaça	48
5.5	Parte 2 Resultados da detecção de fumaça	48
5.6	Parte 3 Resultados da detecção de fumaça	48
5.7	Resultados do experimento 2	49
5.8	Análise de Variância para acurácia	54
5.9	Análise de Variância para acurácia	56

Sumário

1	Introdução	1
1.1	Objetivo	2
1.2	Motivação	3
1.3	Problema de Pesquisa	3
1.4	Apresentação do Trabalho	3
2	Revisão Bibliográfica	5
2.1	Introdução	5
2.2	Detecção de fumaça	5
3	Fundamentos Teóricos	12
3.1	Introdução	12
3.2	O espaço de cor RGB	12
3.3	Formação e cores de fumaça provenientes de incêndios florestais	13
3.4	Análise Estatística e hipóteses de pesquisa	14
4	Desenvolvimento	17
4.1	Introdução	17
4.2	Segmentação de movimento através de subtração de fundo	19
4.3	Classificação dos pixels em cor de fumaça	25
4.4	Análise dos pixels de fumaça para realização da persistência espacial e temporal	32
4.4.1	Agrupamento dos pixels com cor de fumaça	32
4.4.2	Características espaciais e temporais	36

5 Resultados	44
5.1 Resultados Experimentais	44
5.2 Análise Estatística	53
6 Conclusão	60
Referências Bibliográficas	63

Capítulo 1

Introdução

Os incêndios consomem anualmente grandes áreas de florestas, sendo muitas destas áreas zonas protegidas onde existem espécies da fauna e flora em extinção. Os incêndios são também responsáveis pela emissão de grandes quantidades de CO_2 para a atmosfera, contribuindo para o aumento do efeito estufa. Além disso, as queimadas em áreas onde existem torres de alta tensão instaladas, causam prejuízo a essas torres e a toda a estrutura envolvida para o seu funcionamento.

Dessa forma, para recuperar as áreas devastadas por incêndios, é gasta uma enorme quantidade de recursos econômicos e de mão-de-obra. Os resultados desses investimentos são visíveis somente alguns anos mais tarde e para que o ecossistema se recupere são necessários muitos anos.

Uma boa maneira de prevenir a destruição das florestas é através do monitoramento das mesmas a fim de extinguir rapidamente focos de incêndio. A detecção precoce de incêndio permite uma rápida resposta no combate ao mesmo, podendo-se assim evitar perdas na fauna e na flora, bem como perdas de vidas e de bens.

Para uma detecção precoce de incêndio, existe a tradicional vigilância humana e sistemas baseados em sensores que realizam análise química. Entretanto, técnicas de sensores são pouco precisas na localização do incêndio, pois a fumaça pode ser conduzida pelo vento para uma direção contrária ao sensor. Desta forma pode haver uma localização imprecisa do foco de incêndio além de demora na detecção e alto custo financeiro, devido ao grande número de sensores e manutenção dos mesmos. De qualquer forma, uma boa maneira de evitar os estragos causados por um incêndio é antecipar a detecção do fogo, fazendo com que sejam detectados focos de fumaça, especialmente em estágio inicial.

A partir dos anos 90, pesquisas vêm sendo realizadas com o intuito de realizar detecção de fumaça em sequências de vídeos. Com o avanço dos recursos computacionais e de técnicas de visão computacional, essas pesquisas são feitas incluindo uma quantidade maior de ca-

racterísticas da fumaça a serem analisadas, com o objetivo da rápida detecção e diminuição de erros. Nesse sentido, as torres de transmissão de energia elétrica presentes nessas áreas de preservação ambiental podem auxiliar no processo de monitoramento, servindo de base para instalação de câmeras de vídeo e permitindo que áreas estratégicas possam ser monitoradas em tempo real. Isso também contribui para diminuir a rejeição das torres de transmissão pela população, já que as mesmas serão usadas como parte do sistema de monitoramento.

O sistema desenvolvido neste trabalho faz parte de um projeto de monitoramento de linhas de transmissão, para uma empresa do setor energético a CEMIG - Companhia Energética de Minas Gerais com apoio da ANEEL - Agência Nacional de Energia Elétrica, onde câmeras de vídeo são instaladas em torres de transmissão, permitindo desta forma utilizar as imagens fornecidas pelas câmeras para detecção de fumaça. Especificamente, este trabalho tem como objetivo detecção de fumaça proveniente de incêndios florestais em estágio inicial, onde a fumaça contém uma grande quantidade de vapor de água e, sendo, desta forma, predominantemente da cor branca. O Objetivo do projeto é fazer com que os ativos de transmissão de energia sejam utilizados para monitoramento de áreas de proteção ambiental. Além disso, o projeto vai proporcionar para a comunidade em geral o monitoramento dessas regiões através da disponibilização dos vídeos das áreas monitoradas em tempo real através de um sítio na internet. Isso faz com que as pessoas também tenham um papel chave no processo de monitoramento podendo informar a CEMIG sobre um evento que está ocorrendo em um determinado momento.

O processo de detecção de fumaça consiste em três etapas: primeiramente é realizada a detecção de movimento nas imagens fornecidas pelas câmeras; em seguida, os pixels em movimento são classificados quanto à sua cor, com o objetivo de selecionar somente pixels em movimento com cor de fumaça; e por fim a terceira etapa consiste em observar o movimento dos pixels em regiões das imagens e definir para esses pixels, regras de movimentação. Caso as regras da terceira e última etapa sejam satisfeitas será disparado um alarme de detecção de fumaça. O desenvolvimento das etapas será detalhado ao longo desse trabalho.

O método de detecção proposto neste trabalho, chamado de D383S foi comparado com algoritmos existentes na literatura e os resultados dos testes analisados estatisticamente.

1.1 Objetivo

O objetivo do presente trabalho é realizar a detecção de fumaça branca (fumaça que contém maior quantidade de vapor de água) em sequências de vídeos, utilizando técnicas de visão computacional e características espaciais e temporais da fumaça.

1.2 Motivação

A criação de um sistema de detecção de fumaça utilizando técnicas de visão computacional justifica-se como ferramenta de auxílio ao homem, ajudando a detectar ameaças ao meio ambiente e possibilitando o monitoramento de áreas maiores. Note-se que o homem ainda possui maior rapidez e facilidade em distinguir objetos no espaço. Sendo assim as técnicas de visão computacional não vêm substituir o homem nas tarefas de monitoramento ambiental, mas sim fornecer suporte.

1.3 Problema de Pesquisa

A detecção de fumaça por sistemas computacionais não é uma tarefa trivial. O que o ser humano diferencia com relativa facilidade, requer do computador mais recursos para chegar a um resultado, que nem sempre é preciso. Em determinadas situações, até mesmo o homem pode confundir uma nuvem ou uma neblina com um foco de fumaça. Neste contexto o monitoramento e detecção de focos de fumaça em áreas florestais é muito importante, evitando incêndios de grandes proporções.



(a) fumaça ou nuvem?



(b) fumaça ou neblina?

Figura 1.1: Em algumas situações é difícil distinguir fumaça de neblina ou nuvem até mesmo pelo ser humano.

1.4 Apresentação do Trabalho

O trabalho encontra-se dividido em seis partes:

- Introdução.
- Revisão Bibliográfica, onde é feita uma breve descrição dos métodos e técnicas utilizadas em projetos com objetivos semelhantes.

- Características da fumaça, onde são apresentados conceitos sobre formação e comportamento da fumaça.
- Desenvolvimento, onde é feita a descrição detalhada de todo o trabalho desenvolvido.
- Resultados, onde são feitas análises sobre o algoritmo com base nos testes realizados.
- Conclusão.

Capítulo 2

Revisão Bibliográfica

2.1 Introdução

Neste capítulo, são mostrados os esforços já realizados com o objetivo de detectar fumaça em sequências de vídeo ou imagens estáticas. Além disso são realizadas nesse capítulo análises sobre os trabalhos pesquisados.

2.2 Detecção de fumaça

[Kopilovic et al. \(2000\)](#), utilizaram-se das irregularidades no movimento da fumaça devido à sua não-rigidez. Computou-se o fluxo óptico usando duas imagens adjacentes e então usou a entropia das distribuições de direção de movimento da fumaça como característica chave para diferenciar movimento de fumaça de qualquer outro tipo de movimento. Segundo os autores, a entropia das distribuições de direções de fumaça, são diferentes da entropia de qualquer outro objeto em movimento. Não foi mostrada no trabalho a diferença entre os valores de entropia da fumaça e de outros objetos em movimento. O fato desses valores não serem exibidos no trabalho gera incertezas quanto aos resultados.

[Vicente et al. \(2001\)](#) extraíram os movimentos da fumaça em pequenos envoltórios espaciais e agruparam estes movimentos em uma curva fractal. Além disso este artigo faz uma análise dos níveis de cinza de acordo com o movimento da fumaça ao longo do tempo.

De forma similar, [Vicente et al. \(2002\)](#) exploraram o movimento da fumaça, onde são extraídos movimentos locais obtidos com análise de *clusters* de pontos em um espaço multidimensional-temporal. O objetivo principal em seu artigo é rastrear envoltórias dinâmicas e locais de pixels, para então usar histogramas de distribuição de velocidade para realizar a discriminação entre movimento da fumaça e vários fenômenos naturais como nuvens e árvores sacudidas pelo vento que também possuem envoltórias de pixels de acordo com a característica dos seus movimentos. Nesse trabalho, a presença de outros objetos em movimento, típicos de cenas de monitoramento de vídeo, não são levadas em conta. E portanto

falsos o método proposto pelos autores pode apresentar falsos positivos com outros objetos similares a fumaça ou objetos típicos de cenas de monitoramento.

[Toreyin et al. \(2005\)](#) propõem um método para reconhecimento de fumaça em sequências de vídeo, utilizando o método de subtração de fundo para segmentar regiões em movimento, e o monitoramento da diminuição da energia em alta frequência espacial da cena através da transformada espacial wavelet das imagens atuais e das imagens de fundo. Os autores afirmam que as arestas da fumaça são importantes porque elas produzem máximos locais no domínio da transformada wavelet. Com isso deduz-se que uma diminuição nos valores de máximos locais é um indicador de fumaça. Além disso, a cena se torna mais cinzenta quando há fumaça e isso leva à diminuição dos valores de crominância dos pixels da imagem. São também analisadas características das bordas da fumaça, bem como convexidade das regiões de fumaça. Combinando todas essas hipóteses toma-se a decisão final. O método é baseado em cinco passos: (i) Primeiro são encontradas regiões de movimento na imagem através de subtração de fundo. (ii) Depois a diminuição da alta frequência correspondente às arestas da fumaça é verificada por meio da utilização da transformada espacial wavelet. (iii) Se as arestas da fumaça perdem sua ondulação sem desaparecerem completamente então é feita a verificação da diminuição de crominância dos objetos em questão. (iv) A quarta etapa é a análise da tremulação do objeto feita pela transformada wavelet no domínio do tempo. (v) Por fim, a convexidade da região em movimento é verificada. Para testar a convexidade da região candidata a fumaça, são projetadas sobre a região, 5 linhas horizontais e 5 linhas verticais. A análise simplesmente consiste em verificar se os pixels em cada uma das linhas pertence à região em movimento ou não. Se pelo menos 3 pixels consecutivos nas linhas atravessando as regiões em movimento pertencerem à imagem de fundo, a condição de convexidade da região é violada. Se ao longo de qualquer uma das linhas, a convexidade não for encontrada, então os pixels da região são descartados. O método de [Toreyin et al. \(2005\)](#) pode gerar falsos positivos em objetos que passam pela cena e atendam essas características, como por exemplo, neblina. O sistema foi disponibilizado pelos próprios autores por um período limitado de dias, para que os resultados do seu sistema fossem comparados com os resultados do método desenvolvido neste trabalho.

Em outro trabalho [Toreyin et al. \(2006\)](#) aprimoraram o trabalho de [Toreyin et al. \(2005\)](#), usando o método de subtração de fundo para extrair objetos em movimento. Em seguida, com auxílio da transformada wavelet é feita a análise de tremulação e movimento da fumaça e também avaliadas as bordas da região de fumaça e variações na sua textura. Em cada bloco das sub-imagens resultantes, a variação de energia é obtida. A energia é dada pela soma das componentes de alta frequência espaciais no domínio wavelet. Finalmente, dois limiares são definidos para medir uma variação de energia aceitável. O dinamismo da variação é modelado com um modelo oculto de Markov HMM, do inglês (*Hidden Markov Model*), treinado com pixels de fumaça e de objetos parecidos com fumaça, mas que não são fumaça.

[Chen et al. \(2006\)](#) apresentam um método de detecção de fumaça para antecipar sistemas de alarme de fogo baseado em processamento de vídeo. Eles propuseram uma estratégia para classificar os pixels de fumaça baseado em uma regra de decisão estática baseada em cromaticidade. A regra de decisão de cromaticidade é definida pelo nível da cor cinza nos pixels de fumaça. A sua análise estática, leva em conta duas regiões da cor cinza que são o cinza claro e o cinza escuro, deduzindo desta forma que as três componentes R, G e B (do inglês *Red, Green and Blue*) do pixel de fumaça são iguais ou têm valores muito próximos. Além disso, ele utiliza a componente I (intensidade) do modelo de cor HSI (do inglês *Hue, Saturation, Intensity*) para descrever as cores acinzentadas obtendo, dessa forma, limites de intensidade para cinza claro e cinza escuro que variam entre L1 a L2 e entre D1 e D2 níveis de cinza, respectivamente. Assim a regra de análise cromática fica definida pelas condições $R \pm \alpha = G \pm \alpha = B \pm \alpha$ e $L1 \leq I \leq L2$ e $D1 \leq I \leq D2$, se estas três condições forem satisfeitas para um mesmo pixel, então o mesmo é classificado como sendo um pixel de fumaça. Se as regras não forem satisfeitas, ele não será classificado como tal. Estas regras foram utilizadas como sua função de decisão para reconhecimento de fumaça. Além disso, os autores citam que, para classificação de fumaça em ambientes com baixa luminosidade ou à noite, são necessárias câmeras que trabalhem com captura de imagens em infravermelho. O método do autor encontra falsos positivos, pois trabalha com tons de cinza escuro, fazendo com que objetos que se movam e tenham cor escura e atendam a sua regra dinâmica sejam classificados como fumaça. Faltaram, no trabalho do autor, um método de subtração de fundo e um método de rastrear o movimento dos objetos, visando evitar falsos positivos. O trabalho de [Chen et al. \(2006\)](#) foi reproduzido para comparações com o método desenvolvido neste trabalho.

[Xiong et al. \(2007\)](#) realizaram uma análise na complexidade da forma da fumaça baseada na distância entre os pontos de contorno e o centro de massa da forma. Esta abordagem teve sucesso para alguns exemplos de fumaça, mas uma avaliação mais precisa de diferentes características da fumaça tais como movimentação em diferentes ângulos e distâncias não foi realizada. [Calderara et al. \(2011\)](#) afirmam que uma forte variação da forma e bordas das regiões de fumaça não pode ser visualizada devido à direção do vento e campo de visão da câmera, pois o vento muda a forma do vento e cada posição que a câmera está irá capturar uma forma diferente da fumaça. Dessa forma, para áreas externas esse é um método não recomendável.

[Yuan \(2008\)](#) usou um modelo acumulativo de orientações de movimento para realizar detecção de fumaça em tempo real e o seu modelo pode eliminar a maioria dos conflitos entre luzes artificiais e outros objetos que não são fumaça. Além disso, o trabalho realiza a análise de movimento dos objetos, juntamente com análise de cromaticidade desses objetos. Mas o autor consegue detectar a fumaça se espalhando somente em algumas direções, não

em qualquer direção.

Cui et al. (2008) combinaram a transformada wavelet e análise de cor em tons de cinza para analisar a textura da fumaça, mas neste trabalho detecção em tempo real não foi considerado.

Ho (2009) criou um sistema de detecção de fumaça em sequências de vídeo. No qual, primeiramente é feito o processo de subtração de fundo para extrair objetos em movimento nas imagens. Logo após esta primeira etapa é feita uma verificação de cores dos pixels em movimento, no espaço HSI. Depois é verificada a correlação do histograma dos pixels em movimento com o histograma de cor de fumaça. Por fim, rastreia-se a região onde há fumaça. É necessário transformar o espaço de cor em espaço de cor HSI com o objetivo de detectar possíveis pixels de fumaça. Vale lembrar que somente subtração de fundo não é suficiente para rastrear o movimento da fumaça, pois a utilização de subtração de fundo como técnica primária de detecção pode gerar muitos falsos positivos e qualquer objeto com cor de fumaça que se movimenta pode ser detectado como fumaça.

Wei et al. (2009) desenvolveram um método de detecção de fumaça para gerar alarmes de incêndio em ambientes fechados e em locais abertos. O algoritmo de detecção possui 4 passos: (i) segmentar as regiões que contêm movimento no atual quadro do vídeo; (ii) extrair e marcar as regiões conectadas; (iii) realizar o casamento das regiões conectadas com características estáticas e dinâmicas da fumaça, visando encontrar fumaça; e (iv) definir uma regra de alarme se todas as condições propostas forem satisfeitas.

Han et al. (2009) apresentam um método de detecção de fumaça em túneis, Primeiramente todos os objetos em movimento são detectados por meio da técnica de subtração de fundo. Depois, as regiões que não são fumaça são extraídas usando histórico de movimento das imagens e extração de características das imagens utilizando momentos invariantes. Com isso o autor consegue extrair das imagens somente as regiões de fumaça.

Damir et al. (2009) propõem classificar a fumaça utilizando o classificador Bayes ingênuo para separar as regiões candidatas a fumaça e juntamente com o classificador fazer análise de cor das regiões candidatas a fumaça. Além disso, os autores comparam o seu método com outros dois classificadores e realiza também testes com cinco espaços de cores diferentes. Os testes mostram que o espaço de cores RGB, apresentou os melhores resultados na tarefa de detecção de fumaça com relação aos outros quatro espaços de cores testados, que foram os espaços: YCbCr, CIELab, HSI (do inglês *Hue, Saturation, Intensity*) e HSV (do inglês *Hue, Saturation, Value*).

