

Identificação de Incêndios Florestais Utilizando Segmentação de Imagens e Aprendizado de Máquina

Lucas de G. M. Castro, Waldir S. S. Júnior, Celso B. Carvalho

Resumo— Este artigo apresenta o uso de diferentes técnicas de pré-processamento de dados e aprendizado de máquina para detecção de incêndios florestais em imagens. As imagens utilizadas para treinamento foram obtidas de dois bancos de dados distintos e variam em horário e estação climática. O algoritmo kNN e técnicas de pré-processamento como color perception, segmentação de imagens e extração de quartis foram empregados no treinamento. Os valores de acurácia, sensibilidade e especificidade foram utilizados como métricas de avaliação, e os resultados obtidos foram iguais a 98%, 98.6% e 96.2%, respectivamente, sendo superiores a outros trabalhos disponíveis na literatura.

Palavras-Chave— Segmentação de imagens, Aprendizado de máquina, Análise de quartis

Abstract— This research presents the use of different data pre-processing techniques and machine learning for forest fire detection in images. The images used for training were obtained from two distinct databases and vary in time and weather conditions. The kNN algorithm and pre-processing techniques such as color perception, image segmentation, and quartile extraction were employed in the training process. Accuracy, sensitivity, and specificity values were used as evaluation metrics, and the obtained results were equal to 98%, 98.6%, and 96.2%, respectively, being superior to other works available in the literature.

Keywords— Image segmentation, Machine learning, Quartile analysis

I. INTRODUÇÃO

Considerado o principal problema ambiental em 2020, os incêndios florestais afetaram diretamente mais de 47 mil pessoas no Brasil devido à poluição causada [1]. Empresas e áreas de pesquisa dedicaram esforços intensos para indicar maneiras de conter os danos causados pelas queimadas. Na engenharia e computação, as pesquisas para previsão, classificação e identificação de incêndios florestais receberam ampla atenção de cientistas que compreenderam que tais etapas são cruciais na gestão de incêndios florestais, como para respostas a emergência, planejamento do uso da terra e adaptação climática [2].

Uma das principais técnicas para a identificação de fumaça ou fogo é a classificação de imagens, que pode ser realizada

utilizando técnicas de machine learning (ML) ou deep learning (DL) [3]. A classificação da vasta gama de escalas do fogo é um dos principais desafios para essa aplicação. No entanto, a ciência obteve avanços significativos entre 2018 e 2021 com a aplicação de técnicas de ML automatizadas, que podem ser ferramentas valiosas para a detecção de incêndios florestais, como demonstrado nos trabalhos de [4], [5], [6], que apresentam metodologias para detecção de incêndios florestais usando aprendizado de máquina, com resultados variando entre 83% e 97,36% de acurácia.

O trabalho proposto por [7] sugere um método de detecção de incêndios florestais utilizando o espaço de cores YCbCr. Esse espaço de cores é eficiente na separação da luminância e crominância em relação a outros espaços de cores. O sistema alcançou uma acurácia máxima de 99,4%, mas não foi avaliado em bases de dados diferentes, o que pode sugerir over-fitting. Da mesma forma, [8] utilizou técnicas de pré-processamento para classificar imagens de incêndio através das componentes RGB (*Red Green Blue*) pixel-a-pixel, alcançando uma acurácia média de 90%, sem considerar imagens de fumaça e sem informar valores de sensibilidade ou especificidade.

Apesar de resultados promissores, essas técnicas também têm suas limitações, incluindo o tempo elevado para o processamento e o tamanho reduzido das bases de dados utilizadas. Desta forma, este trabalho propõe uma abordagem alternativa para a detecção de incêndios florestais em imagens onde a classificação é realizada através das seguintes operações nas imagens: i) análise pixel-a-pixel; ii) segmentação; iii) utilização de valores das componentes RGB; iv) e cálculo de quartis das componentes RGB. Tal abordagem permitiu a criação de classificadores mais simples e precisos.

