

Detecção Inteligente de Incêndios Florestais Usando Modelos de Aprendizado Profundo

Tarciso Gregório Bernardo de Bello e Samuel Baraldi Mafra

Resumo— Este estudo apresenta uma abordagem para detecção inteligente de incêndios florestais utilizando visão computacional e Internet das Coisas (IoT), sendo seu foco no monitoramento da progressão e regressão dos focos de incêndio. A técnica proposta é baseada no algoritmo YOLOv11, que se destaca pela passagem da imagem na rede neural uma única vez, velocidade e precisão na identificação de objetos. A integração com IoT possibilita uma coleta contínua de dados em tempo real, mesmo em áreas de difícil acesso. Foram utilizadas métricas de desempenho como Acurácia, Precisão, Recall e F1-Score para avaliar a eficácia do modelo proposto.

Palavras-Chave— YOLOv11, IoT, Detecção de Incêndio.

Abstract— This study presents an approach for intelligent detection of forest fires using computer vision and the Internet of Things (IoT), focusing on monitoring the progression and regression of fire outbreaks. The proposed technique is based on the YOLOv11 algorithm, which stands out for passing the image through the neural network only once, and for speed and accuracy in identifying objects. Integration with IoT enables continuous data collection in real time, even in areas that are difficult to access. Performance metrics such as Accuracy, Precision, Recall and F1-Score were used to evaluate the effectiveness of the proposed model.

Keywords— YOLOv11, IoT, Fire Detection.

I. INTRODUÇÃO

Incêndios florestais envolvem a queima rápida de folhas, árvores e galhos, devastando vastas áreas de vegetação e comprometendo ecossistemas inteiros. Esses eventos representam uma ameaça significativa à biodiversidade, ao meio ambiente e à saúde pública, especialmente devido à liberação de gases tóxicos. As causas podem ser naturais, como raios, ou induzidas por atividades humanas, como desmatamento e queimadas ilegais. A detecção precoce é essencial para mitigar danos e aumentar a eficácia das respostas, exigindo a colaboração ativa entre governo e sociedade [1–3].

Tarciso G. B. de Bello e Samuel B. Mafra, Instituto Nacional de Telecomunicações (Inatel), Santa Rita do Sapucaí-MG. e-mails: tarciso.gregorio@mtel.inatel.br, samuelbmafra@inatel.br; Este trabalho é parcialmente financiado pela RNP, com recursos do MCTIC, Grant No. 01245.020548/2021-07, no âmbito do projeto Brasil 6G do Centro de Referência em Radiocomunicações (CRR) do Instituto Nacional de Telecomunicações (Inatel), Brasil, pelo projeto XGM-AFCCT-2024-5-1-2 apoiado pelo xGMobile – EMBRAPIL-Inatel Competence Center on 5G and 6G Networks, com recursos financeiros do PPI IoT/Manufatura 4.0 do MCTI grant number 052/2023, assinado com EMBRAPIL, o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (403827/2021-3), Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) (2021/06946-0), Projeto SEMEAR apoiado pela FAPESP (Grant n°. 22/09319-9), Projeto SAMURAI, apoiado pela FAPESP (Grant 20/05127-2) e pela Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) (APQ-04523-23, APQ-05305-23, APQ-03162-24, APQ-01558-24 e RED-00194-23) e xGMobile (Grant PPE-00124-23). Este trabalho foi suportado por uma bolsa de mestrado da CAPES

No Brasil, os incêndios florestais tem aumentado de forma preocupante. No período de 38 anos entre 1985 à 2023 as áreas de queimadas chegaram a mais de 10 Milhões de hectares devastados. A Caatinga, bioma exclusivamente brasileiro, caracterizado por uma flora seca, tem em média 0,56% de Milhões de hectares afetados por incêndios florestais e queimadas. Em 2022, o país registrou cerca de 85 mil focos de incêndio. Em 2023, esse número subiu para 102 mil, e em 2024, o Brasil enfrentou um novo recorde, com mais de 110 mil incêndios, devastando uma área estimada de 114 mil km² um aumento alarmante de 116% em relação ao ano anterior. Esses dados, agravados pela seca e pelo fenômeno El Niño, destacam a urgência de desenvolver soluções eficazes para monitorar e conter incêndios florestais [4,5].

