



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2024/02.26.19.49-TDI

DETECÇÃO DE FOGO ATIVO POR APRENDIZADO PROFUNDO EM IMAGENS PROVENIENTES DE SATÉLITES

Cristiano Emanuel Pereira Reis

Dissertação de Mestrado do
Curso de Pós-Graduação em
Computação Aplicada, orientada
pelos Drs. Nandamudi Lankalapalli
Vijaykumar, e Luciana Brasil
Rebello dos Santos, aprovada em
07 de dezembro de 2023.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/4AQP858>>

INPE
São José dos Campos
2023

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2024/02.26.19.49-TDI

DETECÇÃO DE FOGO ATIVO POR APRENDIZADO PROFUNDO EM IMAGENS PROVENIENTES DE SATÉLITES

Cristiano Emanuel Pereira Reis

Dissertação de Mestrado do
Curso de Pós-Graduação em
Computação Aplicada, orientada
pelos Drs. Nandamudi Lankalapalli
Vijaykumar, e Luciana Brasil
Rebello dos Santos, aprovada em
07 de dezembro de 2023.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/4AQP858>>

INPE
São José dos Campos
2023

Dados Internacionais de Catalogação na Publicação (CIP)

Reis, Cristiano Emanuel Pereira.

R277d Detecção de fogo ativo por aprendizado profundo em imagens provenientes de satélites / Cristiano Emanuel Pereira Reis. – São José dos Campos : INPE, 2023.
xxii + 89 p. ; (sid.inpe.br/mtc-m21d/2024/02.26.19.49-TDI)

Dissertação (Mestrado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2023.

Orientadores : Drs. Nandamudi Lankalapalli Vijaykumar, e Luciana Brasil Rebelo dos Santos.

1. U-Net. 2. Sentinel-2. 3. Landsat-8. 4. Sensoriamento Remoto. 5. Fogo Ativo. I.Título.

CDU 004.8:528.8



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÃO



INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

DEFESA FINAL DE DISSERTAÇÃO CRISTIANO EMANOEL PEREIRA REIS BANCA Nº 291/2023, REG. 62622/2021

No dia 07 de dezembro de 2023, às 09h, por teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestre em Computação Aplicada, com a exigência de que o trabalho final a ser publicado deverá incorporar as correções sugeridas pela Banca Examinadora, com revisão pelo(s) orientador(es).

Título: "Detecção de fogo ativo por aprendizado profundo em imagens provenientes de satélites."

Membros da Banca:

Dr. Elcio Hideiti Shiguemori - presidente - INPE

Dr. Nandamidi Lankalapalli Vijaykumar - Orientador - INPE

Dra. Luciana Brasil Rebelo Dos Santos – Orientadora – Gran Sasso Science Institute (GSSI) - IFSP

Dr. Alexandre Carlos Brandão Ramos – Membro Externo – UNIFEI

Dr. Carlos Renato Lisboa Francês – Membro Externo – UFPA



Documento assinado eletronicamente por **Alexandre Carlos Brandão Ramos (E), Usuário Externo**, em 20/12/2023, às 09:53 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **nandamudi lankalapalli vijaykumar (E), Usuário Externo**, em 20/12/2023, às 10:25 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Elcio hideiti shiguemori (E), Usuário Externo**, em 20/12/2023, às 11:02 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Carlos Renato Lisboa Frances (E), Usuário Externo**, em 20/12/2023, às 11:19 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Luciana brasil rebelo dos santos (E), Usuário Externo**, em 20/12/2023, às 14:04 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <https://sei.mcti.gov.br/verifica.html>, informando o código verificador **11612381** e o código CRC **662FF815**.

Referência: Processo nº 01340.010059/2023-12

SEI nº 11612381

*“Tudo é do Pai, toda honra e toda glória,
é Dele a vitória, alcançada em minha vida”.*

*FRED PACHECO, em:
“Não há o Impossível - Banda Dom”, 1999*

*Aos meus pais **José Benedito** e **Marlene**,
à minha irmã **Cristiele**,
à minha esposa **Glaudenia**
e ao meu filho **Eduardo Emanuel***

AGRADECIMENTOS

À Deus, que em sua infinita misericórdia, me fortaleceu em todo o processo.

À minha esposa Glaudenia Reis e meu filho Eduardo Emanuel, pela paciência de ambos, que foi fundamental durante os momentos difíceis.

Aos meus pais José Benedito e Marlene Aparecida e minha irmã Cristiele Reis, que me apoiaram e acreditaram que eu chegaria lá.

Aos meus orientadores Vijaykumar e Luciana Brasil, pela competência e praticidade durante todo o processo.

Ao Me. David França, Me. Ednei da Silva Santos, Me. Fernando Mauro, Sr. Wellington Almeida e amigos do CCA-SJ, pelas críticas construtivas e apoio incondicional.

Ao Prof. Dr. Fabiano Morelli que esteve disposto a ajudar e contribuir para o enriquecimento de meu conhecimento.

O tema abordado nesta dissertação de Mestrado está em linha com os objetivos do Centro IARA (Inteligência Artificial Recriando Ambientes). O IARA é um dos 10 Centros aprovados na chamada FAPESP-MCTI-CGL.BR de Centros de Pesquisa Aplicada em Inteligência Artificial (CPA). Agradecimentos pelo suporte ao Centro sob o número do processo: 2020/09835-1.

Aos demais professores do curso de pós-graduação, pelo empenho na ministração de suas disciplinas.

À todos os amigos e familiares, que me apoiaram para que esse dia acontecesse.

RESUMO

A detecção de fogo ativo a partir de imagens de satélite desempenha um papel importante na implementação de políticas de conservação ambiental, fomentar a tomada de decisão e a aplicação da lei. Nos últimos anos, modelos de aprendizado profundo têm obtido sucesso em diversos campos, mas seu uso na detecção de fogo ativo é relativamente recente. Dessa forma, este trabalho aborda a análise da viabilidade do uso de aprendizado profundo para a detecção de fogo ativo. Este estudo identifica, por meio de uma CNN do tipo *U-Net*, a segmentação de fogo ativo em imagens dos satélites Sentinel-2 e Landsat-8, utilizando as máscaras produzidas por métodos conhecidos na literatura e comumente utilizados para a detecção de fogo ativo. Mais especificamente, este estudo compreende dois conjuntos de dados significativos. O primeiro conjunto consiste em 100 cenas do satélite Sentinel-2 e 23 cenas do satélite Landsat-8, abrangendo o período entre janeiro de 2021 e junho de 2023. Essas imagens foram empregadas nas fases de treinamento, validação e testes, abrangendo diversos biomas. Os resultados da fase de validação são promissores, com uma acurácia de 97,98%, embora tenham sido observadas cinco classificações incorretas em quinze execuções. A precisão das imagens do Sentinel-2 alcançou 97,73%. Quanto aos testes realizados com imagens do Landsat-8, a *precision* atingiu 90,22%. O segundo conjunto de imagens se concentra na região da Serra do Cipó, o foco principal deste estudo. Foram utilizadas 15 cenas obtidas em 30 de setembro de 2002 pelo Landsat-8 para fins de teste. O modelo obteve uma *precision* de 93,3%, garantindo a compatibilidade entre os sensores. Estes resultados desempenham um papel significativo no avanço da expertise em detecção de incêndios, fornecendo apoio às iniciativas de preservação ambiental e à implementação de políticas relacionadas.

Palavras-chave: U-Net. Sentinel-2. Landsat-8. Sensoriamento Remoto. Fogo Ativo. Aprendizado Profundo.

ACTIVE FIRE DETECTION THROUGH DEEP LEARNING USING SATELLITE IMAGES

ABSTRACT

The detection of active fires in satellite imagery is of paramount importance for environmental conservation policies, decision-making, and law enforcement. Traditional models for active fire detection typically rely on the comparison of pixels or image regions with specific thresholds tailored to the sensor in use. This study focuses on active fire detection using Sentinel-2 satellite imagery to train a deep learning model. Additionally, tests for active fire detection will be conducted using imagery from both Sentinel-2 and Landsat-8 satellites. In recent years, deep learning models have achieved significant success across various domains, but their application to active fire detection is relatively new. Therefore, it is essential to assess the feasibility of using deep learning for active fire detection. In this study, we aim to identify fire hotspot segmentations in Sentinel-2 and Landsat-8 satellite images using a convolutional neural network architecture known as U-Net. The model is trained using masks generated from widely recognized methods in the literature for fire hotspot detection in Sentinel-2 imagery. Specifically, this study encompasses model training using images from the Sentinel-2 satellite, acquired over a large part of South America from January 2021 to June 2023. Additionally, the model will undergo testing with images from the Landsat-8 satellite dated September 30, 2020, over the Serra do Cipó region, capturing active fire spots and ensuring sensor compatibility.

Keywords: U-Net. Sentinel-2. Landsat-8. Remote Sensing. Active Fire. Deep Learning.

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Aquisição de imagens por Sensoriamento Remoto.	7
2.2 Satélite de sensoriamento remoto da ESA - Sentinel-2.	10
2.3 Bandas Espectrais e Resolução Espacial do Sentinel-2.	11
2.4 Satélite de sensoriamento remoto da USGS - Landsat-8	12
2.5 Comprimento de onda entre os sensores Landsat 7 e 8.	14
2.6 Modelo de Neurônio Artificial de McCulloch e Pitts.	15
2.7 Função de ativação.	18
2.8 Função de ativação ReLU.	19
2.9 Estrutura de uma CNN.	27
2.10 Aplicação de filtro de convolução 3x3.	27
2.11 Operações de pooling.	28
2.12 Max Pooling com kernel 2x2.	29
2.13 Agrupamento tradicional.	29
2.14 Arquitetura U-Net.	31
2.15 Ciclo de Convolução, ReLu, MaxPooling e UpSampling.	32
2.16 Ramo esquerdo da arquitetura.	33
2.17 Ramo direito da arquitetura.	34
2.18 Diagrama da reconstrução por deconvolução.	35
2.19 Saída da arquitetura.	35
4.1 Progresso da área de queimada Serra do Cipó.	54
4.2 Localização da área de estudo.	55
4.3 Visualização de imagens de entrada da U-Net.	58
4.4 Exemplo de imagens de teste da Serra do Cipó.	59
4.5 U-Net queimadas.	60
4.6 Descrição do fluxo de trabalho.	62
4.7 Divisão das imagens de treinamento.	63
4.8 Treinamento e validação do modelo.	66
5.1 Imagens de teste com Sentinel-2.	70
5.2 Imagens de teste com Landsat-8.	71
5.3 Imagens Sentinel-2 sem focos de incêndio.	72
5.4 Imagens Sentinel-2 com nuvens.	72
5.5 Imagens Landsat-8 com nuvens.	72
5.6 Imagens de teste com Landsat-8, Serra do Cipó.	73

LISTA DE TABELAS

	<u>Pág.</u>
2.1 Resolução Espectral das Bandas do Sentinel-2.	10
2.2 Resolução espectral das bandas dos dados do satélite Landsat-8.	13
3.1 Tópicos relacionados.	52
4.1 Resultados - Optimizador e Taxa de Aprendizagem	65
4.2 Valores dos hiperparâmetros do modelo de classificação.	67
5.1 Resultados obtidos na validação e no teste do modelo.	69
5.2 Resultados obtidos nos testes do modelo.	69
5.3 Resultados obtidos com testes do modelo com imagens da área de estudo.	73

LISTA DE ABREVIATURAS E SIGLAS

ABI	–	Advanced Baseline Imager
Adam	–	Adaptive Moment Estimation
APA	–	Área de Proteção Ambiental
AVHRR	–	Advanced Very High Resolution Radiometer
BATC	–	Ball Aerospace and Technologies Corporation
CENSIPAM	–	Centro Gestor e Operacional do Sistema de Proteção da Amazônia
CNN	–	Convolutional Neural Network
DT	–	Decision Trees
EQM	–	Erro Quadrático Médio
ESA	–	European Space Agency
ETM+	–	Enhanced Thematic Mapper Plus
FCN	–	Full Connected Neural
FSDN	–	Fire Smoke Detection Network
GSFC	–	Goddard Space Flight Center
ICMBio	–	Instituto Chico Mendes de Conservação da Biodiversidade
IoU	–	Intersection over Union
KNN	–	k-nearest neighbors
LST	–	Land Surface Temperature
MLP	–	Multi-Layer Perceptron
MLT	–	Mean Local Time
MODIS	–	Moderate Resolution Imaging Spectroradiometer
MSI	–	MultiSpectral Instrument
NASA	–	National Aeronautics and Space Administration
NB	–	Naive Bayes
NDMI	–	Normalized Difference Moisture Index
NDVI	–	Normalized Difference Vegetation Index
NDWI	–	Normalized Difference Water Index
OLI	–	Operational Land Imager
PARNA	–	Parque Nacional
PCA	–	Principal Component Analysis
PDI	–	Processamento Digital de Imagens
RAM	–	Random Access Memory
ReLU	–	Rectified Linear Unit
RF	–	Random Forest
RGB	–	Red, Green, Blue
RNA	–	Redes Neurais Artificiais
SGD	–	Stochastic Gradient Descent
SIG	–	Sistema de Informação Geográfica
SNNS	–	Stuttgart Neural Network Simulator
Suomi NPP	–	Suomi National Polar-orbiting Partnership
SVN	–	Support Vector Machine
SWIR	–	Short-Wave Infrared

- TIFF – Tag Image File Format
- TIRS – Thermal Infrared Sensor
- TRMM – Tropical Rainfall Measuring Mission
- UCs – Unidades de Conservação
- USGS – United States Geological Survey
- VIIRS – Visible Infrared Imaging Radiometer Suite
- VIRS – Visible and Infrared Scanner
- WRS-2 – World Reference System 2

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Contextualização	3
1.2 Objetivos	4
1.2.1 Objetivos específicos	5
2 FUNDAMENTAÇÃO TEÓRICA	7
2.1 Sensoriamento remoto aplicado ao estudo de queimadas	7
2.2 Características dos satélites	9
2.2.1 Satélite Sentinel-2	9
2.2.2 Satélite Landsat-8	11
2.3 Arquitetura de Redes Neurais Artificiais	13
2.3.1 Função de ativação	16
2.3.1.1 Linear	17
2.3.1.2 Tangente hiperbólica	17
2.3.1.3 Sigmoid	17
2.3.1.4 Softmax	17
2.3.1.5 ReLU	18
2.4 Funções de perda	19
2.4.1 Entropia cruzada	19
2.4.2 Dice loss	20
2.4.3 Erro quadrático médio	21
2.5 Otimizadores	22
2.5.1 Gradiente descendente	22
2.5.2 SGD com Momentum	23
2.5.3 Adagrad	23
2.5.4 RMSprop	24
2.5.5 Adam	25
2.6 Redes Neurais Convolucionais (CNN)	26
2.6.1 U-Net	30
2.7 Queimadas e incêndios	34
2.7.1 Risco e perigo de incêndios	36
2.7.2 Fatores influenciadores	37