A Seção II apresenta uma breve fundamentação teórica sobre segmentação de imagens com base em *Graph Cut*, canais RGB, e método k-NN (*k Nearest Neighbors*); A Seção III apresenta as bases de dados utilizadas, a metodologia adotada para implementação de nossa proposta e as métricas de avaliação de desempenho; A Seção IV apresenta os resultados obtidos; Por fim, a Seção VI apresenta as conclusões.

II. FUNDAMENTAÇÃO TEÓRICA

Nesta Seção, são apresentados conceitos relacionados a algoritmos, técnicas e análise utilizados no desenvolvimento deste trabalho.

Lucas de Góes Muniz de Castro, Center for R&D in Elec. and Inf. Tech. (UFAM/CETELI), Universidade Federal do Amazonas, Manaus-AM, e-mail: lucasgmuniz@gmail.com; Waldir S. S. Júnior, Center for R&D in Elec. and Inf. Tech. (UFAM/CETELI), Universidade Federal do Amazonas, Manaus-AM, e-mail: waldirjr@ufam.edu.br; Celso C. Barbosa, Center for R&D in Elec. and Inf. Tech. (UFAM/CETELI), Universidade Federal do Amazonas, Manaus-AM, e-mail: ccarvalho_@ufam.edu.br. Este trabalho foi parcialmente financiado por Universidade Federal do Amazonas.

A. Pré-processamento de Imagens

O pré-processamento de imagens visa melhorar a qualidade da imagem ou torná-la mais adequada para análise, incluindo correções de distorções, ajuste de brilho e realce de cor, filtragem para remoção de ruído, remoção de *background*, entre outras técnicas. É uma etapa importante em aplicações de visão computacional para melhorar a eficiência e precisão dos algoritmos [8].

1) *Segmentação de Imagens baseada em Graph Cut*: Existem diferentes métodos para extração de um objeto em primeiro plano (*foreground*) de uma imagem digital, dentre estes, é possível mencionar o método de segmentação de imagens para extração de objetos através do modelo *graph cut* [9].

O modelo baseia-se na divisão de um grafo em dois subgrafos. O grafo G é composto por um conjunto de vértices (V) e arestas (A), onde cada aresta $\alpha \in A$ tem um peso positivo e conectam os vértices (V). Existem terminais que delimitam como o grafo deve ser dividido em dois subconjuntos de vértices [10]. Desta forma, um *graph cut* pode ser definido como um subconjunto (C) de vértices separados a partir dos terminais, onde $C \subset A$ e $G(C) = V, A \setminus C$ e a função custo definida por:

$$|C| = \sum(\alpha \in C \rho(\alpha)). \quad (1)$$

Tendo nas arestas A a representação da relação entre um pixel e seus vizinhos e cada vértice V representado por um pixel de uma imagem, é possível avaliar os pesos (ρ) de cada aresta que são definidos pela probabilidade de um pixel estar em primeiro ou segundo plano. Quando há grande diferença na cor de um pixel, é atribuído um peso baixo àquela aresta. O algoritmo é então aplicado para segmentar o grafo, dividindo-o em dois subgrupos: o vértice de origem e o de destino, a partir da função de custo [10].

2) *Canais RGB*: O sistema RGB é uma forma de representação de cores, onde as cores são construídas a partir da mistura das três cores principais vermelho, verde e azul. Cada pixel de uma imagem digital é composto por três componentes de cor, sendo um para cada cor primária. A combinação dessas cores primárias em diferentes proporções permite a criação de uma ampla gama de cores, incluindo todas as cores visíveis pelo olho humano [11].

A intensidade de cada cor primária no sistema RGB é representada por um número inteiro entre 0 e 255, onde 0 representa a ausência da cor e 255 representa a cor mais forte possível [11]. Ao combinar diferentes valores de intensidade para cada cor primária, é possível criar uma grande variedade de cores diferentes. Com a separação desses canais e a comparação de seus valores, é possível extrair padrões e identificar tons de cores repetidas. Assim, o sistema RGB permite a representação de cores de forma numérica, o que facilita a manipulação e processamento de imagens digitais [11].

