

Segmentação de Fogo Ativo em Imagens Landsat-8 Utilizando U-Net

Elayni Enoly Sousa Franco



CENTRO DE INFORMÁTICA
UNIVERSIDADE FEDERAL DA PARAÍBA

João Pessoa, 2025

Elayni Enoly Sousa Franco

Segmentação de Fogo Ativo em Imagens Landsat-8 Utilizando U-Net

Monografia apresentada ao curso Ciência de Dados e
Inteligência Artificial do Centro de Informática, da
Universidade Federal da Paraíba, como requisito
para a obtenção do grau de Bacharel em
Ciência de Dados e Inteligência Artificial.

Orientador: Leonardo Vidal Batista

Maio de 2025

Catálogo na publicação
Seção de Catalogação e Classificação

F825s Franco, Elayni Enoly Sousa.

Segmentação de fogo ativo em imagens landsat-8
utilizando U-Net / Elayni Enoly Sousa Franco. - João
Pessoa, 2025.

39 f. : il.

Orientação: Leonardo Vidal Batista.

TCC (Graduação) - UFPB/Informática.

1. Segmentação de imagens. 2. Incêndios florestais.
3. Landsat-8. 4. U-Net. 5. Aprendizado profundo. I.
Batista, Leonardo Vidal. II. Título.

UFPB/CI

CDU 004.8



CENTRO DE INFORMÁTICA
UNIVERSIDADE FEDERAL DA PARAÍBA

Trabalho de Conclusão de Curso de Ciência de Dados e Inteligência Artificial intitulado ***Segmentação de Fogo Ativo em Imagens Landsat-8 Utilizando U-Net*** de autoria de Elayni Enoly Sousa Franco, aprovada pela banca examinadora constituída pelos seguintes professores:

Prof. Dr. Celso Augusto Guimarães Santos
Universidade Federal da Paraíba

Prof. Dr. Richarde Marques da Silva
Universidade Federal da Paraíba

Prof. Dr. Gabriel de Oliveira
University of South Alabama

João Pessoa, 23 de maio de 2025

Centro de Informática, Universidade Federal da Paraíba
Rua dos Escoteiros, Mangabeira VII, João Pessoa, Paraíba, Brasil CEP: 58058-600
Fone: +55 (83) 3216 7093 / Fax: +55 (83) 3216 7117

*“The Road goes ever on and on,
Down from the door where it began.
Now far ahead the Road has gone,
And I must follow, if I can.”*

J.R.R. Tolkien, *The Lord of the Rings*

AGRADECIMENTOS

A conclusão deste trabalho representa não apenas uma realização acadêmica, mas também o reflexo do apoio, do amor e da dedicação de pessoas que caminharam comigo ao longo desta jornada.

Agradeço, com todo meu coração, aos meus pais, apoio fundamental durante toda minha vida. Em especial à minha mãe, que, mesmo não estando mais presente fisicamente, continua sendo minha fonte inesgotável de força e inspiração. Sua ausência é sentida a cada passo, mas sua memória me impulsiona a seguir em frente.

Ao meu namorado, Lucas, e à sua família, minha mais profunda gratidão. Seu apoio constante, acolhimento e incentivo foram essenciais em momentos de cansaço e incerteza. Sem vocês, nada disso teria sido possível. Estendo esse agradecimento à minha sobrinha, Allana, que esteve presente todos os dias dessa jornada.

Aos meus amigos e amigas, pelo suporte nos dias difíceis e pelas risadas nos momentos leves. Agradeço especialmente aos amigos do NA DS, que me acolheram com carinho, me ofereceram companhia e apoio sincero. Obrigada por não me deixarem seguir sozinha.

Ao meu orientador, agradeço pela paciência, dedicação e orientação ao longo de todo o processo, foram fundamentais para que este trabalho se concretizasse.

Também agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), sua atuação, por meio do fomento à produção científica no Brasil e da ampla disponibilização de recursos acadêmicos, foi fundamental para a construção deste trabalho.

A cada um de vocês, meu mais sincero muito obrigada.

RESUMO

Os incêndios florestais representam uma ameaça crescente à biodiversidade, à saúde humana e à estabilidade climática global, impulsionados pelo avanço das mudanças climáticas e do uso descontrolado do solo. No Brasil, a área queimada cresceu 79% em 2024, evidenciando a urgência de sistemas tecnológicos eficazes para o monitoramento ambiental. Este trabalho investiga o uso da arquitetura U-Net para segmentação de fogo ativo em imagens multiespectrais do satélite Landsat-8, com foco em cenários altamente desbalanceados, nos quais as áreas queimadas representam uma pequena fração da imagem. O modelo foi treinado com máscaras geradas por algoritmos tradicionais e avaliado com dados anotados por especialistas, utilizando métricas como F1-Score, IoU, precisão e revocação. Os resultados indicam elevada sensibilidade (0,89) e precisão (0,88), IoU de 0,79 e um coeficiente de correlação de Matthews de 0,88, demonstrando a robustez do modelo mesmo em cenários desafiadores. Conclui-se que a U-Net é uma abordagem promissora para a segmentação de áreas queimadas, especialmente quando associada a estratégias específicas de treinamento e ao tratamento adequado do desbalanceamento de classes, sendo aplicável a sistemas de alerta precoce e monitoramento ambiental em larga escala.

Palavras-chave: Segmentação de imagens, incêndios florestais, Landsat-8, U-Net, aprendizado profundo.

ABSTRACT

Wildfires represent a growing threat to biodiversity, human health, and global climate stability, driven by climate change and uncontrolled land use. In Brazil, the burned area increased by 79% in 2024, highlighting the urgent need for effective technological systems for environmental monitoring. This study investigates the use of the U-Net architecture for active fire segmentation in multispectral images from the Landsat-8 satellite, focusing on highly imbalanced scenarios where burned areas account for a small fraction of the image. The model was trained with masks generated by traditional algorithms and evaluated using expert-annotated data, employing metrics such as F1-Score, IoU, precision, and recall. The results indicate high sensitivity (0.89) and precision (0.88), an IoU of 0.79, and a Matthews Correlation Coefficient of 0.88, demonstrating the robustness of the model even in challenging scenarios. It is concluded that U-Net is a promising approach for burned area segmentation, especially when combined with specific training strategies and appropriate handling of class imbalance, making it applicable to large-scale environmental monitoring and early warning systems.

Keywords: Image segmentation, forest fires, Landsat-8, U-Net, deep learning.