Diante desse cenário, a detecção precoce de incêndios florestais é essencial para minimizar danos ambientais e sociais. A capacidade de identificar focos de incêndio em estágios iniciais permite uma resposta rápida e direcionada, reduzindo a área afetada e, consequentemente, os impactos sobre o ecossistema e a saúde pública. Tradicionalmente, técnicas de combate a incêndios incluem torres de vigilância, essas torres são instaladas em locais estratégicos dentro de áreas florestais, com variação de altura de 15 a 50 metros, dependendo da topografia da região. Ainda sobre as técnicas tradicionais temos o patrulhamento aéreo e análise de dados históricos, mas essas abordagens nem sempre garantem a precisão em tempo real necessária para uma intervenção eficaz [6]. As mudanças climáticas e a complexidade dos ecossistemas florestais exigem soluções tecnológicas avançadas que possam fornecer uma resposta ágil e precisa [7].

Neste artigo, uma abordagem avançada para a detecção de incêndios florestais usando o algoritmos de aprendizado profundo é apresentada, tendo como foco principal medir as oscilações dos focos de incêndios, ou seja, avaliar se o fogo está em fase de aumento ou redução. Trabalhos como o [8–10] mostram de forma precisa a eficiência do uso algoritmos de aprendizado profundo, destacando-se o YOLO para detectar focos de incêndios em tempo real.

Este artigo está organizado da seguinte forma: a Seção II revisa a literatura sobre modelos baseados em de aprendizado profundo e trabalhos relacionados associados a temática de detecção de focos de Incêndio; a Seção III descreve em detalhes a metodologia do sistema proposto; a Seção IV apresenta os resultados da validação experimental; e finalmente a Seção V conclui o artigo e sugere futuras direções de pesquisa no contexto do uso de algoritmos de aprendizado profundo para detecção de incêndios florestais.

II. FUNDAMENTAÇÃO TEÓRICA

A complexidade do ambiente florestal, caracterizado por vegetação densa e variações climáticas, apresenta desafios significativos às abordagens tradicionais de detecção de incêndios florestais. Nesse contexto, modelos avançados de visão computacional e algoritmos de aprendizado profundo, como o *region-based convolutional neural networks* (R-CNN), X-MobileNet e *You Only Look Once* (YOLO) têm se destacado ao aprimorar a precisão e a eficiência do monitoramento em tempo real, possibilitando assim a identificação precoce de focos de incêndio e reduzindo os seus impactos. [10].

A. Algoritmos de aprendizado profundo

Os modelos baseados em regiões, como o R-CNN, em que a imagem é dividida em múltiplas partes para analisar detalhadamente áreas específicas, permitindo uma segmentação precisa dos focos de incêndio. Embora eficazes, essas abordagens exigem várias etapas de processamento, o que pode resultar em maior tempo de inferência, limitando sua aplicação em situações de detecção urgente, como é o caso dos incêndios florestais [11].

O X-MobileNet é uma rede neural convolucional leve, baseada em convoluções separáveis em profundidade (*depthwise separable convolutions*), projetada para reduzir a complexidade computacional sem comprometer significativamente o desempenho. Apesar de sua eficiência e aplicabilidade em dispositivos embarcados, apresenta limitações que podem impactar a detecção de incêndios florestais. A arquitetura compacta do X-MobileNet pode comprometer a precisão na identificação de padrões complexos, especialmente em cenários com iluminação variável e ruídos visuais. [12].