3) *Análise de Quartis*: A análise de quartis é utilizada para dividir um conjunto de dados em quatro subconjuntos com 25% dos elementos do conjunto de dados; O que permite avaliar a tendência central e a dispersão de um conjunto de dados [12].

O primeiro quartil (Q1) refere-se ao valor das 25% menores observações, o segundo quartil (Q2) corresponde as 50% menores observações e o terceiro quartil (Q3) é o valor que delimita as 25% maiores observações [12]. O cálculo dos valores dos quartis inferior e superior de uma amostra baseia-se em calcular a mediana do conjunto de dados x_m e depois calcular a mediana da metade inferior x_l e da metade superior x_u dos dados, para um conjunto de n -observações $X = x_1 \leq \dots \leq x_n$.

Ao aplicar o cálculo dos quartis a um conjunto de dados contendo as componentes R, G ou B de uma imagem, é possível identificar padrões existentes nestes canais, o nível de intensidade de cor e sua variação na imagem, sendo útil para a diferenciação de imagens contendo incêndios de imagens sem incêndios [12].

4) *k-Nearest Neighbors (kNN)*: O *k-Nearest Neighbors* (kNN) é um algoritmo de classificação baseado em instância, ou seja, ele classifica novas amostras de acordo com o que é semelhante a eles em relação às suas características [13].

De maneira geral, o conjunto de dados já categorizados é chamado de conjunto de aprendizado, onde as linhas são vetores n -dimensionais que representam instâncias de treinamento com n características. Para prever a classe de uma nova amostra (referida como exemplo de teste), o algoritmo kNN segue os seguintes passos:

- 1) Calcula a relação de similaridade entre a instância de teste e treinamento.
- 2) Seleciona as k instâncias de treinamento mais similares (próximas) à instância de teste.
- 3) Verifica a classe predominante, ou seja, a classe que aparece com maior frequência dentre as k instâncias selecionadas.
- 4) Atribui a instância de teste à classe predominante.

A similaridade é calculada mediante uma medida de dissimilaridade que é aplicada entre dois vetores. Várias medidas podem ser utilizadas, tais como as distâncias Euclidiana, Manhattan e Minkowski, sendo geralmente adotada na literatura, a distância Euclidiana definida pela Equação 2:

$$dist(u, v) = \sqrt{\sum_{i=1}^N (u_i - v_i)^2}, \quad (2)$$

em que u e v são vetores n -dimensionais; e u_i e v_i representam os valores do atributo i dos respectivos vetores [13].

III. METODOLOGIA

Nesta Seção será apresentada a modelagem utilizada para solucionar o problema proposto. Serão abordadas as implementação das técnicas de treinamento, validação e avaliação dos resultados obtidos. A Fig. 1 demonstra o método proposto, dividido em três etapas: processamento de dados, treinamento de máquina e classificação, tendo as bases de dados de imagem como entrada e a classificação dessas imagens como saída.

A. Base de Dados

Os dados utilizados neste trabalho foram provenientes de duas bases de dados, CorsicanFire Dataset [14] e Deepfire [15], contendo 2000 e 2500 imagens, respectivamente.

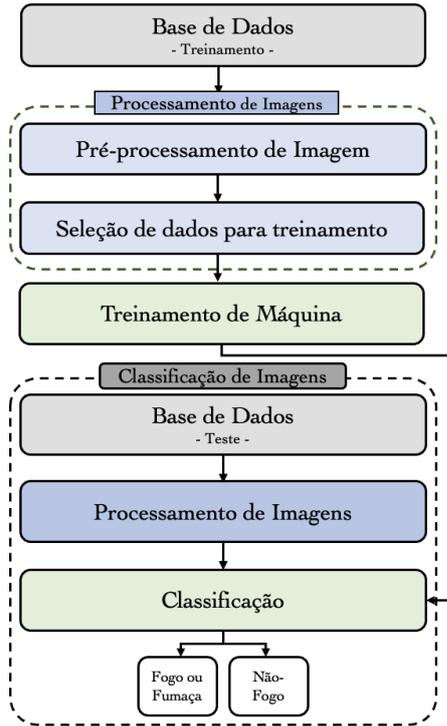


Fig. 1: Diagrama do algoritmo proposto.