LISTA DE FIGURAS

1	Arquitetura U-Net utilizada no modelo.	30
2	Distribuição do IoU.	33
3	Resultados obtidos com diferentes faixas de IoU.	34

LISTA DE TABELAS

1	Bandas espectrais do Landsat 8 (OLI e TIRS).	21
2	Resultados do modelo nos dados anotados por especialistas.	32

LISTA DE ABREVIATURAS

CNN	Convolutional Neural Network
IoU	Intersection over Union
OLI	Operational Land Imager
PAN	Banda Pancromática
PM2.5	Material Particulado com diâmetro menor que 2,5 μm
PM10	Material Particulado com diâmetro menor que 10 μm
SWIR	Short-Wave Infrared (Infravermelho de Ondas Curtas)
TIRS	Thermal Infrared Sensor
U-Net	Unidade Neural em formato de U para Segmentação
USGS	United States Geological Survey
VIS	Visible (Faixa Visível do Espectro)

Sumário

1	INTRODUÇÃO	17
1.1	Definição do Problema	18
1.1.1	Objetivo geral	18
1.1.2	Objetivos específicos	18
1.2	Estrutura da monografia	18
2	CONCEITOS GERAIS E REVISÃO DA LITERATURA	20
2.1	Sensoriamento Remoto	20
2.2	Imagens de Satélite e Funcionamento dos Sensores Orbitais	20
2.3	Imagens do Satélite Landsat-8	21
2.4	Queimadas e Incêndios Florestais e Fogo Ativo	22
2.5	Aprendizado Profundo e Segmentação de Imagens	23
2.6	Arquitetura U-Net	24
2.7	Tratamento de Desbalanceamento em Segmentação	24
2.8	Métricas de Avaliação	25
2.8.1	Intersection over Union (IoU)	25
2.8.2	Precisão	26
2.8.3	Sensibilidade ou Revocação	26
2.8.4	F1-Score (Coeficiente de Dice)	26
2.8.5	Coeficiente de correlação de Matthews (MCC)	27
3	METODOLOGIA	28
3.1	Dados Utilizados	28
3.2	Arquitetura do Modelo	28
3.3	Estratégias de Treinamento	29
3.4	Técnicas de Data Augmentation	30
3.5	Avaliação do Modelo	31
4	APRESENTAÇÃO E ANÁLISE DOS RESULTADOS	32

4.1	Resultados Quantitativos	32
4.2	Resultados Visuais	33
4.3	Discussão dos Resultados	34
5	CONCLUSÕES E TRABALHOS FUTUROS	37
	REFERÊNCIAS	37

1 INTRODUÇÃO

Os incêndios florestais constituem uma ameaça crescente aos ecossistemas, à saúde pública e à economia global, impulsionados por fatores como mudanças climáticas, desmatamento e atividades antrópicas (SYKAS et al., 2024). Casos extremos têm se tornado recorrentes em diversas regiões do mundo. Segundo Shen et al. (2023) e Li et al. (2023), a Austrália foi devastada por incêndios entre 2019 e 2020, com prejuízos estimados em mais de US\$ 100 bilhões. Na Espanha, entre janeiro e agosto de 2022, a área queimada foi quase cinco vezes maior em relação ao ano anterior (LIZ-LÓPEZ et al., 2023). Mesmo em regiões frias, como a Sibéria, os incêndios são responsáveis por mais da metade dos focos registrados na zona boreal (SITNOV; MOKHOV, 2018). Em 2020, os estados da costa oeste dos Estados Unidos enfrentaram os maiores incêndios já registrados, com quase 6 milhões de acres queimados e níveis alarmantes de poluentes atmosféricos, como monóxido de carbono (CO), PM2.5 e PM10 (SANNIGRAHI et al., 2023). Mais recentemente, em janeiro de 2025, novos focos atingiram a região de Los Angeles, causando danos significativos expressivos e forçando evacuações em larga escala (BBC NEWS, 2025).

No Brasil, a situação também é alarmante. Em 2024, a área queimada aumentou 79% em relação ao ano anterior, totalizando mais de 30 milhões de hectares — o segundo maior valor registrado desde 1985 (MAPBIOMAS, 2025). Esse cenário reforça a necessidade urgente de ferramentas tecnológicas para o monitoramento e resposta rápida a incêndios florestais. Neste contexto, este trabalho contribui com o desenvolvimento de um modelo baseado em redes neurais convolucionais (U-Net) para a segmentação de fogo ativo em imagens de satélite, oferecendo uma abordagem promissora para a detecção automatizada e em larga escala de focos de incêndio.

A detecção e o monitoramento desses eventos são fundamentais para a mitigação de seus impactos. Tradicionalmente, essas atividades dependiam de observações humanas e sensores de baixa resolução, métodos que apresentam limitações em termos de cobertura e precisão (ALI; KURNAZ, 2025). Com os avanços no sensoriamento remoto e no aprendizado profundo, tornou-se possível identificar e monitorar focos de incêndio com maior eficácia, utilizando imagens multiespectrais de satélites como o *Landsat-8* e algoritmos baseados em redes neurais convolucionais (PLETSCH et al., 2022). Uma revisão recente realizada por Vasconcelos et al. (2024) destaca o crescimento exponencial das pesquisas em detecção de incêndios com aprendizado profundo nas últimas décadas, evidenciando o interesse e a importância do tema dentro da comunidade científica.

Dentro desse contexto, a utilização da arquitetura U-Net para segmentação de áreas queimadas demonstra-se como uma solução promissora, sobretudo em cenários de detecção de pequenos focos de incêndio (ALI; KURNAZ, 2025).

1.1 Definição do Problema

Apesar dos avanços tecnológicos, a detecção de incêndios florestais em imagens de satélite continua sendo desafiadora, principalmente quando o fogo ocupa menos de 3% dos pixels da imagem (SYKAS et al., 2024). Métodos tradicionais apresentam alta taxa de falsos negativos nessas situações, devido à dificuldade em detectar focos de pequena extensão e intensidade (SCHROEDER et al., 2014; KUMAR E ROY, 2021).

O problema central deste trabalho consiste no desenvolvimento de um modelo de segmentação capaz de detectar focos de incêndio em imagens multiespectrais de alta resolução, mesmo diante de cenários caracterizados por uma acentuada desproporção entre classes fogo e não fogo, uma característica comum nesse tipo de aplicação (Schroeder et al., 2014; Pereira et al., 2021). Nesse contexto, optou-se pela utilização da arquitetura U-Net, conforme detalhado na Seção 2.6, uma vez que diversos estudos destacam sua eficácia na segmentação de pequenos objetos, inclusive em imagens infravermelhas (Chen et al., 2022), bem como sua flexibilidade para lidar com dados multiespectrais e multimodais (Ibtehaz & Rahman, 2019). A adoção de tal abordagem visa contribuir para o aprimoramento dos sistemas de detecção e alerta precoce de incêndios florestais, bem como para a alocação mais eficiente dos recursos destinados ao combate e à mitigação desses eventos, conforme evidenciado por estudos recentes sobre os impactos da exposição à fumaça de incêndios na saúde pública (Gould et al., 2024).

1.1.1 Objetivo geral

Desenvolver e validar um modelo baseado em aprendizado profundo para a segmentação de focos ativos de incêndio em imagens multiespectrais para identificar áreas queimadas.

1.1.2 Objetivos específicos

1. Implementar a arquitetura U-Net, utilizando uma função de perda que atribui maior peso aos erros cometidos na detecção de focos de incêndio, buscando compensar o desbalanceamento entre classes no conjunto de dados ;
2. Avaliar o desempenho do modelo utilizando métricas quantitativas específicas;

1.2 Estrutura da monografia

A estrutura deste trabalho consiste em cinco capítulos.

No Capítulo 1, Introdução, apresenta-se a contextualização do tema, a definição do problema de pesquisa, os objetivos gerais e específicos, bem como a estrutura da monografia.

No Capítulo 2, Conceitos Gerais e Revisão de Literatura, revisam-se os conceitos relacionados ao sensoriamento remoto, incêndios florestais e técnicas de aprendizado profundo aplicadas à segmentação de imagens.