O YOLO utiliza um método de detecção que processa imagens em uma única passagem pela rede neural, destacando-se por sua abordagem baseada na divisão da imagem em uma grade. Para cada célula dessa grade, o modelo prevê simultaneamente as *bounding boxes* e as probabilidades das classes, permitindo uma inferência rápida e eficiente. Essa característica torna o YOLO uma solução eficaz para a identificação de focos de incêndio em tempo real, especialmente em cenários críticos como monitoramento por drones. Velocidade e precisão são fundamentais para a detecção ágil de focos de incêndios e áreas de risco, auxiliando na resposta rápida e na mitigação dos impactos ambientais [10].

B. Trabalhos Relacionados

Em [13], os autores propõem uma técnica inovadora para aprimorar a detecção de incêndios florestais utilizando uma versão aprimorada do modelo YOLOv5. A proposta envolve a modificação da arquitetura original do YOLOv5 para melhorar a representação visual de incêndios florestais, visando aumentar a precisão e a eficiência na identificação de focos de incêndio em tempo real. Os resultados demonstraram que o modelo aprimorado supera abordagens tradicionais, oferecendo uma solução mais eficaz para o monitoramento e a detecção precoce de incêndios em áreas florestais. As inovações incluem ajustes na estrutura da rede neural e otimizações específicas

para lidar com as particularidades das imagens de incêndios florestais, resultando em um desempenho superior em cenários complexos.

Em [14] é apresentado um modelo otimizado do YOLOv7 denominado *Forest Lightweight YOLOv7* (FL-YOLOv7), para detectar pequenos focos de incêndio em imagens aéreas capturadas por drones. A proposta melhora a eficiência do YOLOv7 ao tornar o modelo mais leve e preciso, facilitando sua aplicação em dispositivos com recursos limitados. Para isso, foram feitas melhorias na estrutura da rede neural para reduzir o consumo de processamento, aumentar a precisão na identificação de focos de incêndio e consequentemente aprimorar a detecção. Os resultados obtidos mostraram que o FL-YOLOv7 apresenta uma redução dos erros e permite um monitoramento mais rápido e confiável de incêndios florestais em tempo real.

Em [15] é proposta uma estratégia para a detecção de incêndios florestais utilizando imagens de alta definição capturadas por veículos aéreos não tripulados (VANT). Foi feita uma análise comparativa em termos de precisão e eficiência na identificação de incêndios, entre os modelos YOLOv8, YOLOv7 e YOLOv5, e foi observado que o YOLOv8 teve melhores resultados na identificação de focos de incêndio em tempo real. Os autores destacaram o YOLOv8 como o modelo mais eficiente para detecção em tempo real, devido à sua arquitetura aprimorada e otimizações na extração de características, resultando em melhor acurácia e menor taxa de falsos positivos. Como inovação, o estudo demonstra a viabilidade do uso de modelos de detecção baseados em aprendizado profundo para monitoramento autônomo de incêndios florestais, otimizando a resposta emergencial e reduzindo os impactos ambientais.

III. METODOLOGIA

Neste artigo, é adotada uma solução baseada em IoT para monitoramento em tempo real e detecção de focos de incêndios usando os algoritmos, R-CNN, YOLOv8 e YOLO v11. A abordagem escolhida consistiu na análise comparativa dos modelos em condições similares, com o objetivo de avaliar as métricas de desempenho geradas por esses modelos de aprendizado profundo.

A detecção precisa desses focos é fundamental, pois em um cenário de incêndios florestais, as condições variam significativamente com o tempo e o ambiente, tornando a tarefa complexa. Esses modelos são aplicados para identificar pequenos e grandes focos de incêndios, sob diferentes tipos de vegetação e diferentes condições climáticas, como a presença de fumaça ou variações na iluminação. A Figura 1 exemplifica uma dessas situações, onde é possível identificar focos de incêndio em uma área de vegetação.