A base CorsicanFire [14] contém imagens codificadas nos sistemas RGB e NIR (*Near Infrared*). Neste conjunto de dados, as imagens NIR são capturadas com maior tempo de integração/exposição, o que aumenta o brilho da área de incêndio e facilita a segmentação com técnicas simples de processamento de imagem.

A base de dados DeepFire [15] contém um conjunto de imagens RGB com alta resolução, coletadas ao longo de vários anos em diferentes regiões do mundo, e que foram rotuladas manualmente para indicar a presença ou ausência de incêndios florestais.

Nesta pesquisa, 70% dos dados de cada base foram alocados para treinamento e 30% para teste.

B. Implementação do Modelo

A proposta se iniciou com a fase de pré-processamento das imagens, dividida em quatro etapas:

- 1) Segmentação do primeiro plano da imagem.
- 2) Divisão da imagem em quatro quadrantes.
- 3) Determinação dos valores das componentes RGB.
- 4) Determinação dos valores dos quartis das componentes RGB.

A segmentação do primeiro plano da imagem foi realizada utilizando o método de separação de grafos [10]. Esta fase foi aplicada tanto às imagens das bases de treinamento como para as imagens das bases de testes e teve como objetivo extrair da imagem o primeiro plano, no qual os fenômenos fogo e fumaça podem ser evidenciados. Para imagens que não continham fogo, fumaça ou focos de incêndio, o algoritmo destacava a parte mais rugosa ou com maior relevo, considerando partes planas como segundo plano.

Uma vez concluída a segmentação de imagens, realizou-se a divisão da imagem em quatro partes de tamanhos iguais (divisão em quadrantes), com intuito de eliminar quadrantes desnecessários pela ausência de 1° plano da imagem, a fim de tornar a fase de treinamento mais simples e veloz. A Fig. 2 exemplifica a imagem original (à esquerda), imagem pós segmentação (ao meio) e imagem pós divisão de quadrantes (à direita).



Fig. 2: Imagem original (à esquerda), imagem pós segmentação (ao meio) e imagem pós divisão de quadrantes (à direita).

Em seguida, foi realizada a separação das componentes RGB das imagens, o que possibilitou verificar e comparar os valores de cada uma das componentes RGB dos pixels das imagens. Além disso, o fato de transformar uma imagem em três matrizes numéricas possibilitou aplicar técnicas de processamento de dados à análise.

Para cada quadrante da imagem e, para cada componente RGB de cada quadrante, foram determinados os valores dos quartis dos pixels. A partir da geração dos valores dos quartis, foi possível observar um padrão numérico para a base de dados de treinamento, além de tornar possível a eliminação de quadrantes da imagem com pouca ou nenhuma informação.

Para eliminação de quadrantes com pouca informação, foi utilizado o caso no qual um quadrante possuía valores de quartis para as componentes R, G e B iguais a 0, já que os valores das componentes RGB (0, 0, 0) se referem ao preto ou nulo.

As informações dos quadrantes de imagens não eliminados na etapa anterior, foram inseridas em um arquivo chamado “input.csv”, utilizada como entrada para o treinamento da máquina, com informações do título da imagem original, quadrante da imagem, valores de quartil e a informação se a imagem continha fogo, fumaça ou não possuía esses fenômenos.

Para avaliar como as técnicas de pré-processamento afetavam os valores de acurácia, sensibilidade e especificidade, foram realizados testes incrementais, nos quais as técnicas foram combinadas de acordo com a Tabela I. Todas as combinações das técnicas foram executadas sob as mesmas condições e utilizando as mesmas bases de dados.

O treinamento do modelo kNN foi realizado utilizando como principal parâmetro o valor $2 \leq k \leq 20$.

TABELA I: Descrição dos diferentes métodos de pré-processamento utilizados para realização de testes.