2.7.2.1	Aspectos climáticos	37
2.7.2.2	Aspectos antrópicos	38
2.7.2.3	Fatores topográficos	38
2.7.2.4	Características da vegetação	39
2.8	Detecção de incêndio em imagens de sensoriamento remoto	39
3	REVISÃO BIBLIOGRÁFICA	43
3.1	Detecção de fogo ativo em imagens de satélites	43
3.2	Detecção de focos de incêndios	44
3.3	Utilização da rede <i>U-Net</i>	47
3.4	Comparação dos sensores OLI/Landsat-8 e MSI/Sentinel-2	49
3.5	Considerações finais	51
4	TRABALHO EXPERIMENTAL	53
4.1	Área de estudo	53
4.2	Conjunto de dados	56
4.2.1	Obtenção dos dados	56
4.2.2	Conjunto de dados: imagens da América do Sul	57
4.2.3	Conjunto de dados: área de estudo	59
4.2.4	Descrição da rede implementada	59
4.2.5	Tratamento e pré-processamento dos dados	61
4.2.6	Treinamento da <i>U-Net</i>	61
4.2.7	Experiências para afinar a rede	63
4.2.7.1	Tamanho do lote	64
4.2.7.2	Optimizador e taxa de aprendizagem	64
4.2.8	Métricas de avaliação	67
5	RESULTADOS E DISCUSSÃO	69
6	CONCLUSÃO	75
7	TRABALHOS FUTUROS	77
	REFERÊNCIAS BIBLIOGRÁFICAS	79

1 INTRODUÇÃO

A ocorrência de incêndios florestais e queimadas tem um impacto significativo na exposição de ambientes naturais à subsequente influência climática e ações humanas. Esses eventos resultam na diminuição da biomassa florestal, levando à redução dos estoques de carbono, como destacado por [Sato \(2016\)](#). Incêndios frequentemente são empregados como uma técnica para limpar áreas após a extração de árvores, preparando o terreno para a criação de pastagens e atividades agrícolas, conforme mencionado por [Silva et al. \(2021\)](#).

Durante o processo de combustão da matéria orgânica, ocorre a liberação do dióxido de carbono (CO_2), que é o principal gás de efeito estufa, representando aproximadamente 90% dos gases liberados, conforme discutido por [Lashof \(1991\)](#). Portanto, a queima de biomassa não afeta apenas localmente a cobertura florestal, mas também desempenha um papel importante no ciclo global do carbono, influenciando as mudanças climáticas e a composição atmosférica, como abordado por [Padilla et al. \(2017\)](#).

Os estudos relacionados ao fogo, empregando sensoriamento remoto, podem ser subdivididos em duas abordagens distintas. A primeira envolve a identificação de focos ativos de incêndios, enquanto a segunda se concentra no mapeamento das áreas afetadas após a ocorrência do fogo, reveladas pela deposição de cinzas e carvão, bem como pela modificação da estrutura e biomassa da vegetação.

A identificação de focos ativos de incêndio fornece informações essenciais sobre a localização precisa e o momento exato da ocorrência do fogo. No entanto, essa abordagem não quantifica a extensão das áreas impactadas pelos incêndios detectados, uma vez que se concentra na captação da energia emitida pelo fogo em atividade, antes de considerar a área geral de influência do incêndio, como observado por [Roy et al. \(2022\)](#), [Giglio et al. \(2009\)](#).

Em contraste, a abordagem de mapeamento pós-fogo proporciona a capacidade de delinear o perímetro do incêndio, calcular a área afetada e estimar os danos causados por incêndios florestais, representando uma ferramenta valiosa para avaliar os impactos desses eventos, como discutido por [Giglio et al. \(2006\)](#).

O sensoriamento remoto fornece uma fonte global de dados que é amplamente empregada para o monitoramento de inúmeros incêndios em diversas regiões, como evidenciado por estudos anteriores [Dwyer et al. \(2000\)](#), [Giglio et al. \(2006\)](#), [Ichoku](#)

et al. (2008). A detecção automatizada de incêndios em imagens de sensoriamento remoto representa uma área de pesquisa essencial que contribui significativamente para a extração de informações, destinadas a apoiar processos decisórios informados, conforme enfatizado por Cardil et al. (2019).

A observação contínua da Terra por meio de uma série de sensores embarcados em satélites representa uma abordagem altamente eficaz para monitorar e caracterizar as mudanças na superfície terrestre ao longo do tempo. Os índices de vegetação, derivados de dados obtidos por satélites, desempenham um papel essencial na avaliação das variações no estado fisiológico e nas propriedades biofísicas da vegetação, conforme amplamente demonstrado em estudos anteriores (SHE et al., 2015).

No entanto, é importante ressaltar que, devido às distintas características dos sensores utilizados, podem ocorrer disparidades entre os índices espectrais derivados de múltiplos sensores, mesmo quando aplicados ao mesmo alvo. Essas diferenças são objeto de investigação e análise em pesquisas como as conduzidas por Gallo et al. (2005), She et al. (2015).

No âmbito da evolução dos sensores de sensoriamento remoto, o satélite Sentinel-2, lançado em 2015, se destaca como um exemplo significativo. O Sentinel-2 é mantido pela ESA, (*European Space Agency*), e está equipado com um sensor multiespectral conhecido como o MSI (*MultiSpectral Instrument*). O MSI possui características distintivas que o tornam uma ferramenta relevante para pesquisas em sensoriamento remoto.

Em primeiro lugar, destaca-se a amplitude da área capturada pelo MSI, abrangendo uma faixa territorial de 290 quilômetros. Ademais, é digno de nota o desempenho do satélite em termos de resolução temporal, permitindo a aquisição de dados a cada cinco dias com a presença de dois satélites em órbita, o que contribui para uma cobertura mais consistente e frequente (INACIO, 2022).

A resolução espacial do MSI também é digna de menção, uma vez que oferece múltiplos níveis de detalhamento: resolução espacial alta e média (10, 20 e 60 m). Essa capacidade de resolução espacial variável possibilita a obtenção de imagens que atendem a diversas necessidades de pesquisa e aplicação, conforme descrito em Miranda (2019).

Outro ponto relevante é a extensa gama espectral coberta pelo MSI, com treze bandas espectrais que abrangem comprimentos de onda que variam de 0,4 a 2,2

micrômetros por [Inacio \(2022\)](#). Essa riqueza espectral oferece oportunidades para a análise de uma ampla variedade de fenômenos e características da superfície terrestre.

Esta evolução tecnológica representa um avanço no campo do sensoriamento remoto e desempenha um papel fundamental na pesquisa e na aplicação de inteligência artificial em áreas como agricultura de precisão, monitoramento ambiental e muito mais ([SOTHE et al., 2017](#)).

Já o satélite Landsat-8, cujo lançamento ocorreu em 2013, representou avanços na capacidade de imagens da série Landsat. Esta missão trouxe melhorias substanciais, onde podemos citar a introdução de novas faixas espectrais nos domínios do infravermelho, azul e infravermelho de onda curta SWIR (*Short-Wave Infrared*), bem como aprimoramentos na relação sinal/ruído do sensor e na resolução radiométrica das imagens ([ZHU; WOODCOCK, 2014](#)).

O sensor conhecido como OLI (*Operational Land Imager*), desempenha um papel fundamental, oferecendo imagens ópticas com resolução espacial de 30 metros ([SOTHE et al., 2017](#)). Além disso, apresenta uma faixa de captura que abrange uma extensão de 185 quilômetros. As capacidades espectrais em um total de oito bandas espectrais disponíveis. O período de revisita da órbita do satélite é de dezesseis dias, o que contribui para uma coleta de dados regular e frequente.

Segundo [Li et al. \(2017\)](#), a combinação dos sensores MSI e OLI representa uma valiosa fonte de observações multiespectrais com cobertura global, que está acessível gratuitamente e de forma aberta. No entanto, um dos principais desafios ao utilizar dados de sensoriamento remoto de múltiplas fontes é a necessidade de realizar a inter calibração entre diferentes instrumentos.

Além disso, conforme argumentado por [Schroeder et al. \(2016\)](#), a utilização dos satélites Landsat-8 e Sentinel-2 proporciona uma maior precisão no monitoramento de incêndios, uma vez que a maioria dos outros satélites normalmente empregados para essa finalidade apresentam resolução espacial da ordem de 1 km por *pixel*.

1.1 Contextualização

A série de satélites Landsat tem fornecido imagens contínuas da Terra desde 1972, estabelecendo-se como uma referência no campo de sensoriamento remoto e servindo de base para o desenvolvimento de métodos e aplicações ao longo das décadas. Nos últimos anos, novos satélites foram desenvolvidos e lançados, incluindo a série

Sentinel, com destaque para o Sentinel-2, composta por dois satélites, o Sentinel-2A e o Sentinel-2B, lançados em 2015 e 2017, respectivamente.

Muitos dos métodos amplamente utilizados em sensoriamento remoto, originalmente desenvolvidos para o Landsat, têm o potencial de serem aplicados ao Sentinel-2. No entanto, a detecção de incêndios, um campo específico desse domínio, frequentemente requer métodos adaptados a cada satélite, devido às diferenças nas bandas espectrais e nos limiares de detecção específicos de cada sensor.

No contexto da detecção de incêndios, o desenvolvimento de algoritmos para imagens do Sentinel-2 ainda está em estágios iniciais se comparado ao Landsat. Este cenário destaca a necessidade de abordagens inovadoras.

Um desses avanços é o desenvolvimento de redes neurais, que teve início no final dos anos 80, mas ganhou destaque recentemente graças a avanços tecnológicos. Em 2012, a rede neural AlexNet foi proposta, marcando o início do movimento das CNNs (*Convolutional Neural Network*) (KRIZHEVSKY et al., 2017), capazes de processar grandes volumes de imagens. Desde então, diversas arquiteturas de CNNs, como *U-Net*, VGG16 descrito em Mascarenhas e Agarwal (2021) e GoogleNet (PHAM, 2021), foram desenvolvidas, cada uma com seu próprio propósito em segmentação e classificação de imagens, diferindo em termos de estrutura, número de camadas e filtros.

A arquitetura *U-Net*, introduzida por Ronneberger et al. (2015), provou ser eficaz e eficiente em tarefas de segmentação de imagens, ganhando ampla adoção globalmente. Essa arquitetura é capaz de treinar com eficiência grandes conjuntos de dados, usando um processo de contração para prever *pixels* com alta probabilidade de classificação desejada. Além disso, a *U-Net* também pode ser empregada em cenários com conjuntos de treinamento limitados, tornando-se uma ferramenta versátil para diversas aplicações de segmentação semântica.

Nesse contexto, a identificação de métricas adequadas torna-se fundamental para auxiliar na tomada de decisões ao trabalhar com imagens de satélite.

1.2 Objetivos

Objetivo Geral: O objetivo deste estudo é desenvolver metodologia de identificação de focos ativos de incêndio em imagens obtidas pelos satélites Sentinel-2 e Landsat-8, com o propósito de contribuir o planejamento das equipes de combate a incêndios, proporcionando uma ferramenta de identificação e monitoramento desses eventos.

Para alcançar esse objetivo, será implementada uma rede neural *U-Net* genérica, que poderá ser validada com imagens adquiridas pelo satélite Sentinel-2 e usada para fazer inferências em imagens do satélite Landsat-8. Esse sistema permitirá a identificação de incêndios ativos em ambos os satélites.

1.2.1 Objetivos específicos

Para alcançar o objetivo geral deste trabalho, alguns objetivos específicos deverão ser atingidos:

- a) Elaborar um banco de dados destinado à avaliação de focos de incêndio através de uma variedade de sensores.
- b) Delimitar a extensão da frente do incêndio com o propósito de notificar as equipes de combate ao fogo e possibilitar a preparação para a ação.
- c) Determinar o ponto central do incêndio, visando otimizar a prontidão e a chegada das equipes ao local do fogo.

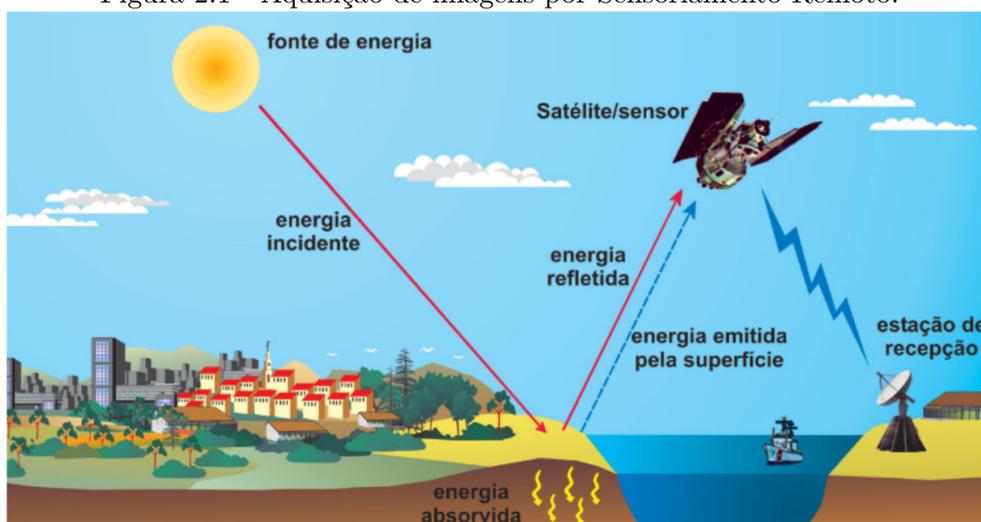
2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, a base teórica está estruturada de maneira abrangente para compreensão dos principais elementos. Na Seção 2.1, exploramos a aplicação do sensoriamento remoto no estudo de queimadas; a Seção 2.2 analisa as características dos satélites empregados nesta pesquisa. Aprofundando-se, a Seção 2.3 investiga a arquitetura das Redes Neurais Artificiais, enquanto a Seção 2.4 detalha as funções de perda. A seguir, a Seção 2.5 examina os otimizadores, seguida pela Seção 2.6 que aborda as Redes Neurais Convolucionais, com destaque para a U-NET. Na Seção 2.7, apresentamos as características específicas de queimada e incêndio. Concluindo, a Seção 2.8 se dedica à discussão sobre a detecção de incêndios em imagens de sensoriamento remoto.