O Capítulo 3, expõe a metodologia, incluindo os dados utilizados, a arquitetura da rede neural implementada e os métodos de avaliação empregados.

No Capítulo 4, Resultados e Discussão, apresentam-se os resultados experimentais obtidos, a análise das métricas de desempenho e a comparação com abordagens existentes na literatura.

Por fim, no Capítulo 5, Conclusão e Trabalhos Futuros, resumem-se os principais achados e propõem-se sugestões para pesquisas futuras.

2 CONCEITOS GERAIS E REVISÃO DA LITERATURA

2.1 Sensoriamento Remoto

O sensoriamento remoto é definido como a ciência de aquisição de informações sobre objetos ou áreas situadas à distância, sem contato físico direto, utilizando sensores que detectam e registram a energia refletida ou emitida (CHUVIECO, 2016). Essa tecnologia permite o monitoramento sistemático da superfície terrestre, sendo amplamente empregada para a detecção de mudanças ambientais, como desmatamentos, queimadas e incêndios florestais (FUSIOKA, 2021). Consolidou-se como uma ferramenta essencial para o monitoramento de eventos ambientais de grande escala, como os incêndios florestais (PLETSCH et al., 2022).

A capacidade de captura de diferentes comprimentos de onda, como o visível (VIS), infravermelho próximo (NIR) e infravermelho de ondas curtas (SWIR), possibilita a identificação de focos de calor e alterações na vegetação (CHUVIECO, 2016). O sensoriamento remoto destaca-se por fornecer dados em ampla escala temporal e espacial, fundamentais para aplicações ambientais e para a gestão de desastres naturais.

2.2 Imagens de Satélite e Funcionamento dos Sensores Orbitais

As imagens de satélite são registros multiespectrais ou hiperespectrais da superfície terrestre, adquiridas por sensores embarcados em plataformas orbitais. Os sensores podem ser classificados como ativos, quando emitem sua própria radiação (como o radar), ou passivos, quando apenas captam a energia solar refletida ou emitida pela superfície terrestre (CHUVIECO, 2016).

Satélites como o *Landsat-8* são amplamente utilizados no monitoramento de incêndios, devido à sua alta resolução espacial, espectral e temporal (BARMPOUTIS et al., 2020). O *Landsat-8*, por exemplo, possui sensores capazes de capturar imagens em diversas bandas espectrais, incluindo faixas sensíveis ao calor, fundamentais para detectar focos de fogo (FUSIOKA, 2021).

O funcionamento dos satélites envolve órbitas específicas, como a órbita heliossíncrona, que permite a obtenção de imagens da mesma área sob iluminação solar constante, facilitando a comparação temporal de fenômenos ambientais (CHUVIECO, 2016).

Através de sensores multiespectrais embarcados em satélites, como o *Landsat-8* e o *Sentinel-2*, torna-se possível a aquisição sistemática de imagens da superfície terrestre, permitindo a identificação e acompanhamento de focos ativos de fogo. A alta resolução espacial e espectral dessas plataformas é determinante para a detecção de focos de incêndio

(SYKAS et al., 2024).

2.3 Imagens do Satélite Landsat-8

O satélite *Landsat-8*, lançado em 2013, integra o programa *Landsat*, uma parceria entre a NASA e o *U.S. Geological Survey* (USGS, 2025). Ele orbita a Terra em uma trajetória quase polar e sincronizada com o Sol, com inclinação de $98,2^\circ$, altitude de aproximadamente 705 km e período orbital de 99 minutos. Seu ciclo de revisita é de 16 dias, com passagem equatorial diária por volta das 10:00 (± 15 minutos), registrando cerca de 740 cenas por dia, segundo o sistema de referência WRS-2 (USGS, 2025).

De acordo com o *U.S. Geological Survey* (USGS, 2025), o *Landsat-8* opera com dois sensores principais: o *Operational Land Imager* (OLI) e o *Thermal Infrared Sensor* (TIRS). O sensor OLI captura imagens com maior precisão radiométrica (12 bits) e possui nove bandas espectrais, enquanto o TIRS opera no infravermelho térmico com duas bandas. As especificações estão detalhadas na Tabela 1.

Tabela 1: Bandas espectrais do Landsat 8 (OLI e TIRS).

Banda	Descrição	Resolução (m)	Faixa espectral (μm)
B1	Aerosol Costeiro (Coastal)	30	0.43 – 0.45
B2	Azul (Blue)	30	0.45 – 0.51
B3	Verde (Green)	30	0.53 – 0.59
B4	Vermelho (Red)	30	0.64 – 0.67
B5	Infravermelho Próximo (NIR)	30	0.85 – 0.88
B6	SWIR 1	30	1.57 – 1.65
B7	SWIR 2	30	2.11 – 2.29
B8	Pancromática (PAN)	15	0.50 – 0.68
B9	Cirrus (detecção de nuvens)	30	1.36 – 1.38
B10	Infravermelho Térmico (TIRS 1)	100 (reamostrado)	10.6 – 11.19
B11	Infravermelho Térmico (TIRS 2)	100 (reamostrado)	11.5 – 12.51

Os dados são disponibilizados como produtos de Nível 1, com correções radiométricas e geométricas aplicadas, podendo ser convertidos para reflectância ou radiância no topo da atmosfera, conforme orientações do USGS (2025).

O OLI fornece um avanço substancial em relação à geração anterior de sensores *Landsat*, operando com profundidade de 12 bits (4096 níveis de cinza), o que melhora a relação sinal-ruído e permite uma caracterização mais detalhada da superfície terrestre. Os dados são disponibilizados como produtos de Nível 1, com correções radiométricas e geométricas aplicadas, podendo ser convertidos para reflectância ou radiância no topo da

atmosfera a partir dos coeficientes disponíveis no arquivo de metadados (MTL) (USGS, 2025).

2.4 Queimadas e Incêndios Florestais e Fogo Ativo

As queimadas consistem na utilização controlada do fogo para o manejo de áreas agrícolas e pastoris, prática comum em diversas regiões tropicais (ARRUDA et al., 2018). Já os incêndios florestais caracterizam-se pela propagação descontrolada do fogo em ambientes naturais, podendo ter origem tanto antrópica quanto natural (ARAGÃO et al., 2020).

Nas últimas décadas, observou-se um aumento na frequência e na intensidade dos incêndios florestais, impulsionado por fatores climáticos e atividades humanas, o que tem resultado em prejuízos ecológicos, sociais e econômicos consideráveis (ALI; KURNAZ, 2025). Em biomas como o Cerrado brasileiro, o fogo desempenha uma função ecológica ambígua, sendo capaz de atuar como agente natural de renovação da vegetação, mas também como vetor de degradação ambiental quando associado a práticas humanas descontroladas (PLETSCH et al., 2022).

De acordo com Chuvieco (2016), o fogo é parte integrante da dinâmica ecológica de diversos ecossistemas, sendo essencial para processos naturais de regeneração. No entanto, a sua intensificação antrópica, especialmente na Amazônia e no Cerrado, tem causado severos impactos ambientais, principalmente relacionados ao desmatamento ilegal e à expansão agropecuária (ARAGÃO et al., 2020).