Método de Pré-processamento	Etapas Realizadas
M1	Determinação dos valores das componentes RGB e seleção de dados
M2	M1 + Extração do primeiro plano
M3	M2 + Divisão em quadrantes
MC	M3 + Cálculo dos quartis

C. Métricas de avaliação de desempenho

Para avaliar o modelo de classificação e a eficiência do teste, foram consideradas a acurácia, sensibilidade e especificidade como medidas de avaliação de desempenho [16]. A acurácia mede a proporção de predições corretas e indica o desempenho geral do modelo, demonstrado na Equação 3:

$$Acurácia(\%) = \frac{Previsões\ Corretas}{Previsões\ Realizadas}. \quad (3)$$

O valor de sensibilidade indica a probabilidade de um indivíduo avaliado, por exemplo, como doente de ter seu teste positivo, conforme indicado na Equação 4:

$$S(\%) = \frac{Verdadeiros\ Positivos}{Verdadeiros\ Positivos + Falsos\ Negativos}. \quad (4)$$

O valor de especificidade indica a probabilidade de um indivíduo avaliado e normal ter seu teste negativo para a doença, conforme indicado na Equação 5:

$$E(\%) = \frac{Verdadeiros\ Negativos}{Verdadeiros\ Negativos + Falsos\ Positivos}. \quad (5)$$

IV. RESULTADOS OBTIDOS

Os valores descritos nessa Seção foram obtidos a partir do uso de 1350 imagens de testes. Os testes foram realizados em etapas incrementais, conforme descrito na Tabela 1 da Seção IV, e as máquinas de treinamento foram configuradas de acordo com as especificações descritas no item B da Seção IV.

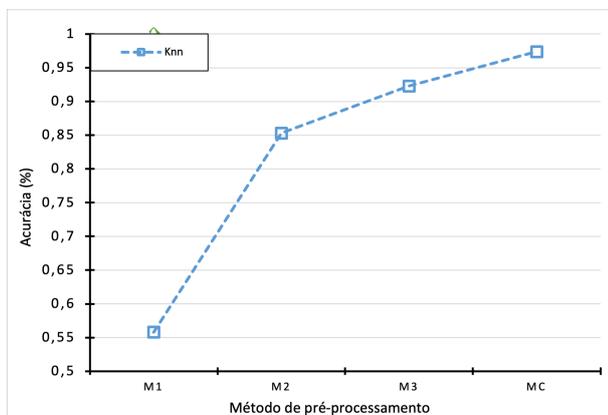


Fig. 3: Resultados de acurácia para diferentes métodos (M1, M2, M3 e MC) com o algoritmo de classificação kNN, com resultados M1 = 55,8%; M2 = 85,3%; M3 = 92,3%; MC = 97,4%.

Na Fig. 3, observa-se que o método M1 utilizado em conjunto com o algoritmo de classificação kNN gerou valor de acurácia de 55,8%, enquanto os métodos M2 e M3 geraram resultados entre 85,8% e 92,3%, respectivamente. Por fim, o método MC gerou resultado 97,5% de acurácia, ao empregar o algoritmo K-NN com k=5.

O resultado apresentado na Fig. 4 indica que dentre as 2000 imagens testadas, o classificador kNN cometeu 33 erros. Dentre estes erros, 26 se referem a imagens de florestas que o algoritmo classificou como incêndios e 7 imagens de incêndios que o algoritmo classificou apenas como florestas. A Fig. 5 exemplifica imagens onde o algoritmo cometeu erros.

True Label	Predicted Label	
	Fogo	Floresta
Fogo	668	7
Floresta	26	649

Fig. 4: Matriz de confusão do método completo.



Fig. 5: Exemplo das imagens classificadas erroneamente, contendo incêndio (acima) e contendo apenas florestas (abaixo).

Nas imagens da parte superior da Fig. 5, é possível perceber que os falsos negativos ocorreram a partir do pré-processamento, que retornou como resultado imagens predominantemente verdes e com pequenos tons de amarelo ou cinza, sem a existência de fogo ou fumaça, o que ocasionou erro de classificação. O mesmo ocorre para os falsos positivos, onde o primeiro plano extraído das imagens originais possuía tons predominantemente quentes, como vermelho ou laranja.

