

14º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2023

Desenvolvimento de um sistema de extração de características para classificação de queimadas em florestas com auxílio de imagens aéreas de pequeno formato

MATHEUS P. MAGALHÃES¹, NATAL H. CORDEIRO²

¹Laboratório de Automação Aplicada a Automação (LCAA), matheus.magalhaes@aluno.ifsp.edu.br.

²Laboratório de Automação Aplicada a Automação (LCAA), natalhenrique@ifsp.edu.br

Área de conhecimento (Tabela CNPq): 1.03.03.05-7 Processamento Gráfico (Graphics).

RESUMO: As queimadas florestais são problemas conhecidos e que podem ocorrer em várias localidades, de maneira natural ou intencional. Diversas tecnologias tem sido desenvolvidas para combater queimadas de vários tipos de vegetação devido às consequências relacionadas com o desmatamento, com a extinção da fauna, com possíveis destruições de construções e ainda, com a produção de resíduos poluentes. O presente trabalho apresenta o desenvolvimento de um sistema de extração de características que permite formar um conjunto de dados (*dataset*). Por meio desse *dataset* será gerado um modelo capaz de executar inferências com intuito de detectar a presença de queimadas florestais de forma automática. Para o desenvolvimento das técnicas de extração de características que formam o *dataset* foi necessário selecionar imagens aéreas de pequeno formato contendo queimadas em florestas. Dessa forma, a primeira etapa deste trabalho foi executada com a pesquisa de uma base de imagens contendo uma diversidade de tipos de queimadas em florestas. A segunda etapa foi consolidada com a implementação de filtros extratores de características que permitiram refinar e organizar os dados para formar o *dataset*, usado para classificação. A terceira etapa teve como finalidade experimentar e comprovar se as características selecionadas que formam o *dataset* foram capazes de realizar classificações com acurácia. Para essa etapa utilizou-se uma técnica de classificação probabilística (*Bayesnet*) que após a sua implementação foi possível produzir inferências a partir de algumas características extraídas e mostraram ser capazes de classificar queimadas de maneira automática.

PALAVRAS-CHAVE: Extração de características, queimadas florestais, classificação, *BayesNet*.

Development of a feature extraction system for classification of fires in forests with the aid of small-format aerial images

ABSTRACT: Forest fires are known problems and can occur in various locations, naturally or intentionally. Several technologies have been developed to combat the burning of various types of vegetation due to the consequences related to deforestation, the extinction of fauna, the possible destruction of buildings and the production of polluting waste. The present work presents the development of a feature extraction system that allows the formation of a specific dataset to carry out automatic classification to detect the presence of fire. For the development of feature extraction techniques that form

the dataset, it was necessary to select small-format aerial images containing forest fires. Thus, the first stage of this work was carried out with the search of an image database containing a diversity of types of fires in forests. The second stage was consolidated with the implementation of feature extractor filters that allowed refining and organizing the data to form the dataset, used for classification. The third stage aimed to experiment and prove whether the selected characteristics that form the dataset were capable of performing accurate classifications. For this stage, a probabilistic classification technique (Bayesnet) was used, which after its implementation made it possible to produce inferences from some extracted characteristics and proved to be capable of classifying fires automatically.

KEYWORDS: Feature extraction, forest fires, classification, BayesNet.

INTRODUÇÃO

As frequentes queimadas em florestas geram um alto prejuízo ao meio ambiente, elas prejudicam tanto as vidas dos animais que vivem na região como também a vegetação que possui forte relação com o ecossistema. Existem tecnologias que permitem realizar uma análise sobre uma determinada região e alertam sobre uma possível queimada. O PRODES (Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite) (INPE (2021)), utiliza sensores que fornecem imagens já georreferenciadas, com mapas de calor e com escalas de temperatura em zonas de queimadas, para depois essas imagens serem utilizadas em estudos. O objetivo principal deste trabalho é apresentar uma nova metodologia de extração de características aplicada em florestas que permita gerar um conjunto de dados (*dataset*) que sirva como base para a produção de um modelo capaz de compreender inferências específicas para a detecção de queimadas de maneira automática. Essa aplicação poderá ser executada a partir de imagens capturadas por uma câmera acoplada em um veículo aéreo não tripulável (VANT), que por sua vez, sobrevoará regiões com trajetos pré-programados em busca de analisar possíveis queimadas.