2.1 Sensoriamento remoto aplicado ao estudo de queimadas

O sensoriamento remoto, de acordo com Florenno (2007), é uma poderosa técnica que se baseia na aquisição de imagens através de equipamentos capazes de captar a reflexão das radiações eletromagnéticas emitidas por alvos na superfície terrestre. Essa abordagem permite a obtenção de informações detalhadas sobre uma determinada área, objeto ou fenômeno sem a necessidade de contato físico entre o pesquisador, o sensor e a área de estudo, conforme ilustrado na Figura 2.1.

Figura 2.1 - Aquisição de imagens por Sensoriamento Remoto.



Fonte: Florenno (2007).

O campo do sensoriamento remoto abrange diversas técnicas, incluindo fotografias aéreas, imagens de radar e dados de satélite. Conforme apontado por Slater (1980), os sistemas sensores capazes de capturar e registrar a radiância refletida ou emitida por objetos na superfície terrestre e na atmosfera têm desempenhado um papel fundamental em estudos de diagnóstico e planejamento do uso de recursos naturais.

Uma das técnicas frequentemente empregadas por essa ferramenta em diagnósticos e planejamento de recursos naturais é a análise multitemporal. Conforme descrito por Novo (2010), a análise multitemporal envolve a manipulação de imagens da mesma área em diferentes datas, permitindo a identificação de mudanças ao longo do tempo.

Dessa forma, as séries temporais de dados de sensoriamento remoto representam ferramentas valiosas para identificar e caracterizar as dinâmicas dos ecossistemas terrestres em uma escala temporal, como ressaltado por Zhang et al. (2013). Essas séries temporais auxiliam na detecção e monitoramento de uma variedade de alterações na superfície terrestre ao longo do tempo, incluindo o acompanhamento de incêndios em uma área ao longo de vários anos.

Santos et al. (2011a) destacam a crescente importância das geotecnologias como um recurso valioso para subsidiar a identificação de incêndios florestais, permitindo a localização, quantificação e a realização de análises espaço-temporais das áreas afetadas. A detecção de áreas queimadas por meio do Sensoriamento Remoto depende da captação de fontes de radiação, como a emissão resultante da queima, a reflexão das áreas incendiadas e a reflexão do solo exposto. Uma das abordagens mais comuns para identificar áreas queimadas envolve a observação das mudanças na superfície entre as áreas com vegetação e as áreas de solo exposto (FRANÇA; FERREIRA, 2005).

A obtenção de informações detalhadas, monitoradas e atualizadas sobre a extensão e a localização de áreas queimadas é de extrema importância, uma vez que permite a avaliação e quantificação dos impactos ecológicos, o monitoramento das mudanças na cobertura do solo e a condução de estudos de impacto ambiental decorrentes dos incêndios florestais. O Sensoriamento Remoto se revela como uma ferramenta valiosa para a obtenção dessas informações, especialmente em áreas extensas afetadas pelo fogo ou regiões de difícil acesso (PEREIRA et al., 1997). Pinheiro e Borges (2014) corroboram que o Sensoriamento Remoto, quando combinado com o geoprocessamento, são ferramentas essenciais para a rápida detecção de mudanças ambientais.

Conforme argumentado por [Batista \(2004\)](#), o uso do Sensoriamento Remoto como uma ferramenta para a detecção de focos de calor é amplamente justificado, especialmente em países de grande extensão territorial, como o Brasil. O monitoramento de incêndios em escala nacional e regional por meio de imagens de satélite representa um método eficiente e de custo acessível em comparação com outras abordagens de detecção.

[Silva et al. \(2013\)](#) chegaram à conclusão de que o uso de imagens de satélite em conjunto com técnicas de Sensoriamento Remoto para o estudo de incêndios florestais é, de fato, um método eficaz, direto e viável. Esse método demonstrou sua capacidade de fornecer informações sobre a localização precisa das áreas afetadas e permitir a quantificação desses eventos. De acordo com [Corrêa e Alencar \(2013\)](#), o monitoramento de incêndios por meio de imagens de satélite é imprescindível, especialmente em regiões onde a supervisão intensiva é limitada, uma condição que caracteriza a situação no país.

Como evidenciado, o Sensoriamento Remoto se estabelece como uma ferramenta relevante para a identificação de incêndios florestais, sobretudo em áreas de difícil acesso e monitoramento. Essa abordagem permite a análise de informações georreferenciadas, tornando possível a quantificação e a localização de focos de calor em todo o território nacional.

2.2 Características dos satélites

2.2.1 Satélite Sentinel-2

A ESA tem desenvolvido uma série de satélites conhecidos como Sentinel, ilustrado na Figura 2.2, que demonstraram grande capacidade na coleta de informações físicas, biológica e biofísica na superfície terrestre ([MALENOVSKÝ et al., 2012](#)). Os dados do Sentinel-2 representam produtos de grande importância e promissores no campo do Sensoriamento Remoto ([WANG et al., 2016](#)). A disponibilidade de imagens de satélite gratuitas e o acesso a aplicativos de processamento de imagens de código aberto fornecidos pela ESA têm facilitado a condução de estudos em diversas áreas do Sensoriamento Remoto.

O satélite Sentinel-2 opera em uma órbita quase polar e é equipado com um sensor MSI, que conta com uma largura de 290 km e tem uma dimensão de 100 por 100 km, 12 bits por *pixel*, e é capaz de recolher informação de 13 bandas espectrais que variam entre o visível, o infravermelho próximo e o infravermelho de ondas curtas.

Figura 2.2 - Satélite de sensoriamento remoto da ESA - Sentinel-2.



Fonte: ESA (2014).

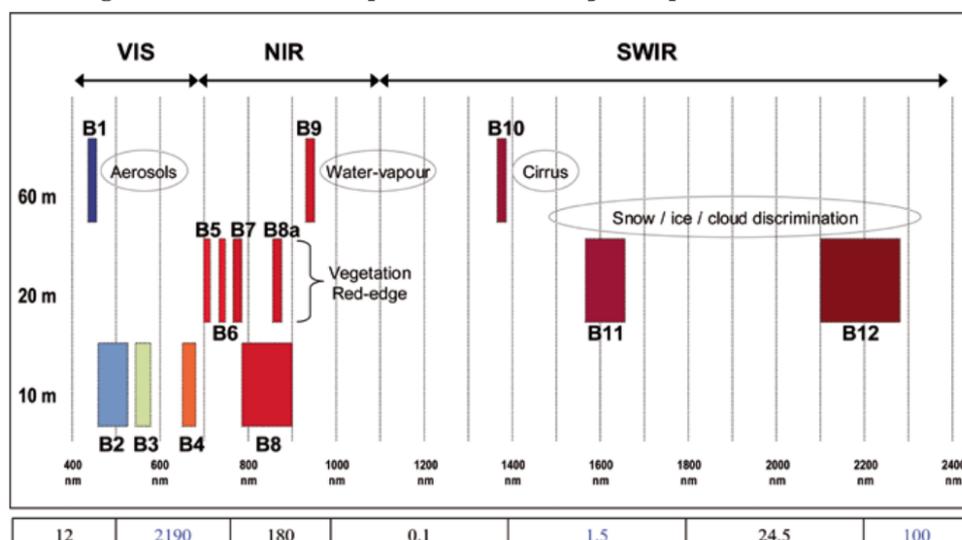
A resolução espacial do Sentinel-2 varia de 10 a 60 metros, sendo que quatro das bandas possuem uma resolução de 10 metros, seis têm resolução de 20 metros e três têm resolução de 60 metros, obedecendo a uma faixa espectral como se observa na Tabela 2.1 e Figura 2.3. A frequência de revisitação do satélite é de 10 dias com um único satélite e de 5 dias quando ambos os satélites operacionais estão em funcionamento (AGENCY, 2015).

Tabela 2.1 - Resolução Espectral das Bandas do Sentinel-2.

Resolução espacial (m)	Nome da Banda	Número da Banda	S2A		S2B	
			Comprimento de onda central (nm)	Largura de banda (nm)	Comprimento de onda central (nm)	Largura de banda (nm)
10	Blue	B02	492,4	66	492,1	66
	Green	B03	559,8	36	559	36
	Red	B04	664,6	31	664,9	31
	NIR	B08	832,8	106	832,9	106
20	Red Edge 1	B05	704,1	15	703,8	16
	Red Edge 2	B06	740,5	15	739,1	15
	Red Edge 3	B07	782,8	20	779,7	20
	Red Edge 4	B08A	864,7	21	864	22
	SWIR 1	B11	1613,7	91	1610,4	94
	SWIR 2	B12	2202,4	175	2185,7	185
60	Aerossol	B01	442,7	21	442,2	21
	Water Vapor	B09	945,1	20	943,2	21
	Cirrus	B10	1373,5	31	1276,9	30

Fonte: Bezerra et al. (2018).

Figura 2.3 - Bandas Espectrais e Resolução Espacial do Sentinel-2.



Fonte: Marin (2015).

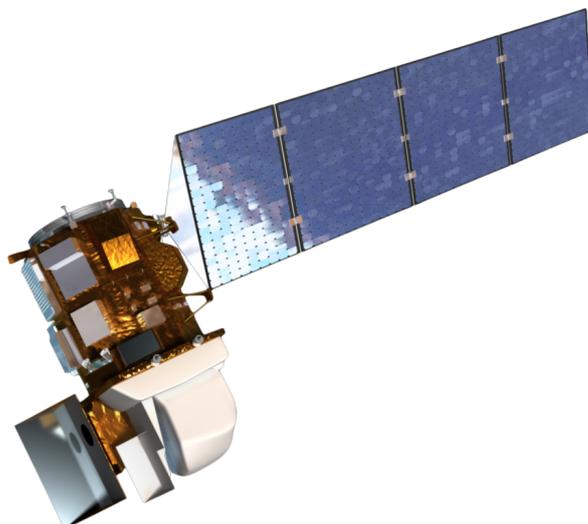
2.2.2 Satélite Landsat-8

Desde o início dos anos 1970, os satélites da série Landsat têm desempenhado um papel fundamental ao fornecer imagens multiespectrais contínuas da Terra. Esse registro retrospectivo da superfície do nosso planeta tem sido essencial para aprofundar nossa compreensão do impacto das atividades humanas no meio ambiente. Os dados Landsat têm encontrado aplicações em diversas áreas, incluindo gestão de recursos terrestres e aquáticos, exploração de recursos naturais como petróleo e minerais, previsão da produtividade agrícola, monitoramento da qualidade do ar e da água, detecção de mudanças climáticas e produção de mapas cartográficos conforme (MUELLER, 2019).

Em 11 de fevereiro de 2013, a NASA (*National Aeronautics and Space Administration*) lançou o Landsat-8. Esse satélite é equipado com dois sensores essenciais: o TIRS e o OLI. Ambos fornecem dados de alta resolução espacial da superfície terrestre, uma contribuição que já dura mais de 40 anos e atende a diversas necessidades de pesquisa e aplicação. O desenvolvimento desses sensores foi liderado pelo GSFC (*Goddard Space Flight Center*) para o TIRS (*Thermal Infrared Sensor*) e, no caso do OLI, pela BATC (*Ball Aerospace and Technologies Corporation*), conforme ilustrado na Figura 2.4.

O Landsat-8 realiza revisitações a um mesmo ponto na Terra a cada 16 dias, operando em órbita quase circular e quase polar, mantendo uma altitude constante de

Figura 2.4 - Satélite de sensoriamento remoto da USGS - Landsat-8.



Fonte: NASA (2013).

705 km em relação à linha do Equador. Sua passagem sobre a linha do Equador ocorre por volta das 10:11 da manhã, com uma variação mínima de aproximadamente 15 minutos. Além disso, as imagens do Landsat-8 apresentam resolução espacial moderada, variando de 15 a 100 metros por pixel, e operam em múltiplos espectros, incluindo visível, infravermelho próximo, infravermelho de onda curta e infravermelho térmico. E tem a capacidade de capturar mais de 700 cenas por dia (MUELLER, 2019).

Para adquirir essas imagens, o Landsat-8 é equipado com dois sensores a bordo: o OLI e o TIRS. A Tabela 2.2 apresenta informações detalhadas sobre cada banda, seus comprimentos de onda correspondentes e resoluções espaciais, bem como a especificação dos sensores responsáveis pela aquisição (MIRANDA, 2019).

Oferece revisita ao mesmo ponto da Terra em até 16 dias (resolução temporal). O Landsat-8 opera em uma órbita quase circular, quase polar e sincronizada com o Sol, com uma altitude de 705 km da linha do Equador. Conta com uma travessia equatorial às 10:11 da manhã (+-15 min) na hora local média MLT durante o nó descendente. Nesta órbita, o Landsat-8 segue uma sequência de trilhas, fixas no solo definidas pelo WRS-2 descritas em (MUELLER, 2019).

Fornecendo imagens de resolução espacial moderada, de 15 a 100 metros por *pixel*, o Landsat-8 opera nos espectros do visível, infravermelho próximo, infravermelho de onda curta e infravermelho térmico, capturando mais de 700 cenas por dia. A

Tabela 2.2 traz as informações de cada banda, comprimentos de onda e resolução espacial, assim como os sensores responsáveis pela aquisição.

Tabela 2.2 - Resolução espectral das bandas dos dados do satélite Landsat-8.

Sensor	Bandas Espectrais	Resolução Espectral (nm)	Resolução Espacial (m)	Resolução Temporal	Área Imageada	Resolução Radiométrica
OLI (Operational Lander Imager)	(B1) Azul Costeiro	0.43 - 0.45	30	16 dias	170 x 183 km	16 dias
	(B2) Azul	0.45 - 0.51				
	(B3) Verde	0.53 - 0.59				
	(B4) Vermelho	0.64 - 0.67				
	(B5) Infra Vermelho Próximo	0.85 - 0.88				
	(B6) Infra Vermelho Médio	1.57 - 1.65				
	(B7) Infra Vermelho Médio	2.11 - 2.29				
	(B8) Pancromática	0.50 - 0.68				
	(B9) Cirrus	1.36 - 1.38				
TIRS (Termal Infrared Sensor)	(B10) Infra Vermelho Termal	10.6 - 11.19	100			
	(B11) Infra Vermelho Termal	11.5 - 12.51				

Fonte: USGS (2013).