A Tabela 2 ilustra os resultados de sensibilidade e especificidade obtidos a partir dos métodos propostos na Seção III. Os melhores resultados foram obtidos com o uso do método MC, com 95,9% de Sensibilidade e 96,2% de Especificidade.

TABELA II: Resultados obtidos de sensibilidade e especificidade para diferentes métodos.

	Sensibilidade	Especificidade
M1	35.4%	76.2%
M2	82.0%	88.6%
M3	91.3%	93.3%
MC	98.6%	96.2%

Em uma análise comparativa, a Tabela 3 ilustra a comparação entre os estudos [5], [7] e [8] e o método proposto, ao utilizar o conjunto de dados CorsicanFire (2017). Os resultados alcançados evidenciam que o método proposto supera as referências literárias tanto em termos de tempo de classificação quanto à valores de acurácia.

TABELA III: Comparação dos resultados obtidos ao submeter trabalhos disponíveis na literatura a mesma base de dados.

Método	Tempo de Classificação por Imagem (s)	Acurácia (%)
Zhang (2022)	0,085	93,33
Premal (2014)	0,113	96,33
Bakri (2018)	0,145	88,40
Método Proposto	0,025	97,40

V. CONCLUSÕES

Neste trabalho foi proposto método de identificação de incêndios florestais com base em segmentação de imagens e aprendizado de máquina, utilizando dados das componentes RGB para identificação de padrões de intensidade de cores. O método projetado utiliza a análise de quartis na representação dos dados para melhorar a precisão de identificação, auxiliando na eliminação de dados desnecessários para o treinamento. A segmentação foi um processo importante no método proposto utilizado para extrair o primeiro plano da imagem, potencializando os dados necessários para identificação de padrões. A divisão em quadrantes auxiliou no tratamento de dados, tornando a imagem menor e com identificação mais simples e precisa, bem como a extração das componentes de cor RGB e o cálculo de quartis, a fim de que a imagem pudesse ser traduzida como informações numéricas resumidas, simplificando os dados de entrada para os algoritmos de ML.

A acurácia média da proposta MC desse trabalho é comparável aos disponíveis na literatura, que utilizam arquiteturas mais complexas e com bases de dados maiores, obtendo como melhor resultado a acurácia de 97,4%. Ao obter taxa de sensibilidade de 98,6%, é possível afirmar que o método MC proposto foi capaz de identificar incêndios florestais com alta precisão e baixo índice de falsos negativos.

Ao comparar os resultados entre imagens sem pré-processamento (métodos M1, M2 e M3) e com a proposta do método (MC) é possível afirmar que a combinação entre a segmentação de imagens, divisão por quadrantes e extração de valores RGB foi bem-sucedida, já que a inserção sequencial desses métodos mostrou melhoria nos resultados obtidos.

Além disso, por se tratarem de processos simples e rápidos, o método proposto não se restringe somente a análise de incêndios, oferecendo a capacidade de explorar espectros de cores para avaliar densidades florestais, características de produtos agrícolas, estado do solo e áreas relacionadas. Para trabalhos futuros, propõem-se a adaptação do método para o tratamento de dados extraídos de vídeos, respectiva análise do tempo de processamento, comparação com os resultados de imagens mais nítidas e frames de vídeos.