A coleta e treinamento de dados é essencial para garantir que os modelos tenham um conjunto de treinamento diversificado e representativo dos cenários reais de incêndios florestais. A formação do banco de imagens ou *dataset* envolve a coleta de um conjunto de imagens abrangendo cenários com e sem fogo, garantindo diversidade em diferentes condições ambientais. Todas as imagens que formaram o *dataset* foram



Fig. 1: Imagem do Treinamento - Detecção de Incêndios.

obtidas a partir de um treinamento do corpo de bombeiros de Pouso Alegre, Minas Gerais, Brasil. Essas imagens foram capturadas por *drones* e por câmeras, em vários pontos da queimada, incluindo diferentes tipos de vegetação e iluminação garantindo assim diversificação.

A seguir a etapa de seleção das imagens temos a etapa de rotulação das imagens que desempenha um papel crucial na qualidade do treinamento dos modelos de detecção, como R-CNN, YOLOv8 e YOLOv11, pois impacta diretamente na capacidade do modelo em aprender a identificar com precisão os objectos, nesse caso, os focos de incêndio. A rotulação manual das imagens envolve a aplicação de caixas delimitadoras (*bounding boxes*) nas áreas afetadas pelo fogo, com o objetivo de marcar as regiões específicas que contêm os focos de incêndio. Para essa tarefa, foi utilizada a ferramenta *Roboflow*, que facilita o processo de rotulação ao permitir a anotação precisa e a organização eficiente dos dados.

Após a rotulação, as 80 imagens selecionadas são divididas em três grupos: 70% para treinamento, 15% para validação e 15% para teste, tendo apenas uma classe denominada *fire*(fogo). Essa divisão permite que o modelo aprenda a partir do maior número de imagens possível, validando o desempenho durante o treinamento e avaliando sua capacidade de generalização em novos dados durante a fase de teste. A seguir as imagens foram incluídas nos modelos para treinamento.

O uso de YOLOv8 ou YOLOv11, por exemplo, permite um treinamento mais eficiente e rápido, aproveitando a capacidade desses modelos de realizar detecção em tempo real com alta precisão, o que é essencial no contexto de incêndios florestais, onde a rapidez na detecção pode salvar vidas e preservar o meio ambiente. A Figura 2, mostra as oscilações de um foco de incêndio. O cálculo dessas oscilações é baseado na área dos *bounding boxes* que o modelo identifica como focos de incêndios. A medida que os *pixels* das caixas delimitadoras identificadas como fogo aumenta o foco de incêndio também está em fase de aumento. Desta forma conseguimos aferir se o foco de incêndio está em fase de aumento ou redução.

Tendo como objetivo a detecção do aumento ou redução dos focos de incêndios é proposto um sistema como ilustrado na Figura 3, onde uma câmera é responsável por coletar as imagens dos focos de incêndio e um dispositivo computacional



Fig. 2: Gráfico do Aumento e Redução dos focos de Incêndios.

como a Raspberry pi pode ser utilizada para processamento das imagens e envio dos dados coletados, como em um cenário de Internet das Coisas.

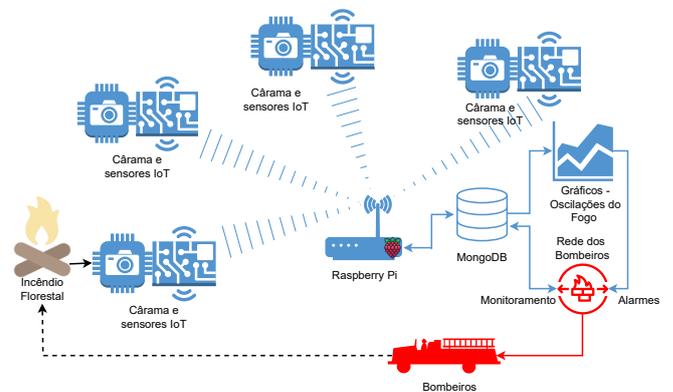


Fig. 3: Modelo do Sistema IoT Proposto.