As queimadas podem ser classificadas em dois grandes grupos:

- **Naturais:** Resultantes de fenômenos como descargas elétricas atmosféricas, geralmente associadas a períodos de estiagem prolongada (CHUVIECO, 2016).
- **Antrópicas:** Provocadas por ações humanas, de forma intencional — para renovação de pastagens, preparo agrícola — ou de forma ilegal, visando a expansão de áreas produtivas (ARRUDA et al., 2018).

Segundo Liz-López et al. (2023), na maioria dos casos, os incêndios florestais possuem origem desconhecida. Em contrapartida, nos casos em que a origem é conhecida, constata-se um índice de mais de 90% do número total de incêndios florestais causados por ação humana. Ao se analisar os biomas brasileiros, a ação humana é responsável pela maioria dos incêndios registrados e, em geral, apresenta maior intensidade e severidade ambiental (ARAGÃO et al., 2020).

Os impactos dos incêndios florestais são vastos e profundos, afetando diretamente a biodiversidade, os ciclos biogeoquímicos e o equilíbrio climático global (ARRUDA et al.,

2018). A queima da vegetação libera grandes quantidades de dióxido de carbono (CO_2) e outros gases de efeito estufa, intensificando o aquecimento global (ARAGÃO et al., 2020).

Além disso, destaca-se o conceito de fogo ativo, definido como a presença de calor detectável a partir de sensores remotos, indicando combustão em curso no momento da aquisição da imagem (SCHROEDER et al., 2016). A detecção de focos de fogo ativo é fundamental para sistemas de monitoramento e resposta rápida, pois permite identificar áreas com queima em tempo real, diferenciando-as de áreas já queimadas ou em processo de regeneração (MURPHY et al., 2016).

No contexto deste trabalho, a segmentação de fogo ativo em imagens multiespectrais é especialmente desafiadora, pois envolve a identificação precisa de pequenos focos com características espectrais e térmicas específicas, muitas vezes ocultos em meio à vegetação ou mascarados por condições atmosféricas adversas. Assim, compreender a distinção entre fogo ativo e demais formas de queima é essencial para o desenvolvimento de modelos de segmentação mais eficazes e aplicáveis a sistemas de alerta precoce.

2.5 Aprendizado Profundo e Segmentação de Imagens

O aprendizado profundo transformou a análise de imagens de sensoriamento remoto, permitindo a modelagem de padrões complexos e não lineares sem a necessidade de extração manual de características (JAIN et al., 2020; FUSIOKA, 2021). Segundo Goodfellow, Bengio e Courville (2016), redes neurais profundas constroem representações hierárquicas dos dados, aprendendo desde padrões simples até abstrações de alto nível.

Em tarefas de segmentação semântica, cujo o objetivo é classificar cada pixel de uma imagem, as *Convolutional Neural Networks* (CNNs) e suas variantes têm se destacado pela capacidade de capturar relações espaciais e espectrais complexas presentes em imagens multiespectrais (SYKAS et al., 2024). Essa capacidade é particularmente relevante em aplicações de detecção de queimadas, em que os sinais espectrais podem ser sutis e dispersos ao longo das diferentes bandas do sensor.

O treinamento de modelos de aprendizado profundo em tarefas de segmentação semântica é geralmente conduzido de maneira supervisionada, ou seja, com o uso de exemplos previamente rotulados que indicam a classe associada a cada pixel da imagem de entrada (JAIN et al., 2020; FUSIOKA, 2021). Nessa abordagem, a rede é treinada para aprender uma função que relacione imagens multiespectrais às respectivas máscaras de segmentação, que indicam as regiões classificadas (por exemplo, áreas queimadas). O processo de otimização envolve a minimização de uma função de perda — como a Binary Cross-Entropy — que quantifica o erro entre a predição da rede e os rótulos reais. Esse erro é então propagado de volta pelas camadas da rede por meio do algoritmo de retropropagação, permitindo o ajuste iterativo dos pesos da rede. Algoritmos de otimização, como

o Adam, são amplamente utilizados para acelerar esse processo e melhorar a convergência (GOODFELLOW et al., 2016).

Diante do exposto, considera-se que o aprendizado profundo representa a abordagem mais promissora atualmente para a segmentação de áreas queimadas em imagens de satélite, dada sua capacidade de generalizar padrões complexos a partir de grandes volumes de dados.

2.6 Arquitetura U-Net

A arquitetura U-Net, proposta originalmente por Ronneberger, Fischer e Brox (2015) para segmentação precisa de imagens biomédicas, consiste em uma rede neural convolucional desenvolvida especificamente para tarefas de segmentação de imagens. Sua estrutura em formato de “U” é composta por dois caminhos principais: um caminho de contração (*encoder*), responsável por extrair e condensar as características relevantes da imagem, e um caminho de expansão (*decoder*), encarregado de recuperar a resolução espacial e reconstruir a segmentação pixel a pixel. Uma das características mais relevantes da U-Net é o uso de conexões de salto (*skip connections*) entre as fases correspondentes dos caminhos de compressão e expansão, o que permite preservar informações espaciais finas e melhorar a delimitação de bordas e objetos pequenos, como focos de incêndio isolados. Embora originalmente concebida para aplicações biomédicas, essa arquitetura foi amplamente adaptada e aplicada com sucesso no campo do sensoriamento remoto, incluindo a segmentação de áreas queimadas (FUSIOKA, 2021; ALI; KURNAZ, 2025).

A robustez da U-Net para segmentação de pequenas áreas, como queimadas, decorre da combinação de camadas convolucionais profundas com a capacidade de aproveitar múltiplas resoluções de entrada simultaneamente (JAIN et al., 2020). Além disso, a U-Net é menos dependente de grandes volumes de dados rotulados em comparação com outras arquiteturas mais complexas, fator que a torna especialmente vantajosa em cenários onde os focos de incêndio representam uma minoria dos dados disponíveis (ALI; KURNAZ, 2025).

O uso da U-Net em imagens multiespectrais permite integrar informações de diferentes bandas espectrais, aumentando a capacidade do modelo de identificar sinais sutis de fogo que seriam imperceptíveis em imagens ópticas convencionais (PLETSCH et al., 2022).

2.7 Tratamento de Desbalanceamento em Segmentação

A detecção de incêndios via segmentação enfrenta um desafio central: o forte desbalanceamento entre classes, onde áreas queimadas representam uma minoria expressiva

dos pixels nas imagens (SYKAS et al., 2024). Conforme discutido por Goodfellow, Bengio e Courville (2016), o desbalanceamento de classes pode comprometer o desempenho de modelos de aprendizado supervisionado, favorecendo a predição da classe majoritária.

Para mitigar esse efeito, técnicas de ponderação da função de perda, atribuindo maior peso aos erros de classificação da classe minoritária na *Binary Cross-Entropy*, são amplamente utilizadas (ALI; KURNAZ, 2025). Além disso, a aplicação de estratégias de *data augmentation* direcionadas para amostras com baixa presença da classe de interesse contribui para ampliar a representatividade da classe minoritária no conjunto de treinamento, aumentando a robustez e a generalização do modelo.

2.8 Métricas de Avaliação

A avaliação do desempenho de modelos de segmentação semântica requer métricas específicas que quantifiquem a sobreposição entre a predição e a referência de verdade. Em cenários desbalanceados, como a detecção de áreas queimadas em imagens de satélite, é fundamental adotar métricas que considerem tanto os acertos quanto os erros de classificação. Nesta subseção, são apresentadas as principais métricas utilizadas neste trabalho: *Intersection over Union* (IoU), *F1-Score*, Precisão e Revocação.