Kim et al. (2010) apresentaram um método prático que se aplica para detecção de fumaça

em vídeo em ambientes abertos. Funciona bem para incêndios florestais, julgando pelos vídeos capturados pelos autores. De acordo com a descrição pelo autor, o método é voltado somente para detecção de fumaça. Primeiramente, o sistema recebe a sequência de quadros do vídeo, logo depois calcula o tamanho médio da imagem e depois realiza o cálculo de diferença da imagem. Após obter a área onde houve movimento, essa área é segmentada.

[Chunyu et al. \(2010\)](#) utilizaram fluxo óptico para determinar o campo de movimento da fumaça. A primeira etapa é realizar subtração de fundo para obter regiões candidatas a fumaça. Logo depois é utilizada uma regra de decisão baseada em cor para verificação dos pixels selecionados na primeira etapa. Então o autor utiliza o método de fluxo óptico [Kanade et al. \(1981\)](#) para calcular o fluxo óptico das regiões candidatas. As características de movimento são calculadas com base nos resultados do fluxo óptico e usadas para diferenciar fumaça de outros objetos em movimento. Por fim uma rede neural é utilizada para classificar as características da fumaça de outras características que não são de fumaça.

[Maruta et al. \(2010\)](#) consideram que a imagem da fumaça é um fractal. Eles utilizam um expoente desse tipo de fractal para calcular o valor desse expoente para a fumaça. Eles comparam o valor do expoente do fractal com a transformada wavelet da imagem. Os autores utilizam essas técnicas para analisar textura e características físicas da fumaça. Para análise de movimento, é usada uma técnica que verifica acumulação do movimento da fumaça no tempo.

[Calderara et al. \(2011\)](#) apresentam um sistema de detecção de fumaça, utilizando subtração de fundo para segmentar regiões com movimento. A teoria da decisão Bayesiana é utilizada para detecção de fumaça na cena, juntamente com análise da imagem por meio da transformada wavelet e informações de espaço de cores. Um modelo estatístico da energia da imagem é criado para analisar a diminuição de energia que geralmente ocorre quando a fumaça cobre a cena. Assim o processo de detecção é fortalecido, comparando as cores do quadro de entrada com as cores de fumaça. O sistema é robusto e eficiente na detecção de fumaça. [Calderara et al. \(2011\)](#) afirmam em seu artigo que o trabalho está focado somente em detecção de fumaça em sequências de vídeos, que se nas sequências de vídeos aparecerem falsos positivos, eles serão detectados. Os autores afirmam ainda que obtiveram 100% de acurácia em seus testes, mas os vídeos testados são somente vídeos que contêm imagens de fumaça, não utilizando vídeos de teste com objetos ou situações que simulem fumaça.

[Yuan \(2011\)](#) propôs outro modelo de detecção de fumaça em 4 etapas. Primeiro, por meio de análise multi-escalar, uma pirâmide de imagens de 3 níveis foi construída. Logo após padrões binários locais LBP (do inglês *Local Binary Patterns*), que são insensíveis à rotação de imagens e condições de iluminação, são extraídos em cada nível da pirâmide para gerar a pirâmide LBP. Na terceira etapa padrões binários locais baseados em variância LBPV (do

inglês *Local Binary Patterns based on Variance*), são extraídos para gerar a pirâmide LBPV. E por fim histogramas das pirâmides LBP e LBPV são computados e então todos os histogramas são concatenados em um vetor de características aprimorado. Uma rede neural é treinada e usada para discriminação entre fumaça e objetos que não são fumaça.

[Tung et al. \(2011\)](#) utilizaram uma abordagem definida em quatro etapas para realizar a detecção de fumaça. Primeiro realiza segmentação das regiões em movimento. A segunda etapa consiste na utilização de lógica nebulosa (do inglês *fuzzy*) para agrupar regiões candidatas a fumaça das regiões em movimento. Na terceira etapa são extraídos parâmetros de características espaciais e temporais das regiões candidatas a fumaça. Esses parâmetros incluem um vetor de movimento, rugosidade da superfície e aleatoriedade da área de fumaça. No quarto passo do método, os parâmetros extraídos do terceiro estágio são usados como características de entrada para treinar um classificador SVM (do inglês *Support Vector Machine*), que é usado para tomada de decisão.

[Yuan \(2012\)](#) propõe uma arquitetura para extrair características invariantes na forma da fumaça, além disso é utilizado o classificador de padrões *Adaboost* para melhorar o desempenho da classificação das características extraídas.

[Millan-Garcia et al. \(2012\)](#) propuseram um algoritmo para detectar a presença de fumaça usando sequências de vídeo captadas por câmeras IP (do inglês *Internet Protocol*), nas quais são empregadas características importantes de fumaça, tais como cor, movimento e propriedades de crescimento. Para uma detecção de fumaça eficiente na plataforma de câmera IP, um algoritmo de detecção deve operar diretamente no domínio da transformada discreta de cossenos para reduzir o custo computacional. No esquema proposto, em primeiro lugar nas regiões de fumaça, candidatos são estimados usando o movimento e as propriedades de fumaça cor; depois usando operações morfológicas o ruído é reduzido. Finalmente, as propriedades de crescimento das regiões de fumaça são analisadas ao longo do tempo.

[Junzhou et al. \(2013\)](#) propuseram uma combinação da técnica de diferença entre quadros baseada em blocos com padrões binários locais de três planos ortogonais LBP-TOP (do inglês *Local Binary Patterns from Three Orthogonal Planes*), para analisar as características dinâmicas da fumaça. Com o objetivo de reduzir os falsos positivos os autores criaram um histograma de imagens de fumaça para registrar os resultados de classificação de blocos candidatos a fumaça. Uma máquina de vetor de suporte (SVM) (do inglês *Support Vector Machines*) é empregada para avaliar o desempenho das características propostas na classificação de blocos candidatos a fumaça.

Como visto na maioria dos artigos, os autores estão trabalhando com detecção de fumaça em vídeos ou imagens. [Chen et al. \(2006\)](#), [Toreyin et al. \(2005\)](#), [Wang et al. \(2009\)](#) e outros au-

tores reforçam que vídeos possuem uma área maior de alcance para monitoramento, além de câmeras apresentarem custo inferior em relação a sensores, já que não é necessário utilização de câmeras de alta definição para a tarefa de detecção. A maioria dos autores utiliza vídeos com resolução de 320x240 pixels para os testes em seus algoritmos. Isto constitui vantagem sobre sensores para os quais existe o problema de a fumaça ser levada para longe em ambientes abertos, devido as ações dos ventos.

Além disso, os autores citados neste capítulo afirmam que cores e formas são duas das mais importantes características para detecção de fumaça. Afirmam também que a fumaça possui cor branca antes das chamas estarem em um estágio avançado.

Capítulo 3

Fundamentos Teóricos

3.1 Introdução

Neste capítulo serão brevemente abordados conceitos teóricos necessários para o desenvolvimento do trabalho. O Espaço de cor RGB, características da fumaça e análise estatística serão mencionados nas seções a seguir.

3.2 O espaço de cor RGB

Cor é uma propriedade importante que permite ao ser humano analisar imagens, com ou sem auxílio de técnicas computacionais. A identificação de objetos ou interpretação de uma cena podem ser simplificados utilizando cores.

O processo psicofisiológico de percepção de cores pelo cérebro humano ainda não é completamente compreendido. Os aspectos físicos da cor, estudados há muitos anos por diversos pesquisadores, podem ser definidos por uma base formal fundamentada por resultados teóricos e experimentais [Gonzalez \(2002\)](#).

A cor é percebida pelo olho humano quando a luz é refletida ou emitida por um objeto. Dessa forma, todas as sensações de cor percebidas pelo olho humano são, na verdade, combinações das intensidades dos estímulos recebidos por células fotossensíveis que compõem a retina [Pedrini et al.\(2007\)](#).

Matematicamente, o modelo de cores RGB é baseado em um sistema de coordenadas cartesianas, em que o espaço de cores é um cubo, como mostrado na Figura 3.1. As cores primárias vermelho (R, *Red*), verde (G, *Green*) e azul (B, *Blue*) estão em três vértices do cubo, as cores primárias complementares ciano, magenta, e amarelo estão em outros três vértices. O vértice junto à origem é o preto e o mais afastado da origem corresponde à cor branca.

A equação que melhor descreve o modelo RGB para cada ponto em seu espaço de cores é dada por:

$$f(x, y) = (R, G, B). \quad (3.1)$$

Onde,

R, G e $B \in [0, k]$, com k assumindo valores inteiros de 0 até 255.

No modelo RGB a escala de cinza se estende pela diagonal do cubo, ou seja, a reta que une a origem (preto) até o vértice mais distante (branco). A escala de cinza no modelo RGB é obtida pela média dos canais do modelo.




Figura 3.1: Cubo representativo do espaço de cor RGB.

3.3 Formação e cores de fumaça provenientes de incêndios florestais

A fumaça branca, que é o alvo deste trabalho, é tecnicamente conhecida como um tipo de aerossol. [Friedlander \(2000\)](#) utiliza o termo aerossol para descrever todos os sistemas de pequenas partículas suspensas no ar. Essas partículas têm geralmente o diâmetro menor que $1 \mu m$ ($1 \times 10^{-6} m$). A ciência dos aerossóis desempenha um papel chave em diferentes

campos, incluindo: ciências atmosféricas, produção industrial de pigmentos e pós metálicos e controle de contaminação em indústrias farmacêuticas e microeletrônicas.

A fumaça é formada quando há queima de material combustível por uma fonte de calor e com presença de comburentes (Urbanski et al. 2009)

Em incêndios florestais existem dois tipos de fumaça que são geradas, as quais possuem composição primária bastante similar, mas cores diferentes. De acordo com Hinds (1999) e Motta (2008), a fumaça é composta primariamente por dióxido de carbono (CO_2), vapor de água, monóxido de carbono (CO), materiais particulados, hidrocarbonetos, óxidos de nitrogênio e traços de minerais. A coluna de fumaça tem sua cor e forma determinadas por fatores como: qualidade dos combustíveis, intensidade calórica do incêndio, superfície da área ardente e estabilidade atmosférica.

Desta forma, a cor branca da coluna de fumaça indica que o material combustível tem pouco material lenhoso e apresenta alta umidade. A cor branca deve-se ao volume de vapor de água liberado na queima dos combustíveis florestais (área de vegetação contendo grande quantidade de folhagem verde). Quando a fumaça possui cor com tons de cinza mais escuros, é um indicativo de que o material combustível apresenta maior quantidade de material lenhoso (área de vegetação contendo grande quantidade de árvores sem folhas, geralmente em períodos de pouca chuva) e baixa umidade Motta (2008).

A Figura 3.2 mostra exemplos de tipos de fumaça, de acordo com o material combustível utilizado.



(a) Incêndio florestal



(b) Pneus queimando

Figura 3.2: diferentes tipos de fumaça de acordo com o material combustível.

3.4 Análise Estatística e hipóteses de pesquisa

Neste trabalho será feita uma análise estatística dos resultados obtidos nos experimentos com o algoritmo proposto. Sendo assim, faz-se necessário que alguns conceitos sejam brevemente expostos, visando facilitar entendimento posterior.

Será realizado nesse trabalho um teste de hipóteses de pesquisa visando comparar o

método D383S com métodos existentes na literatura. São definidas hipóteses de pesquisa e a partir destas hipóteses verificar se os resultados obtidos nos experimentos realizados são ou não compatíveis com as hipóteses de pesquisa. Para verificarmos se os dados estão ou não de acordo com uma das hipóteses definidas temos alguns valores que auxiliam na tomada de decisão para aceitação ou rejeição de hipóteses. *Valor-p* - O valor-p é o menor nível de significância com o qual não se rejeitaria a hipótese nula H_0 , com os dados de um determinado experimento. No caso deste trabalho, o nível de significância escolhido foi $\alpha = 0,05$, ou seja, para que a hipótese nula seja rejeitada, é necessário que o valor de p seja menor que 0,05 (Montgomery, 2002). Além disso o valor-p representa a probabilidade da diferença observada entre os tratamentos/categorias ser devido ao acaso, e não aos fatores verdadeiramente estudados.

A escolha do nível de significância do experimento, no caso deste trabalho, 95% de significância, é escolhido arbitrariamente, de acordo com a necessidade de cada experimentador e do experimento em questão. O valor de 95% é um valor amplamente utilizado na literatura Montgomery (2002).

- *Estatística de teste F* - Essa estatística indica o tamanho da diferença da variância entre grupos (variância conhecida), em relação ao tamanho da variância dentro de cada grupo (variância desconhecida) Montgomery (2002). O objetivo na análise do teste F é encontrar uma maior diferença nas médias amostrais entre grupos e conseqüentemente uma maior variância entre os grupos diferentes. No caso, se a estatística de teste F de um dado experimento for maior que uma distribuição de probabilidade já calculada, com mesmo nível de significância do experimento sendo realizado e com mesmo número de graus de liberdade no numerador e no denominador, indica diferença entre as médias dos grupos testados, rejeitando dessa forma a hipótese nula.

Tanto a estatística de teste F, quanto o *valor-p* podem ser usados para realizar uma análise estatística de um experimento, a fim de aceitar ou rejeitar a hipótese nula. Para este trabalho foram definidas duas hipóteses de pesquisa:

- H_0 - O método D383S não obteve melhor desempenho do que os métodos existentes na literatura.
- H_1 - O método D383S obteve melhor desempenho que os métodos existentes na literatura.

A análise estatística do experimento realizado neste trabalho será detalhada no capítulo de resultados.

Este capítulo apresentou uma síntese de técnicas utilizadas para detecção de fumaça, assim como um resumo dos principais fundamentos necessários para compreender o método D383S desenvolvido e analisado nos próximos capítulos.

Capítulo 4

Desenvolvimento

4.1 Introdução

Neste capítulo serão detalhadas as etapas de desenvolvimento do método proposto neste trabalho. O método proposto para detecção de fumaça será chamado de D383S. Antes do detalhamento de cada etapa da solução proposta, é importante mostrar a visão geral da solução e como as três etapas que a compõem irão interagir.

Como mostrado na revisão bibliográfica, uma das características mais exploradas para a segmentação de fumaça em vídeo é o espaço de cores. De maneira intuitiva percebemos que existem fumaças mais claras e outras mais escuras. Este trabalho será focado na fumaça clara pois esta representa a cor da fumaça no seu estágio inicial em situações de incêndios florestais.

Entretanto, esta característica sozinha não é confiável para tomada de decisão para classificação de fumaça em vídeos, devido ao fato que podem aparecer nos vídeos diversos objetos de cor similar à cor de fumaça, como nuvens, carros, etc. Segundo [Friedlander \(2000\)](#), outro fato observado é que a fumaça se move em movimento lateral e ascendente. Isso depende do referencial de onde a câmera está obtendo as imagens. Ainda sobre o movimento da fumaça, é observado que à medida que a intensidade das chamas aumenta a velocidade de movimento da fumaça aumenta. Ainda segundo [Friedlander \(2000\)](#) a área da fumaça também cresce à medida que o tempo passa, e mantém seu tamanho, ou se dispersa quando fica muito grande ou se distância do foco que gera a mesma. Usando algumas dessas observações, um sistema para detecção de fumaça foi desenvolvido.

Com o objetivo de reduzir o tamanho da área a ser analisada, bem como o número de pixels, a primeira etapa da solução busca determinar as regiões de movimento no vídeo. Isso é feito através da técnica de subtração de fundo estimada pela média adaptativa. As áreas onde foram detectados focos de movimento são mantidas para serem analisadas pela segunda etapa do sistema.

A segunda etapa da solução verifica a cor dos pixels contidos nas regiões de movimento. Essa etapa irá considerar como pixels candidatos a pixels de fumaça todos os pixels que contêm cor similar à cor de fumaça, que no caso específico deste trabalho visa detectar a fumaça gerada em regiões florestais e em estágio inicial, visando antecipar sistemas de detecção de fogo. A cor da fumaça alvo deste estudo é o tom de cinza próximo à cor branca. Nesta fase da solução é feita uma comparação: se os pixels em movimento obtidos na primeira etapa estiverem dentro de uma região do espaço RGB delimitada por esferas de contenção obtidas na segunda etapa do algoritmo, então o pixel é considerado como pixel com cor de fumaça.

A terceira e última etapa da solução consiste no agrupamento dos pixels obtidos na primeira e segunda etapa, a fim de unir em conjuntos bem definidos os pixels espalhados por toda a imagem. Nessa etapa é calculado um ponto médio para cada cluster, para verificar o movimento de cada cluster entre um quadro e outro. Se os clusters satisfizerem as regras de movimentação definidas na terceira etapa do algoritmo proposto, então o pixel é considerado um pixel de fumaça.




Figura 4.1: Fluxograma contendo a visão geral das etapas do método proposto.

A Figura 4.1 mostra o fluxograma contendo a visão geral das etapas do sistema. Cada etapa será detalhada em suas particularidades e terão também seus fluxogramas específicos.

4.2 Segmentação de movimento através de subtração de fundo

A primeira etapa para o desenvolvimento de um sistema de detecção de fumaça é segmentar e detectar objetos de interesse que estão em movimento em sequências de vídeo, diferenciando estes dos objetos estáticos. Quanto maior a qualidade com que os objetos em movimento forem extraídos, menor será o custo computacional nas etapas seguintes. A subtração de fundo é uma das primeiras etapas de processamento de imagens para sistemas de visão computacional, que consiste em separar *background* (imagem de fundo) e *foreground* (primeiro plano), ou seja, separar o que faz parte do fundo da cena e o que não faz parte do fundo da cena. Para a tarefa de segmentação de fundo existem diversos algoritmos, cada um deles com comportamentos distintos [Toreyin et al. \(2006\)](#).

A subtração de fundo é um dos métodos mais comuns de segmentação principalmente em situações em que o fundo é estático, comum em sistemas de segurança por vídeo. A subtração de fundo consiste basicamente em selecionar ou então compor um quadro que servirá como fundo da imagem, o qual não pode conter objetos em movimento ou qualquer outro tipo de objeto que não pertença ao fundo. Em seguida, é calculada a diferença pixel a pixel entre o quadro atual e o quadro de fundo. Caso esta diferença seja menor que um limiar definido, esse pixel pertence ao fundo, caso contrário, pertence ao objeto detectado [Ferreira \(2007\)](#).