Uma das tecnologias utilizadas para ajudar o combate contra as queimadas florestais, é através de técnicas de aprendizado de máquina. Diversos trabalhos utilizam redes neurais, com um treinamento realizado a partir de um banco de imagens, para assim realizar reconhecimento de padrões e gerar as classificações. Porém, muitos desses trabalhos não possibilitam visualizar a composição do *dataset* e sendo assim, não permitem a sua customização. Dessa forma, é possível que mesmo com um grande número de imagens utilizadas para o processo aprendizado, ao sistema ainda pode realizar classificações ineficientes para locais que possam apresentar situações específicas.

Foram analisados diversos trabalhos com o tema para detecção de queimadas utilizando aprendizado de máquina. Grande parte dos trabalhos utilizaram câmeras estáticas para monitorar um ambiente aberto e conseguiram cumprir com qualidade seu papel de monitoramento de queimadas florestais. Porém, em florestas muito fechadas e com uma grande área, uma única câmera é um grande fator limitante por ter um campo de visão restrito.

Outro fator em comum a se observar é que todas as técnicas de aprendizado implementadas nos trabalhos ((Huang et al., 2022), (Li et al., 2022), (Majid et al., 2022), (Khan et al., 2021)) são CNNs Redes Neurais Convolucionais (em inglês, CNN), com algumas variações entre elas, exceto no trabalho de (Hashemzadeh e Zademehti, 2019). Uma CNN, realiza os cálculos de pesos e hiperparâmetros em uma área delimitada, que percorre toda a dimensão da imagem, onde tende a buscar semelhanças com o que foi treinado, retornando ao final o resultado filtrado. As redes neurais aplicadas nos trabalhos citados funcionam com um treino provido a partir de um banco de imagens para assim realizar

reconhecimento de padrões e gerar as classificações.

Neste trabalho, aplicaram-se técnicas de visão computacional para extração de características com uma abordagem semelhante com o trabalho de (Hashemzadeh e Zademehdi, 2019). Essas características permitiram construir um *dataset* capaz de ser customizado para qualquer tipo de floresta ou tipos de queimadas.

MATERIAIS E MÉTODOS

A fumaça e o fogo são os principais objetos de interesse deste trabalho. A metodologia definida para extração das características desses objetos de interesse pode ser vista nas Figuras 1 e 2. Observe que na Figura 1, o retângulo 1 (cor vermelha) representa a detecção de fumaça e os retângulos de numeração 2 (cor amarela) representa a detecção de fogo. Após definição dos objetos de interesse, definiram-se as características que deveriam ser extraídas para a classificação de queimadas de maneira automática: cor média do fogo e da fumaça ao redor do centro de massa; tamanho do fogo e da fumaça em *pixels*; movimentação do fogo e da fumaça em *pixels*. Todas estas características são capturadas no Módulo de visão (ver figura 1, item (b)).




Figura 1: A imagem (a) demonstra a detecção dos objetos de interesse. O retângulo com bordas vermelhas (1), representa a detecção da fumaça. Os retângulos com bordas amarelas (2) representam a detecção do fogo. A imagem (b) demonstra a arquitetura do projeto, segmentado em módulos.

O centro de massa dos objetos de interesse (Fogo e fumaça) é uma das características extraídas das imagens (ver SFFF do item (b) da Figura 01) e que ajudam a obter a cor (RGB) que compõe o *dataset* do presente trabalho. O centro de massa é a localização do *pixel* central a partir de todo o contorno do objeto de interesse. Ao detectar algum dos objetos de interesse, o algoritmo retorna a cor média ao redor do centro de massa. Isso ocorre a partir dos valores RGB fornecidos por uma grade 9x9 *pixels* (ver Figura 02) em torno do centro de massa.

Na linha 2 do Algoritmo 01, foi implementado um laço de repetição para possibilitar a extração das características de cada quadro (imagem RGB) do video capturado. A biblioteca *OpenCV* disponibiliza uma função que já decompõe o vídeo em quadros e outra função que realiza a sua conversão para uma matriz de valores inteiros. A partir dessa matriz é possível aplicar algumas técnicas de processamento de imagem. Observa-se na linha 4 (Alg 01) a aplicação um filtro gaussiano capaz de eliminar ruídos que são irrelevantes e que podem prejudicar o processo de detecção de um objeto de interesse.