REFERÊNCIAS

- [1] Brandão, A. et Al. A benchmarking analysis of open-source business intelligence tools in healthcare environments. *Information* 2016, 7, 57.
- [2] REUTERS. "Desastres causam prejuízo de US\$ 210 bi em 2020, dizem seguradoras". Exame, 7 de janeiro de 2021. Disponível em: < <https://exame.com/esg/desastres-causam-prejuizo-de-us-210-bi-em-2020-dizem-seguradoras/>>. Acesso em: 30 de jan. de 2023.
- [3] L. Giglio et Al. (2018). The Collection 6 MODIS burned area mapping algorithm and product. *Remote Sensing of Environment*, 217, 72–85.
- [4] X. Chen et Al. "Wildland Fire Detection and Monitoring Using a Drone- Collected RGB/IR Image Dataset" in *IEEE Access*, vol. 10, pp. 121301-121317, 2022, doi: 10.1109/ACCESS.2022.3222805.
- [5] S. Zhang, N. Qu, T. Zheng and C. Hu, "Series Arc Fault Detection Based on Wavelet Compression Reconstruction Data Enhancement and Deep Residual Network," in *IEEE Transactions on Instrumentation and Measurement*, vol. 71, pp. 1-9, 2022, Art no. 3508409, doi: 10.1109/TIM.2022.3158990.
- [6] V. Khryashchev and R. Larionov, "Wildfire Segmentation on Satellite Images using Deep Learning," 2020 Moscow Workshop on Electronic and Networking Technologies (MWENT), Moscow, Russia, 2020, pp. 1-5, doi: 10.1109/MWENT47943.2020.9067475.
- [7] C. E. Premal and S. S. Vinsley, "Image processing based forest fire detection using YCbCr colour model," 2014 International Conference on Circuits, Power and Computing Technologies [ICCPCT-2014], Nagercoil, India, 2014, pp. 1229-1237, doi: 10.1109/ICCPCT.2014.7054883.
- [8] N. S. Bakri, R. Adnan, A. M. Samad and F. A. Ruslan, "A methodology for fire detection using colour pixel classification," 2018 IEEE 14th International Colloquium on Signal Processing Its Applications (CSPA), Penang, Malaysia, 2018, pp. 94-98, doi: 10.1109/CSPA.2018.8368692.
- [9] BOYKOV, Y. Y.; JOLLY, M. P. Interactive graph cuts for optimal boundary region segmentation of objects in n-d images. In: *IEEE International Conference on Computer Vision*, 2001, Vancouver, BC: Proceedings... IEEE, 2001. v. 1, p. 105–112.
- [10] ROTHER, C.; KOLMOGOROV, V.; BLAKE, A. "GrabCut": Interactive Foreground Extraction Using Iterated Graph Cuts. *ACM Transactions on Graphics (TOG)*, v. 23, n. 3, p. 309–314, 2004.
- [11] CHAVES-GONZÁLEZ, J. M.; VEGA-RODRÍGUEZ, M. A.; GÓMEZ-PULIDO, J. A.; SÁNCHEZ-PÉREZ, J. M. Detecting skin in face recognition systems: A colour spaces study. *Digital Signal Processing*, 20(3):806–823, 2010.
- [12] KAKUMANU, P.; MAKROGIANNIS, S.; BOURBAKIS, N. A survey of skin-color modeling and detection methods. *Pattern recognition*, 40(3):1106–1122, 2007.
- [13] JOARDER A. H. E FIROZZAMAN M. Quartiles for Discrete Data. *Teaching Statistics*. vol. 23, no 3, 2001.
- [14] Cover, T. M. e Hart, P. E. Nearest Neighbor Pattern Classification. *Ieee Transactions On Information Theory*, vol. vol. 13, no. 1, 1967.
- [15] B. Hopkins, L. O'Neill, F. Afghah, A. Razi, A. Watts, P. Fule, et al., FLAME 2: Fire detection and modeling: Aerial Multi-spectral image dataset, 2022, [online] Available: <https://iee-dataport.org/open-access/flame-2-fire-detection-and-modeling-aerial-multi-spectral-image-dataset>.
- [16] Tom Toulouse, Lucile Rossi, Antoine Campana, Turgay Celik, Moulay A. Akhloufi, Computer vision for wildfire research: An evolving image dataset for processing and analysis, *Fire Safety Journal*, Volume 92, 2017, Pages 188-194, ISSN 0379-7112, <https://doi.org/10.1016/j.firesaf.2017.06.012>.
- [17] BEERAVALLI, V. Apresenta informações sobre comparação de modelos de classificação de machine learning. Disponível em: < <https://medium.com/@vijaya.beeravalli/comparison-of-machine-learning-classification-models-for-credit-card-default-data-c3cf805c9a5a>> Acesso em: 21 abr. 2022.