Um dos objetivos principais no desenvolvimento ou na escolha de um algoritmo de subtração de fundo é que ele seja robusto em relação a algumas variáveis como: iluminação, presença de sombras, objetos em movimento, regiões com superfícies espelhadas, oscilações na câmera e mudanças na geometria do fundo. Para o método de subtração de fundo, é importante que as câmeras fiquem posicionadas de forma que não se movimentem. Movimento nos vídeos que serão processados pelo método D383S causam problemas no método de subtração de fundo como mostrado por [Truyenque \(2005\)](#) e [Ferreira \(2008\)](#).

A idéia da subtração de fundo é subtrair da imagem atual uma imagem de referência, a qual é adquirida e modelada a partir de um fundo estático durante um certo período de tempo, conhecido como período de treinamento. Assim, o fundo pode ser qualquer um, desde que permaneça razoavelmente estático. É conhecido que as torres e postes se movimentam de acordo com a ação da força dos ventos sobre suas estruturas. Dessa forma antes de detalharmos a etapa de subtração de fundo, bem como o método escolhido, é importante verificar quando a ação dos ventos na torre ou poste irá gerar grandes oscilações na câmera, caso isso aconteça, o método de subtração de fundo é prejudicado.

[Klein \(2005\)](#) mostra que em condições normais de temperatura (15°C) e de pressão ($1\text{atm} = 1,013 \times 10^5 \text{Pa}$), a pressão dinâmica do vento é obtida por:

$$q = 0,613V_k^2 \quad \text{sendo } q \text{ em } \text{N/m}^2, V_k \text{ em } \text{m/s} \quad (4.1)$$

Sendo:

V_k - velocidade característica.

A velocidade característica do vento V_k , é obtida pela multiplicação da velocidade básica V_0 pelos fatores S_1 , S_2 e S_3 , então:

$$V_k = V_0 S_1 S_2 S_3 \quad (4.2)$$

Sendo:

S_1 , S_2 e S_3 são fatores topográficos, que variam de acordo com o relevo do terreno onde a torre se encontra.

Novamente Klein (2005), diz que a velocidade básica do vento V_0 , é a velocidade de uma rajada de três segundos, a 10 metros acima do terreno onde a torre está instalada. Ela ainda mostra que a determinação da velocidade básica do vento V_0 , foi obtida através de análise estatística, levando em consideração as velocidades máximas anuais de 49 cidades do Brasil, entre os anos de 1954 e 1974. No Brasil a velocidade básica do vento V_0 varia entre 30 e 50 m/s, sendo que valores inferiores a 30 m/s não causam impactos em torres de transmissão de energia elétrica segundo NBR-6123.

Os estudos de Klein (2005), Oliveira (2006) e Jens (1984) mostram que o deslocamento médio nas pontas das torres de transmissão (ponto mais alto da torre) é de 40 mm. E a frequência de oscilação média no topo de uma torre de transmissão de energia é de 0,6 Hz. De acordo com os dados obtidos sobre a movimentação das torres de transmissão, a amplitude de deslocamento das mesmas juntamente com a baixa frequência de oscilação não irão trazer problemas para o algoritmo de subtração de fundo, já que o algoritmo aceita pequenas movimentações nas sequências de vídeos analisados. Outro fator importante é que as câmeras não serão instaladas no topo das torres de transmissão, sendo assim esses valores de deslocamento e frequência de oscilação das torres de transmissão diminuem nas partes mais baixas da estruturas.

Agora que é conhecido que o deslocamento das torres de transmissão não irá causar problemas no processamento da técnica de subtração de fundo, podemos escolher uma dentre diversas técnicas de subtração de fundo existentes na literatura. Algoritmos de subtração de fundo são utilizados com muita frequência na literatura, com o objetivo de detectar objetos em movimento. Stauffer et al., (1999) propuseram um algoritmo que lida com múltiplos modelos de fundos, essa proposta é conhecida como mistura de gaussianas, onde cada pixel pode ser modelado por uma mistura de três a cinco gaussianas.

Kim et al. (2004) apresentaram um método chamado *Codebook*. Esse algoritmo permitiu a construção de um modelo de fundo a partir de longas sequências de vídeo. Haritaoglu et al. (2000) propuseram o método W4, que faz a subtração de fundo baseada em estatísticas de uma distribuição normal. O trabalho tem bons resultados publicados, mas o autor descarta informações fornecidas pelas cores e trabalha somente com a luminância presente nas imagens. Isso faz com que o algoritmo não segmente objetos escuros ou de luminância similar à do modelo de fundo.

Piccardi (2004) publicou uma revisão de literatura de diversas técnicas de subtração de

fundo, analisando o desempenho e consumo de recursos computacionais de cada uma delas. Dentre as técnicas de subtração de fundo analisadas, o autor destaca a técnica de subtração de fundo estimado pela média adaptativa como a técnica com melhor desempenho e menor custo computacional.

Com base nos estudos de (Piccardi, 2004), o algoritmo escolhido para a primeira etapa do sistema de detecção de fumaça em vídeos foi o algoritmo de subtração de fundo estimado pela média adaptativa. Esta técnica foi proposta por Donohoe et al. (1988), que desenvolveram um formato adaptativo para criar o modelo de fundo de uma sequência de imagens. Neste algoritmo é utilizada uma taxa α que determina quanto o quadro atual i exerce influência no modelo de fundo atual. O modelo de fundo B_i é inicializado com o primeiro quadro e os próximos quadros atualizam o modelo conforme a equação 4.3, onde $\alpha \in (0, 1)$ e i é o número de quadros do vídeo.

$$B_i(x, y) = \begin{cases} f_{i-1}(x, y), & \text{se } i = 2; \\ (1 - \alpha)B_{i-1}(x, y) + \alpha f_{i-1}(x, y), & \text{se } i > 2; \end{cases} \quad (4.3)$$

Para identificar a região de interesse ou alvo que não pertença ao fundo é determinado um limiar τ e então é feito o cálculo da diferença do quadro atual e do quadro calculado como quadro de fundo (*background*). A equação 4.4 apresenta como é realizado este cálculo, em que $A_i(x, y)$ é o alvo a ser identificado, $f_i(x, y)$ é o quadro atual e $B_i(x, y)$ é o fundo atual. O resultado do processo de segmentação para o i -ésimo quadro de entrada $A_i(x, y)$ será 1 (um) para cada pixel de $A_i(x, y)$, se a diferença entre o quadro atual e o fundo for maior que um limiar previamente definido τ , ou 0 (zero), caso contrário. Essa diferença é calculada pixel a pixel nos quadros do vídeo.

$$A_i(x, y) = \begin{cases} 1, & \text{se } |f_i(x, y) - B_i(x, y)| > \tau; \\ 0, & \text{caso contrário;} \end{cases} \quad (4.4)$$

O parâmetro τ é o limiar da subtração de fundo. É necessário que esse parâmetro seja previamente ajustado de acordo com a resolução e características específicas do vídeo em questão e do ambiente a ser analisado.

Da mesma forma deve ser feito com o parâmetro α : caso α seja definido com um valor muito próximo a 0 (zero), o fundo se adapta muito lentamente às alterações no cenário, ou seja, o cenário pode ser modificado e o modelo do fundo pode não corresponder a esse cenário, podendo dessa forma levar o algoritmo a detectar falsos positivos por um longo período de tempo. Já quando α é definido com um valor muito próximo de 1 (um), o fundo irá se adaptar rapidamente às alterações no cenário e essa velocidade na adaptação pode

fazer com que partes dos alvos sejam perdidas por serem rapidamente consideradas como partes integrantes do fundo.

Os valores de α e τ foram determinados experimentalmente através de testes em vídeos com e sem imagens de fumaça, em ambientes externos e internos. Não existem valores padrão para os parâmetros envolvidos na subtração de fundo, essa questão também foi abordada em (Dedeoglu, 2004) e (Collins et al., 2000).

Na figura 4.2 é possível visualizar o fluxograma ou diagrama de blocos da primeira etapa de desenvolvimento do método D383S, que é a fase de subtração de fundo.

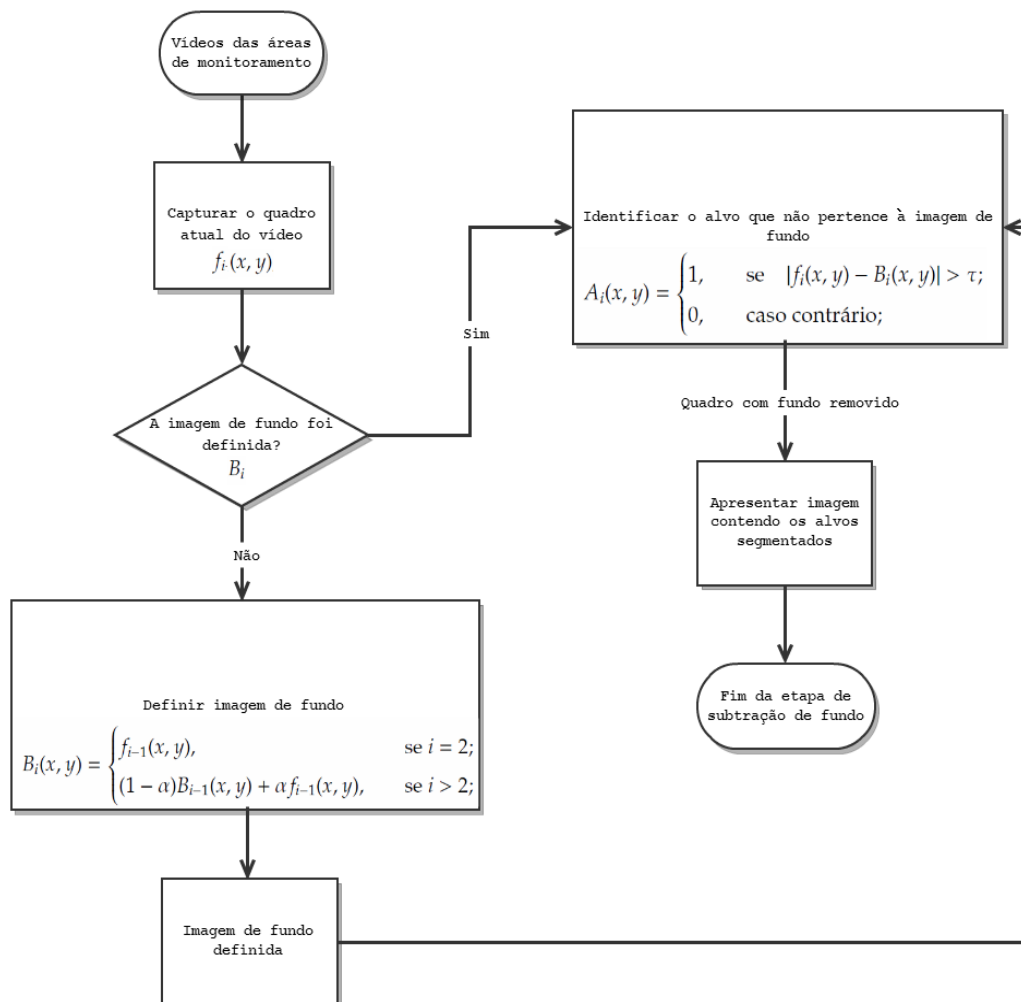


Figura 4.2: Fluxograma da etapa de subtração de fundo estimada pelas médias adaptativas.

A figura 4.3 mostra o resultado de testes com o algoritmo de subtração de fundo, variando os valores de α e deixando fixo o valor do limiar $\tau = 50$.




Figura 4.3: Exemplo de segmentação variando os valores de α . Cada linha mostra os resultados da variação de α para cada vídeo. Para $\tau = 50$

Percebe-se que à medida que o valor de α se aproxima de 1 (um) o fundo é atualizado rapidamente e as alterações no cenário são consideradas parte do fundo. Em alguns vídeos a partir do valor de $\alpha = 0,3$, já não são detectados alvos em movimento. Já com o valor de α próximo de 0 (zero) como no caso de $\alpha = 0,0075$ no vídeo 2 o homem que aparece nas imagens é detectado pelo algoritmo de subtração de fundo, bem como a fumaça em movimento. A próxima etapa do método D383S elimina falsos positivos detectados pelo algoritmo de subtração de fundo, através da classificação das cores dos pixels. Esse assunto será tratado na próxima seção deste capítulo.

A Figura 4.4 mostra o resultado dos testes da subtração de fundo em vídeos, variando os valores do limiar da subtração de fundo τ e mantendo o parâmetro α fixado em 0,0075.




Figura 4.4: Exemplo de segmentação variando os valores de τ . Cada linha mostra os resultados da variação de τ para cada vídeo.

4.3 Classificação dos pixels em cor de fumaça

A próxima fase do sistema de detecção de fumaça é fazer com que os pixels em movimento detectados através de subtração de fundo na primeira etapa sejam classificados quanto às suas cores. No nosso caso os pixels são classificados ou não como pixels de cor de fumaça.

A técnica escolhida para classificação das cores dos pixels foi o algoritmo das k-médias. Proposta por MacQueen (1967), é uma técnica de aprendizado não-supervisionado que busca classificar um determinado conjunto de dados através de um número k de *clusters* definidos a priori pelo usuário da técnica. O objetivo principal é definir k centróides, sendo que esses centróides devem ser posicionados de forma que eles fiquem o mais distante possível uns dos outros. O próximo passo do algoritmo é associar os diversos pontos do conjunto de dados, no nosso caso são os pixels selecionados na primeira etapa, com o centróide mais próximo. Quando não houver mais nenhum ponto sem estar associado a um centróide, então a primeira iteração está feita.

Agora é necessário recalculer k novos centróides como pontos centrais dos *clusters* obtidos com o primeiro passo do algoritmo. Após calcular todos os k novos centróides, uma nova associação deve ser feita entre os mesmos pontos do conjunto de dados e o novo centróide mais próximo. Dessa forma, ocorre uma repetição desse passo. Como resultado dessa repetição, os k centróides mudam sua localização, passo a passo até que nenhuma modificação no conjunto de dados seja necessária. Nesse caso os centróides não irão mais se mover.

Esse algoritmo busca minimizar a função objetivo, neste caso a função do erro médio quadrático. A função objetivo é dada pela equação 4.4

$$J(c) = \operatorname{argmin} \sum_{i=1}^k \sum_{j=1}^n \|x_i^j - c_i\|^2 \quad (4.4)$$

Onde,

$\|x_i^j - c_i\|^2$ é a distância euclidiana entre x_i^j e c_i .

k é o número de centros dos k *clusters*.

n é a quantidade de dados contidos no i -ésimo *cluster*.

x_i^j é o i -ésimo ponto do i -ésimo *cluster*.

c_i é o centro do i -ésimo *cluster*.

Após obter os conjuntos e seus determinados centróides são geradas esferas de contenção, onde o raio da esfera se baseia no desvio padrão dos pixels contidos no conjunto, mais a posição do centróide do conjunto sendo o centro da esfera. Com esse modelo a maior parte dos pixels fica incluso dentro das esferas e variando o numero de centróides ou conjuntos é

possível ajustar a área de detecção dos pixels de fumaça.

Por fim, um pixel é considerado como pixel com cor de fumaça se:

$$D(P_{x,y}, C_k) < R_k \quad (4.5)$$

Onde,

$P_{x,y}$, é a localização do pixel no espaço de cores.

C_k é o centróide k.

R_k é o raio da esfera de contenção.

$D(P_{x,y}, C_k)$ é a distância do pixel até o ponto central do centróide mais próximo.

Neste trabalho foram utilizadas 30 esferas de contenção. Esse número foi necessário, pois conteve a maioria dos pixels de fumaça no espaço RGB. Utilizar mais esferas gera maior complexidade computacional ao sistema, pois temos mais regiões de contenção a serem verificadas, sem que haja melhoria relevante na classificação por cor.

O espaço de cor RGB representa de forma completa as características de cor da fumaça, já que na fumaça as cores predominantes estão na escala de cinza do espaço RGB. De acordo com [Damir et al. \(2009\)](#) em seu trabalho que também busca resolver o problema de detecção de fumaça, ele utiliza o classificador de Bayes para detecção de fumaça como o primeiro nível de classificação e em segundo nível ele utiliza informação contida nos espaços de cores. Ele testou o desempenho do seu classificador associado a cinco espaços de cores diferentes e chegou à conclusão que os espaços de cores RGB e HSI são os espaços de cores que apresentaram melhor resultado para detecção de fumaça, com uma leve vantagem para o espaço RGB em alguns testes.




Figura 4.5: Pixels de cor de fumaça no espaço RGB

A Figura 4.5 mostra os pixels de fumaça alvo deste trabalho no espaço RGB. Os pixels que estão contidos nas esferas de contenção nesta imagem, não foram obtidos com imagens da base de dados de teste, mas sim de uma base de dados de treinamento, composta por 50 imagens contendo fumaça. Essas imagens foram segmentadas manualmente, para fornecer ao classificador somente imagens com fumaça, separando a fumaça de outros objetos na imagem. A Figura 4.6, mostra exemplos de imagens segmentadas manualmente.




Figura 4.6: Exemplo de Imagens segmentadas manualmente, para treinamento do classificador.

A Figura 4.7 mostra o fluxograma do algoritmo das k-médias.

A Figura 4.8 mostra algumas imagens do conjunto de treinamento.

A Figura 4.9 mostra o resultado da segmentação de pixels do conjunto de imagens retiradas dos vídeos de teste, utilizando as regra de verificação dos pixels dentro das esferas de contenção. As regiões em vermelho foram as regiões segmentadas.

Para comparar os resultados obtidos com a segmentação realizada com a técnica do algoritmo das k-médias, foi feito um experimento realizando uma segmentação utilizando limiares simples nas três coordenadas do espaço RGB, resultando em um volume na forma de um paralelepípedo para separar os pixels de fumaça no espaço RGB, como pode ser visto na Figura 4.10. A utilização do paralelepípedo para separar os pixels, equivale a utilização de limiares, como apresentado em diversos artigos como no artigo de [Chen et al. \(2006\)](#) e [Tung and Kim \(2011\)](#). A Figura 4.11 mostra o resultado da segmentação retangular do conjunto de imagens retiradas dos vídeos de teste. As regiões em azul foram as regiões segmentadas. É possível perceber que cores que não estão na escala de cinza foram segmentadas, como no o exemplo do vídeo 7 da figura 4.11, onde um muro teve regiões segmentadas. Isso se deve ao fato de que a separação dos pixels de fumaça no espaço utilizando um paralelepípedo, gera uma área maior de busca, fazendo com que pixels que não têm cor de fumaça, também seja segmentados pelo classificador.