IV. AVALIAÇÃO E RESULTADOS

Tendo como objetivo a análise da eficiência da metodologia proposta, os experimentos foram realizados usando um banco de dados de imagens de incêndios florestais, tal como mencionado na seção anterior. Para os testes, todos os modelos de aprendizagem profunda foram treinados em 2000 épocas, com tamanho das imagens em 640x640 e tamanho do lote em 16. Os resultados demonstram que o YOLOv11 teve melhor desempenho comparado com os outros modelos, tal como apresentado na Tabela I. A evolução do modelo YOLOv11 durante o treinamento é apresentada na Figura 4, em que podemos observar claramente o decaimento das perdas ao longo das iterações de treinamento, tanto para as imagens de treinamento quanto para as imagens de validação, o que indica uma convergência estável do modelo. Esse comportamento é fundamental para avaliar a eficiência do YOLOv11, pois um decaimento consistente das perdas sugere que o modelo está aprendendo de forma eficiente e se ajustando bem aos dados, sem sinais de *overfitting*. A seguir, a curva das perdas nas imagens de validação apresenta uma trajetória semelhante, evidenciando que o modelo está generalizando bem para dados não vistos durante o treinamento.

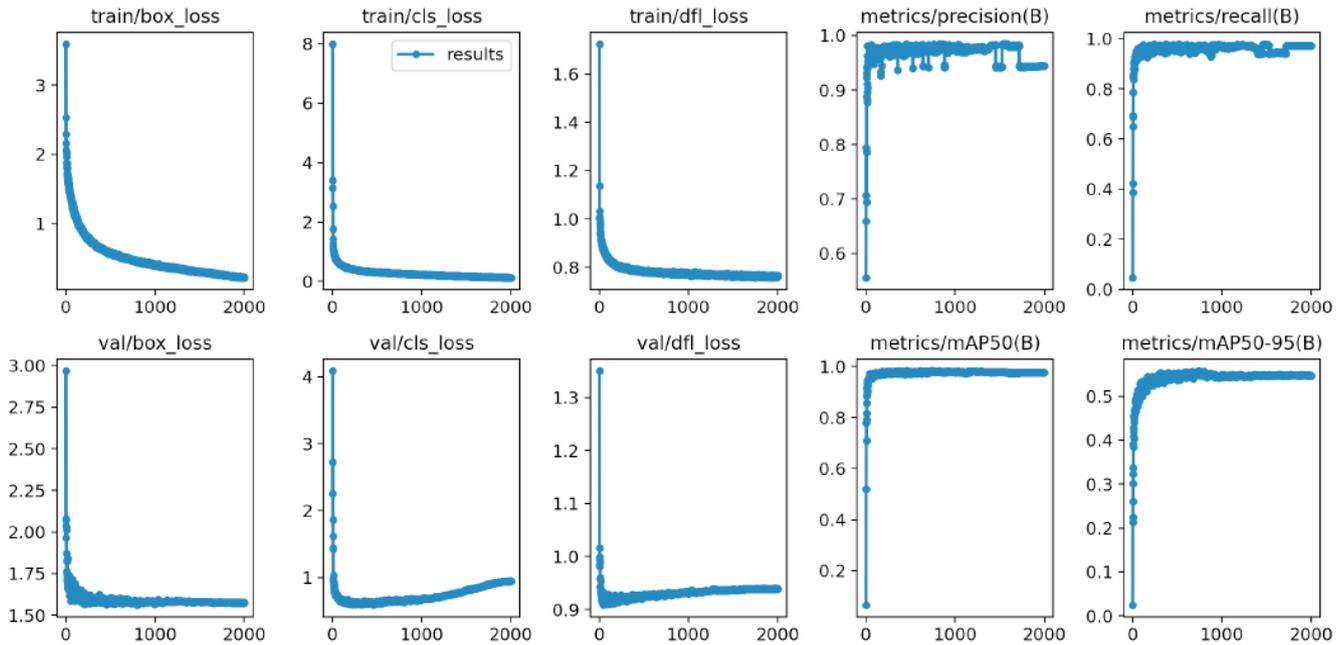


Fig. 4: Evolução do treinamento e validação do modelo YOLOv11

TABELA I: Comparação do Desempenho dos modelos de Detecção de Incêndios Florestais.