Após essa etapa, é realizado a conversão do espaço de cor RGB para o espaço de cor HSV (ver linha 6, Alg. 1). Após aplicação desse método, é possível visualizar nas linhas 8, 10, 12 e 14, do Algoritmo 1, que o sistema permite definir os limiares (Lower, e Upper) para realçar as características dos objetos fogo e fumaça. O valor Upper define o valor máximo (de 0 a 255 nos canais RGB) e o Lower o valor mínimo. Com isso o algoritmo aplica um filtro entre estes dois limiares para eliminar ruídos. Com a




Figura 2: A imagem (a) é a imagem original. As imagens (b e c) apresentam as características (pontos vermelhos) que o submódulo SDCCM possivelmente pode gerar (ver item (b) da Figura 01), sendo a imagem (b) o fogo detectado e a imagem (c) a fumaça detectada. O ponto vermelho nas imagens (b e c) representa o centro de massa de cada característica.

definição dos limiares para cada objeto de interesse, foi implementada a função “inRange” da biblioteca *OpenCV* (ver linha 12, Alg. 1). Essa função tem como finalidade separar um objeto de interesse com base no intervalo de valores dos seus *pixels* no espaço de cores HSV. Por meio dessa separação, é possível delimitar e calcular o tamanho de cada objeto de interesse usando a função “count” da *OpenCV* (ver linhas 14, Alg. 1), que contabiliza os *pixels* delimitados pela função inRange.

A partir da obtenção dos tamanhos (TamC) de cada objeto de interesse em *pixels*, foi possível aplicar a função para calcular o centro de massa dos objetos. Essa aplicação pode ser vista na linha 16 do algoritmo 1 com o uso da função Cm, que retorna as coordenadas (X e Y) do centro de massa de cada objeto.

Com as coordenadas do centro de massa (CMF) de cada objeto de interesse foi possível armazenar o valor em RGB do centro de massa. Esses valores RGB de cada objeto de interesse compõe o *dataset* produzido para calcular a probabilidade de presença de queimadas na floresta. Dessa forma, a obtenção desses valores são realizadas em tempo de execução para cada quadro (imagem extraída do vídeo). Para atingir uma melhor acurácia dos valores RGB, capturou-se também, os valores dos *pixels* vizinhos, pertencentes a uma matriz 3x3 ao redor do centro de massa. Essa matriz permite calcular o valor médio dos valores RGB nesta área. Para isso foram somados os valores de cada cor RGB e a partir da somatória, dividiu-se esse valor pela quantidade de elementos (nove) da matriz.

As últimas características dos objetos de interesse que completaram o *dataset* proposto neste trabalho são relacionadas com a detecção de movimentos. Normalmente, as regiões onde presenciam fogo e fumaça geram mudanças devido à sensibilidade ao vento e também a evolução da região de queimadas. Para detectar essas mudanças, armazenou-se o tamanho dos objetos de interesse em diferentes momentos. Para cada quadro extraído do vídeo, um novo tamanho dos objetos fogo e fumaça foram detectados. Dessa forma, realizou-se a subtração do tamanho do fogo e da fumaça entre a imagem corrente com as anteriores (três quadros). Sendo assim, foi possível obter a diferença de tamanho em *pixels*, e armazenar essa diferença no *dataset*. O algoritmo armazena os valores em cada quadro e realiza o cálculo do movimento entre os quadros. Isso resulta no valor da diferença da quantidade de *pixels* do objeto de interesse (ver figura 4).

Algoritmo 1: aplicação das técnicas de extração de características, a partir das cores de fogo e de fumaça, definidas para o sistema de extração de característica.

Algorithm 1 Algoritmo de extração de cores, centro de massa e tamanhos dos objetos de interesse.

Input Vídeo aéreo com queimada florestal **Output** Quadros finais para o objeto de interesse (Qf) com a característica extraída da imagem, tamanho da característica ocupada na imagem em *pixels* ($TamC$) e resultado do cálculo do centro de massa (CMF)

Require: opencv

```

1: Obtém quadro a partir do vídeo
2: while Captura vídeo do
3:   // Adiciona blur no quadro atual
4:    $B \leftarrow GaussianBlur(Q, (x, y), sigma)$ 
5:   // Adiciona filtro HSV para quadro com blur
6:    $Hsv \leftarrow cvtColor(B, COLOR_BGR2HSV)$ 
7:   // Define valores mínimos para ser aplicado ao filtro de cada característica
8:    $Lower \leftarrow [R, G, B]$ 
9:   // Define valores máximos para ser aplicado ao filtro de cada característica
10:   $Upper \leftarrow [R, G, B]$ 
11:  // Define máscara com os limiares para o objeto de interesse
12:   $MaskFum \leftarrow inRange(Hsv, Lower, Upper)$ 
13:  // Calcula tamanho da característica a partir da máscara aplicada
14:   $TamC \leftarrow cv2.countNonZero(MaskFog)$ 
15:  // Calcular o centro de massa do objeto de interesse
16:   $CMF \leftarrow Cm(Qf, TamC)$ 
17: end while
    return  $FeaturesVector[Qf, CMF, TamC]$ 

```

RESULTADOS E DISCUSSÃO

Após o desenvolvimento do algoritmo para a extração das características, realizou-se a pesquisa de vídeos contendo queimadas (fogo) em florestas. Para essa etapa, dividiram-se os vídeos em duas classes (vídeos com fogo e vídeos sem fogo). Os vídeos foram necessários para experimentar os algoritmos extratores de características e também para produzir os dados que formaram o *dataset*. Os vídeos foram extraídos do site <https://www.pexels.com..> Destes vídeos foram realizados a detecção (ver figura 3 e 4) extração de características para construir o *dataset*.