É possível ver uma diferença significativa entre as duas formas de segmentação. Já que utilizando a técnica do algoritmo das k-médias segmentou-se com mais precisão a fumaça mais clara, objetivo deste trabalho. E na segmentação com limiar retangular (cubo), houve segmentação de regiões onde a fumaça é mais escura, o que nesse caso não é objetivo desse trabalho. Selecionar um número maior de pixels de fumaça que não são a fumaça alvo de detecção para a terceira etapa do sistema de detecção de fumaça, gera mais custo

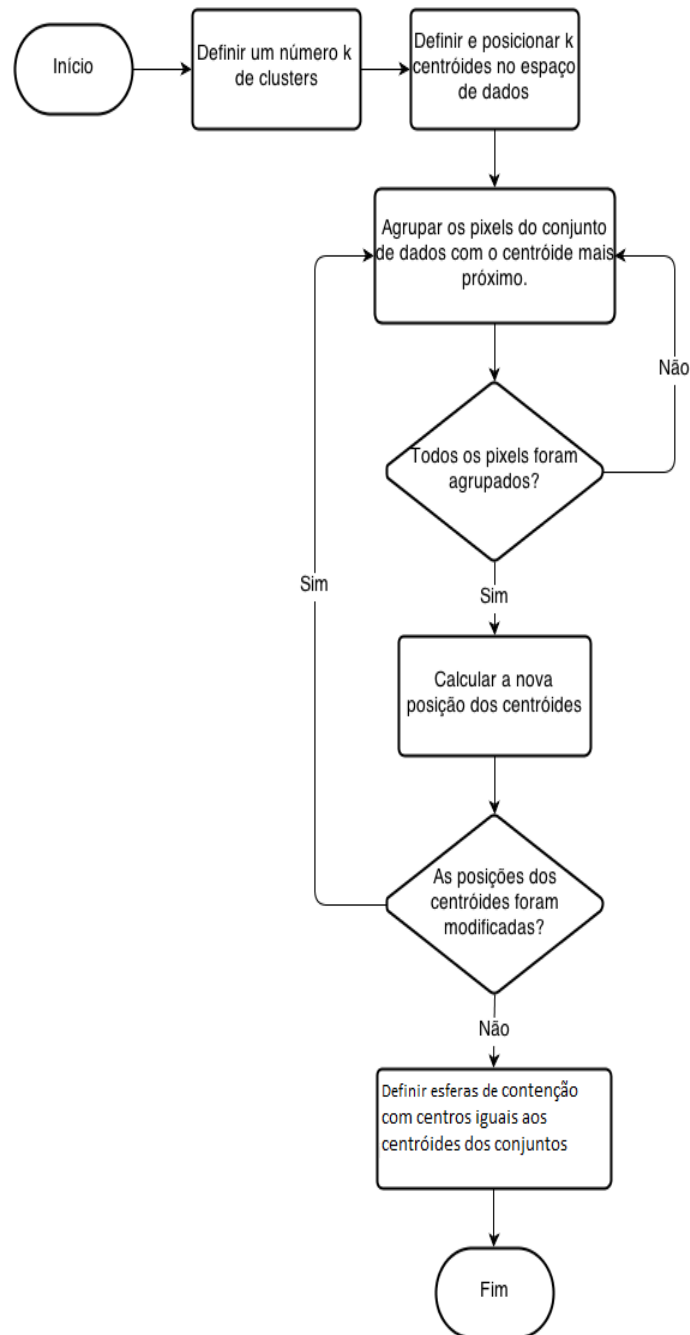


Figura 4.7: Fluxograma detalhando as etapas do algoritmo das k-médias.

computacional para a etapa de agrupamento dos pixels. A utilização do algoritmo das k-médias, reduziu o espaço de busca, fazendo com que a área a ser comparada tenha somente os pixels com cor de fumaça que são os pixels da fase inicial do incêndio.

4.4 Análise dos pixels de fumaça para realização da persistência espacial e temporal

Nesta seção será descrita a terceira e última etapa do algoritmo de detecção de fumaça, onde serão avaliadas as características espaciais e temporais dos pixels de fumaça. Segundo

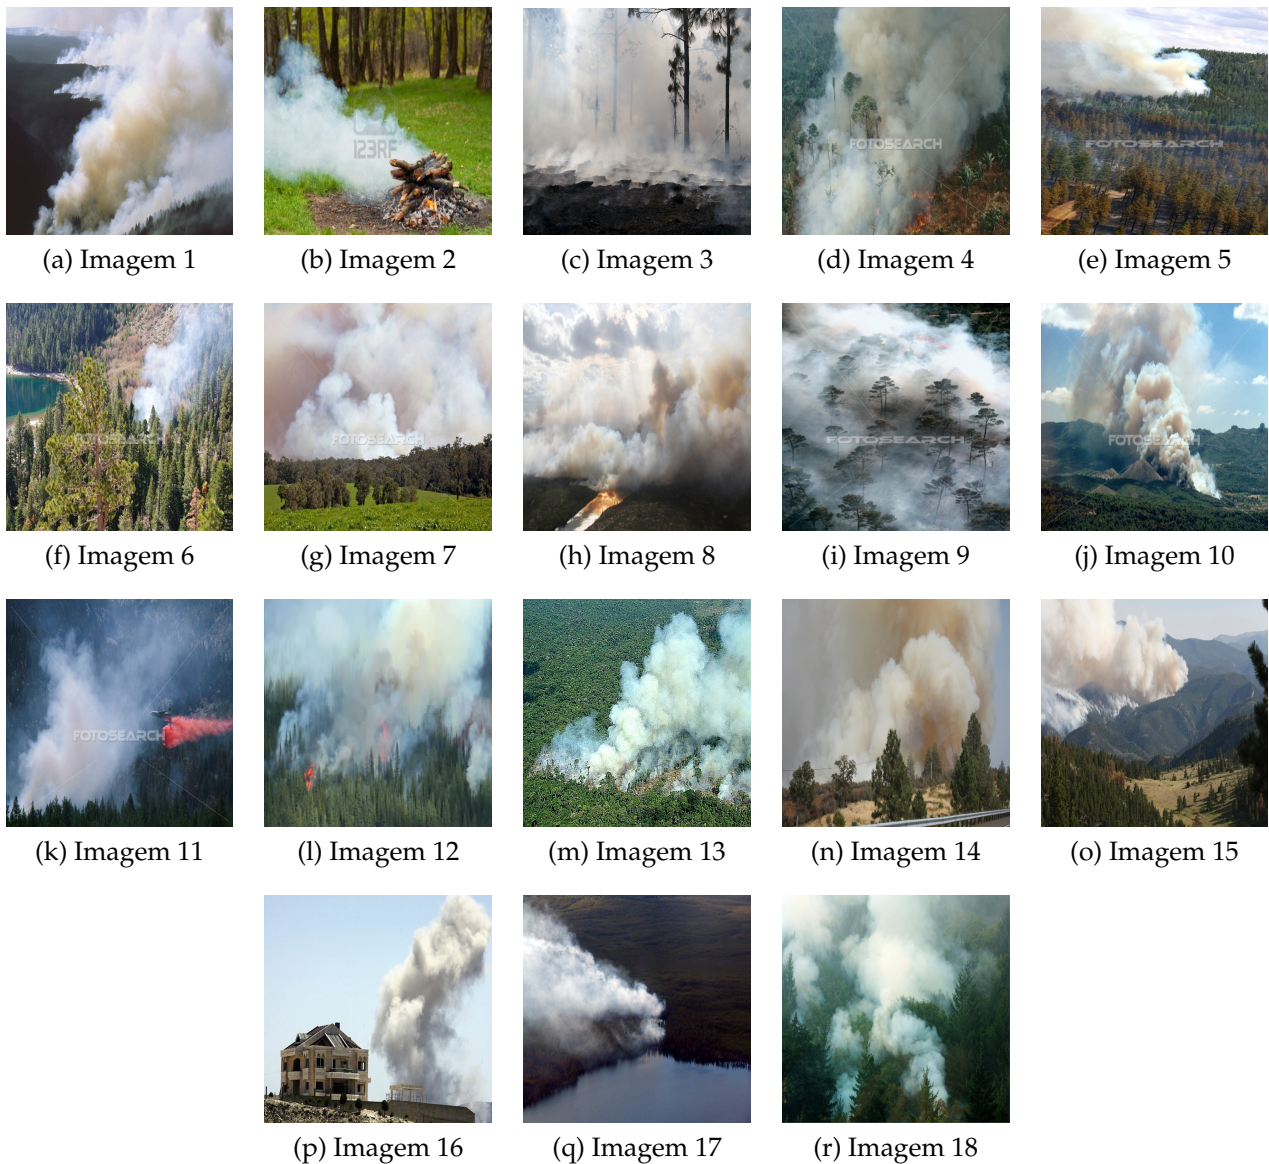


Figura 4.8: Algumas imagens do conjunto de treinamento.

[Tung and Kim \(2011\)](#), [Chunyu et al. \(2010\)](#), [Wei et al. \(2009\)](#) e [Toreyin et al. \(2005\)](#), quando a fumaça aparece, ela sobe de uma posição estável na tela, flutuando para cima de maneira difusa. A área, tamanho e número de regiões de fumaça são variadas e mudam de quadro a quadro e a superfície e bordas das regiões da fumaça são irregulares. Segundo estes autores, estas características são necessárias para separar objetos que tenham cor de fumaça e estão em movimento da fumaça verdadeira.

Com o conhecimento dessas características, um novo modelo foi elaborado utilizando movimento e existência temporal da fumaça para o método D383S.



Figura 4.9: Quadros dos vídeos de teste e resultado da segmentação realizada utilizando a área delimitada pelas esferas de contenção destacado na cor vermelha.




Figura 4.10: Pixels com cor de fumaça no espaço RGB, delimitados por um paralelepípedo

4.4.1 Agrupamento dos pixels com cor de fumaça

Para utilização das características espaciais e temporais ao longo dos diversos quadros sem que haja aumento no custo computacional, é necessário obter algum tipo de informação que

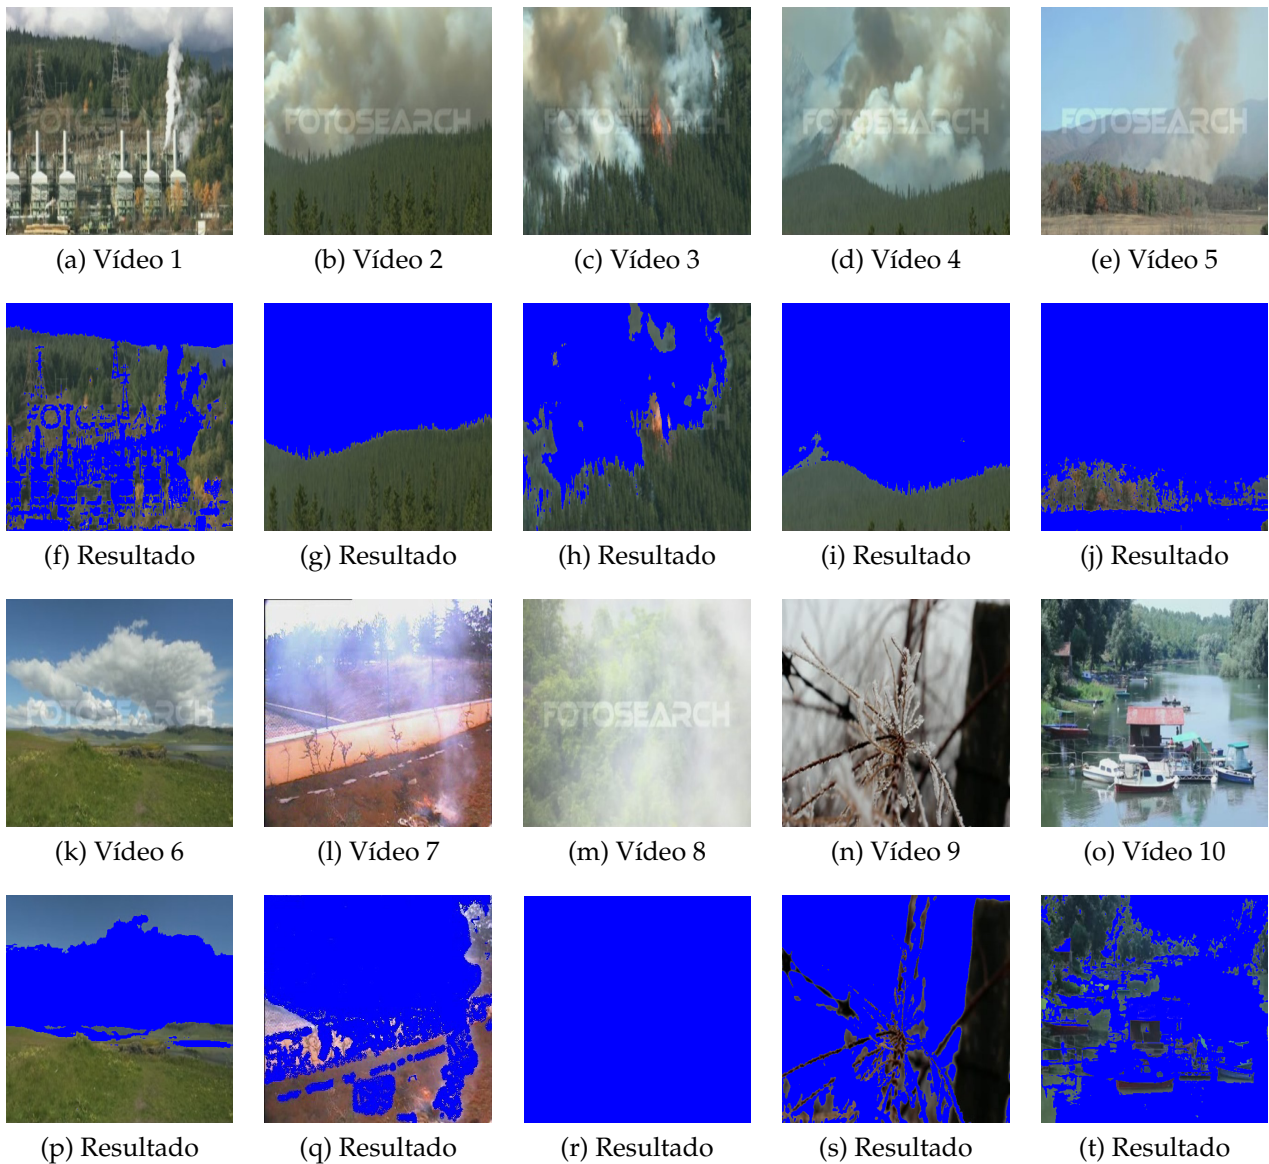


Figura 4.11: Quadros dos vídeos de teste e resultado da segmentação utilizando-se a área delimitada pela região retangular destacado na cor azul. Equivale a utilização de limiares simples.

possa ser usado ao longo do tempo. Desta forma um modelo de rastreamento dos objetos com cor de fumaça foi elaborado, onde os pixels classificados nas duas etapas anteriores, são primeiramente separados em *clusters* distintos e em seguida serão extraídas as características espaciais e temporais de cada *cluster*, onde cada cluster é um conjunto de pixels com cor de fumaça. Os *clusters* espaciais mencionados nessa etapa são diferentes dos clusters no espaço de cores da etapa anterior.

Para separação dos *clusters* ou grupos, foi utilizada uma técnica de agrupamento que se ajusta às características do problema, que necessita que o algoritmo de agrupamento escolhido seja rápido e que não necessite de um número de grupos especificados previamente, pois não é possível saber quantos objetos com cor de fumaça irão ocorrer em uma cena. Desta forma, algoritmos que necessitam de um parâmetro que determina número de grupos, como

o algoritmo das k-médias, não podem ser usados nesta etapa.

A técnica de agrupamento utilizada nesta etapa foi a estrutura de dados conjuntos disjuntos. Segundo [Cormen et al. \(2002\)](#) um conjunto é dito disjunto quando ele não possui nenhum elemento pertencente a outro conjunto, ou seja, não possui interseção com outros conjuntos. Este algoritmo é um tipo de algoritmo de união-procura (*union-find*) [Cormen et al. \(2002\)](#).

A biblioteca OpenCV especializada em visão computacional utilizada no desenvolvimento deste trabalho utiliza florestas de conjuntos disjuntos para resolver o problema de separação de vários grupos, onde uma floresta é composta por uma coleção de árvores binárias $S = S_1, \dots, S_k$, onde cada árvore binária gerada pelo algoritmo representa um conjunto disjunto. Este algoritmo de união-procura é composto por três operações:

- *Make-set* (criar conjunto) - Esta operação cria um novo conjunto para cada objeto do espaço. No nosso caso a técnica cria um conjunto para cada pixel, onde cada pixel será o representante inicial do seu grupo. Sendo cada grupo unitário inicialmente.
- *Union* (união) - Esta operação realiza a união de dois conjuntos. Esta operação é realizada quando um membro de um conjunto está contido em outro em outro conjunto. Esta operação reduz o número de conjuntos no espaço.
- *Find-set* (procura-conjunto) - A última operação procura e retorna o endereço de memória (ponteiro) do representante do grupo (pai) sendo avaliado.

Ainda existem duas heurísticas aplicadas à florestas de conjuntos disjuntos, visando melhorar o desempenho do algoritmo. Essas heurísticas são a união por ordenação (ordem ou *rank*) da árvore e a compressão de caminho ([Cormen et al., 2002](#)).

A união por ordenação, faz com que a árvore com menor número de nós aponte para a raiz da árvore com maior número de nós, fazendo com que a árvore menor seja anexada à maior. Nesta técnica a ordem ou *rank* da árvore binária é incrementada somente quando houver união de duas árvores de mesma altura. A ordem inicial das árvores quando os conjuntos são criados é 0, assim uma árvore binária com apenas um elemento possui ordem=0.

A compressão de caminho é utilizada durante a operação procura-conjunto, fazendo com que cada nó percorrido na procura da raiz aponte diretamente para a raiz. A compressão de caminho não altera a ordem da árvore binária.