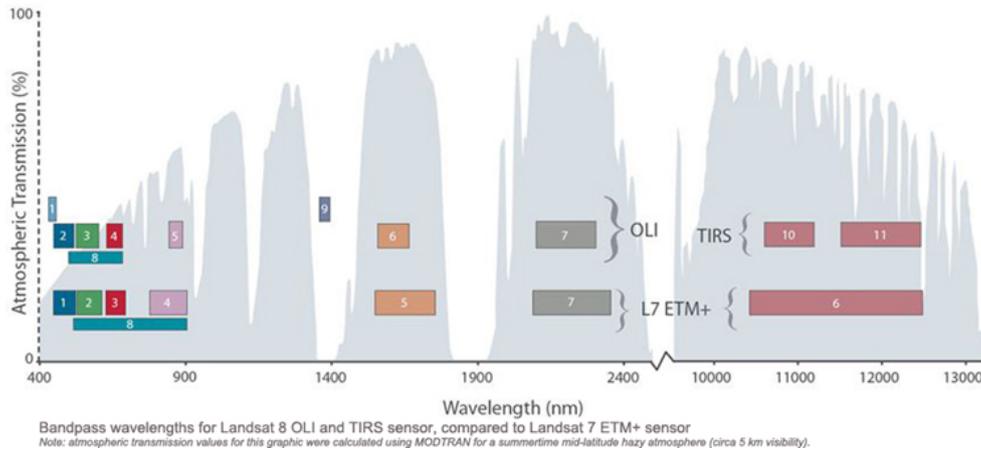
Em comparação com os satélites Landsat anteriores, o Landsat-8 incorpora dois novos sensores, conforme ilustrado na Figura 2.5. O sensor OLI guarda semelhanças com o sensor ETM+ (*Enhanced Thematic Mapper Plus*) do Landsat-7, mas se diferencia ao apresentar duas novas bandas espectrais: a banda 1, destinada à detecção de *coastal aerosol*, e a banda 9, projetada para identificação de cirrus. Em contraste, o sensor TIRS introduz uma banda infravermelha térmica de alta resolução, com aproximadamente 30 metros de detalhamento, em comparação com a geração anterior de satélites Landsat, que oferecia cerca de 60 metros de resolução espacial nesse espectro (MIRANDA, 2019).

O sensor OLI abriga um total de 9 bandas espectrais de infravermelho próximo, varrendo uma faixa de 190 km, com uma resolução espacial de 30 metros para todas as bandas, com exceção da banda 8, conhecida como pancromática, que proporciona uma resolução espacial mais fina de 15 metros.

2.3 Arquitetura de Redes Neurais Artificiais

Uma das principais complexidades na aplicação de redes neurais reside em selecionar a arquitetura mais adequada, dado que esse procedimento é essencialmente experimental e consome considerável tempo de execução. Na prática, é necessário submeter o processo a uma abordagem que busque testar variados métodos de aprendizado e

Figura 2.5 - Comprimento de onda entre os sensores Landsat 7 e 8.



Fonte: Sadeck Geotecnologias (2016).

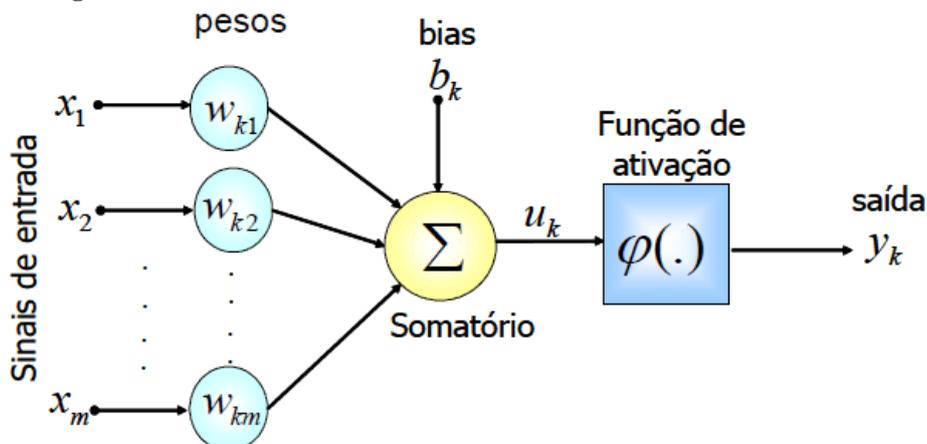
as distintas configurações que uma rede pode assumir para a resolução eficaz de um problema específico (MIRANDA et al., 2009). De maneira geral, é possível categorizar as arquiteturas de redes em três classes distintas: redes de camada única, redes de múltiplas camadas e redes recorrentes.

As Redes Neurais Artificiais (RNAs) representam algoritmos computacionais que incorporam um modelo matemático inspirado na estrutura de organismos inteligentes, permitindo assim a simplificação da operação cerebral em sistemas computacionais. Semelhantemente ao funcionamento do cérebro humano, conforme ilustrado na Figura 2.6, as RNAs possuem a capacidade de aprendizado e tomada de decisões com base nas experiências adquiridas. Essa abordagem de processamento constitui um esquema que viabiliza o armazenamento de conhecimento mediante aprendizagem, tornando possível a aplicação desse conhecimento nas tarefas específicas a que se destina (SPÖRL et al., 2011).

Conforme descrito por Haykin (2001), a analogia entre a rede neural e o cérebro humano pode ser identificada por dois aspectos fundamentais: a) o conhecimento é obtido pela rede a partir de seu ambiente, mediante o processo de aprendizagem; b) as forças de conexão entre neurônios, representadas pelos pesos sinápticos, são empregadas para armazenar o conhecimento adquirido.

As redes neurais são constituídas por uma quantidade específica de entradas e unidades de processamento, conectadas por meio de pesos sinápticos. A propagação das entradas ocorre ao longo da topologia da RNA, sendo modificadas pelos pesos sinápticos e pela função de ativação (AF) dos neurônios, conforme destacado por

Figura 2.6 - Modelo de Neurônio Artificial de McCulloch e Pitts.



Fonte: Fernandes et al. (1999).

Machado e Fonseca Júnior (2013). Recebendo n neurônios como entrada em (y_i) , o neurônio k calcula a sua saída através de:

$$y_k = AF \left(\sum_{i=1}^n (y_i W_{ki} + b_k) \right) \quad (2.1)$$

Onde: y_i representa a saída calculada pelo neurônio i , W_{ki} é o peso sináptico entre o neurônio i e o neurônio k , e b_k é o peso associado a um valor constante e não nulo para o neurônio k , conhecido como bias. Quando o neurônio está conectado às entradas, o termo y_i é substituído pela entrada correspondente (MACHADO; Fonseca Júnior, 2013).

Observa-se a necessidade de determinar os pesos sinápticos e o bias para a utilização efetiva de uma RNA. O processo de estimação desses parâmetros, denominado treinamento, é caracterizado por uma iteração contínua na qual os parâmetros iniciais são sucessivamente atualizados até alcançar a convergência. Considerando a iteração j , o peso w_{ki} é ajustado da seguinte maneira:

$$w^{(j)}_{ki} = w^{(j-1)}_{ki} + \Delta w^{(j)} \quad (2.2)$$

com $\Delta w^{(j)}$ sendo o vetor de correção ao parâmetro w_{ki} na iteração j .

Devido às características não-lineares presentes no mapeamento entre camadas de

RNAs *feedforward*, essas redes se destacam como ferramentas adequadas para o controle e modelagem de sistemas. As abordagens matemáticas convencionais para o controle de sistemas não-lineares recorrem a técnicas de linearização, transformando a tarefa de controle não-linear em tarefas menores de controle linear. Embora essa abordagem seja eficaz, ela nem sempre reflete com precisão a realidade dos sistemas físicos, podendo resultar em soluções subótimas. Devido à sua capacidade de modelar ações não lineares, as RNAs surgem como uma ferramenta para o controle de sistemas (BRAGA et al., 2000).

Conforme abordado por Braga et al. (2000), um modelo básico de RNA contém elementos distintos que constituem a base do modelo, os quais desempenham papéis específicos na estrutura e operação dessa rede. Entre esses componentes, destacam-se as sinapses, responsáveis por representar as conexões entre os neurônios da RNA, cada uma com um peso sináptico atribuído. O integrador, por sua vez, realiza a soma ponderada dos sinais de entrada, levando em consideração os pesos sinápticos associados. Adicionalmente, a função de ativação atua limitando a amplitude do valor de saída de um neurônio, enquanto o bias é um valor externamente aplicado a cada neurônio, influenciando a entrada líquida da função de ativação e modulando seu efeito. Esses elementos fundamentais constituem a base do modelo de RNA

Segundo Paoletti et al. (2018) as RNAs têm sido amplamente empregadas na classificação de dados; no entanto, sua aplicação ainda enfrenta desafios, especialmente no que diz respeito ao processamento de volumes elevados de informações. Tal cenário resulta em um aumento no tempo de computação necessário para o aprendizado, além de provocar a saturação dos parâmetros da rede (*overfitting*).

2.3.1 Função de ativação

Funções de ativação, conforme discutido por Tiwari (2020), desempenham um importante papel nas redes neurais ao introduzir não-linearidade nas saídas de suas camadas. Esse processo possibilita que a rede aprenda representações mais complexas, aprimorando, assim, sua capacidade de modelar relações não lineares nos dados. Além disso, as funções de ativação desempenham um papel na estabilização da saída da rede durante o treinamento, impedindo que os valores dos pesos cresçam indefinidamente. Em ausência de uma função de ativação, uma rede neural se reduziria a uma combinação linear de camadas, resultando em limitações significativas na sua capacidade de aprendizado.

2.3.1.1 Linear

A função de ativação linear, conforme abordada por Furtado (2019), é uma função elementar que não introduz não-linearidade na rede neural. Sua representação gráfica assemelha-se a uma simples linha reta, como na equação $y = ax$. Se todas as camadas da rede empregarem essa função de ativação, o resultado global será linear, independentemente do número de camadas. Por esse motivo, a função de ativação linear é usualmente reservada para a camada de saída da rede, onde a saída desejada consiste em uma combinação linear das entradas. Nas camadas intermediárias da rede, torna-se imperativo o uso de funções de ativação não lineares, a fim de capacitar a rede a aprender representações mais complexas e abrangentes dos dados.

2.3.1.2 Tangente hiperbólica

A função tangente hiperbólica, conforme discutido em detalhes por Campos et al. (2017), costuma produzir resultados superiores em comparação à função *sigmoid*. Por essa razão, é frequentemente empregada nas camadas ocultas de redes neurais. Os valores gerados pela função tangente hiperbólica estão contidos no intervalo de -1 a 1, o que desempenha um papel fundamental na centralização dos dados. Esse fator torna a tarefa de aprendizado para as camadas subsequentes mais eficiente, uma vez que a média da camada oculta é mantida próxima de 0.

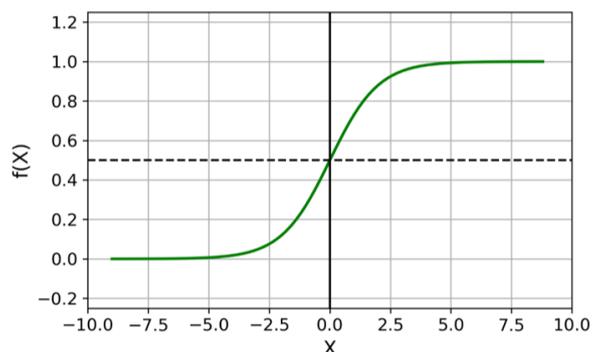
2.3.1.3 Sigmoid

A função *sigmoid*, discutida nesta dissertação referência de Sousa (2022), é uma função de ativação que realiza o mapeamento de valores reais para o intervalo entre 0 e 1. Essa característica torna a função *sigmoid* especialmente útil em contextos de problemas de classificação binária, onde a saída da rede pode ser interpretada como a probabilidade de pertencer à classe positiva. Quando a entrada da função *sigmoid* ultrapassa um determinado limiar, geralmente estabelecido em 0.5, a saída se aproxima de 1, indicando uma forte confiança na pertinência à classe positiva. Por outro lado, quando a entrada é inferior a esse limiar, a saída se aproxima de 0, o que denota uma forte convicção na classe negativa. Nos problemas de classificação binária, a decisão é tomada por meio da comparação entre a saída da função *sigmoid* e o limiar, frequentemente definido em 0.5 Conforme ilustrado na Figura 2.7.

2.3.1.4 Softmax

A função *softmax*, detalhada no estudo de Vargas et al. (2016), compartilha semelhanças com a função *sigmoid*, mas encontra seu principal emprego em problemas de

Figura 2.7 - Função de ativação.



Fonte: Adaptado de Richards (2016).

classificação. Geralmente, é aplicada na camada de saída de um modelo de aprendizado de máquina com o propósito de gerar probabilidades indicativas das classes associadas a cada entrada.

A função *softmax* realiza cálculos exponenciais para cada valor de entrada e, em seguida, normaliza os resultados de tal forma que a soma das probabilidades seja igual a 1. Ela é um instrumento valioso para transformar as saídas do modelo em uma distribuição de probabilidade que reflete a confiança do modelo em relação a cada classe. Nesse contexto, a classe com a maior probabilidade costuma ser selecionada como a classe de predição conforme explicado em Conferência Internacional sobre Inteligência Artificial e Estatística (2011). Matematicamente, a função exponencial é aplicada a cada elemento z_j do vetor de entrada $z \in \mathbb{C} = [z_1, \dots, z_C]$ e normalizada pela soma de todas essas exponenciais:

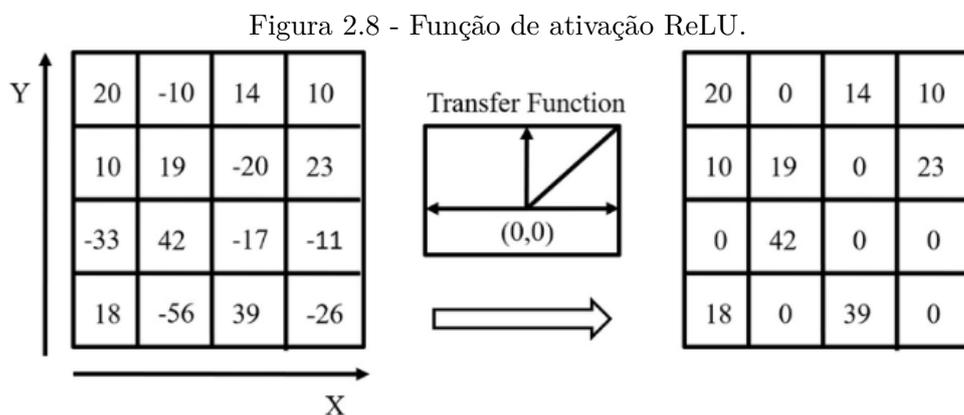
$$\text{softmax}(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (2.3)$$

2.3.1.5 ReLU

A função de ativação *ReLU*, discutida por Bruschi (2022), é uma escolha comum para as camadas ocultas de redes neurais. Esta função destaca-se pela sua eficiência computacional, superando a *sigmoid* e a tangente hiperbólica devido às operações matemáticas mais simples. Além disso, a *ReLU* demonstra melhor desempenho e oferece uma solução para o problema do desaparecimento do gradiente. Esse problema ocorre quando as camadas mais profundas da rede são treinadas a uma velocidade muito lenta, devido à diminuição exponencial do gradiente à medida que se propa-

gam pelas camadas iniciais.