2.8.1 Intersection over Union (IoU)

Em tarefas de segmentação semântica, é essencial quantificar o grau de sobreposição entre a predição do modelo e a máscara de referência. Uma das métricas mais utilizadas para esse fim é o *Intersection over Union* (IoU), também conhecida como índice de Jaccard.

O IoU é definido como a razão entre a área de interseção e a área de união entre a predição e a verdade de referência, conforme a Equação 1:

$$\text{IoU} = \frac{|\text{Predição} \cap \text{Referência}|}{|\text{Predição} \cup \text{Referência}|} \quad (1)$$

Na prática, isso significa que o valor de IoU será 1 quando a predição for idêntica à máscara real, e 0 quando não houver nenhuma sobreposição. Em problemas com forte desbalanceamento entre classes, como é o caso da segmentação de áreas queimadas em imagens de satélite, o IoU se torna especialmente útil por penalizar predições com excesso de falsos positivos ou falsos negativos.

Valores de IoU acima de 0,5 são, em geral, considerados aceitáveis para segmentações razoáveis, embora isso dependa do contexto da aplicação.

2.8.2 Precisão

A precisão mede a proporção de pixels preditos como positivos que realmente pertencem à classe de interesse. Em outras palavras, indica a taxa de verdadeiros positivos entre todos os positivos previstos pelo modelo.

$$\text{Precisão} = \frac{\text{VP}}{\text{VP} + \text{FP}} \quad (2)$$

Onde VP representa os verdadeiros positivos, ou seja, casos em que o modelo acertou, e FP representa os falsos positivos, quando o modelo errou ao classificar incorretamente um elemento como pertencente à classe de interesse. Altos valores de precisão indicam um baixo índice de alarmes falsos (falsas detecções).

2.8.3 Sensibilidade ou Revocação

A Revocação, também conhecida como sensibilidade ou taxa de detecção, mede a proporção de elementos relevantes que foram corretamente identificados pelo modelo. No contexto de segmentação, representa a capacidade do modelo de cobrir toda a área real da classe positiva.

$$\text{Revocação} = \frac{\text{VP}}{\text{VP} + \text{FN}} \quad (3)$$

Valores elevados de revocação indicam que o modelo foi capaz de identificar a maior parte da área queimada, minimizando omissões (falsos negativos).

2.8.4 F1-Score (Coeficiente de Dice)

O *F1-Score* é uma métrica harmônica entre precisão e revocação, amplamente utilizada em tarefas de classificação e segmentação, especialmente em cenários desbalanceados. Também conhecido como Coeficiente de Dice, o *F1* penaliza desbalanceamentos entre falsos positivos e falsos negativos, fornecendo uma avaliação equilibrada entre os dois extremos.

Sua fórmula é dada pela Equação 4:

$$F1 = \frac{2 \cdot \text{Precisão} \cdot \text{Revocação}}{\text{Precisão} + \text{Revocação}} \quad (4)$$

Valores próximos de 1 indicam excelente desempenho, enquanto valores baixos refletem falhas na cobertura ou precisão da segmentação.

2.8.5 Coeficiente de correlação de Matthews (MCC)

O Coeficiente de Correlação de Matthews (MCC) é uma métrica amplamente utilizada para avaliar o desempenho de classificadores binários, especialmente em cenários com forte desbalanceamento entre classes, como é o caso da segmentação de focos de incêndio, em que a classe positiva (fogo) representa uma fração ínfima dos dados.

O MCC leva em consideração todas as entradas da matriz de confusão (verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos), fornecendo uma medida de correlação entre as predições do modelo e os rótulos reais. Sua fórmula é dada por:

$$\text{MCC} = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$

Os valores do MCC variam de -1 a $+1$, onde:

- $+1$ indica predição perfeita;
- 0 indica ausência de correlação (equivalente a uma predição aleatória);
- -1 indica correlação negativa total (todas as predições estão incorretas).

Diferentemente de métricas como Acurácia ou *F1-Score*, o MCC continua sendo confiável mesmo em *datasets* altamente desbalanceados, pois penaliza de forma proporcional tanto os falsos positivos quanto os falsos negativos. Por esse motivo, o MCC foi incluído neste trabalho como métrica complementar para avaliar a robustez do modelo em detectar com precisão as regiões de foco de incêndio, sem se beneficiar artificialmente do grande volume de pixels de fundo corretamente classificados.

3 METODOLOGIA

3.1 Dados Utilizados

O conjunto de dados empregado neste trabalho foi disponibilizado por Pereira et al. (2021) por meio de um repositório público no GitHub¹. As imagens são provenientes do satélite *Landsat-8* e foram recortadas em *patches* de 256×256 pixels, contendo 10 bandas espectrais, com exceção da banda pancromática.

As máscaras de treinamento foram geradas exclusivamente com base em métodos tradicionais de detecção de fogo ativo, conforme proposto por Schroeder et al. (2016), Murphy et al. (2016) e Kumar e Roy (2018). Neste trabalho, foram utilizadas apenas as máscaras produzidas pelo método de Kumar e Roy (2018), devido à sua maior capacidade de equilibrar a identificação de focos de fogo com a redução de falsos positivos, conforme evidenciado por Pereira et al. (2021). Embora a literatura aponte que a combinação de diferentes métodos possa aumentar a robustez das detecções, a adoção de uma única abordagem visou assegurar consistência metodológica e simplicidade na análise.

Cabe destacar que as imagens com anotações manuais de especialistas, também disponibilizadas no `\textit{dataset}`, foram utilizadas exclusivamente na etapa de avaliação, não sendo incorporadas ao treinamento. Esse procedimento buscou garantir uma avaliação imparcial, bem como mensurar adequadamente a capacidade de generalização do modelo.

A separação dos conjuntos de treino e teste foi realizada a partir dos *scripts* originais adaptados, fornecidos no repositório. O conjunto de dados resultante totalizou 143.133 *patches* com suas respectivas máscaras para o treinamento, e 100 *patches* com anotações manuais para o teste. Optou-se por incluir todas as amostras disponíveis com máscaras válidas, geradas conforme o método de Kumar e Roy (2018), de modo a maximizar o aproveitamento dos dados destinados ao treinamento e à validação.

3.2 Arquitetura do Modelo

O modelo desenvolvido neste trabalho baseia-se na arquitetura U-Net (RONNEBERGER et al., 2015), adaptada para aceitar entradas de 10 canais correspondentes às bandas espectrais do *Landsat-8*. A rede foi configurada com 16 filtros iniciais, aumentando progressivamente conforme o aprofundamento da rede, e incorporando camadas de *Batch Normalization* e *Dropout* (com taxa de 0,1) para mitigar o *overfitting*.

A saída do modelo é uma máscara binária de 256×256 pixels, onde cada pixel indica a presença (1) ou ausência (0) de fogo ativo.

¹<https://github.com/pereira-gha/activefire>

3.3 Estratégias de Treinamento

O treinamento do modelo foi realizado utilizando:

- Função de perda: *Binary Cross-Entropy with Logits*, ajustada com peso positivo (100.0) para lidar com o forte desbalanceamento entre classes (pixels de fogo versus pixels de fundo). Esse valor foi definido empiricamente com base na proporção média observada de pixels positivos, que representa frequentemente menos de 3% da imagem. A atribuição de um peso elevado à classe minoritária visa compensar sua sub-representação, amplificando a penalização por erros de classificação e incentivando o modelo a aprender seus padrões. O valor de 100.0 foi estabelecido após testes incrementais até alcançar estabilidade de convergência e alta sensibilidade nos dados de validação.