O pseudocódigo abaixo especifica a implementação do algoritmo, onde o pai de um nó x é representado por $p * x$. O procedimento conexão (*Link*), é uma sub-rotina chamada pela

operação de união, que faz a operação de atualização do nó pai e o valor da ordem deste nó pai, quando necessário para as diferentes árvores.

Pseudocódigo de florestas de conjuntos disjuntos:

1: *CRIAR – CONJUNTO*(*Pixelx*)

2: $p * x = x$;

3: $ordem[x] = 0$;

1: *UNIÃO*(*Pixelx*, *Pixely*)

2: *CONEXÃO* (*PROCURA – CONJUNTO*(*Pixelx*), *PROCURA – CONJUNTO*(*Pixely*));

1: *CONEXÃO* (*Pixelx*, *Pixely*)

2: **se** $ordem[x] > ordem[y]$ **então**

3: $p * y = x$;

4: **senão**

5: $p * x = y$;

6: **se** $ordem[x] == ordem[y]$ **então**

7: $ordem[y] \leq ordem[y] + 1$;

8: **fim se**

9: **fim se**

Pseudocódigo da operação *PROCURA-CONJUNTO* com compressão

1: *PROCURA – CONJUNTO*(*Pixelx*)

2: **se** $x \neq p * x$ **então**

3: $p * x = \text{PROCURA – CONJUNTO}(p * x)$; **retorne**

4: $p * x$;

5: **fim se**

O procedimento procura-conjunto é um procedimento de duas passagens: ele efetua uma passagem para cima no caminho de localização, a fim de encontrar a raiz, e depois faz uma segunda passagem de volta para baixo no caminho de localização, com o objetivo de atualizar cada nó, de modo que aponte diretamente para a raiz. Cada chamada de procura-conjunto retorna $p[x]$ (Fiorio and Gustedt, 1996), (Cormen et al., 2002).

A biblioteca de visão computacional utilizada neste trabalho, faz uma varredura em todos os nós das árvores, no nosso caso os pixels, para fazer a comparação de igualdade. A função de comparação de igualdade usada pela biblioteca é a distância euclidiana quadrada

ou absoluta. Assim, pixels serão integrantes de um mesmo conjunto disjunto se a distância euclidiana entre eles for menor que um limiar previamente definido. Por exemplo, se o limiar para comparação de igualdade for igual a 10, os conjuntos disjuntos serão formados por pixels com distância euclidiana menor ou igual a 10.

Abaixo o pseudocódigo da função de igualdade utilizada pelo OpenCV (*Open Source Computer Vision Library*):

```
1: IGUALDADE( $\beta$ )
2: para cada par de nós ( $Pixelx, Pixely$ )
3: se ( $pixelx \neq pixely$ ) e  $d(pixelx, pixely) < \beta$  então
4:   União( $pixelx, pixely$ );
5: fim se
6:
```

Onde,

β , é um limiar de distância para agrupamento, sendo definido empiricamente pelo usuário, de acordo com o contexto do problema.

$d(pixelx, pixely)$, é a distância euclidiana quadrada entre os nós ou pixels x e y .

Neste trabalho o limiar de distância para agrupamento foi ajustado empiricamente de acordo com a resolução de cada vídeo testado.

A Figura 4.12 mostra os pixels de fumaça agrupados na terceira etapa do algoritmo. Cada pixel carrega uma medida de distância em metros na cena, possibilitando a medição da distância entre objetos ou *clusters* a serem considerados conjuntos disjuntos. A cada conjunto disjunto criado, no caso o *cluster*, é atribuída uma cor diferente.




Figura 4.12: Grupos obtidos na etapa de agrupamento. (a) Imagem original, (b) Agrupamento dos diferentes focos de fumaça, utilizando os pixels classificados pelas etapas anteriores. Cada cor representa um objeto diferente que será monitorado. Ainda na figura (b) exemplos de grupos destacados, que são eliminados com o limiar de tamanho mínimo do grupo.

Para evitar pequenos grupos de pixels que são oriundos da primeira etapa do algoritmo, devido a ruído nas imagens, e que podem gerar falsos positivos, é necessário tratá-los nesta etapa do algoritmo.

Para remover esses pequenos grupos de pixels, destacados na imagem 4.12, foi criado um limiar de tamanho mínimo do grupo β_{min} . Esse limiar restringe o número de pixels do grupo. O limiar é definido empiricamente, de acordo com a resolução de cada vídeo testado. Para que um conjunto disjunto seja considerado como um resultado válido desta fase do algoritmo (fase de agrupamento) deve respeitar também a regra 4.6. Çelik et al. (2007) abordaram este problema, onde ele afirma que os grupos de pixels obtidos em um vídeo de resolução de 176x144 pixels, devem ter o tamanho mínimo de 5 pixels. Valor este que foi utilizado nos testes do algoritmo proposto neste trabalho (D383S) para vídeos com resolução de 160x120 pixels e incrementado linearmente para vídeos com maior resolução.

$$S_i \in \mathbf{S}, \text{ se número de elementos de } S_i \geq \beta_{min} \quad (4.6)$$

Onde,

S_i , é um conjunto disjunto.

\mathbf{S} , é o grupo de conjuntos disjuntos.

Com os grupos obtidos, serão avaliadas as características espaciais e temporais de cada

grupo, que serão detalhadas na próxima seção.

4.4.2 Características espaciais e temporais

Com os grupos obtidos através das regras descritas na seção 4.4.1, vamos tratar primeiro as informações espaciais. Cada grupo tem o ponto médio aritmético de suas coordenadas calculado. Esse valor do ponto médio de cada grupo será chamado de P_m . A partir de P_m , é definido o quanto cada grupo pode se mover, através do parâmetro de limiar de movimento do grupo, que é chamado de β_{mov} . Este valor é dado em pixels e é usado nas duas dimensões da cena (largura e altura), gerando uma caixa de contenção ao redor do grupo, permitindo avaliar e estimar o quanto um objeto se movimenta na cena. Em Çelik et al. (2007) foi criada uma área de observação retangular em volta dos objetos na cena, com 2 vezes o valor da altura e largura do grupo, para compensar o movimento dos objetos. O valor deste limiar foi ajustado de acordo com os testes com os vídeos que compõem a base dados do experimento. De acordo com a resolução do vídeo e com o contexto do problema, um valor deve ser definido. Para um vídeo de resolução de 320x240 pixels, o valor do limiar foi $\beta_{mov} = 50$.

Esta metodologia permite que um grupo se desloque em uma área razoavelmente grande da cena ao longo do tempo, característica essa necessária devido ao movimento de expansão da fumaça. Esta metodologia é usada por Çelik et al. (2007), e ainda permitindo que possam ser excluídos da cena objetos que se movam linear e rapidamente, como uma pessoa ou um carro.

Para a análise temporal dos objetos, foi usado um conceito baseado no algoritmo de colônia de formigas. Vale lembrar que não está sendo implementado aqui nesta etapa o algoritmo de colônia de formigas, mas somente o conceito de temporalidade presente na técnica. Dorigo (1999), mostrou que é possível criar novas técnicas para resolução de problemas, observando comportamento de insetos em suas colônias.

A técnica ACO (*Ant Colony Optimization*) ou otimização com colônia de formigas, foi proposta por Dorigo (1992) baseada na observação do comportamento das formigas que procuram o menor caminho entre a colônia e a fonte de comida, utilizando um modelo em que cada formiga deposita feromônio pelo caminho que ela utilizou, formando assim uma trilha de feromônios que serão seguidas por outras formigas.

Em Dorigo (1999) experimentos realizados com formigas em situações com caminhos longos e curtos entre a colônia e a fonte de alimento, mostram o mecanismo de funcionamento dos feromônios, em que formigas que escolhem o caminho mais curto, conseguem fazer viagens mais rápidas e como consequência mais feromônios são depositados neste caminho, enquanto que o caminho mais longo tem um número menor de viagens e em conjunto com

a evaporação dos feromônios, se torna cada vez menos utilizados pelas formigas, sendo descartado posteriormente.

Com base nestes trabalhos, duas variáveis temporais baseadas no comportamento de depósito e evaporação de feromônios foram adicionadas ao algoritmo D383S e serão utilizadas juntamente com as características espaciais da fumaça, onde cada grupo registrado nos quadros passados são análogos a um caminho da técnica de colônia de formigas.

Como uma coluna de fumaça tem um tempo de duração e movimento, existe similaridade com o experimento de colônia de formigas, em que a fumaça que está se movimentando dentro de uma área em torno do combustível irá provocar um contínuo depósito de feromônios, que serão chamados neste trabalho de variável de existência ou Vex , permitindo que a cada quadro a Vex do grupo que forma a fumaça seja incrementada, assim como ocorre no caso do caminho curto das formigas. Para objetos com cor de fumaça e movimento linear ao longo da cena, como pessoas ou carros, os grupos gerados por estes objetos terão um incremento menor da Vex ao longo do tempo, não sendo capazes de superar a evaporação da variável de existência e evitando assim possíveis falsos positivos gerados por esses objetos. Estes tipos de objetos possuem similaridade com o caminho longo do experimento das formigas, onde há um depósito menor de feromônios. A evaporação da Vex será controlada pela taxa de atualização ou Vat dos grupos.

Sendo assim, uma matriz foi gerada, onde serão guardadas as informações relevantes de cada grupo detectado ao longo do tempo no vídeo. Cada entrada desta matriz (M) representa um grupo de pixels detectado e agrupado anteriormente S_i , contendo as seguintes informações: ponto médio do grupo Pm , existência Vex e atualização Vat .

A variável Vex contém a informação do tempo em quadros que o grupo está sendo capturado e persistido segundo suas características temporais e espaciais, enquanto a Vat informa a quantos quadros o grupo não recebe uma atualização.

Para que Vex seja incrementada, é necessário que o objeto na cena esteja se movimentando dentro de uma área determinada pelo parâmetro β_{mov} . Dessa forma cada grupo no quadro atual, terá o seu ponto médio Pm_s subtraído do ponto médio de grupos anteriores Pm_i que estavam em quadros anteriores e estão contidos em (M). Caso o valor absoluto desta diferença esteja dentro da área delimitada por β_{mov} , Pm_i será atualizado para o novo valor contido em Pm_s , indicando que esse grupo é o mesmo grupo do quadro anterior e seu ponto médio alterou (indica movimento do objeto) e sua V_{exi} incrementada e sua V_{ati} zerada.

Caso nos quadros anteriores não exista nenhum grupo com Pm_i próximo ao grupo do quadro atual, significa que esse é um grupo diferente e uma nova entrada em (M) é criada

com o seu Pm_{n+1} , recebendo o valor de Pm , $Vex_{n+1} = 1$ e $Vat_{n+1} = 0$, onde n é o número total de entradas de (M).

Abaixo o pseudo-código, que auxilia no entendimento da técnica utilizada, utilizado como entrada o resultado do algoritmo de agrupamento.

```

1: ATUALIZA-M-Vex( $S, \beta_{mov}, M$ )
2:  $m = tamanho(S)$ ;
3: para  $h \leftarrow 1$  até  $m$  faça
4:    $Pm_S =$  calcula média ( $S_h$ );
5:    $existe = 0$ ;
6:    $n = tamanho(M)$ ;
7:   enquanto  $i \leq n$  até  $n$  faça
8:     se  $|Pm_S - Pm_i| < \beta_{mov}$  então
9:        $Pm_i = Pm_S$ ;
10:       $Vex_i = Vex_i + 1$ ;
11:       $Vat_i = 0$ ;
12:       $existe = 1$ ;
13:      Interrompa;
14:     fim se
15:   fim enquanto
16:   se  $existe \neq 1$  então
17:      $Pm_{n+1} = Pm_S$ ;
18:      $Vex_{n+1} = 1$ ;
19:      $Vat_{n+1} = 0$ ;
20:   fim se
21: fim para

```

Para que um grupo seja classificado como fumaça, ele deverá ter um valor de existência, que será controlado por um limiar de persistência temporal e espacial $Vper$. Este limiar é dado em quadros. Quando um grupo ultrapassa esse limiar, esse grupo é persistido temporal e espacialmente, gerando outra regra de classificação para o algoritmo D383S, abaixo a definição da regra:

$$P_{Si} = \begin{cases} 1, & \text{se } Vex_i > Vper; \\ 0, & \text{caso contrário;} \end{cases} \quad (4.7)$$

Onde,

P_{Si} é uma variável que terá valor 0 ou 1 dependendo se a regra de persistência for satisfeita.

Ao fim do processamento de cada quadro, o parâmetro Vat recebe um incremento de valor 1. Dessa forma se um grupo esteve sempre existindo, sua Vat sempre terá valor igual a 1 e a variável de atualização será incrementada. Sendo depois calculado a evaporação, que ocorrerá quando um grupo deixar de ser atualizado por algum tempo. Neste caso, a partir do momento que Vex não é atualizado, a cada quadro a variável Vat será incrementada. Por fim, um grupo será apagado da matriz (M), se esse grupo não for atualizado pelo tempo estipulado por $Vper$ ($Vat > Vper$), eliminando completamente a entrada correspondente na matriz (M), evitando que a matriz cresça, eliminando grupos formados por objetos antigos

façam parte do modelo. Eliminar o valor de Vex de uma só vez é importante para evitar por exemplo, em caso de existência de focos de fumaça persistida, mas por algum fator esses focos não são persistidos por 5 quadros devido ao vento que levou o grupo de pixels para outra região, nesse caso, caso o grupo volte para a mesma região da cena no próximo quadro, ele continuará sendo persistido.

Abaixo o pseudo-código que ilustra a variável de atualização do grupo e mostra a evaporação do grupo:

```
1: ATUALIZA-M-Vat( $S, Vper$ )
2: para  $i \leftarrow 1$  até tamanho(M) faça
3:    $Vat_i = Vat_i + 1;$ 
4:   se  $Vat_i > Vper$  então
5:     Apaga  $Pm_i, Vex_i$  e  $Vat_i;$ 
6:   fim se
7: fim para
```

Vale lembrar que a evaporação ocorre quando a variável Vat é incrementada. Se a variável Vex de um grupo não estiver sendo atualizada, então a variável Vat será. Sempre quando uma não é incrementada a outra é. A Figura 4.13 abaixo mostra exemplos de variações no limiar de persistência temporal $Vper$, mostrando exemplos onde a atualização dos grupos é prejudicada, fazendo com que esses grupos não consigam superar a evaporação e conseqüentemente gerando uma menor detecção de focos de incêndio.

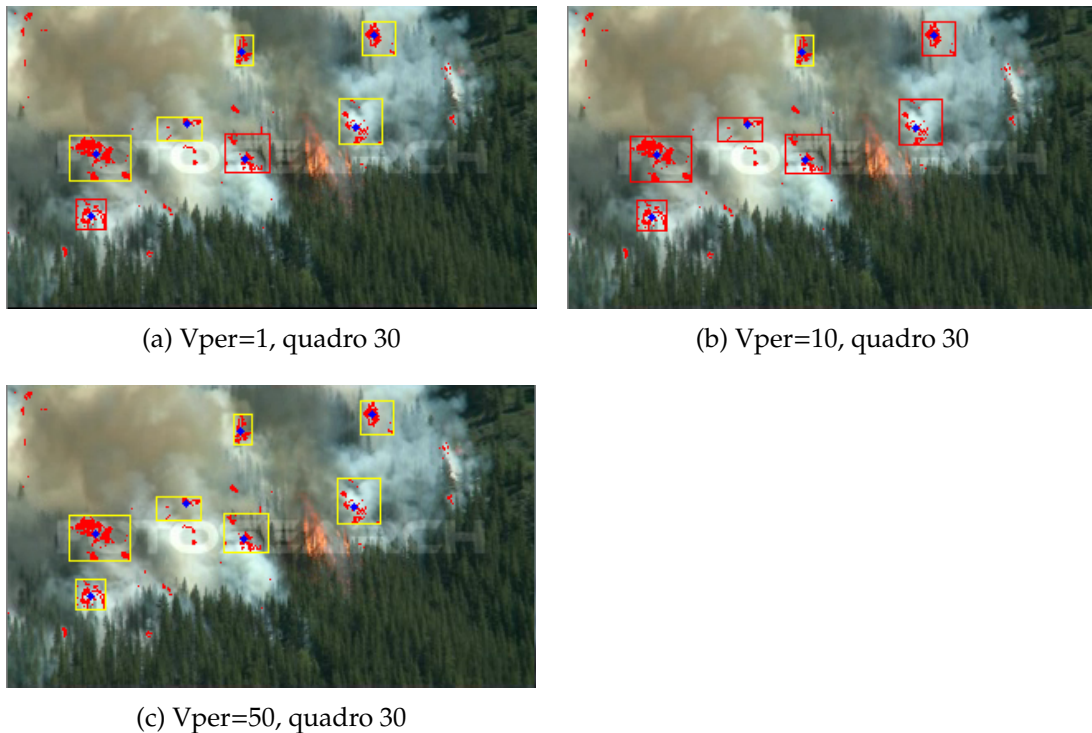


Figura 4.13: Exemplos da evaporação de grupos de acordo com o limiar de persistência temporal V_{per} . Nesta figura pode ser observado como o limiar de persistência influencia na detecção de focos de fumaça. Quadro amarelo indica que o objeto está em estado de atenção mas ainda não foi persistido. Quadro vermelho indica que o objeto foi persistido.

A figura 4.13 (a) mostra que com o valor do limiar $V_{per} = 1$, a maioria dos grupos são evaporados, pois se em dois quadros um grupo não for atualizado, ele é evaporado da matriz de grupos, isso diminui o número de quadros com detecção de fumaça. No caso da Figura (a) o número de quadros detectados corretamente com fumaça foi de 57 quadros em 100. Já na sub-figura (b), o valor de 10 quadros para o limiar de persistência temporal, mostrou-se efetivo, pois gera equilíbrio para detecção dos grupos, onde um grupo para ser classificado como fumaça, terá que ser atualizado por mais quadros, por outro lado, se ele deixar de ser atualizado por um período de tempo (10 quadros) ele será evaporado. Lembrando que para os exemplos da Figura 4.13 dez quadros equivalem a um segundo. Na sub-figura (c) o valor de $V_{per} = 50$, para que um grupo seja persistido é necessário que ele esteja em atualização por 50 quadros. Isso dificulta ainda mais a persistência dos grupos, fazendo com que eles sejam evaporados mais rapidamente, pois alguns grupos se movimentam mais rapidamente ao longo do tempo, ultrapassando a região de movimento mínimo antes de completar 50 quadros, ou até mesmo desaparecendo da imagem, sendo dessa forma evaporados da matriz de grupos. Para o limiar de persistência igual a 50 o número de quadros corretos detectados com fumaça foi de 40 em 100.