A função *ReLU* retorna 0 para todos os valores negativos e o próprio valor para valores positivos, como visto na Figura 2.8. Embora seja computacionalmente leve, não é centrada em zero. Devido ao resultado ser zero para valores negativos, a *ReLU* tem o efeito de 'desativar' alguns neurônios durante o passo *forward*, acelerando o treinamento, mas potencialmente resultando na inatividade desses neurônios, incapazes de aprender se receberem apenas valores negativos. Adicionalmente, a *ReLU* pode gerar ativações explosivas, uma vez que não possui um limite superior para valores positivos. Com isso, a função *ReLU* é amplamente utilizada no treinamento de redes neurais, embora não seja comumente empregada na camada de saída (GOODFELLOW et al., 2016a).



Fonte: Adaptado de Shi e Zhao (2023).

2.4 Funções de perda

Nos últimos anos, têm sido propostos vários algoritmos para segmentação de imagens que fazem uso de diferentes funções de perda durante o processo de aprendizado.

2.4.1 Entropia cruzada

A Entropia Cruzada, também conhecida como "*cross-entropy*" em inglês, é uma função de perda amplamente empregada em problemas de aprendizado de máquina, principalmente em tarefas de classificação como visto em (MA, 2020). Seu propósito é medir a disparidade entre a distribuição de probabilidade prevista pelo modelo e a distribuição real dos rótulos de treinamento.

A principal finalidade da Entropia Cruzada é quantificar a diferença entre as probabilidades previstas pelo modelo e os rótulos verdadeiros. Quanto maior a discrepância entre essas distribuições de probabilidade, maior será o valor da função de perda. No processo de treinamento do modelo, a Entropia Cruzada é usada como o critério de otimização, no qual o objetivo é minimizar o valor da função de perda.

Uma das vantagens da Entropia Cruzada é sua capacidade de capturar a incerteza associada à tarefa de classificação. Ela penaliza com mais rigor as previsões incorretas que o modelo faz com alta confiança, incentivando, assim, o modelo a se tornar mais preciso em suas previsões. Além disso, a Entropia Cruzada é diferenciável, o que a torna compatível com o uso de algoritmos de otimização baseados em gradiente para aperfeiçoar os parâmetros do modelo.

Em problemas de classificação binária é geralmente expressa como:

$$L(y, \hat{y}) = -(y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})) \quad (2.4)$$

2.4.2 Dice loss

De acordo com [Ma \(2020\)](#) *Dice* é uma função de perda empregada em problemas de segmentação de imagens, nos quais o objetivo consiste em subdividir uma imagem em várias regiões ou classes distintas. O nome "*Dice Loss*" provém de sua formulação, que se baseia no coeficiente *Dice*, uma métrica para avaliar a sobreposição entre duas máscaras de segmentação.

Que utiliza a função:

$$DiceLoss(y, \bar{p}) = 1 - \frac{2y\bar{p} + 1}{y + \bar{p} + 1} \quad (2.5)$$

Essa função de perda, conhecida como Perda *Dice*, é calculada com base na comparação entre a máscara de segmentação prevista pelo modelo e a máscara de segmentação verdadeira obtida a partir dos rótulos de treinamento. A fórmula habitual para calcular a Perda *Dice* é simplesmente 1 menos o coeficiente *Dice*. O coeficiente *Dice*, por sua vez, é calculado como o dobro da interseção entre as duas máscaras, dividido pela soma das áreas das duas máscaras.

A Perda *Dice* apresenta diversas vantagens, sendo uma delas a habilidade de lidar com desequilíbrios entre as classes, algo comum em problemas de segmentação de imagens, em que algumas regiões podem ser significativamente menores ou mais

raras do que outras. Em comparação com outras funções de perda, a Perda *Dice* penaliza os falsos negativos de forma mais suave, o que frequentemente resulta em segmentações aprimoradas em regiões com baixa sobreposição.

Adicionalmente, a Perda *Dice* pode ser combinada com outras funções de perda, como a Entropia Cruzada, para criar funções de perda compostas que consideram diferentes aspectos do problema de segmentação. Ela é amplamente aplicada como critério de otimização durante o treinamento do modelo, com o objetivo de minimizar o valor da Perda *Dice*.

2.4.3 Erro quadrático médio

O EQM, (Erro Quadrático Médio), é uma função de perda amplamente empregada em problemas de aprendizado de máquina, com destaque especial para tarefas de regressão. Essa métrica é calculada como a média dos quadrados das discrepâncias entre as previsões do modelo e os valores reais dos rótulos de treinamento.

A fórmula geralmente usada para calcular o EQM é a seguinte:

$$EQM = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.6)$$

onde y_i é o valor previsto pelo modelo, \hat{y}_i é o valor verdadeiro do rótulo de treinamento e N é o número total de amostras de treinamento.

O EQM é empregado como função de perda durante o processo de treinamento do modelo, com o propósito de ajustar os pesos dos parâmetros do modelo, de modo a minimizar o valor do EQM. Esta métrica é particularmente eficaz em problemas de regressão, nos quais o objetivo é prever valores numéricos contínuos.

Uma das vantagens notáveis do EQM é sua capacidade de penalizar fortemente previsões incorretas, uma vez que o quadrado das diferenças amplifica erros maiores. No entanto, é importante ressaltar que essa métrica pode ser sensível a *outliers*, ou seja, a amostras de treinamento que se encontram significativamente distantes dos demais pontos de dados. Além disso, o EQM pode ser influenciado por desequilíbrios de escala nos dados, o que pode resultar em resultados distorcidos, particularmente em cenários nos quais as variáveis de entrada apresentam escalas substancialmente diferentes.

2.5 Otimizadores

Nos modelos de aprendizagem profunda e automática, uma função de perda é empregada para avaliar o desempenho do modelo em um dado ponto. O processo de aprendizagem é essencialmente um processo de treinamento da rede neural, visando minimizar essa função de perda. A lógica por trás dessa abordagem é que uma redução do erro na função de perda reflete um desempenho aprimorado do modelo. Esse procedimento de minimização (ou maximização) de uma expressão matemática é denominado otimização.

Os otimizadores desempenham um papel fundamental nesse contexto. São algoritmos ou métodos que se encarregam de ajustar os atributos da rede neural, tais como os pesos e a taxa de aprendizagem, com o objetivo de diminuir as perdas e resolver problemas de otimização.

Diversos otimizadores estão disponíveis, incluindo o Gradiente Descendente, o Gradiente Descendente em Lote, o SGD (*Stochastic Gradient Descent*), o SGD com *momentum*, o *RMSprop*, o *Adagrad*, o *Adam* (*Adaptive Moment Estimation*), entre outros. Cada um desses otimizadores possui suas próprias características distintas e é aplicado de acordo com a natureza do problema em questão, bem como as necessidades específicas do modelo de aprendizagem profunda. A escolha apropriada do otimizador pode ter um impacto substancial no desempenho do modelo durante o processo de treinamento.

2.5.1 Gradiente descendente

Segundo Ruder (2016) o Gradiente Descendente é uma técnica empregada na minimização de uma função objetivo $J(\theta)$, que depende dos parâmetros de um modelo $\theta \in R^d$. Essa técnica opera por meio da atualização desses parâmetros na direção contrária ao gradiente da função objetivo, representado como $\nabla_{\theta} J(\theta)$. O valor do hiperparâmetro conhecido como taxa de aprendizagem, denotado como η , desempenha um papel crucial na otimização, pois ele dita o tamanho dos passos tomados durante o processo. Em essência, a taxa de aprendizagem influencia a velocidade com a qual o mínimo local da função é alcançado. Em outras palavras, o Gradiente Descendente segue a direção do declive da superfície modelada pela função objetivo, avançando de cima para baixo até que o valor mínimo seja atingido. É importante mencionar que existem diversas variações do Gradiente Descendente, cada uma com suas próprias características distintas e estratégias específicas para a atualização dos parâmetros.

2.5.2 SGD com Momentum

O SGD pode enfrentar dificuldades em áreas onde a superfície da função objetivo tem curvas acentuadas em uma dimensão e mais suaves em outras, o que é comum em torno de mínimos locais. Nessas situações, o SGD pode oscilar em torno desses mínimos locais e fazer progresso lento ao longo do fundo em direção ao mínimo global.

Uma abordagem para mitigar esse problema é o SGD com *Momentum*, que é um método que acelera o SGD na direção relevante e suaviza as oscilações conforme descrito por (QIAN, 1999). Ele faz isso adicionando uma fração γ do vetor de atualização do passo de tempo anterior ao vetor de atualização atual.

Analogamente, o uso de *momentum* é como empurrar uma bola colina abaixo. A bola acumula velocidade enquanto desce, tornando-se mais rápida ao longo do caminho até atingir sua velocidade terminal. O mesmo acontece com a atualização dos parâmetros: o termo *momentum* aumenta para as dimensões cujos gradientes apontam na mesma direção, reduzindo as atualizações para as dimensões cujos gradientes mudam de direção (SILVA, 2019). Como resultado, a convergência do otimizador é acelerada e as oscilações são reduzidas. O usual é considerar $\gamma = 0.9$. Adotando $g_t = \nabla_{\theta} L(\theta_t | x, y)$, temos a regra de iteração:

$$v_{t+1} = \gamma v_t + \eta g_t \tag{2.7}$$

$$\theta_{t+1} = \theta_t - v_t \tag{2.8}$$

2.5.3 Adagrad

O *Adagrad* é um algoritmo de otimização baseado em gradientes que se adapta automaticamente para ajustar as taxas de aprendizagem dos parâmetros, levando em consideração a frequência das *features*. Especificamente, ele realiza atualizações menores (ou seja, com taxas de aprendizagem baixas) para os parâmetros associados a *features* que ocorrem com frequência e, por outro lado, efetua atualizações maiores (ou seja, com taxas de aprendizagem elevadas) para os parâmetros relacionados a *features* menos frequentes. Isso faz com que o *Adagrad* seja particularmente adequado para lidar com dados dispersos.

Uma das principais vantagens do *Adagrad* é que ele elimina a necessidade de ajustes manuais das taxas de aprendizagem. Geralmente, o valor padrão de 0,01 é suficiente para a taxa de aprendizagem como mencionado em (DUCHI et al., 2011).

No entanto, o *Adagrad* pode enfrentar o desafio da acumulação de gradientes quadráticos no denominador, resultando em uma diminuição contínua da taxa de aprendizagem à medida que o treinamento progride, levando a valores extremamente pequenos. Esse cenário pode fazer com que o algoritmo se torne incapaz de aprender novos padrões.

A equação do Adagrad para atualização de parâmetros é a seguinte:

$$\theta_{t+1,i} = \theta_{t,i} - \frac{\eta}{\sqrt{G_{t,ii} + \epsilon}} \cdot g_{t,i} \quad (2.9)$$

Onde: - $\theta_{t+1,i}$ é o novo valor do parâmetro i no passo de tempo $t + 1$.

- $\theta_{t,i}$ é o valor atual do parâmetro i no passo de tempo t .

- η é a taxa de aprendizagem.

- $G_{t,ii}$ é a soma dos quadrados dos gradientes passados até o passo de tempo t para o parâmetro i .

- $g_{t,i}$ é o gradiente do erro em relação ao parâmetro i no passo de tempo t .

- ϵ é um valor pequeno (geralmente próximo a zero) usado para evitar a divisão por zero.

2.5.4 RMSprop

O *RMSprop* é uma solução proposta por (HINTON et al., 2012) para abordar o desafio da rápida diminuição da taxa de aprendizagem observada no *Adagrad*. A abordagem do *RMSprop* para resolver esse problema envolve a divisão da taxa de aprendizagem pela média exponencialmente decrescente dos gradientes ao quadrado. (HINTON et al., 2012) recomendou o uso de um valor de 0.9 para o hiperparâmetro γ , que controla a taxa de decaimento exponencial, e um valor de 0.001 para a taxa de aprendizagem, com base em sua vasta experiência e em resultados de estudos anteriores na literatura de otimização de gradientes. Como resultado, o *RMSprop* tem conquistado ampla adoção como uma alternativa eficaz ao *Adagrad* em diversas aplicações de aprendizado de máquina (SILVA, 2019).

$$\Delta\theta_{t,i} = -\frac{\eta}{\sqrt{E(g_{t,i}^2) + \epsilon}}g_{t,i} \quad (2.10)$$

$$\theta_{t+1,i} = \theta_{t,i} + \Delta\theta_{t,i} \quad (2.11)$$

Geoff Hinton sugere que sejam usados os valores $\gamma = 0.9$ e $\eta = 0.001$.

2.5.5 Adam

O otimizador Adam é um método de otimização de gradientes que calcula taxas de aprendizagem adaptativas para cada parâmetro conforme visto em (ADAM..., 2015). Além de manter uma média exponencialmente decrescente dos gradientes quadrados anteriores (representada por v_t), este otimizador também mantém uma média exponencialmente decrescente dos gradientes anteriores (representada por m_t), que é uma característica compartilhada com o *SGD com Momentum*. Enquanto o *SGD com Momentum* pode ser comparado a uma bola rolando colina abaixo, o algoritmo *Adam* pode ser visualizado como uma bola com atrito, capaz de encontrar mínimos planos na superfície de erro. As médias exponencialmente decrescentes dos gradientes anteriores m_t e dos gradientes quadrados anteriores v_t são calculadas usando as seguintes fórmulas:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (2.12)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (2.13)$$

Aqui, as estimativas m_t e v_t no algoritmo *Adam* representam o primeiro momento (ou seja, a média) e o segundo momento (ou seja, a variância descentralizada), respectivamente. Inicializadas como vetores de zeros, as estimativas m_t e v_t , de acordo com os criadores do *Adam*, tendem a se aproximar de zero, especialmente nas etapas iniciais e quando as taxas de decaimento são pequenas (ou seja, quando β_1 e β_2 estão próximos de 1). Para corrigir esse viés, são calculadas as estimativas corrigidas pelo bias do primeiro e segundo momento:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (2.14)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (2.15)$$

2.6 Redes Neurais Convolucionais (CNN)

As Redes Neurais Convolucionais compõem uma categoria do aprendizado profundo, focada no reconhecimento de imagens. Diversas arquiteturas de CNN, tais como *VGGNet*, *ResNet*, *LeNet* e *AlexNet*, conforme mencionado em [Kim et al. \(2021\)](#), além das redes *U-Net* e *W-Net* discutidas em [Machkour et al. \(2023\)](#), têm sido alvo de estudo devido à sua eficácia.