Modelos	Acurácia	Precisão	Recall	F1-Score
Yolov11	98,60%	98,97%	98,90%	98,97%
Yolov8	98,10%	98,10%	98,30%	98,35%
RCNN	94,65%	95,80%	96,85%	96,87%

As subfiguras na Figura 4 com os termos *Precision*, *Recall* e *mAP* fornecem uma visão detalhada da evolução do desempenho do sistema ao longo do treinamento. Essas métricas são essenciais para avaliar a capacidade dos modelos em detectar focos de incêndio de forma precisa e confiável, sem comprometer a velocidade de inferência. Além disso, as flutuações nas métricas de validação podem ser interpretadas como uma indicação de como o modelo se adapta às variações dos dados, enquanto a estabilidade das métricas ao longo do treinamento demonstra a robustez do YOLOv11. Esse processo de monitoramento contínuo durante o treinamento e validação é vital para garantir que o modelo atinja a máxima eficiência na detecção de incêndios florestais.

V. DISCUSSÕES E CONCLUSÃO

A proposta do sistema apresentado neste trabalho demonstra a capacidade dos modelos de aprendizado profundo na tarefa de detecção de incêndios florestais. Como mostrado anteriormente, foi possível observar que o YOLOv11 teve um desempenho maior comparado com o YOLOv8 e R-CNN, quanto às métricas de desempenho analisadas. Sendo assim, ainda existem desafios a serem superados, como um banco de dados mais diversificado e a inclusão de possíveis classes, como fumaça, o que melhora o desempenho dos modelos.

Embora os modelos tenham apresentado ótimos resultados na detecção de focos de incêndio e na análise da progressão

e regressão do fogo, durante a pesquisa observamos que a qualidade e a diversidade do banco de imagens desempenham um papel fundamental na obtenção de resultados consistentes e precisos. A composição de um conjunto de dados sólido, que inclua uma variedade de cenários de fogo e não-fogo, é essencial para garantir que o modelo aprenda a distinguir de maneira eficaz entre diferentes tipos de incêndios, variações climáticas, condições de iluminação e tipos de vegetação. Imagens que incluem várias situações, como incêndios em diferentes estágios de evolução, presença de fumaça densa, variações de tempo (diurno e noturno) e tipos variados de cobertura vegetal, são cruciais para que os modelos consigam generalizar de maneira eficiente.

O uso de modelos de visão computacional e modelos de aprendizado profundo, como o YOLOv11, YOLOv8 e R-CNN, para a detecção de incêndios florestais oferece uma solução inovadora e eficaz, com um potencial significativo para preservar o meio ambiente e salvar vidas. Em comparação com as técnicas tradicionais de combate a incêndios, que frequentemente dependem de abordagens manuais e possuem baixa eficiência em termos de tempo de resposta e alcance, as tecnologias baseadas em inteligência artificial permitem uma detecção em tempo real. Isso possibilita uma intervenção mais rápida e precisa, especialmente em áreas de difícil acesso, onde os métodos convencionais muitas vezes falham ou têm sucesso limitado [16,17].