Agora que todas as regras da etapa de análise espacial e temporal foram abordadas, os grupos detectados em cada quadro são utilizados para calcular uma caixa de contenção, limitada pelos pixels mais externos do grupo, que será, amarela indicando que o objeto já está sendo observado e que é um possível foco de incêndio, em que neste caso a regra 4.7 não

foi satisfeita, ou que a variável de existência ainda não é maior que a variável de persistência, mas tem pelo menos valor igual a 1. Quando a regra 4.7 for satisfeita, será indicado que o grupo de pixels observado é um foco de fumaça e será traçado ao redor deste grupo uma caixa vermelha. Dessa forma a condição para efetuar o alarme de detecção de fumaça é alcançada quando algum grupo obtiver a persistência temporal e espacial, indicando foco de fumaça na cena.

$$ALARME = \begin{cases} 1, & \text{se } \exists P_{Si} = 1; \\ 0, & \text{caso contrário;} \end{cases} \quad (4.8)$$

Abaixo a figura 4.14 mostra o resultado final onde todas as regras de persistência espacial e temporal são satisfeitas, na figura podem ser vistos focos de fumaça persistidos (caixa vermelha) e focos em estado de observação (caixa amarela).




Figura 4.14: Resultado final da persistência espacial e temporal. (a) Quadro original, (b) Quadro com 4 focos de fumaça distintos. No quadro da figura (b), os pixels de cor vermelha indicam que todas as regras de persistência temporal e espacial foram satisfeitas.

Abaixo na tabela 4.1 são mostrados os valores utilizados para cada tipo de parâmetro no desenvolvimento do algoritmo para detecção de fumaça.

Tabela 4.1: Tabela contendo os valores para os parâmetros utilizados nos experimentos deste trabalho

Parâmetro	Valor	Métodos onde é usado
τ limiar da subtração de fundo	25, 50, 50, 70, 72, 74, 80, 80 (valores utilizados da menor resolução para a maior resolução respectivamente), definidos empiricamente.	algoritmo 2, D383S
β_{min} limiar de tamanho mínimo do grupo	5, 30, 30, 50, 50, 60, 65, 70 (valores utilizados da menor resolução para a maior resolução respectivamente), definidos empiricamente.	D383S
β limiar de distância para agrupamento	Valores variando de 10, 10, 10, 15, 15, 20, 22, 22 pixels (valores utilizados da menor resolução para a maior resolução respectivamente), definidos empiricamente.	D383S
β_{mov} limiar de movimento do grupo	10, 50, 50, 80, 80, 100, 100 (valores utilizados da menor resolução para a maior resolução respectivamente), definidos empiricamente.	D383S
V_{per} limiar de persistência temporal	10 quadros para todas as resoluções utilizadas. Definido empiricamente.	D383S

Capítulo 5

Resultados

5.1 Resultados Experimentais

Neste capítulo são apresentados o ambiente de teste e os resultados experimentais do método proposto neste trabalho, que estamos chamando de método D383S.

O método D383S para detecção de fumaça, foi desenvolvido utilizando a linguagem de programação C++, além disso, foi utilizada a biblioteca de processamento de imagens OpenCV. Os resultados obtidos com o método proposto são comparados com três algoritmos existentes na literatura. O algoritmo 1 foi extraído de (Chen et al., 2006), o algoritmo 2 foi extraído de (Chen et al., 2006) adicionado ao método de subtração de fundo e o algoritmo 3 foi extraído de (Toreyin et al., 2005).

Todos os testes que serão mostrados neste capítulo foram realizados utilizando o mesmo recurso computacional, com as seguintes configurações: Processador com clock de 2.97 GHz, Memória RAM de 8 GB e 1 TB de disco rígido.

Para avaliar o desempenho do método D383S e dos métodos presentes na literatura, são utilizados os valores de acurácia de cada método.

Onde:

$$\text{Acurácia} = \frac{\text{Avaliações Verdadeiras}}{\text{Total de Avaliações}} \quad (5.1)$$

Os valores da acurácia são obtidos através da contagem das classificações realizadas em cada quadro dos vídeos utilizados para testar os sistemas. Sendo que podemos ter as seguintes avaliações para cada quadro.

- Verdadeiro positivo: Quadro contendo fumaça identificado corretamente com presença de fumaça.
- Falso positivo: Quadro não contendo fumaça identificado incorretamente com presença de fumaça.

- Verdadeiro Negativo: Quadro não contendo fumaça identificado corretamente com ausência de fumaça.
- Falso Negativo: Quadro contendo fumaça identificado incorretamente com ausência de fumaça.

Os resultados são considerados corretos para os valores verdadeiros positivos e verdadeiros negativos, pois existem vídeos na base de teste que não contém nenhum quadro com fumaça e vídeos em que todos os quadros há presença de fumaça.

Para testar o método proposto e os algoritmos convencionais, foram realizados dois experimentos, cada um deles contendo bases de dados diferentes.

A base de dados utilizada no primeiro experimento é formada por 10 vídeos em 8 resoluções diferentes, sendo que cada vídeo contém 10 quadros por segundo e um total de 10 segundos de duração, totalizando assim 100 quadros por vídeo. A base de dados contém 5 vídeos que não contém fumaça em nenhum dos quadros e outros 5 vídeos contendo fumaça em todos os seus quadros. Já o segundo experimento utilizou uma base de dados de 13 vídeos com resolução de 320 x 240 pixels. Abaixo tabelas com descrição de cada vídeo utilizado no experimento.

No segundo experimento foram comparados o método D383S e o algoritmo 3, pois a base de dados do segundo experimento foi utilizada no trabalho original onde o algoritmo 3 foi desenvolvido e o autor do trabalho divulga seus resultados para essa base de dados, bem como disponibiliza a mesma para testes.

As descrições dos vídeos podem ser vistos nas tabelas [5.1](#) e [5.2](#) abaixo:

Tabela 5.1: Descrição dos vídeos do experimento 1.

Vídeos	Descrição do vídeo
Vídeo 1	Dia de céu aberto com nuvens.
Vídeo 2	Dia de céu aberto com nuvens vídeo 2.
Vídeo 3	Névoa na floresta.
Vídeo 4	Galhos congelados se movimentando em um fundo acinzentado.
Vídeo 5	Leito de um rio com algumas embarcações se movimentando e gerando reflexo na água.
Vídeo 6	Fumaça em uma floresta.
Vídeo 7	Fumaça em uma floresta.
Vídeo 8	Fumaça em uma floresta.
Vídeo 9	Fumaça em uma floresta.
Vídeo 10	Fumaça saindo de uma chaminé.

Tabela 5.2: Descrição dos vídeos do experimento 2.

Vídeos	Descrição do vídeo
Vídeo 1	Pequeno foco de fumaça em uma floresta.
Vídeo 2	Luzes de faróis de carros a noite.
Vídeo 3	Luzes de faróis de carros a noite vídeo 2.
Vídeo 4	Fumaça distante em uma floresta.
Vídeo 5	Fumaça sendo gerada em um jardim.
Vídeo 6	Fumaça sendo gerada em um jardim vídeo 2.
Vídeo 7	Queimando papéis para gerar fumaça em um ambiente fechado.
Vídeo 8	Pequeno foco de fumaça em uma floresta vídeo 2.
Vídeo 9	Fumaça saindo de uma chaminé ao fundo de uma região residencial.
Vídeo 10	Fumaça em um estacionamento.
Vídeo 12	Fumaça de um sinalizador em frente de um cesto de lixo.
Vídeo 13	Fumaça saindo de uma lata de lixo filmado por uma janela.

As figuras 5.1 e 5.2 mostram imagens dos vídeos de teste utilizados no experimento.



Figura 5.1: Exemplo de vídeos de teste para o primeiro experimento.

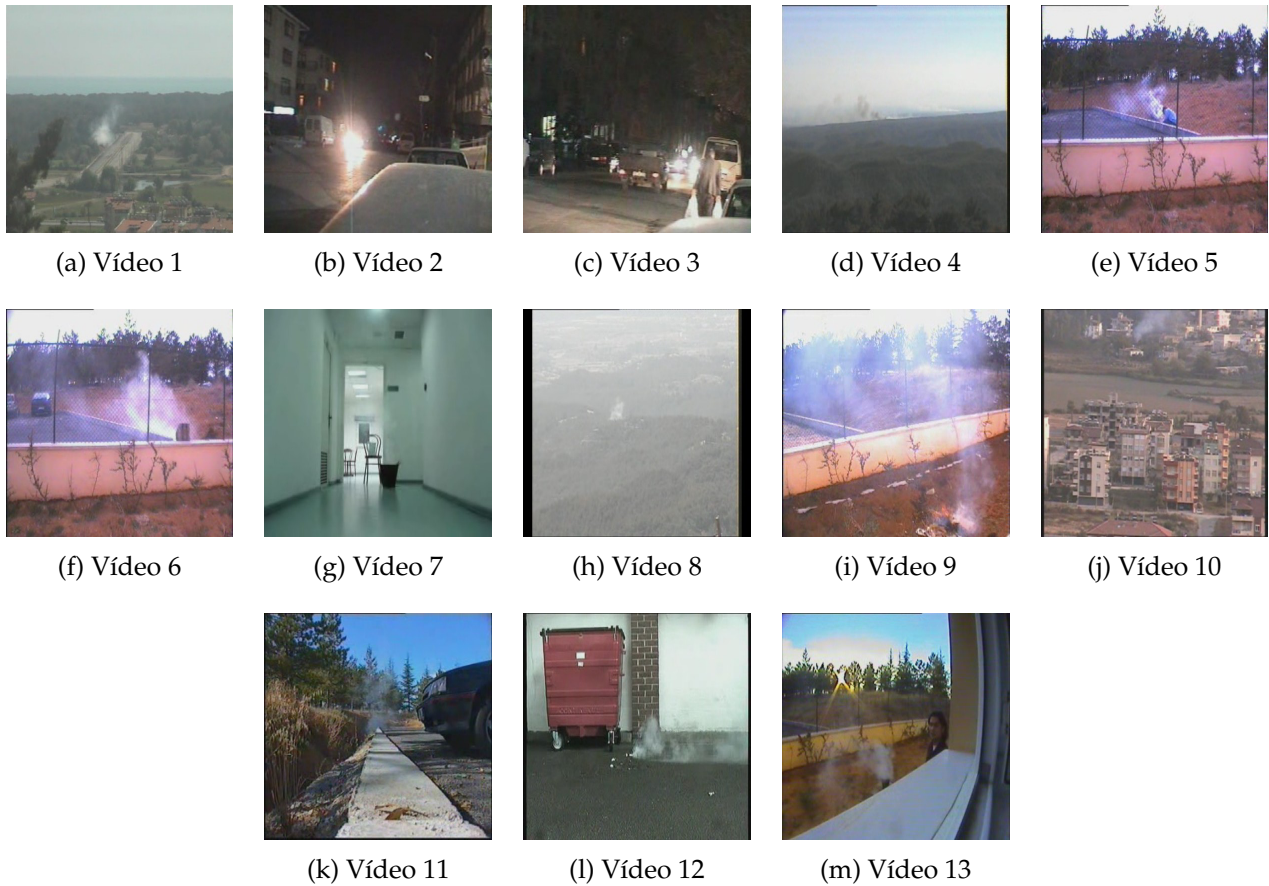


Figura 5.2: Exemplo de vídeos de teste para o segundo experimento.

Os vídeos utilizados no segundo experimento possuem sempre a mesma resolução e quantidade de quadros por segundo. Todos os vídeos têm resolução de 320x240 pixels e taxa de reprodução de 10 quadros por segundo. Cada vídeo possui tempo de duração diferente. Os vídeos do segundo experimento totalizam 15604 quadros. Para o experimento 1 existe um total de 8000 quadros avaliados, sendo que são 1000 quadros por resolução em oito diferentes resoluções testadas. No segundo experimento foram utilizados vídeos de 320x240 pixels devido ao fato dessa resolução contribuir para obter melhores resultados de detecção de fumaça e também por ter sido essa a resolução utilizada por Toreyin em seus experimentos.

A tabela 5.3 mostra a quantidade total de quadros dos vídeos do primeiro e segundo experimento, além da quantidade de quadros contendo fumaça e quantidade de quadros onde não há presença de fumaça.

Tabela 5.3: Quantidade de quadros dos vídeos utilizados no experimento e quantidade de quadros com e sem fumaça

	Experimento 1	Experimento 2
Total de quadros	8000	15604
Total de quadros com fumaça	4000	8228
Total de quadros sem fumaça	4000	7376

As tabelas 5.4, 5.5, 5.6 e 5.7 mostram respectivamente o número de avaliações positivas e negativas para cada método. As avaliações positivas são compostas por valores agregados de verdadeiros positivos e verdadeiros negativos e as avaliações negativas são compostas por valores agregados de falsos positivos e falsos negativos. Devido ao tamanho dos dados do experimento 1 os resultados foram divididos em três tabelas.

Tabela 5.4: Parte 1 Resultados da detecção de fumaça do método D383S e dos algoritmos convencionais para vídeos do experimento 1.

Métodos	Resoluções					
	160x120		320x240		352x288	
	Acertos	Erros	Acertos	Erros	Acertos	Erros
D383S	767	233	803	197	801	199
Algoritmo 1	443	757	401	599	404	596
Algoritmo 2	652	348	708	292	675	325
Algoritmo 3	759	241	776	224	716	284

Tabela 5.5: Parte 2 Resultados da detecção de fumaça do método D383S e dos algoritmos convencionais para vídeos do experimento 1.

Métodos	Resoluções					
	640x480		704x576		800x600	
	Acertos	Erros	Acertos	Erros	Acertos	Erros
D383S	778	222	781	219	785	215
Algoritmo 1	403	597	402	598	402	598
Algoritmo 2	670	330	665	335	656	454
Algoritmo 3	648	352	762	238	747	253

Tabela 5.6: Parte 3 Resultados da detecção de fumaça do método D383S e dos algoritmos convencionais para vídeos do experimento 1.

Métodos	Resoluções			
	1280x720		1920x1080	
	Acertos	Erros	Acertos	Erros
D383S	727	273	702	298
Algoritmo 1	352	648	352	648
Algoritmo 2	633	357	645	355
Algoritmo 3	665	335	648	412

Tabela 5.7: Resultados da detecção de fumaça do método D383S e do algoritmo 3 para vídeos do experimento 2.

Métodos	Acertos	Erros
D383S	12044	3560
Algoritmo 3	11605	3999

Com os resultados obtidos nos testes dos dois experimentos, o próximo passo é calcular a acurácia de detecção de fumaça para cada método e a taxa de detecção de falsos positivos para cada método.

O método D383S obteve melhor desempenho em todos os testes do experimento 1. O Algoritmo 3 obteve o segundo melhor desempenho, seguido dos algoritmos 2 e 1 nesta ordem.

O objetivo principal nos testes foi buscar o número verdadeiros positivos (fumaça identificada corretamente como fumaça) maior que falsos negativos (fumaça não identificada como fumaça) e falsos positivos (onde não há fumaça mas foi detectado como fumaça) em ambos os experimentos e o valor total de verdadeiros positivos sempre foi maior que a soma de falsos negativos e falsos positivos.

Nos experimentos o método D383S alcançou uma taxa inferior de falsos positivos quando comparado com outros métodos, com taxas de verdadeiros positivos maiores que falsos negativos, mas as taxas de verdadeiros positivos não foram tão maiores que a taxa de falsos negativos, devido ao fato de que se buscamos não encontrar nenhum falso positivo, consequentemente, teremos uma menor quantidade de quadros detectados como fumaça. Com isso o percentual de acertos dos métodos é reduzido, mas garantimos ao método proposto maior confiabilidade. Outro fator importante é que o método D383S não detectou nenhum falso positivo nos vídeos que contêm fumaça em todos os quadros.

O algoritmo 1 é o método com maior taxa de detecção de falsos positivos, devido ao fato de ele não fazer a análise de movimento nos vídeos. O método do algoritmo 1 detecta como fumaça quaisquer objetos com cor de fumaça nos vídeos. Objetos que possuem cor de fumaça serão apontados como fumaça.

O algoritmo 2 faz a análise da região de interesse, mas possui o problema de detectar como fumaça qualquer objeto com cor de fumaça e que esteja em movimento. A análise da região de interesse é realizada através do método de subtração de fundo. A adição deste método já contribuiu significativamente para redução de falsos positivos no método do algoritmo 1.

O método D383S além de detectar a região de interesse e verificar as cores dos pixels, busca rastrear o movimento dos objetos de interesse classificados como fumaça. Após analisar o movimento da região de interesse nos eixos na vertical e na horizontal durante um período de tempo, o algoritmo faz a decisão se o objeto em movimento pode ser considerado fumaça. Essa análise é um diferencial que garante redução de falsos positivos. Um exemplo é o vídeo 1 do experimento 1. Em altas resoluções é possível ver um pássaro de cor semelhante a cor de fumaça movimentando-se no vídeo. O pássaro é exibido no vídeo durante 2 segundos. Esse pássaro é detectado como fumaça pelo algoritmo 2, pois ele está em movimento e possui cor semelhante à cor de fumaça. No método proposto esse pássaro não foi detectado como fumaça, pois para a análise de movimento do método D383S, ele não é considerado fumaça.

Abaixo o gráfico da figura 5.3 apresenta os resultados comparativos dos valores de acurácia de detecção de fumaça para o experimento 1. Da esquerda para direita a ordem das colunas é: D383S, algoritmo 1, algoritmo 2 e algoritmo 3.




Figura 5.3: Acurácia de detecção do método D383S versus algoritmos convencionais

No primeiro experimento, o método D383S obteve melhor desempenho que os algoritmos convencionais para a base de dados de vídeos com diferentes resoluções e contendo vídeos com e sem a presença de fumaça. A acurácia média de detecção do método proposto,

algoritmo 1, algoritmo 2 e algoritmo 3 foram 77,1%, 39,4%, 66,2% e 71,5% respectivamente.