A função de perda ponderada assume a forma:

$$\mathcal{L}(p, y) = -\alpha \cdot y \cdot \log(p) - (1 - y) \cdot \log(1 - p)$$

onde $y \in \{0, 1\}$ é o rótulo do pixel, $p \in (0, 1)$ é a probabilidade prevista e $\alpha = 100.0$ é o peso atribuído à classe positiva. Essa formulação faz com que os erros nos pixels da classe de interesse (foco de incêndio) tenham impacto amplificado no gradiente de otimização, o que é fundamental em cenários fortemente desbalanceados.

- Otimização: Otimizador Adam, com taxa de aprendizado inicial de 1×10^{-5} . Esse valor foi escolhido por apresentar bom equilíbrio entre estabilidade e velocidade de convergência em testes preliminares, evitando oscilações no gradiente e possibilitando treinamento robusto em dados ruidosos.
- Tamanho do lote: 16 amostras por *batch*. Este valor foi definido com base na capacidade de memória da GPU utilizada (8 GB), de forma a permitir o treinamento sem comprometimento do desempenho, garantindo que múltiplas amostras fossem processadas simultaneamente sem perda de resolução ou truncamento de gradientes.
- Épocas máximas: 50. Embora o modelo costuma convergir antes desse limite, esse valor foi definido como margem superior para garantir que o processo de treinamento tivesse tempo suficiente de adaptação, mesmo em cenários com maior variabilidade espectral ou amostral.
- *Early Stopping*: Aplicado com paciência de três épocas, interrompendo o treinamento se não houver melhoria da perda de validação nesse intervalo. Essa técnica visa evitar o overfitting, reduzindo o tempo de treinamento sem comprometer o desempenho. O valor de paciência foi definido com base na taxa média de estabilização observada durante os ciclos iniciais de treinamento.

Como mostrado na Figura 1, a arquitetura implementada segue o padrão da U-Net, composta por quatro blocos de codificação, cada um contendo duas camadas convolucionais seguidas de operações de *pooling* e *dropout*. O gargalo (bottleneck) é formado por duas camadas convolucionais com 256 filtros. Na fase de decodificação, cada etapa consiste em uma camada de convolução transposta para aumento de resolução, concatenação com o respectivo mapa de características da fase de codificação e duas camadas convolucionais para refinamento. A saída do modelo é produzida por uma camada convolucional 1×1 , gerando o mapa de segmentação binária.




Figura 1: Arquitetura U-Net utilizada no modelo.

Fonte: Autoria Própria.

3.4 Técnicas de Data Augmentation

Para melhorar a generalização do modelo frente à alta variabilidade espectral e espacial dos focos de incêndio, foi aplicada uma estratégia leve de *Data Augmentation* a todas as amostras do conjunto de treinamento. As transformações utilizadas foram:

- Espelhamento horizontal aleatório;

- Espelhamento vertical aleatório;
- Rotações aleatórias de 90°, 180° ou 270° .

Essas técnicas foram selecionadas por preservarem as características geométricas dos focos de incêndio, além de introduzirem variações controladas na orientação e localização das áreas queimadas. Isso contribui para aumentar a diversidade dos dados sem comprometer a fidelidade semântica das máscaras, reduzindo o risco de sobreajuste.

3.5 Avaliação do Modelo

A avaliação do modelo foi conduzida utilizando um subconjunto de imagens disponibilizado pelo autor da base de dados, contendo máscaras de queimadas geradas manualmente por especialistas. Essas anotações não foram utilizadas no treinamento, sendo reservadas exclusivamente para análise da capacidade de generalização do modelo.

As métricas utilizadas para quantificar o desempenho foram:

- *F1-Score*: métrica harmônica entre precisão e revocação, amplamente utilizada em tarefas de segmentação de áreas queimadas;
- *IoU*: mede a interseção entre predição e referência em relação à sua união;
- *Precisão e Revocação*: para análise mais detalhada dos erros de omissão e comissão;
- *MCC*: métrica que avalia a correlação entre as predições do modelo e os rótulos reais, considerando todos os quadrantes da matriz de confusão. É especialmente adequada em cenários com desbalanceamento entre classes, como o presente caso, portanto fornece uma medida equilibrada da qualidade da classificação binária.

As métricas foram calculadas de forma global sobre todo o conjunto avaliado, acumulando verdadeiros positivos, falsos positivos e falsos negativos entre todos os *patches*, conforme práticas estabelecidas em *benchmarks* de segmentação semântica (EVERINGHAM et al., 2010; LIN et al., 2014).

Além disso, foi analisada a distribuição dos valores de *IoU* por imagem, com o objetivo de compreender a variabilidade do desempenho do modelo em diferentes cenários de complexidade e proporção de áreas queimadas.

4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

Nesta seção, são apresentados e analisados os resultados obtidos a partir dos experimentos realizados. Inicialmente, descrevem-se os principais indicadores de desempenho do modelo, seguidos da interpretação crítica dos resultados em comparação com a literatura e as hipóteses levantadas no trabalho.

4.1 Resultados Quantitativos

A avaliação do modelo sobre o conjunto de dados anotado por especialistas resultou nas métricas exibidas na Tabela 2.

IoU	Precisão	Revocação	F1-Score	MCC
0,79	0,88	0,89	0,88	0,88

Tabela 2: Resultados do modelo nos dados anotados por especialistas.

Fonte: Autoria Própria.

Os resultados indicam que o modelo alcançou desempenho elevado na tarefa de segmentação, com revocação de 0,89 e precisão de 0,88, o que reflete uma boa capacidade de identificar corretamente os pixels da classe *fogo*, com baixos índices de falsos positivos e falsos negativos.

O *F1-Score* de 0,88 representa um bom equilíbrio entre precisão e revocação. Já o IoU global de 0,79 demonstra que a interseção entre as predições e as anotações de referência é substancial, mesmo considerando o forte desbalanceamento de classe presente nos dados.

A Figura 2 mostra a distribuição dos valores de IoU por imagem. Observa-se uma leve variabilidade entre as amostras, com a maior parte das imagens apresentando desempenho superior a 0,7, e poucos casos abaixo de 0,3. Isso evidencia que o modelo se comporta de maneira consistente na maioria das situações.




Figura 2: Distribuição do IoU.

Fonte: Autoria Própria.

A métrica MCC, com valor 0,88, também corrobora a robustez do modelo, indicando alto grau de concordância entre as previsões e as anotações, mesmo em um cenário desbalanceado.

4.2 Resultados Visuais

Além das métricas quantitativas, foram realizadas análises qualitativas por meio da visualização dos resultados de segmentação produzidos pelo modelo. Para isso, selecionaram-se exemplos representativos distribuídos em três faixas distintas de desempenho, com base nos valores de IoU.

A Figura 3 apresenta todas as imagens analisadas, categorizadas conforme o desempenho obtido. As subfiguras (a) e (b) ilustram casos em que as segmentações alcançaram IoU superior a 0,7, sendo consideradas exemplos de desempenho elevado. Nessas amostras, observa-se que o modelo foi capaz de delimitar de forma precisa a área queimada, com boa sobreposição entre predição e máscara de referência.