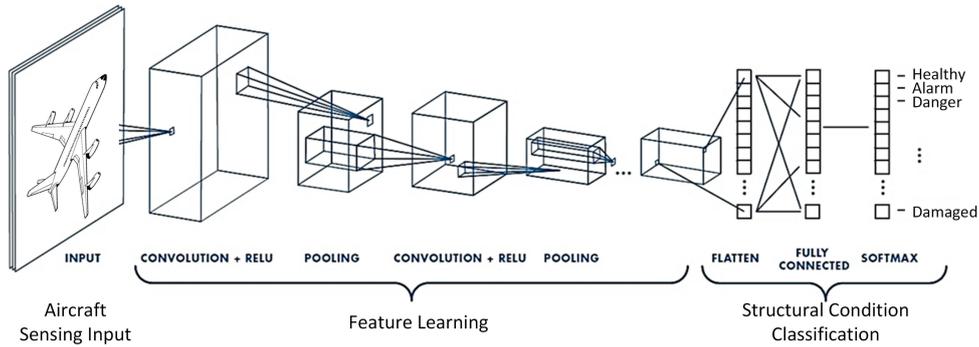
Os avanços nas tecnologias digitais da informação, com destaque para as Unidades Gráficas de Processamento, juntamente com o aumento exponencial na disponibilidade de dados no formato digital, impulsionaram o desenvolvimento das Redes Neurais Artificiais Profundas. Essas redes, desenvolvidas pelo grupo de pesquisa liderado por [\(LECUN et al., 2015\)](#) no final da década de 90, inicialmente para tarefas como o reconhecimento de dígitos em cheques, têm desempenhado um papel fundamental na evolução das técnicas de reconhecimento de padrões. Essa evolução tem sido gradualmente marcada pela substituição progressiva dos métodos clássicos por abordagens baseadas em *Deep Learning*, que têm demonstrado resultados superiores [\(KRIZHEVSKY et al., 2012\)](#).

Quanto ao conceito de "aprendizado profundo", não existe um consenso estrito sobre a distinção precisa entre redes profundas e rasas. De maneira geral, redes profundas são caracterizadas por conterem várias camadas de treinamento e serem aplicadas a grandes volumes de dados [\(LECUN et al., 2015\)](#).

Nas abordagens tradicionais de aprendizado de máquina, as imagens normalmente passam por uma etapa de conversão em vetores de atributos ou características antes de serem utilizadas em sistemas de reconhecimento de padrões [\(SOUZA, 2019\)](#). Em contrapartida, em uma Rede Neural Convolucional, a própria imagem, seja pré-processada ou não, é diretamente inserida na primeira camada da rede, como ilustrado na [Figura 2.9](#). Nessa camada, durante o treinamento, a CNN automaticamente extrai um conjunto de atributos de baixo nível, representados por filtros convolucionais.

Quanto aos filtros convolucionais, seu funcionamento pode ser compreendido a partir de uma perspectiva matemática como um produto de matrizes, como ilustrado na [Figura 2.10](#). A operação de convolução é composta por três componentes essen-

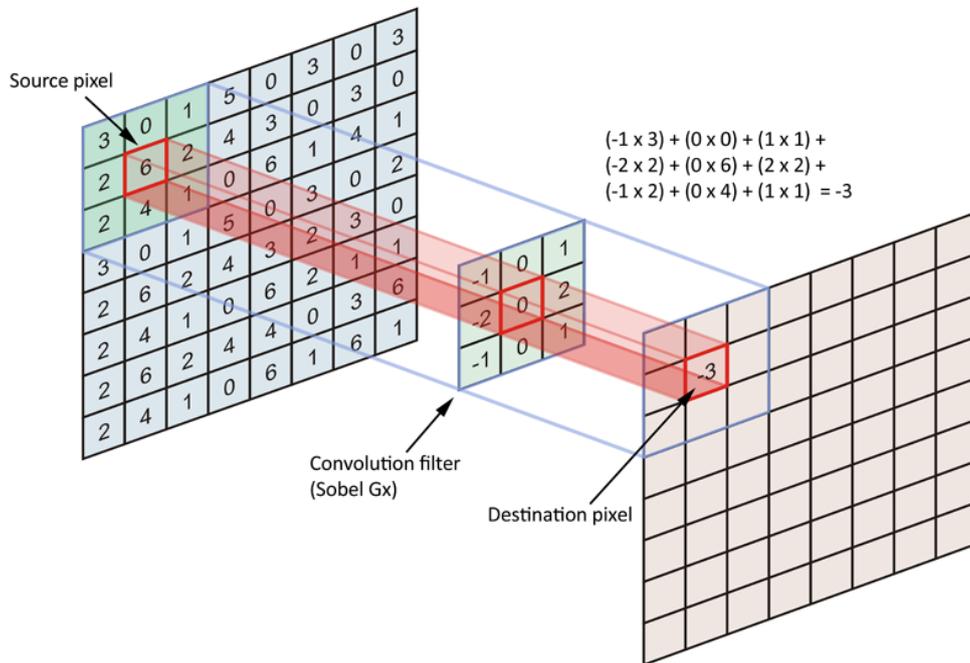
Figura 2.9 - Estrutura de uma CNN.



Fonte: Elhamraoui (2020).

ciais: a entrada, o detector de características, comumente referido como o *kernel* de convolução, e o mapa de características, que é o resultado gerado por essa operação.

Figura 2.10 - Aplicação de filtro de convolução 3x3.



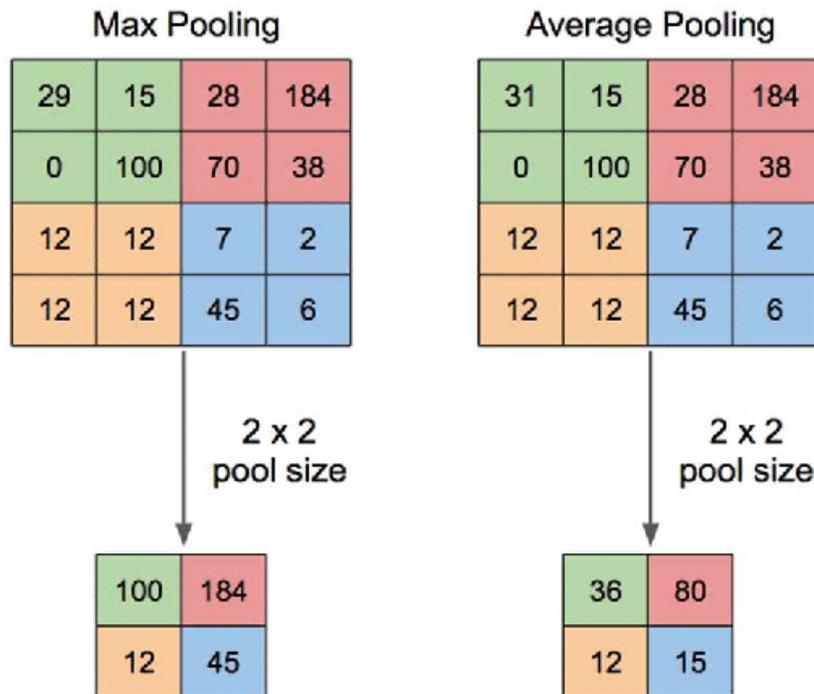
Fonte: Adaptada de Souza e Magalhães (2018).

Em linhas gerais, os filtros convolucionais na primeira camada têm a capacidade de capturar elementos visuais básicos, tais como pontos, linhas e bordas que delimitam variações de tons de cinza ou cores na imagem. A aplicação da convolução entre a

imagem de entrada e esses múltiplos filtros resulta na criação de um conjunto de mapas de ativação, os quais se assemelham a imagens filtradas. A camada convolucional subsequente processa os mapas de ativação obtidos na camada anterior, fazendo uso de outros filtros que são automaticamente ajustados durante o treinamento da rede. Este processo gera novos mapas de ativação, que por sua vez serão submetidos à próxima camada convolucional, e assim sucessivamente.

Outra operação fundamental realizada em redes convolucionais é conhecida como *Pooling*, que tem como objetivo realçar as características mais significativas da imagem. Nessa operação, uma janela é deslizada pela imagem, destacando o valor médio ou máximo encontrado nessa janela conforme ilustrado na Figura 2.11.

Figura 2.11 - Operações de pooling.



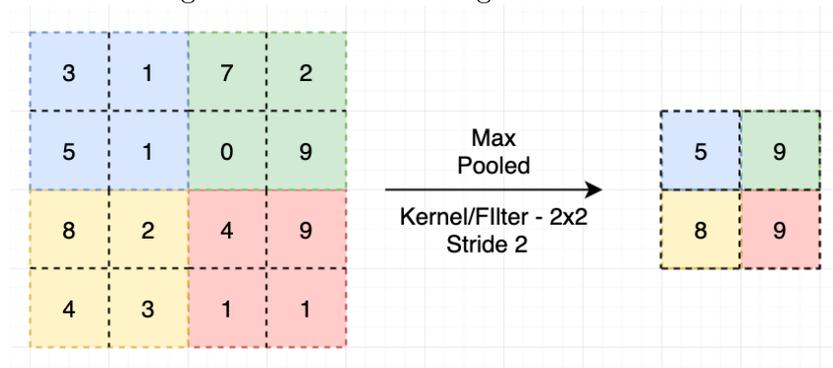
Exemplo de operação de *max pooling* e *average pooling* com um tamanho de filtro de *pixel* 2x2 a partir de uma entrada de *pixel* 4x4. No *max pooling*, cada filtro seleciona o valor máximo e, em seguida, é organizado em uma nova saída com tamanho de 2x2 *pixels*. Enquanto no *average pooling*, o valor obtido é a média do tamanho do filtro.

Fonte: Yani et al. (2019).

A camada de *pooling*, que opera nos mapas de características, possui dimensões menores e apresenta diferentes métodos de *pooling*. O *pooling* pode ser realizado por

média, onde é calculada a média de cada valor no mapa de características, ou por soma. No entanto, o método mais comum é o *pooling* máximo. A operação de *pooling* máximo, ilustrada na Figura 2.12, utiliza um filtro de dimensões 2x2, com um passo de 2 e sem sobreposição. Nessa operação, apenas o valor máximo é passado para a camada seguinte, enquanto os demais valores são descartados. Portanto, dos valores de entrada 3, 5, 1, 1, apenas o valor máximo, que é 5, é retido.

Figura 2.12 - Max Pooling com kernel 2x2.

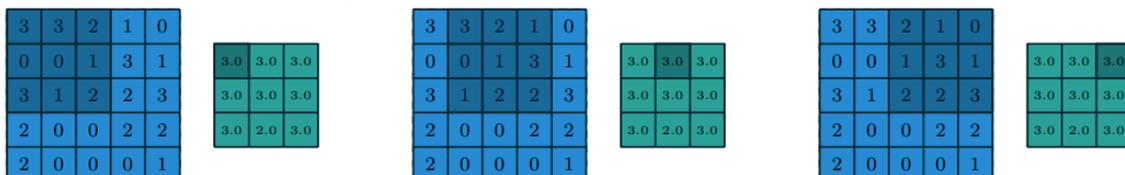


Fonte: Escalona Uriel e Arce (2019).

O uso de um passo de 2 significa que o filtro se move pela imagem de entrada em incrementos de dois, resultando em uma imagem de saída com metade do comprimento e da largura em comparação à imagem de entrada.

Um exemplo adicional de *pooling*, conforme mostrado na Figura 2.13, demonstra a aplicação da função *max pooling* a uma imagem de entrada com dimensões 5x5, utilizando um *stride* de 1. Isso resulta em uma saída com dimensões reduzidas para 3x3.

Figura 2.13 - Agrupamento tradicional.



Fonte: Adaptada de Dumoulin e Visin (2016).

Uma característica importante das camadas de *pooling* máximo é a preservação da relação espacial. Isso significa que essas camadas adquirem um certo nível de invariância a pequenos deslocamentos, rotações e alterações de escala, o que é fundamental em tarefas de processamento de imagens, como visto em (LECUN et al., 2015).

Quanto ao algoritmo de aprendizado utilizado em redes neurais convolucionais profundas, o *backpropagation* tem sido o mais amplamente empregado, conforme indicado por Goodfellow e outros autores em *Deep Learning* (GOODFELLOW et al., 2016b). Um aspecto notável das Redes Neurais Convolucionais Profundas é a sua capacidade de aprendizado hierárquico: à medida que se avança pelas camadas da rede, as características aprendidas se tornam progressivamente mais complexas, representando combinações das características das camadas anteriores. Esse processo resulta na formação de uma hierarquia de atributos, onde as camadas subsequentes criam níveis de abstração cada vez mais elevados.

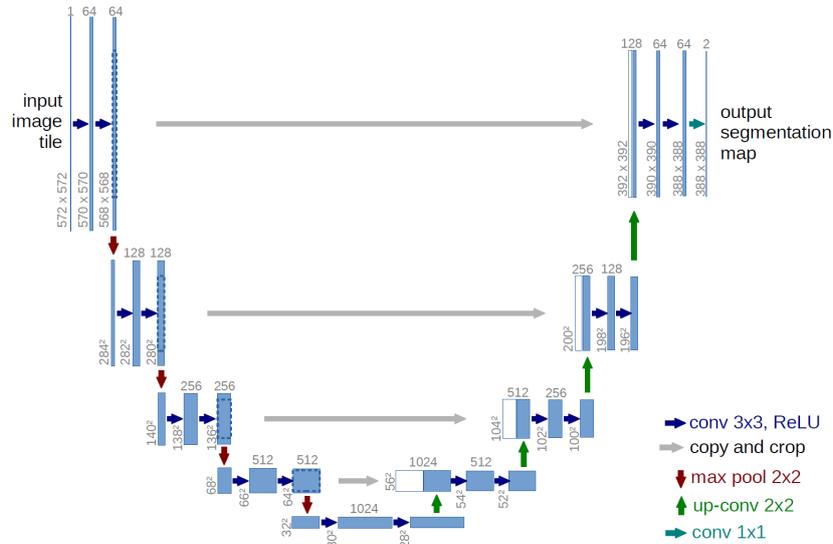
2.6.1 U-Net

Uma arquitetura de CNN amplamente adotada para a segmentação de imagens é conhecida como *U-Net*, e foi originalmente proposta por (RONNEBERGER et al., 2015). A *U-Net* foi concebida inicialmente para ser aplicada em imagens biomédicas, com o propósito de auxiliar em tarefas que incluem detecção, quantificação de células e medições de formas, como destacado por (FALK et al., 2019) e exemplificado na Figura 2.14.