O gráfico da figura 5.4 apresenta os valores das taxas de falsos positivos na detecção de fumaça para o método D383S e para os algoritmos convencionais para o experimento 1.

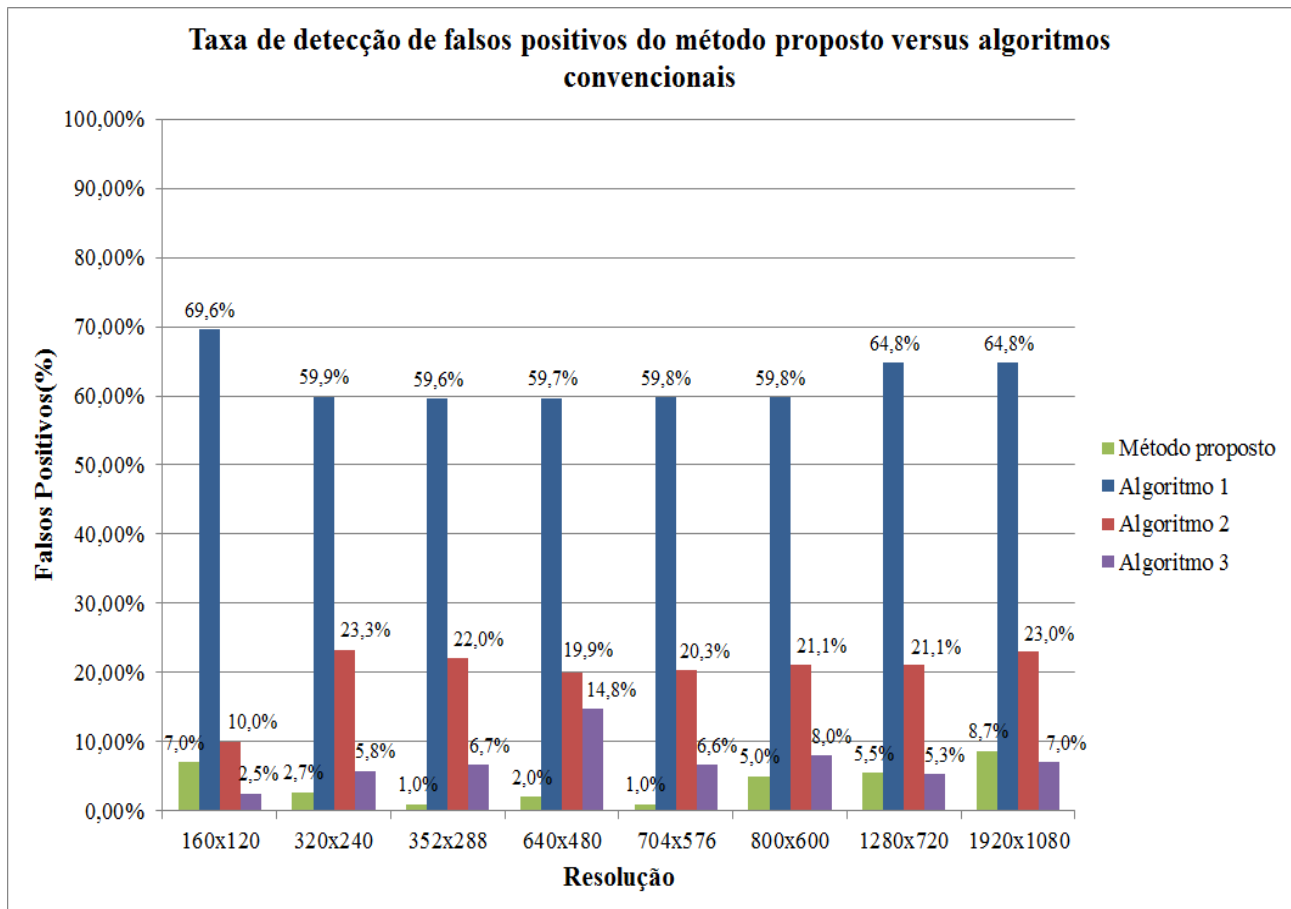


Figura 5.4: Taxa de detecção de falsos positivos do método D383S versus algoritmos convencionais

Na avaliação dos resultados de taxa de detecção de falsos positivos para vídeos de fumaça, o método D383S mais uma vez apresentou bons resultados. No vídeo de controle em que galhos congelados balançam em sentido vertical, todos os métodos apresentaram maior taxa de detecção de falsos positivos. Os valores médios de taxa de falsos positivos para o método D383S, algoritmo 1, algoritmo 2 e algoritmo 3 foram 4,1%, 62,2%, 20% e 7% respectivamente.

O vídeo que mostra o leito de um rio com algumas embarcações também contribuiu para a detecção de falsos positivos em altas resoluções como 1280x720 e 1920x1080.

O método D383S e o algoritmo 3 detectaram pouca fumaça no vídeo 9 do experimento 1. Nesse vídeo há fumaça em uma floresta em um período em que a maioria das árvores estão com os galhos secos e há pouco verde, gerando uma fumaça com cor predominantemente marrom. Desta forma são poucos os quadros em que há fumaça com as cores acinzentadas, foco dos dois algoritmos. A fumaça marrom ocorre quando no processo de queima existe

maior concentração de material que não contém grande quantidade de moléculas de água.

Para o método D383S, em testes com vídeos em baixas resoluções há maior detecção de fumaça para o vídeo 9 do experimento 1. À medida que a resolução aumenta, os valores caem, devido ao fato da velocidade de movimento dos pixels ser maior, fazendo com que a pouca quantidade de fumaça que poderia ser classificada não atenda aos critérios de rastreamento de objetos do algoritmo.

A adição do método de subtração de fundo ao algoritmo 2 contribuiu para o aumento da acurácia em 26,8%, em relação ao algoritmo 1. Este fato ocorreu para todos os vídeos de todas as resoluções testadas no experimento 1.

O gráfico da figura 5.5 apresenta os resultados comparativos dos valores de acurácia de detecção de fumaça para o experimento 2.




Figura 5.5: Acurácia de detecção do método D383S versus algoritmo 3

O gráfico da figura 5.6 apresenta os valores das taxas de falsos positivos na detecção de fumaça para o método D383S e para o algoritmo 3 para o experimento 2.

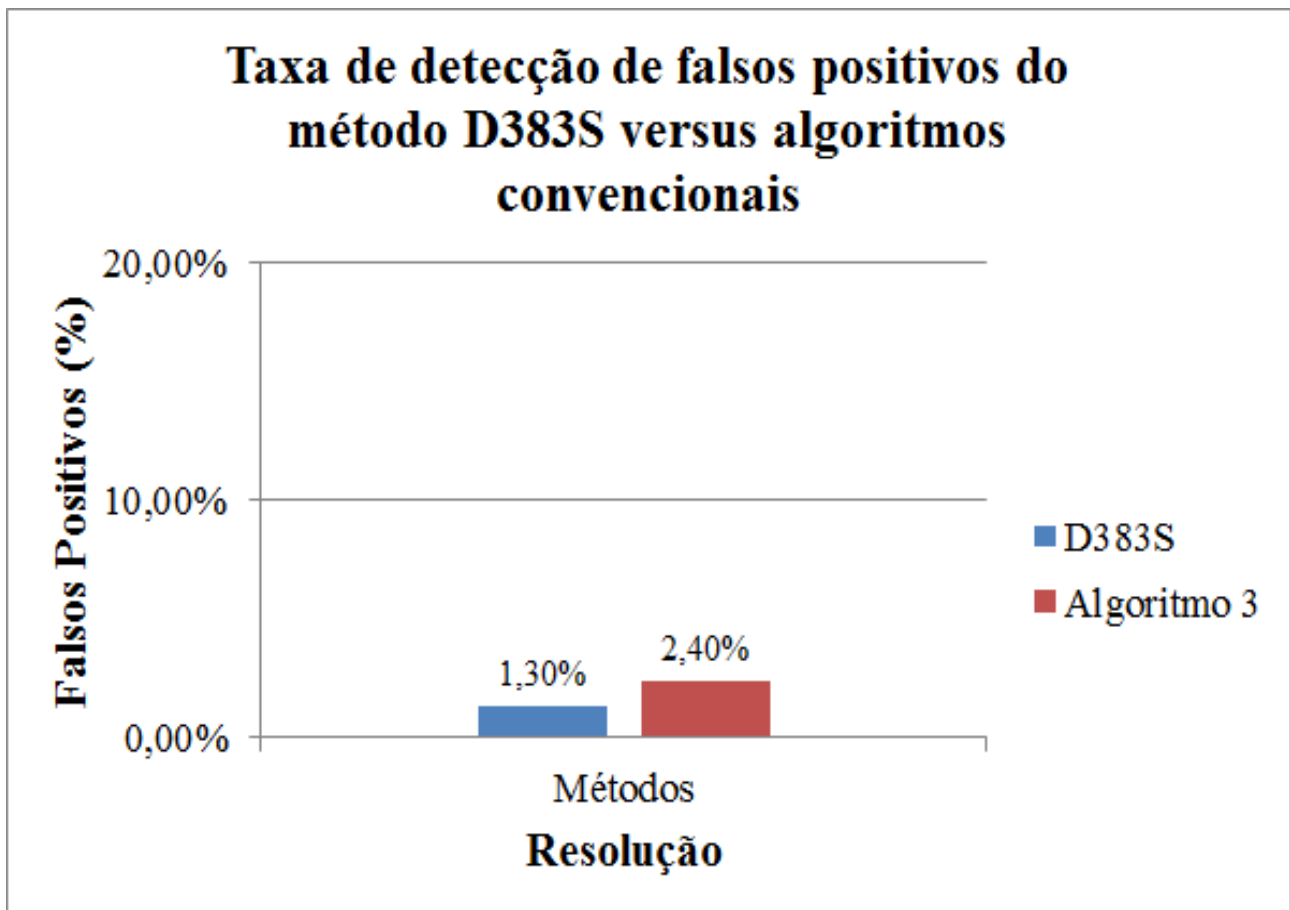


Figura 5.6: Taxa de detecção de falsos positivos do método D383S versus algoritmo 3

5.2 Análise Estatística

Após realizar os experimentos e coletar os resultados, é necessário validar se o experimento foi elaborado de forma correta. O objetivo de utilizar um teste estatístico se faz necessário para verificar se podemos ou não rejeitar as hipóteses definidas neste trabalho que são: H_0 - o método D383S não obteve melhor desempenho do que os métodos existentes na literatura e H_1 - o método D383S obteve melhor desempenho do que os métodos existentes na literatura. A ferramenta utilizada neste trabalho para testar o experimento é a análise de variância (ANOVA), com ela podemos verificar também se as amostras do nosso experimento apresentam normalidade na sua distribuição de valores e se os dados apresentaram aleatoriedade ao longo dos experimentos.

No experimento 1 a variável de resposta (acurácia) é discreta e aleatória. Os fatores envolvidos no teste são: Métodos com quatro níveis, nesse caso os quatro métodos testados. O outro fator é resolução com oito níveis, nesse caso as oito resoluções testadas. Os valores de acurácia testados no experimento são os acertos.

O intervalo de confiança da análise estatística será de 95% $\alpha = 0,05$. Esse valor de intervalo de confiança nos garante que se realizarmos o experimento inúmeras vezes, de acordo

com a metodologia descrita para o experimento e utilizando uma base de dados com os mesmos padrões deste trabalho, teremos 95% de chance de encontrar o mesmo resultado da análise estatística encontrado neste trabalho.

A tabela 5.8 mostra o resultado da análise de variância para acurácia para o experimento 1, onde GL (Graus de Liberdade) é a dimensão das amostras testadas, F é o valor da estatística de teste para o teste de *Fisher-Snedecor* e P (valor-p).

Tabela 5.8: Análise de Variância para acurácia

Fonte	GL	F	P
Método	3	354,17	0,0001
Resolução	7	6,00	0,001
Erro	21		
Total	31		

Onde, GL significa Graus de liberdade, F se refere a estatística de teste de Fisher e P ao valor-p.

As estatísticas de teste $F_{0,05,3,21} = 3,07$ e $F_{0,05,7,21} = 2,48$, foram menores que as estatísticas de teste F do nosso experimento. Isso mostra que os fatores métodos e resolução têm influência na geração dos valores de acurácia. Como o valor da estatística de teste do fator método foi maior que a estatística de teste F com três graus de liberdade no numerador e 21 graus de liberdade no denominador, podemos aceitar a hipótese alternativa de que o sistema desenvolvido neste trabalho teve desempenho superior de acurácia de detecção de fumaça comparado com os algoritmos convencionais. Como vimos nos gráficos, o método proposto teve o melhor desempenho quando comparado com outros métodos.

A análise de variância confirmou isso com a estatística de teste e com o valor $p = 0,0001$, menor que o a significância do teste $\alpha = 0,05$. Isso significa que os dados estão dentro da área de 95% de confiança da distribuição amostral, e que existe 0,01% de probabilidade dos resultados obtidos no primeiro experimento serem devidos a fatores que não estão sendo estudados no experimento. O resultado obtido no primeiro experimento tem 99,99% de probabilidade de ser obtido pelos fatores método e resolução.

A análise de variância afirma com 95% de confiança que esse experimento realizado com a metodologia descrita nesse capítulo e com a base de dados utilizada, o método proposto obteve melhor desempenho comparado aos algoritmos convencionais.

Nas figuras 5.7 e 5.8 estão os gráficos de distribuição normal dos dados e ordem de

coleta dos dados do experimento, esses gráficos são gerados juntamente com a análise de variância, com objetivo de garantir ainda mais a consistência do experimento 1.

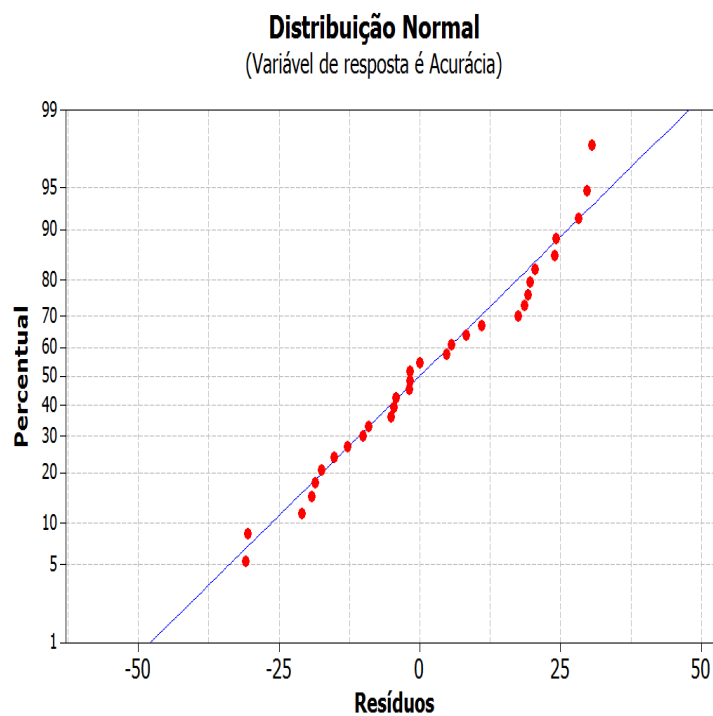


Figura 5.7: Distribuição normal dos dados coletados no experimento 1

No gráfico da figura 5.7 os dados estão distribuídos próximos à reta da distribuição de probabilidade normal. Não há nenhum "Outlier", indicando que nossos dados apresentam consistência, ou seja, nada de anormal.




Figura 5.8: Ordem de coleta dos dados no experimento 1

O gráfico da figura 5.8 mostra se os dados foram coletados de forma aleatorizada, ou seja, se não há nenhum tipo de tendência do experimentador nos dados. O que caracterizaria tendência neste gráfico seria os pontos que representam os dados coletados seguirem um padrão em forma de cone. Isso não ocorre no gráfico do experimento 1, garantindo que nossos dados estão aleatorizados e sem influências do experimentador.

Agora vamos apresentar os resultados da análise estatística para o experimento 2, a variável de resposta continua sendo a acurácia, mas os fatores mudaram. Como a resolução nesse experimento foi 320x240 para todos os vídeos, e como os vídeos possuem tempo de duração variado, além de quantidade de quadros com e sem fumaça também variados, os vídeos para o experimento 2 tornaram-se fatores da ANOVA.

A tabela 5.9 mostra o resultado da análise de variância para acurácia para o experimento 2.

Tabela 5.9: Análise de Variância para acurácia

Fonte	GL	F	P
Método	1	2,53	0,138
Vídeos	12	173,55	0,001
Erro	12		
Total	25		

Onde, GL significa Graus de liberdade, F se refere ao teste de Fisher e P ao valor-p.

A estatística de teste padrão $F_{0,05}1, 12 = 4,74$, foi maior que a estatística do teste do experimento para os métodos proposto e algoritmo 3. Com isso aceitamos a hipótese nula. Além disso, o valor $p = 0,138$ foi maior que a significância do teste $\alpha = 0,05$. Com relação ao valor p , existe 13% de probabilidade dos resultados obtidos serem dados por outros fatores que não são os fatores estudados. Para o intervalo de confiança de 95%, não foi possível rejeitar a hipótese nula.

Apesar de nos resultados gráficos do experimento 2 os resultados do método proposto serem superiores aos resultados do algoritmo 3, o que a análise estatística diz é que com os dados obtidos com o experimento não é possível garantir com 95% de confiança que o método proposto é superior ao algoritmo 3 para a base de dados do experimento 2.

A diferença entre a acurácia do método proposto e a acurácia do algoritmo 3 foi 3.6% para o experimento 2. Mesmo sem a análise estatística já não era possível afirmar que com os testes do experimento 2 que o método proposto é superior ao método do algoritmo 3.

Os gráficos da figura 5.9 e 5.10 mostram a distribuição normal dos dados e aleatorização da coleta dos dados do experimento 2 respectivamente. Mais uma vez, os gráficos mostram normalidade e aleatoriedade nos dados coletados.