Além disso, ao utilizar algoritmos avançados como o YOLOv11, é possível monitorar a evolução dos focos de incêndio, analisando tanto o aumento quanto a redução da intensidade do fogo ao longo do tempo. Essa capacidade de rastreamento dinâmico não só melhora a eficácia da detecção, mas também permite uma gestão mais eficiente dos recursos durante o combate ao incêndio, direcionando as equipes de resposta

para as áreas de maior risco. Assim, a aplicação de modelos de visão computacional e aprendizado profundo não apenas supera as limitações das abordagens tradicionais, mas também abre novas possibilidades para prevenção e mitigação de desastres naturais de maneira mais sustentável e eficaz [18,19].

Este artigo teve como principais contribuições a comparação de modelos de aprendizado profundo aplicados a detecção de incêndios florestais, com foco na eficiência do YOLOv11, e a criação de um novo banco de imagens, abrangendo diversos cenários e estágios de evolução dos incêndios. O conjunto de dados desenvolvido inclui imagens capturadas em diferentes fases do incêndio, desde os estágios iniciais, com pequenos focos de fogo, até os estágios finais, em que o fogo começa a se reduzir. Esse banco de imagens foi crucial para o treinamento e a validação do modelo, garantindo que ele aprenda a identificar focos de incêndio em diversas condições, como variações na intensidade e diferentes tipos de vegetação.

Para trabalhos futuros, seria extremamente valioso expandir o conjunto de dados para incluir imagens capturadas por drones em diversos pontos de um incêndio florestal, permitindo uma cobertura mais abrangente das diferentes fases da queimada. A diversidade de condições climáticas, como variações na intensidade da fumaça, iluminação e umidade, pode proporcionar uma maior robustez ao modelo, permitindo que o YOLOv11 detecte focos de incêndio de forma mais precisa, independentemente das condições ambientais. A inclusão de imagens diurnas e noturnas, além de diferentes tipos de vegetação e topografia, tornaria o banco de dados ainda mais representativo da realidade dinâmica dos incêndios florestais.

Além disso, a combinação de modelos de aprendizado profundo pode aumentar significativamente a eficiência na detecção de incêndios. A fusão de diferentes abordagens, como a integração de YOLOv11 com redes de segmentação semântica ou modelos de redes neurais recorrentes (RNNs) para rastreamento temporal, pode melhorar a capacidade do sistema de detectar incêndios não apenas em tempo real, mas também de analisar a evolução dos focos de incêndio ao longo do tempo. Essa combinação poderia proporcionar uma análise mais precisa do aumento e redução dos focos, identificando padrões complexos e ajustando as respostas de combate de forma mais dinâmica e eficaz. Em última análise, a implementação dessas melhorias poderia resultar em um sistema mais robusto e adaptável, que possa lidar com uma variedade maior de cenários e fornecer informações mais detalhadas para a tomada de decisões durante o combate a incêndios florestais.

AGRADECIMENTOS

Agradecemos ao Ministério das Telecomunicações, Tecnologias de Informação e Comunicação de Angola. Agradecemos

também ao corpo de Bombeiros de Pouso Alegre - MG - Brasil.