As subfiguras (c) e (d) correspondem a casos intermediários, com IoU entre 0,3 e 0,7. Nesses exemplos, embora o modelo tenha identificado parte da área de fogo, há regiões com sobreposição incompleta, evidenciando limitações na generalização espacial da segmentação.

Por fim, as subfiguras (e) e (f) representam os casos com IoU inferior a 0,3. Nessas amostras, a segmentação falhou em representar a área de interesse com fidelidade, apre-

sentando previsões inconsistentes ou completamente ausentes, o que pode ser atribuído à baixa proporção de fogo na imagem ou a ruídos espectrais que dificultam a identificação.

Essa análise qualitativa complementa os resultados numéricos, permitindo compreender de forma mais aprofundada os acertos e limitações do modelo em diferentes situações.




Figura 3: Resultados obtidos com diferentes faixas de IoU.
Fonte: Autoria Própria.

4.3 Discussão dos Resultados

Os resultados obtidos indicam que o modelo apresenta elevada sensibilidade, com revocação superior a 0,89, além de um alto índice de precisão, atingindo 0,88, o que revela que a maioria das detecções realizadas corresponde, de fato, a áreas queimadas. Esse desempenho representa um avanço relevante, sobretudo diante do forte desbalanceamento entre as classes, considerando que a proporção de pixels associados ao fogo é frequentemente inferior a 3% nas imagens avaliadas.

Estudos prévios, como os de Fusioka (2021) e Ali e Kurnaz (2025), relatam dificuldades semelhantes ao aplicar modelos de segmentação em contextos desbalanceados, sendo comum o uso de funções de perda ponderadas e estratégias de *data augmentation* — abordagens também empregadas neste trabalho.

A média de IoU por imagem de 0,63 e o IoU global de 0,79 indicam boa sobreposição

entre as previsões e as máscaras de referência, mesmo em imagens com baixa incidência de focos de incêndio. O valor elevado do *F1-Score* de 0,88 também corrobora o equilíbrio entre os acertos e erros do modelo.

As análises visuais reforçam esses achados, revelando que o modelo tende a formar melhor em focos mais extensos e homogêneos. Em contrapartida, quando o fogo aparece de forma esparsa ou fragmentada, a segmentação pode apresentar imprecisões, como também observado por Pletsch et al. (2022).

Estudo recente de Singh et al. (2024) também empregou a arquitetura U-Net para segmentar áreas queimadas em imagens Landsat-8, alcançando um F1-Score de 0,6869, desempenho inferior ao obtido neste trabalho. Assim como nesta análise, os autores observaram que a U-Net superou a SegNet tanto em precisão quanto em tempo de inferência, reforçando sua robustez em cenários com alta variabilidade espacial. Além disso, sugerem a combinação de tarefas de classificação e segmentação em um pipeline unificado, o que representa uma direção promissora para ganhos de desempenho em contextos complexos.

Shirvani et al. (2023) demonstraram que a adição de blocos residuais e mecanismos de atenção à arquitetura U-Net (RAUNet) resulta em melhor desempenho para detecção de queimadas em florestas tropicais abertas, especialmente em focos pequenos, alcançando IoU de até 0,92. Apesar das diferenças nos sensores utilizados (*Sentinel-2* ao invés de *Landsat-8*), os resultados apontam para o potencial da incorporação de componentes mais sofisticados na arquitetura da U-Net empregada neste trabalho, como mecanismos de atenção espacial e blocos residuais.

Ainda em relação à melhoria da segmentação, Shen et al. (2023) destacam que a inclusão de variáveis atmosféricas e espectrais pode aumentar a acurácia da classificação de risco de incêndios. Embora o presente trabalho tenha como foco a segmentação direta de áreas queimadas, esse tipo de enriquecimento de entrada pode ser explorado no futuro como forma de reduzir incertezas em predições pontuais.

Outro desafio importante diz respeito à escassez de máscaras rotuladas por especialistas, o que dificulta a construção de bases de validação mais robustas. Marto et al. (2023) propõem o uso de aprendizado ativo (*active learning*) aliado à segmentação fraca (*weak supervision*) para detecção de fogo e fumaça em vídeos RGB. Embora os dados utilizados sejam distintos, os desafios são semelhantes: lidar com dados ruidosos, incompletos ou limitados. Os autores demonstram que estratégias iterativas de amostragem podem reduzir de forma expressiva a necessidade de anotações extensas, o que abre possibilidades para sua adaptação a contextos de sensoriamento remoto multiespectral.

Além disso, estudo recente realizado no bioma Pantanal, Brasil, demonstrou a aplicação de redes neurais convolucionais para detecção em tempo real de incêndios ativos, com resultados promissores (COSTA et al., 2025). Tal abordagem reforça a aplicabilidade

de modelos baseados em aprendizado profundo para cenários complexos e ecossistemas sensíveis, como os biomas brasileiros, indicando um caminho relevante para futuros aprimoramentos.

Portanto, os resultados obtidos reforçam a adequação da U-Net para a tarefa de segmentação de áreas queimadas, especialmente em regiões com foco bem definido. Sua elevada sensibilidade e precisão a tornam uma candidata promissora para sistemas de alerta precoce. No entanto, para lidar com a variabilidade espacial e espectral presente em imagens mais complexas, podem ser necessárias estratégias complementares, como arquiteturas multiescala, mecanismos de atenção espacial, fusão de dados espectrais com variáveis ambientais, ou até mesmo o uso de aprendizado ativo para seleção de amostras mais informativas.

Essas direções futuras podem contribuir para a construção de sistemas mais robustos e adaptáveis às diferentes realidades ambientais, especialmente em aplicações operacionais voltadas à gestão e mitigação de incêndios florestais.

5 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho apresentou o desenvolvimento e avaliação de um modelo de segmentação semântica baseado na arquitetura U-Net para identificação de focos de incêndio em imagens multiespectrais do satélite *Landsat-8*. O principal desafio abordado foi o forte desbalanceamento entre classes, típico nesse tipo de aplicação, em que as áreas queimadas representam uma pequena fração da imagem.

Os resultados demonstraram que o modelo alcançou desempenho expressivo, com sensibilidade (revocação) de 0,89 e precisão de 0,88, evidenciando sua capacidade de detectar focos de incêndio com baixo índice de falsos positivos. O *F1-Score* de 0,88 e o IoU global de 0,79 confirmam a boa sobreposição entre as predições e as máscaras de referência, mesmo em um cenário de alta complexidade espectral e espacial.

As análises visuais reforçaram que a U-Net apresenta bom desempenho em focos bem definidos e extensos. Por outro lado, em casos com áreas queimadas muito pequenas, dispersas ou de baixo contraste, a segmentação pode apresentar limitações, especialmente em ambientes com maior ruído ou heterogeneidade.

Ainda assim, os resultados obtidos superam *benchmarks* da literatura recente para tarefas similares, demonstrando que a U-Net permanece uma das arquiteturas mais robustas e eficientes para a detecção de queimadas. Este trabalho contribui ao aplicar técnicas modernas de aprendizado profundo em um contexto real e desafiador, validando a eficácia de estratégias como ponderação da função de perda e *data augmentation* seletivo.