A arquitetura *U-Net* foi desenvolvida a partir de CNN tradicional, que originalmente tinha como objetivo a classificação de imagens, onde a entrada *input* era uma imagem e a saída era um rótulo de classe. No entanto, em contextos biomédicos, a necessidade vai além da simples confirmação ou negação de uma doença; também é necessário localizar a área que apresenta a anormalidade clínica, como enfatizado por Falk et al. (2019) e Ronneberger et al. (2015).

A *U-Net* foi projetada para resolver o desafio de localizar anomalias detectadas. A capacidade de localização e diferenciação de anomalias é alcançada principalmente por dois motivos: em primeiro lugar, a *U-Net* realiza classificação *pixel a pixel*, embora seja treinada em regiões (*patches* ou *chips*), o que exige que a entrada e a saída tenham o mesmo tamanho; em segundo lugar, a arquitetura inclui uma fase de expansão específica para compensar a perda de capacidade de localização decorrente das múltiplas convoluções na fase de contração (GLÄNZER et al., 2023).

Figura 2.14 - Arquitetura U-Net.



A arquitetura da rede. A rede é baseada na arquitetura U-Net, ou seja, uma rede convolucional codificadora/decodificadora de quatro níveis estendida por portas, links residuais e blocos recorrentes. A rede segmenta uma classe em imagens de queimadas. Imagens de entrada foram recortadas em *patches* com tamanhos de $64 \times 64 \times 1$ e, após o processamento, costurando-as novamente na imagem original. Detalhes sobre os elementos individuais da arquitetura de rede são fornecidos nas caixas inferiores.

Fonte: Ronneberger et al. (2015).

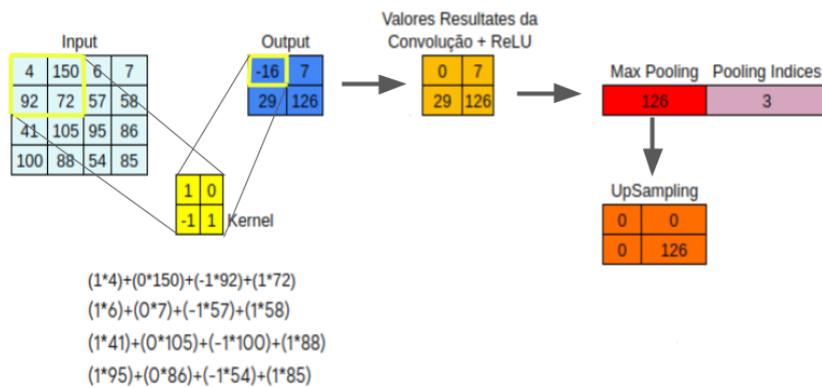
Nesta estrutura, o lado esquerdo da *U-Net* é chamado de caminho de contração, codificador ou *Encoder* dos mapas de características. Esta é a entrada das imagens na rede, passando por operações de convolução e subamostragem. À medida que a rede avança em profundidade, a quantidade de mapas de características aumenta, enquanto a resolução desses mapas diminui progressivamente.

A metade direita da *U-Net* é chamada de caminho de expansão, decodificador ou *Decoder* dos mapas de características. No *Decoder*, são implementadas novas operações, tais como *dropout* e *up-convolution*. Essas operações têm o efeito de reduzir a quantidade de mapas de características à medida que são propagadas pela rede, enquanto, por outro lado, provocam um aumento progressivo na resolução. Isso resulta na geração de uma máscara de segmentação na saída, que possui as mesmas dimensões das imagens de entrada.

Ao ser inserida na *U-Net*, cada imagem é submetida a filtros convolucionais com janelas de tamanho 3×3 . A arquitetura da *U-Net* inclui 64 filtros de convolução na primeira camada, gerando assim 64 mapas de características. Os termos "Mapas de

Características"ou "Mapas de Ativação"referem-se aos resultados da filtragem, sendo assim denominados devido às operações internas da *U-Net*. Nela, cada operação de convolução é sucedida pela aplicação da função de ativação *ReLU*, que permite apenas a passagem adiante dos valores positivos nos mapas de características. Os valores negativos são ajustados para zero durante esse processo conforme ilustrado na Figura 2.15.

Figura 2.15 - Ciclo de Convolução, ReLu, MaxPooling e UpSampling.



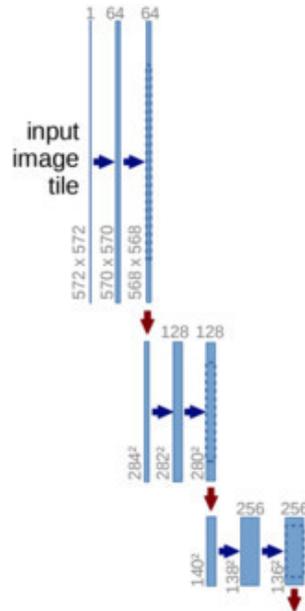
Fonte: Produção do autor.

Após a realização de duas operações de convolução seguidas pela ativação *ReLU*, a imagem de entrada, inicialmente composta por 4 canais, resulta em uma saída que consiste em 64 mapas de características, mantendo uma resolução total de 64x568x568, como ilustrado na Figura 2.16. Não ocorre perda de resolução após essas operações, apesar do uso de filtros de convolução de tamanho 3x3 e um *stride* igual a 1. Essa abordagem impede a perda de linhas e colunas de pixels nas bordas após as operações de convolução (GONZALEZ RAFAEL C.; WOODS, 2008).

O *Max Pooling* utilizado na *U-Net* provoca a perda de resolução na matriz de entrada, selecionando apenas o valor máximo de uma janela deslizante. O resultado da subamostragem consiste em um subconjunto representativo da entrada. Essa técnica é utilizada para diminuir o processamento necessário com a resolução da imagem de entrada (GLÄNZER et al., 2023). Além disso, é fundamental para que a rede identifique características em diferentes níveis de detalhes, que podem variar desde linhas e contornos até objetos inteiros.

Semelhante à operação de convolução, a subamostragem utiliza uma janela deslizante

Figura 2.16 - Ramo esquerdo da arquitetura.



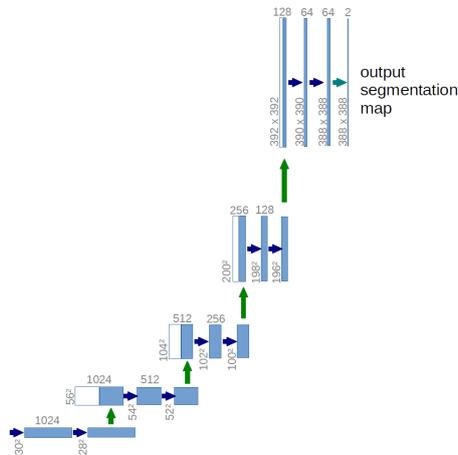
Fonte: Adaptado de Ronneberger et al. (2015).

na imagem com um passo definido. Na *U-Net*, a janela possui dimensões de 2×2 , e o valor do passo (*stride*) é igual a 2 tanto na horizontal quanto na vertical, como visto na Figura 2.12. Isso garante que a janela de subamostragem seja sempre aplicada em regiões distintas da matriz, sem sobreposição. Como resultado, a resolução é reduzida pela metade na saída da operação de *Max Pooling* da *U-Net*.

Na fase de expansão da rede *U-Net*, são realizadas operações de *padding* seguidas por convoluções transpostas, como explicado por Gonzalez Rafael C.; Woods (2008). A convolução transposta é uma técnica de *upsampling* que aumenta as dimensões das imagens. Por exemplo, no início do ramo ascendente da *U-Net*, conforme mostrado na Figura 2.17, a convolução transposta expande a imagem de entrada de $28 \times 28 \times 1024$ para $56 \times 56 \times 1024$. Em seguida, essa imagem é concatenada com a correspondente do caminho de contração, formando uma imagem de tamanho $56 \times 56 \times 1024$. Essa concatenação é necessária para combinar informações das camadas anteriores e obter previsões mais precisas.

À medida que a arquitetura *U-Net* avança, com camadas de informações texturais e contextuais adicionadas devido à fase de contração e à aplicação sucessiva de filtros convolucionais, o tamanho da matriz e a capacidade de localização são restaurados graças à fase de expansão, com suas convoluções transpostas e operações de *padding*,

Figura 2.17 - Ramo direito da arquitetura.



Fonte: Adaptado de Ronneberger et al. (2015).

conforme ilustrado na Figura 2.18, A convolução transposta faz no ramo direito o trabalho inverso que o *Max Pooling* faz no ramo esquerdo.

As redes convolucionais comumente empregam a não-linearidade *ReLU* para assegurar que a ativação dos mapas de características seja sempre positiva. Visando obter reconstruções válidas, que também devem manter valores positivos em cada camada, o sinal reconstruído é submetido a uma não-linearidade *ReLU*. A utilização de funções de ativação distintas demandaria ajustes nessa etapa, uma vez que seria necessário encontrar uma função capaz de reverter o efeito da função de ativação utilizada conforme visto em Bruschi (2022).

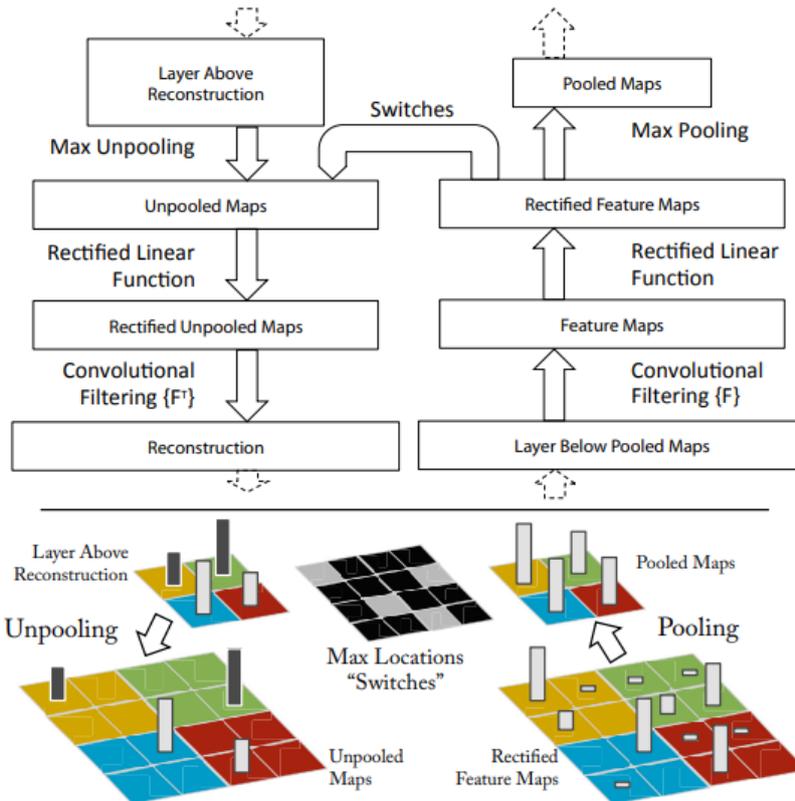
Isso nos leva à última etapa da arquitetura *U-Net*, onde ocorre a segmentação semântica, atingindo o objetivo central de uma CNN, ou seja, a previsão ou classificação matricial, como ilustrado na Figura 2.19.

2.7 Queimadas e incêndios

No contexto da classificação de eventos com presença de fogo em áreas rurais e/ou florestais, existem duas definições distintas que são frequentemente encontradas na literatura: queimadas e incêndios. Essas definições são amplamente discutidas e, em alguns casos, são usadas de maneira geral.

De acordo com o Manual para Formação de Brigadista de Prevenção e Combate aos Incêndios Florestais do Instituto Chico Mendes de Conservação da Biodiversidade

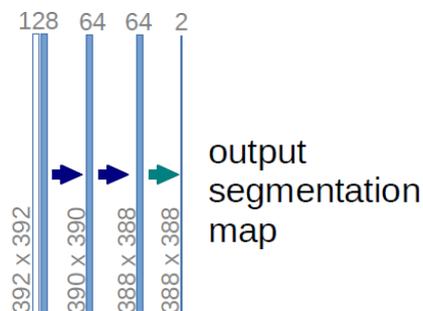
Figura 2.18 - Diagrama da reconstrução por deconvolução.



Uma camada deconvolucional (à esquerda) ligada a uma camada convolucional (à direita). A rede deconvolucional reconstrói uma versão aproximada dos *feature maps* da camada convolucional anterior. Em baixo: Uma ilustração da operação de *unpooling*, usando *switches* que guardam a posição do máximo local em cada região de *pooling* (zonas coloridas) de uma rede convolucional.

Fonte: Zeiler e Fergus (2014).

Figura 2.19 - Saída da arquitetura.



Fonte: Adaptado de Ronneberger et al. (2015).

(LEMOS et al., 2021), o termo 'queimada controlada' se refere a uma prática agrícola ou florestal que utiliza o fogo de maneira planejada, com controle cuidadoso de sua intensidade e limitação a uma área predeterminada. Por outro lado, o termo 'incêndio florestal' (também usado para descrever incêndios em outros tipos de vegetação, como capoeiras, campos e pradarias) é definido como a ocorrência de fogo sem controle, que afeta qualquer forma de vegetação e pode ser desencadeado por causas naturais, intencionais ou por negligência.

Dessa forma, o termo 'incêndio' pode ser compreendido como a ocorrência de queimas não controladas, eventos que fazem parte da categoria de desastres naturais ocorrendo em escalas local e regional. Esses incêndios podem ter origem natural, como aqueles causados por raios, ou podem ser resultado de causas acidentais, como fogos de artifício, faíscas de estradas de ferro, fogueiras de acampamento, quedas de balões, rompimentos de cabos de alta tensão, entre outras. Além disso, incêndios também podem ser provocados intencionalmente de forma criminosa, como mencionado por Berlinck e Batista (2020).

Por outro lado, as 'queimadas' estão associadas a práticas de manejo, ou seja, são queimas controladas realizadas pela ação humana, conforme explicado por Sales et al. (2019).

Independentemente da origem, é importante destacar que tanto os incêndios quanto as queimadas causam danos à biodiversidade e modificam a paisagem, afetando diretamente o equilíbrio dos ecossistemas, como observado por Lopes et al. (2018). Além disso, esses eventos liberam grandes quantidades de dióxido de carbono (CO₂) na atmosfera, contribuindo para as mudanças climáticas, como destacado por Venkatesh et al. (2020).

2.7.1 Risco e perigo de incêndios

No Brasil, frequentemente, os termos 'risco' e 'perigo' são utilizados como sinônimos, embora tenham significados distintos. De acordo com a definição de Tedim e Carvalho (2013), o termo 'perigo' pode ser compreendido como um fenômeno, evento ou atividade humana potencialmente prejudicial que pode resultar em perda de vidas, ferimentos ou outros impactos na saúde, danos materiais, perda de meios de subsistência e serviços, perturbação social e econômica, ou dano ambiental. Por outro lado, 'risco' é definido como a combinação da probabilidade de ocorrência de um evento e suas consequências negativas associadas.