REFERÊNCIAS

- [1] J. Verde and J. L. Zêzere, "Assessment and validation of wildfire susceptibility and hazard in Portugal," *Natural Hazards and Earth System Sciences*, vol. 10, no. 3, pp. 485–497, 2010.
- [2] M. Flannigan, A. S. Cantin, W. J. De Groot, M. Wotton, A. Newbery, and L. M. Gowman, "Global wildland fire season severity in the 21st century," *Forest Ecology and Management*, vol. 294, pp. 54–61, 2013.
- [3] J. F. Santos, R. V. Soares, and A. C. Batista, "Perfil dos incêndios florestais no Brasil em áreas protegidas no período de 1998 a 2002," *Floresta*, vol. 36, no. 1, pp. 93–100, 2006.
- [4] M. M. Veras, "Mudanças climáticas e incêndios florestais: implicações sobre a saúde," *Ciência e Cultura*, vol. 76, no. 3, pp. 01–07, 2024.
- [5] W. J. Franca Rocha, R. N. Vasconcelos, S. G. Duverger, D. P. Costa, N. A. Santos, R. O. Franca Rocha, M. M. de Santana, A. A. Alencar, V. L. Arruda, W. V. d. Silva *et al.*, "Mapping burned area in the caatinga biome: Employing deep learning techniques," *Fire*, vol. 7, no. 12, p. 437, 2024.
- [6] A. A. Alkhatib, "A review on forest fire detection techniques," *International Journal of Distributed Sensor Networks*, vol. 10, no. 3, p. 597368, 2014.
- [7] J. F. de Oliveira-Junior, D. Mendes, W. L. F. Correia Filho, C. A. da Silva Junior, G. de Gois, A. M. d. R. F. Jardim, M. V. da Silva, G. B. Lyra, P. E. Teodoro, L. C. G. Pimentel *et al.*, "Fire foci in south America: Impact and causes, fire hazard and future scenarios," *Journal of South American Earth Sciences*, vol. 112, p. 103623, 2021.
- [8] "Aproveitando a tecnologia uav e o algoritmo yolov9 para detecção de incêndios florestais em tempo real," in *2024 Conferência Internacional de Automação Russa (RusAutoCon)*.
- [9] S. Wang, T. Chen, X. Lv, J. Zhao, X. Zhao, M. Xiao, and H. Wei, "Forest fire detection based on lightweight yolo," in *2021 33rd Chinese Control and Decision Conference (CCDC)*. IEEE, 2021, pp. 1560–1565.
- [10] S. Goyal, M. Shagill, A. Kaur, H. Vohra, and A. Singh, "A yolo based technique for early forest fire detection," *Int. J. Innov. Technol. Explor. Eng*, vol. 9, pp. 1357–1362, 2020.
- [11] "Arquitetura renn para detecção de incêndios florestais," in *2023 13ª Conferência Internacional sobre Computação em Nuvem, Ciência de Dados e Engenharia (Confluence)*.
- [12] A. Namburu, P. Selvaraj, S. Mohan, S. Ragavanantham, and E. T. Eldin, "Forest fire identification in uav imagery using x-mobilenet," *Electronics*, vol. 12, no. 3, p. 733, 2023.
- [13] L. Cao, Z. Shen, and S. Xu, "Efficient forest fire detection based on an improved yolo model," *Visual Intelligence*, vol. 2, no. 1, p. 20, 2024.
- [14] Z. Xiao, F. Wan, G. Lei, Y. Xiong, L. Xu, Z. Ye, W. Liu, W. Zhou, and C. Xu, "Fl-yolov7: A lightweight small object detection algorithm in forest fire detection," *Forests*, vol. 14, no. 9, p. 1812, 2023.
- [15] X. Jia, Y. Wang, and T. Chen, "Forest fire detection and recognition using yolov8 algorithms from uavs images," in *2023 IEEE 5th International Conference on Power, Intelligent Computing and Systems (ICPICS)*, 2023, pp. 646–651.
- [16] K. Avazov, M. Mukhiddinov, F. Makhmudov, and Y. I. Cho, "Fire detection method in smart city environments using a deep-learning-based approach," *Electronics*, vol. 11, no. 1, p. 73, 2021.
- [17] T.-H. Chen, P.-H. Wu, and Y.-C. Chiou, "An early fire-detection method based on image processing," in *2004 International Conference on Image Processing, 2004. ICIP'04.*, vol. 3. IEEE, 2004, pp. 1707–1710.
- [18] S. Goyal, M. Shagill, A. Kaur, H. Vohra, and A. Singh, "A yolo based technique for early forest fire detection," *Int. J. Innov. Technol. Explor. Eng*, vol. 9, pp. 1357–1362, 2020.
- [19] P. Li and W. Zhao, "Image fire detection algorithms based on convolutional neural networks," *Case Studies in Thermal Engineering*, vol. 19, p. 100625, 2020.