Como perspectivas para trabalhos futuros, recomenda-se:

- Investigar o uso de mecanismos de atenção e arquiteturas multiescala para melhorar a detecção de focos pequenos e dispersos;
- Integrar dados multitemporais ou de sensores complementares (como *Sentinel-2* e *MODIS*);
- Adotar estratégias de aprendizado semi ou auto-supervisionado, ampliando o uso de dados não anotados;
- Explorar abordagens de aprendizado ativo para reduzir a necessidade de anotações manuais extensas.

Conclui-se que a combinação de modelos baseados em aprendizado profundo com estratégias adequadas de tratamento de dados pode impulsionar a precisão, a robustez e a aplicabilidade de sistemas de monitoramento de incêndios florestais em larga escala.

REFERÊNCIAS

- ALI, Abdallah Waleed; KURNAZ, Sefer. Optimizing deep learning models for fire detection, classification, and segmentation using satellite images. **Fire**, v. 8, n. 2, p. 36, jan. 2025.
- ARAGÃO, Luiz Eduardo O. C. et al. 21st century drought-related fires counteract the decline of Amazon deforestation carbon emissions. *Nature Communications*, v. 9, n. 1, 2020.
- ARRUDA, F. V. D. et al. Trends and gaps of the scientific literature about the effects of fire on Brazilian Cerrado. *Biota Neotropica*, v. 18, p. 1–6, 2018.
- BARMPOUTIS, Panagiotis; KUMAR, Vijay; ZHOU, Shuhui. Satellite-based burned area mapping via deep learning. *Fire*, v. 3, n. 4, p. 74, 2020.
- BBC NEWS. **Maps and images reveal scale of LA wildfire devastation**. 14 jan. 2025. Disponível em: <https://www.bbc.com/news/articles/cg525q2gg14o>. Acesso em: 18 abr. 2025.
- CHEN, D., ZHANG, H., YANG, X., & ZHAO, L. (2022). UIU-Net: U-Net in U-Net for infrared small object detection. *arXiv preprint arXiv:2212.00968*.
- CHUVIECO, Emilio. **Fundamentals of Satellite Remote Sensing: An Environmental Approach**. 2. ed. Boca Raton: CRC Press, 2016.
- COSTA, D. C.; BATISTA, L. V.; SILVA, R. M.; SANTOS, C. A. G. Real-Time Active Fire Detection in the Pantanal Biome, Brazil, Using Convolutional Neural Networks. *Fire Technology*, 2025.
- SYKAS, D. et al. Deep learning approaches for wildfire severity prediction: a comparative study of image segmentation networks and visual transformers on the EO4WildFires dataset. *Fire*, v. 7, p. 374, 2024. DOI: <https://doi.org/10.3390/fire7110374>.
- EVERINGHAM, M. et al. *The PASCAL Visual Object Classes (VOC) Challenge*. *International Journal of Computer Vision*, v. 88, n. 2, p. 303–338, 2010.
- FUSIOKA, A. M. *Detecção de fogo ativo por aprendizado profundo em imagens provenientes do satélite Landsat-8*. 2021. Dissertação (Mestrado em Computação Aplicada) – Universidade Tecnológica Federal do Paraná, Curitiba, 2021.
- GOULD, C. F., NADEU, K. C., & BURKE, M. (2024). Health Effects of Wildfire Smoke Exposure. *Annual Review of Medicine*, 75, 19.1–19.16.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.

- IBTEHAZ, N., & RAHMAN, M. S. (2020). MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation. *Neural Networks*, 121, 74–87.
- JAIN, P. et al. A review of machine learning applications in wildfire science and management. *arXiv preprint*, arXiv:2003.00646v2, 2020.
- KUMAR, S. S.; ROY, D. P. Global operational land imager Landsat-8 reflectance-based active fire detection algorithm. *International Journal of Digital Earth*, v. 11, n. 2, p. 154–178, 2018.
- LI, J. et al. A clustering algorithm to organize satellite hotspot data for the purpose of tracking bushfires remotely. *The R Journal*, 2023.
- LIN, T. Y. et al. *Microsoft COCO: Common Objects in Context*. In: ECCV 2014.
- LIZ-LÓPEZ, H. et al. **Spain on fire: A novel wildfire risk assessment model based on image satellite processing and atmospheric information**. 2023.
- MAPBIOMAS. **Área queimada no Brasil cresce 79% em 2024 e supera os 30 milhões de hectares**. 22 jan. 2025. Disponível em: <https://brasil.mapbiomas.org/2025/01/22/area-queimada-no-brasil-cresce-79-em-2024-e-supera-os-30-milhoes-de-hectares/>. Acesso em: 20 abr. 2025.
- MARTO, Tiago; BERNARDINO, Alexandre; CRUZ, Gonçalo. Fire and smoke segmentation using active learning methods. *Remote Sensing*, v. 15, n. 17, p. 4136, 2023.
- MURPHY, Sam W. et al. Hotmap: global hot target detection at moderate spatial resolution. *Remote Sensing of Environment*, v. 177, p. 78–88, 2016.
- PEREIRA, G. H. A. et al. *Active fire detection in Landsat-8 imagery: a large-scale dataset and a deep-learning study*. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021.
- PLETSCH, Mikhaela A. J. S. et al. Near real-time fire detection and monitoring in the MATOPIBA region, Brazil. **Remote Sensing**, v. 14, n. 13, p. 3141, jun. 2022.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. *U-Net: Convolutional networks for biomedical image segmentation*. In: MICCAI 2015. p. 234–241.
- SANNIGRAHI, Srikanta et al. **Effects of West Coast forest fire emissions on atmospheric environment: a coupled satellite and ground-based assessment**. 2023.
- SCHROEDER, Wilfrid et al. Active fire detection using Landsat-8/OLI data. *Remote Sensing of Environment*, v. 185, p. 210–220, 2016.

- SCHROEDER, W., OLIVA, P., GIGLIO, L., & CSISZAR, I. A. (2016). The New VIIRS 375 m active fire detection data product: Algorithm description and initial assessment. *Remote Sensing of Environment*, 143, 85–96.
- SINGH, Swapnil et al. Beyond boundaries: unifying classification and segmentation in wildfire detection systems. *Multimedia Tools and Applications*, 2024.
- SITNOV, S. A.; MOKHOV, I. I. Comparative analysis of active fire characteristics in the boreal forests of Eurasia and North America based on satellite data. *Izvestiya, Atmospheric and Oceanic Physics*, v. 54, p. 966–978, 2018. DOI: 10.1134/S0001433818090347.
- SHEN, Shuchang et al. **FireRisk: A remote sensing dataset for fire risk assessment with benchmarks using supervised and self-supervised learning**. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2023. p. 17603–17613.
- SHIRVANI, Zeinab; ABDI, Omid; GOODMAN, Rosa C. High-resolution semantic segmentation of woodland fires using residual attention UNet and time series of Sentinel-2. *Remote Sensing*, v. 15, n. 5, p. 1342, 2023.
- UNITED STATES GEOLOGICAL SURVEY. **Landsat 8 overview**. 2025. Disponível em: <https://www.usgs.gov/landsat-missions/landsat-8>. Acesso em: 19 abr. 2025.
- VASCONCELOS, R. N. et al. Fire detection with deep learning: a comprehensive review. *Land*, v. 13, p. 1696, 2024.