Figura 3: A imagem (a) é a imagem original. As imagens (b e c) apresentam as características que foram detectadas pelo submódulo SDCCM (ver item (b) da Figura 01), sendo a imagem (b) o fogo detectado e a imagem (c) a fumaça detectada.

Com a aplicação do algoritmo de extração de características realizada, formou-se um *dataset* (ver item (b) da Figura 01) que possui as características extraídas de acordo com a metodologia proposta.

No *dataset* gerado (Tabela 1) foi adicionado a característica "temfogo", no qual possui os valores: verdadeiro ou falso.

Este *dataset* foi testado com o algoritmo *BayesNet* com o *software WEKA*. Após aplicado o método probabilístico em 48 instâncias, sendo 24 dessas classificadas com a presença de queimada e 24 com a ausência de queimada, obteve-se a acurácia de 96,70%.




Figura 4: Exemplo e demonstração do processo que o Submódulo SDM (ver item (b) da Figura 01) realiza para capturar o valor do movimento. Observe que é executada a comparação entre o quadro atual (c) com outros quadros anteriores (a e b).

Tabela 1: Primeiras linhas do *dataset* gerado a partir das características extraídas pelo algoritmo 01.

RgbRFogo	RgbGFogo	RgbBFogo	rgbRfumaca	RgbGFumaca	RgbBFumaca	QtdMovFogo	QtdMovFumaca	TamanhoFogo	TamanhoFumaca	temFogo
79	97	58	178	188	206	81	1158	707	33978	true
60	72	51	170	184	203	19	368	727	35114	true
67	72	47	173	185	204	8	194	699	34172	true
65	74	48	168	185	203	151	1220	878	36334	true
97	85	27	97	85	27	0	0	0	0	false
99	89	36	99	89	36	0	0	0	0	false

CONCLUSÕES

Diferente dos trabalhos que utilizaram redes neurais sem disponibilizar os métodos de extração de características e a composição do *dataset*, este trabalho teve como principal objetivo atuar por um caminho diferente, no qual o *dataset* produzido possibilita ser totalmente customizado. Os métodos de extração de características propostos e usados para compor os *datasets*, são capazes de realizar a detecção de queimadas em florestas de maneira automática através de algoritmos de aprendizados de máquina. As próximas etapas desse trabalho visa a implantação do sistema em um VANT para a realização de sobrevoos com o intuito de analisar os resultados in loco.

REFERÊNCIAS

- HASHEMZADEH, M.; ZADEMEHDI, A. Fire detection for video surveillance applications using ica k-medoids-based color model and efficient spatio-temporal visual features. *Expert Systems with Applications*, v. 130, p. 60–78, 2019. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417419302490>>.
- HUANG, P. et al. A combined real-time intelligent fire detection and forecasting approach through cameras based on computer vision method. *Process Safety and Environmental Protection*, v. 164, p. 629–638, 2022. ISSN 0957-5820. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957582022005675>>.
- INPE. Metodologia para monitoramento da floresta usada nos projetos prodes e deter. *Metodologia para monitoramento da floresta usada nos projetos PRODES e DETER.*, 2021. Disponível em: <<http://mtc-m21c.sid.inpe.br/col/sid.inpe.br/mtc-m21c/2021/01.25.18.31/doc/publicacao.pdf>>.
- KHAN, S. et al. Deepsmoke: Deep learning model for smoke detection and segmentation in outdoor environments. *Expert Systems with Applications*, v. 182, p. 115125, 2021. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417421005662>>.
- LI, Y. et al. An efficient fire and smoke detection algorithm based on an end-to-end structured network. *Engineering Applications of Artificial Intelligence*, v. 116, p. 105492, 2022. ISSN 0952-1976. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0952197622004821>>.
- MAJID, S. et al. Attention based cnn model for fire detection and localization in real-world images. *Expert Systems with Applications*, v. 189, p. 116114, 2022. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417421014445>>.