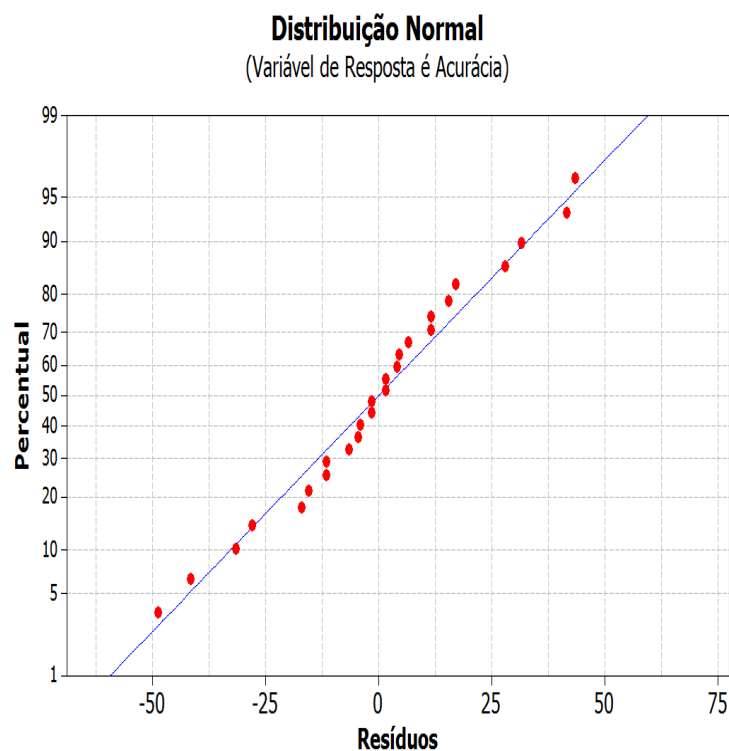


Figura 5.9: Distribuição normal dos dados coletados no experimento 2




Figura 5.10: Ordem de coleta dos dados no experimento 1

A figura 5.11 mostra os resultados obtidos pelo método D383S no primeiro experimento para vídeos contendo fumaça. O retângulo vermelho indica detecção de fumaça.

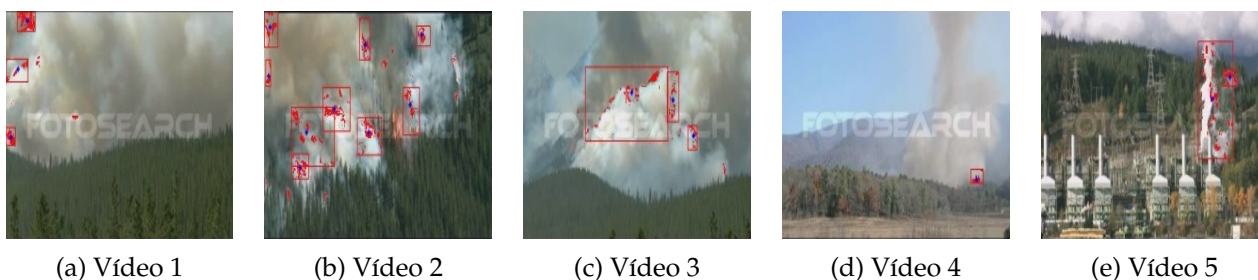


Figura 5.11: Resultados do método proposto para o primeiro experimento. O retângulo vermelho indica detecção de fumaça.

A figura 5.12 mostra os resultados obtidos pelo método D383S no segundo experimento para vídeos contendo fumaça. O retângulo vermelho indica detecção de fumaça.




(a) Vídeo 1



(b) Vídeo 2




(c) Vídeo 3



(d) Vídeo 4



(e) Vídeo 5



(f) Vídeo 6



(g) Vídeo 8



(h) Vídeo 9

Figura 5.12: Resultados do método proposto para o segundo experimento. O retângulo vermelho indica detecção de fumaça.

Capítulo 6

Conclusão

Neste trabalho foi desenvolvido um sistema de detecção de fumaça, visando antecipar sistemas de detecção de fogo, utilizando processamento de imagens. Este tipo de sistema auxilia na prevenção de incêndios, que é uma das maiores causas de desmatamento natural em todo o mundo. A autonomia do sistema permite que o mesmo monitore florestas em pontos chave e de difícil acesso, bem como a redução de recursos humanos em vigilância. Mas a intervenção humana nas tarefas de vigilância serão sempre necessárias para casos em que o sistema detecte falsos positivos.

Dos testes realizados com o sistema, conclui-se que ele tem um desempenho robusto com baixo percentual de falsos positivos. Um ponto positivo é que o sistema conseguiu baixas ocorrências de falsos negativos, que é quando há existência de fumaça em um quadro, e essa fumaça não está sendo detectada pelo sistema.

Com relação aos falsos positivos, eles ocorreram em vídeos contendo imagens de neblina, galhos congelados se movimentando e até mesmo de um vídeo em que o reflexo de um barco de cor branca na água simula cor e movimento de fumaça. Só que se os parâmetros forem ajustados para não detectar esses falsos positivos, por outro lado não teremos detecção de fumaça em quadros que realmente tenham fumaça. Os vídeos de controle que são os vídeos que não têm imagens de fumaça, possuem situações similares a fumaça.

O falso positivo pode ser verificado com auxílio do ser humano. Já o falso negativo é mais grave, pois existe a fumaça em um determinado ambiente e ela não está sendo detectada, gerando riscos graves e tornando o sistema proposto ineficiente.

Dos trabalhos pesquisados na literatura, a maioria dos autores não utilizou vídeos com imagens de objetos que simulam fumaça, com exceção de (Toreyin et al., 2005), (Tung and Kim, 2011) e outros poucos autores, que utilizaram vídeos de controle, mas nenhum deles usou vídeos com uma base desafiadora de vídeos utilizados nos testes deste trabalho. Os vídeos de neblina, galhos congelados e leito do rio foram utilizados visando testar o sistema com

situações de extrema dificuldade e mostrando as limitações de detecção do sistema.

Nos testes realizados o sistema apresentou desempenho superior com relação aos sistemas existentes na literatura, selecionados para testes comparativos com o método D383S. Para o primeiro experimento a análise estatística confirmou que o método D383S apresentou melhor acurácia que os métodos existentes na literatura.

Já para o segundo experimento, o método proposto apresentou melhores resultados em relação aos métodos existentes na literatura, mas com os dados obtidos no experimento, a análise estatística com 95% de certeza, não afirma que o método D383S sempre vai ser melhor que os métodos da literatura, para as configurações do segundo experimento. Isso se deve ao fato de no segundo experimento o método D383S e o método do algoritmo 3 apresentarem resultados de acurácia e falsos positivos muito similares.

Outro fator importante é que este trabalho investigou a influência das resoluções de vídeo na tarefa de detecção de fumaça. Foi um fator que contribuiu para aprimorar a qualidade dos experimentos e mostrar que com imagens de baixa resolução apresentaram melhores taxas de acurácia que imagens de alta resolução e também com menores taxas de falsos positivos. Isso torna o método de detecção utilizando imagens de câmera de monitoramento, um método de menor custo, já que não são necessárias câmeras que gerem imagens de alta resolução.

Os fatores que fizeram com que o sistema desenvolvido neste trabalho apresentasse desempenho melhor que os métodos existentes na literatura, se deram na utilização de uma biblioteca de desenvolvimento voltada para visão computacional que está sempre em constante atualização, além de estruturas de dados sempre otimizadas, visando baixo custo computacional. A utilização de uma biblioteca especializada não é o principal responsável pelo bom desempenho do algoritmo mas sim parte integrante de toda a estratégia de desenvolvimento. A codificação foi feita de forma a evitar laços de repetição e estruturas de dados desnecessárias, contribuindo para maior qualidade do código desenvolvido.

A técnica de subtração de fundo utilizada neste trabalho também foi a técnica que utiliza menor custo computacional e melhores resultados, conforme estudos da literatura apresentados neste trabalho. Ela cumpriu o seu objetivo, segmentando regiões em movimento com rapidez e precisão.

A segunda parte do algoritmo também teve um diferencial de qualidade, que foi diminuir a região de busca para comparação de cor. A utilização de um limiar que se ajusta melhor aos pixels de fumaça no espaço de cor RGB, contribuiu para a melhoria do algoritmo reduzindo falsos positivos, já que a área de comparação de cores é a área onde os pixels com

cor de fumaça se encontram. Foi uma vantagem ao uso de limiares extremos simples para classificação de cor.

A terceira parte do algoritmo também contribuiu para redução de falsos positivos, verificando o tempo de permanência dos objetos candidatos a fumaça na imagem, bem como a direção do movimento destes objetos, eliminando objetos que se movam rapidamente na cena e além disso definindo um limiar de tempo, fazendo com que para que um objeto seja classificado ele deva permanecer por um período de tempo na imagem antes de ser classificado.

As escolhas ponderadas dos limiares utilizados nas etapas de desenvolvimento do algoritmo também contribuíram para um bom desempenho do mesmo, auxiliando na redução de falsos positivos.

Outro fator que contribuiu para a qualidade experimental do trabalho proposto foi a utilização de uma base de dados de controle, que testou o sistema em situações difíceis com objetos parecidos com fumaça, lembrando que a maioria dos trabalhos abordados na revisão de literatura, com exceção de [Toreyin et al. \(2005\)](#), não mostram testes realizados com vídeos ou imagens de controle. São somente trabalhos focados em detecção de fumaça em vídeos, como o trabalho de [Calderara et al. \(2011\)](#) e [Chen et al. \(2006\)](#). Os testes realizados tinham como objetivo promover situações o mais similares possíveis com fumaça, fazendo com que fossem verificadas as limitações do método proposto.

Existem ainda muitas possibilidades a serem exploradas em trabalhos futuros como: estudos analisando o desempenho de novos classificadores de padrões, como as máquinas de comitê, que empregam a estratégia de combinar as respostas de vários classificadores especialistas, em uma resposta única; analisar o desempenho desses novos classificadores associados aos diversos tipos de espaços de cores diferentes; outra boa proposta de trabalho futuro é a busca de soluções para o problema de detecção de fumaça durante períodos noturnos, utilizando processamento de imagens.

Ainda que ainda haja muito o que ser desenvolvido, a ferramenta implementada pode ser efetivamente utilizada no processo de detecção de incêndios em áreas de preservação ambiental. Ao se fazer isto, linhas de transmissão, inicialmente vistas como estruturas nocivas ao meio ambiente, tornam-se instrumentos de proteção ambiental.

Referências Bibliográficas

- Calderara, S., Piccinini, P., and Cucchiara, R. (2011). Vision based smoke detection system using image energy and color information. *Mach. Vision Appl.*, 22(4):705–719.
- Chen, T.-H., Yin, Y.-H., and Shi-Feng Huang, Y.-T. Y. (2006). The smoke detection for early fire-alarming system base on video processing. In *Intelligent Information Hiding and Multimedia Signal Processing, 2006. IIH-MSP '06. International Conference on*, pages 427–430.
- Chunyu, Y., Jun, F., Jinjun, W., and Yongming, Z. (2010). Video fire smoke detection using motion and color features. *Fire Technology*, 46(3):651–663.
- Collins, R. T., Lipton, A. J., Kanade, T., Fujiyoshi, H., Duggins, D., Tsin, Y., Tolliver, D., Enomoto, N., Hasegawa, O., and Peter Burt, L. W. (2000). A system for video surveillance and monitoring.
- Cormen, T. H., Leiserson, C. E., Rivest, R. L., and Stein, C. (2002). *Algoritmos, Teoria e Prática*. Elsevier, 6 edition.
- Cui, Y., Dong, H., and Zhou, E. (2008). An early fire detection method based on smoke texture analysis and discrimination. In *Image and Signal Processing, 2008. CISP '08. Congress on*, volume 3, pages 95–99.
- Damir, K., Darko, S., and Toni, J. (2009). Histogram-based smoke segmentation in forest fire detection system. *Information Technology and Control*, 38(3).
- Dedeoglu, Y. (2004). *Moving object detection, tracking and classification for smart video surveillance*. PhD thesis, Bilkent University, Turkey.
- Donohoe, G., Hush, D., and Ahmed, N. (1988). Change detection for target detection and classification in video sequences. In *Proceeding of ICASSP*, pages 1084–1087.
- Dorigo, M. (1992). *Optimization, Learning and Natural Algorithms (in Italian)*. PhD thesis, Dipartimento di Elettronica, Politecnico di Milano.
- Dorigo, M. (1999). Ant colony optimization: A new meta-heuristic. In *Proceedings of the Congress on Evolutionary Computation*, pages 1470–1477. IEEE Press.
- Çelik, T., Demirel, H., Ozkaramanli, H., and Uyguroglu, M. (2007). Fire detection using statistical color model in video sequences. *J. Vis. Comun. Image Represent.*, 18(2):176–185.

- Ferreira, M. A. L. (2007). *Detecção de movimento através de subtração de fundo para vigilância eletrônica automática*. PhD thesis, Pontifícia Universidade Católica do Rio de Janeiro.
- Ferreira, M. A. L. (2008). *Vigilância e Monitoramento em Tempo Real de Veículos em Rodovias com Câmeras Não-Calibradas, dissertação de mestrado*. PhD thesis, Pontifícia Universidade Católica do Rio de Janeiro.
- Fiorio, C. and Gustedt, J. (1996). Two linear time union-find strategies for image processing. *Theor. Comput. Sci.*, 154(2):165–181.
- Friedlander, S. K. (2000). *Smoke, dust, and haze : fundamentals of aerosol dynamics, 2nd Ed.* Topics in chemical engineering. Oxford University Press, New York.
- Gonzalez, Rafael C. e Woods, R. E. (2002). *Digital image processing*. Prentice-Hall, 2. ed. edition.
- Haritaoglu, I., Harwood, D., and Davis, L. S. (2000). W4: Real-time surveillance of people and their activities. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22:809–830.
- Hinds, W. C. (1999). *Aerosol Techonology: Properties, Behaviour, and Measurement of Airbone Particles, 2nd Ed.* John Willey and Sons.
- Ho, C.-C. (2009). Machine vision-based real-time early flame and smoke detection. *Measurement Science and Technology*, 20(4):045502.
- Jens, Jacob Jensen, G. F. (1984). Dynamic behaviour of transmission towers: field measurements. *Engineering Structures*, 6(4):288 – 296.
- Junzhou, C., Yong, Y., and Qiang, P. (2013). Dynamic analysis for video based smoke detection. *IJCSI International Journal of Computer Science Issues*, 10(2).
- Kim, K., Chalidabhongse, T., Harwood, D., and Davis, L. (2004). Background modeling and subtraction by codebook construction. In *Image Processing, 2004. ICIP '04. 2004 International Conference on*, volume 5, pages 3061–3064 Vol. 5.
- Klein, T. (2005). *Estudo em túnel de vento das características aerodinâmicas em torre metálicas treliçadas*. PhD thesis, Universidade Federal de Porto Alegre.
- Kopilovic, I., Vágvölgyi, B., and Szirányi, T. (2000). Application of panoramic annular lens for motion analysis tasks: Surveillance and smoke detection. In *ICPR*, pages 4714–4717.
- MacQueen, J. B. (1967). Some methods for classification and analysis of multivariate observations. In *Proc. of the fifth Berkeley Symposium on Mathematical Statistics and Probability*, volume 1, pages 281–297. University of California Press.
- Maruta, H., Yamamichi, T., Nakamura, A., and Kurokawa, F. (2010). Image based smoke detection with two-dimensional local hurst exponent. In *Industrial Electronics (ISIE), 2010 IEEE International Symposium on*, pages 1651 –1656.

- Millan-Garcia, L., Sanchez-Perez, G., Nakano, M., Toscano-Medina, K., Perez-Meana, H., and Rojas-Cardenas, L. (2012). An early fire detection algorithm using ip cameras. *Sensors*, 12(5):5670–5686.
- Montgomery, D. C. (2002). *Applied statistics and probability for engineers, 3rd Ed.* Jonh Wiley Sons.
- Motta, D. S. (2008). *Identificação dos fatores que influenciam no comportamento do fogo em incêndios florestais*. PhD thesis, Universidade Federal Rural do Rio de Janeiro.
- Oliveira, M. I. R. (2006). *Análise Estrutural de torres de transmissão de energia submetidas aos efeitos dinâmicos induzidos pelo vento*. PhD thesis, Universidade do Estado do Rio de Janeiro.
- Piccardi, M. (2004). Background subtraction techniques: a review. In *2004 IEEE International Conference on Systems, Man and Cybernetics*, volume 4, pages 3099–3104.
- Toreyin, B. U., Dedeoglu, Y., and U. Gudukbay, A. E. e. (2005). Contour based smoke detection in video using wavelets. *Pattern Recognition Letters*.
- Toreyin, B. U., Dedeoglu, Y., and U. Gudukbay, A. E. e. (2006). Computer vision based method for real-time fire and flame detection. *pattern recognition letters*.
- Truyenque, M. (2005). *Uma aplicação de visão computacional que utiliza gestos da mão para interagir com o computador. Dissertação de mestrado, Programa de pós graduação em informatica.* PhD thesis, Pontifícia Universidade Católica do Rio de Janeiro.
- Tung, T. X. and Kim, J. M. (2011). An effective four-stage smoke-detection algorithm using video images for early fire-alarm systems. *Fire Safety Journal*, 46(5):276 – 282.
- Wang, S.-J., Jeng, D.-L., and Tsai, M.-T. (2009). Early fire detection method in video for vessels. *Journal of Systems and Software*, 82(4):656–667.
- Wei, Z., Wang, X., An, W., and Che, J. (2009). Target-tracking based early fire smoke detection in video. In *Image and Graphics, 2009. ICIG '09. Fifth International Conference on*, pages 172–176.
- Xiong, Z., Caballero, R., Wang, H., Finn, A., Lelic, M. A., and Peng, P. (2007). Video-based smoke detection: possibilities, techniques, and challenges suppression and detection research and applications. *A Technical Working Conference (SUPDET)*.
- Yuan, F. (2008). A fast accumulative motion orientation model based on integral image for video smoke detection. *Pattern Recognition Letters*, 29(7):925 – 932.
- Yuan, F. (2011). Video-based smoke detection with histogram sequence of lbp and lbpv pyramids. *Fire Safety Journal*, 46(3):132 – 139.

Yuan, F. (2012). A double mapping framework for extraction of shape-invariant features based on multi-scale partitions with adaboost for video smoke detection. *Pattern Recognition*, 45(12):4326 – 4336.