Conforme a definição de Camillo (1999), o 'perigo de incêndio' é a presença de material combustível que, devido à sua natureza, localização, arranjo ou qualquer combinação desses fatores, pode ser queimado e, caso ocorra, representar um risco para a vida humana, propriedade/benfeitorias e o ambiente. Por outro lado, o 'risco de incêndio' é a probabilidade real ou potencial de ocorrência de um incêndio ou outra forma de combustão de materiais, que pode colocar em perigo a vida humana, propriedade/benfeitorias e o ambiente.

Em termos gerais, o 'perigo de incêndio' é usado para descrever a predisposição ou suscetibilidade de uma determinada área à ocorrência desse evento, enquanto o 'risco de incêndio' se refere à probabilidade ou chance de um incêndio ocorrer com base em sua predisposição (POURGHASEMI et al., 2020).

2.7.2 Fatores influenciadores

A ocorrência e disseminação espacial de incêndios e queimadas constituem um processo complexo e não linear, impulsionado pela interação de processos bióticos e abióticos, que dependem da escala geográfica, como observado por Chuvieco et al. (2019). Bui et al. (2017) descrevem que a ocorrência e a distribuição desses eventos são influenciadas por quatro fatores principais, a saber: aspectos climáticos, ação humana, características topográficas e propriedades da vegetação. A seguir, apresentamos uma descrição dos principais fatores que influenciam incêndios e queimadas, conforme destacado na literatura.

2.7.2.1 Aspectos climáticos

Os aspectos climáticos desempenham um papel fundamental na determinação dos padrões dos regimes de incêndios e queimadas, como observado por Marlon et al. (2013). Não é surpreendente que o relatório do Painel Intergovernamental sobre Mudanças Climáticas, visto em Organização das Nações Unidas (ONU) (2008), sugira que até 2040, as mudanças climáticas deverão aumentar a frequência e a gravidade dos incêndios e queimadas em todo o mundo, principalmente devido ao aumento da temperatura associado à redução das taxas de precipitação, que são fatores críticos no comportamento do fogo.

Os fatores climáticos desempenham um papel importante, pois afetam diretamente a umidade dos combustíveis naturais, como a serapilheira, gramíneas secas e material lenhoso não vivo, que, por sua vez, determinam o potencial de ignição e propagação do fogo. Essas condições incluem temperatura, precipitação, velocidade do vento,

umidade do ar e umidade do solo, como destacado por [Marlon et al. \(2013\)](#).

Em resumo, a variabilidade climática exerce uma influência direta sobre a ocorrência de incêndios e queimadas, uma vez que regula a disponibilidade de água no sistema solo/planta/atmosfera, fatores determinantes na acumulação e na predisposição da biomassa a ser queimada, conforme observado por [Abram et al. \(2021\)](#).

2.7.2.2 Aspectos antrópicos

Estudos indicam que áreas próximas a atividades humanas, como estradas e assentamentos, apresentam um alto risco de incêndios, conforme apontado por [Venkatesh et al. \(2020\)](#). No entanto, [Marlon et al. \(2013\)](#) descreve uma tendência global em que os incêndios são mais frequentes em áreas com níveis intermediários de densidade populacional. A ocorrência desses eventos é mais rara em áreas densamente povoadas, como áreas urbanas, onde a vegetação é mais limitada e a paisagem é altamente fragmentada. Da mesma forma, em áreas com baixa densidade populacional, como regiões desérticas e polares, os incêndios também são menos frequentes devido às condições climáticas adversas e à baixa cobertura vegetal.

Por outro lado, observa-se um aumento significativo na frequência de incêndios, na faixa de 10% a 20%, apenas em áreas com até 0,1 pessoas por quilômetro quadrado.

2.7.2.3 Fatores topográficos

Os aspectos topográficos, que incluem a altitude, declividade e exposição, desempenham um papel fundamental, pois conseguem integrar informações sobre a região, como as condições meteorológicas médias e a variabilidade espaço-temporal de fatores climáticos, como temperatura do ar, precipitação e radiação solar, como mencionado por [Leuenberger et al. \(2018\)](#). Esses fatores têm influência direta no ciclo de vida da cobertura vegetal e no uso da terra, o que, por sua vez, afeta a ocorrência de incêndios e queimadas.

A altitude, por exemplo, é uma variável fisiográfica essencial que regula a temperatura, umidade e velocidade do vento, desempenhando um papel crítico na propagação de incêndios. Isso ocorre porque a altitude influencia a estrutura da vegetação, a umidade do combustível e a umidade do ar. Por outro lado, a declividade afeta a taxa de propagação do fogo, com incêndios se movendo mais rapidamente em terrenos com inclinação e mais lentamente em terrenos planos. Além disso, relevos mais ondulados tendem a favorecer incêndios mais rápidos em comparação com áreas com declividade mais baixa, conforme observado por [Camargo et al. \(2019\)](#).

A orientação do terreno se refere à direção para a qual as encostas do terreno estão voltadas. Esse fator influencia a quantidade de radiação solar que incide sobre o terreno e, conseqüentemente, afeta a umidade do solo, a temperatura do ar e a velocidade do vento. Quanto mais direta for a incidência de radiação solar, maior será a temperatura do ar e menor a umidade, o que tem um impacto direto no tipo de vegetação e em seu grau de ressecamento, tornando-a mais propensa a queimar, como explicado por [Venkatesh et al. \(2020\)](#).

2.7.2.4 Características da vegetação

A dinâmica de uso e ocupação do solo pode também influenciar significativamente a frequência e a gravidade dos incêndios e queimadas em uma determinada região, como destacado por [Marlon et al. \(2013\)](#). Isso ocorre porque as mudanças na paisagem transformam os elementos naturais, afetando a disponibilidade de biomassa vegetal, seu grau de ressecamento e, conseqüentemente, sua susceptibilidade ao fogo.

Em áreas naturais, como densas florestas, ocorre a interceptação da radiação solar, o que contribui para reduzir a temperatura do ar e do material combustível. Além disso, essa vegetação atua como uma barreira natural que diminui a velocidade do vento dentro da floresta, reduzindo as taxas de evaporação e, conseqüentemente, dificultando o ressecamento do material combustível, conforme mencionado por [Gomes et al. \(2020\)](#). Por outro lado, em áreas que sofreram alterações, além das mudanças contínuas na carga de combustível, ocorrem alterações nas taxas de evaporação e na temperatura da superfície. Isso aumenta a vulnerabilidade a incêndios, como apontado por [Aquilué et al. \(2020\)](#).

Portanto, em estudos relacionados à suscetibilidade de incêndios e queimadas, é comum utilizar índices de vegetação para analisar o teor de umidade do combustível. Além disso, mapas de uso e cobertura da terra são empregados para avaliar as alterações na cobertura vegetal, que são fatores potencialmente explicativos da ocorrência desses eventos, conforme destacado por [Pourghasemi et al. \(2020\)](#).

2.8 Detecção de incêndio em imagens de sensoriamento remoto

A técnica de Sensoriamento Remoto tem como um dos principais objetivos a obtenção de informações valiosas através da captura de imagens de satélite, como destacado por [CENTENO \(2003\)](#). No contexto da detecção de incêndios, o propósito é identificar quais *pixels* em uma imagem indicam a presença de fogo, permitindo assim a localização precisa, a extensão e a data do evento.

Os estudos sobre métodos automáticos para a detecção de incêndios têm raízes que remontam à década de 1970, quando se começou a analisar quais intervalos espectrais seriam mais adequados para essa finalidade, como mencionado por [Kondratyev et al. \(1972\)](#). [Matson e Holben \(1987\)](#) já destacavam que o Sensoriamento Remoto era a única alternativa viável para monitorar esses eventos em regiões remotas. Em seu estudo, esses autores empregaram o sensor AVHRR (*Advanced Very High Resolution Radiometer*), em um estudo de caso na região amazônica.

Na década de 1990, o sensor VIRS (*Visible and Infrared Scanner*), a bordo da missão TRMM (*Tropical Rainfall Measuring Mission*), também foi utilizado para a detecção automática de incêndios. Os algoritmos desenvolvidos para o TRMM-VIRS eram baseados nos algoritmos do AVHRR, mas incluíam análises contextuais, ou seja, avaliações da vizinhança de *pixels*, não se limitando apenas à análise individual de *pixels*, como discutido por [Giglio et al. \(2003\)](#).

No âmbito da detecção de incêndios, uma abordagem pioneira foi apresentada por [Kaufman et al. \(1998\)](#). Eles desenvolveram um método utilizando o sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*), o qual foi posteriormente aprimorado por [Giglio et al. \(2003\)](#). O sensor MODIS continua sendo uma ferramenta fundamental para a detecção de incêndios devido à sua importância e à extensa vida útil, proporcionando cobertura global quase diária. Esse sensor é capaz de identificar incêndios com áreas que variam de 100 a 300 metros quadrados ([MAIER et al., 2013](#)).

O sensor MODIS, por exemplo, equipa os satélites Terra e Aqua da NASA, oferecendo uma resolução espacial que varia de 250 metros a 1 quilômetro por *pixel*. Esses satélites orbitam a uma altitude de cerca de 705 quilômetros e têm uma taxa de revisita de 1 a 2 dias ([BORGES et al., 2021](#)).

Além disso, o sensor AVHRR, com uma resolução espacial de 1 quilômetro por *pixel*, está presente nos satélites NOAA-18 (833 quilômetros de altitude), NOAA-19 (870 quilômetros de altitude) e METOP-B (827 quilômetros de altitude), todos com revisita diária ([OLIVEIRA, 2022](#)).

Outra opção é o sensor VIIRS (*Visible Infrared Imaging Radiometer Suite*), montado nos satélites NASA/NOAA, Suomi NPP (*Suomi National Polar-orbiting Partnership*) e NOAA-20. Ele possui uma resolução espacial de 375 metros e revisita diária ([LI et al., 2020](#)).

O sensor ABI (*Advanced Baseline Imager*), equipa o satélite geoestacionário GOES-16, posicionado a uma altitude de cerca de 36.000 quilômetros da Terra. O ABI é capaz de capturar imagens a cada 10 minutos, oferecendo uma resolução espacial que varia de 500 metros a 2 quilômetros ([BARMPOUTIS et al., 2020](#)).

Esses sensores e satélites desempenham um papel fundamental no monitoramento de incêndios, proporcionando uma cobertura global abrangente e revisita frequente. No entanto, é importante ressaltar que esses sensores têm uma resolução espacial relativamente limitada. Além disso, existem outros sensores de média resolução espacial, como o Landsat-8 e o Sentinel-2, que serão abordados de forma mais detalhada nesta pesquisa.

3 REVISÃO BIBLIOGRÁFICA

Este capítulo aborda tópicos relevantes para a pesquisa, começando com uma breve revisão dos métodos de detecção de fogo ativo em imagens de satélite. Em seguida, discute-se o uso da rede *U-Net* em aplicações de Sensoriamento Remoto e a comparação entre imagens capturadas pelos sensores OLI/Landsat-8 e MSI/Sentinel-2 no mapeamento da uso e cobertura da terra.

A detecção de fogo ativo em imagens de satélite é um campo pouco explorado, e a literatura revela que a rede *U-Net* tem sido utilizada em diversos contextos, mas ainda carece de investigação específica para essa aplicação. Além disso, a comparação entre os sensores OLI/Landsat-8 e MSI/Sentinel-2 é um tema amplamente estudado em Sensoriamento Remoto.

Neste capítulo, os tópicos relacionados são organizados da seguinte forma: na Seção 3.1, são discutidos os métodos de detecção de fogo ativo em imagens de satélite; a Seção 3.2 aborda a detecção de focos de incêndio a partir de diversas fontes de dados; a Seção 3.3 explora o uso da rede *U-Net*; na Seção 3.4, são apresentados estudos de comparação entre os sensores OLI/Landsat-8 e MSI/Sentinel-2. Finalmente, na Seção 3.5, são apresentadas as considerações finais deste capítulo.

3.1 Detecção de fogo ativo em imagens de satélites

No trabalho de Fusioka (2021), é apresentada uma abordagem para a detecção de fogo ativo por meio da aplicação de técnicas de aprendizado profundo em imagens capturadas pelo satélite Landsat-8. O estudo utilizou imagens coletadas nos meses de Agosto e Setembro de 2020, as quais foram previamente anotadas manualmente. O objetivo principal foi avaliar a capacidade das redes neurais em se aproximar das anotações realizadas por especialistas humanos.

As arquiteturas de rede neural testadas no estudo demonstraram a capacidade de se equiparar aos métodos clássicos presentes na literatura. O desempenho mais notável alcançado foi uma métrica *F1-score* de 94.2% e um IoU (*Intersection over Union*) de 89.0%. Em comparação com as anotações manuais, as redes neurais superaram os métodos tradicionais, apresentando um *F1-score* de 89.7% e um IoU de 81.4% em grande parte dos casos.

Além do trabalho apresentado por Fusioka (2021), outros estudos têm abordado diferentes métodos para a detecção de áreas com fogo ativo. Por exemplo, Pereira et al. (2012) conduziram uma análise dos valores médios da área afetada por fogo

ativo na América do Sul, considerando diferentes tipos de cobertura vegetal. Essa análise foi baseada na potência radiativa do fogo, a qual foi calculada a partir de dados provenientes de satélites de média/baixa resolução.

Para este estudo, foram utilizados sensores orbitais, como o MODIS, a bordo da plataforma Terra, bem como os sensores TM e ETM+ dos satélites Landsat 5 e Landsat 7, respectivamente. Além disso, o sensor *GOES Imager*, integrante da constelação de satélites GOES, também foi empregado na análise.

No estudo conduzido por Pereira (2021.), foi abordado o desafio da detecção de incêndios ativos por meio da aplicação de técnicas de aprendizado de máquina em imagens provenientes dos satélites Landsat-8 e Sentinel-2. O trabalho envolveu a avaliação de tanto métodos de aprendizado de máquina quanto técnicas de aprendizado profundo, com o objetivo de identificar qual abordagem apresentava um desempenho superior no processo de detecção de incêndios.

Os experimentos foram conduzidos utilizando um amplo conjunto de dados em escala global e demonstraram a eficácia das abordagens de detecção. Os resultados obtidos revelaram que os modelos treinados com base em imagens do Landsat-8 atingiram uma eficiência de detecção superior a 90%, conforme avaliado pela métrica *F-Score*, amplamente reconhecida nos principais rankings de segmentação. Além disso, os mesmos métodos também foram capazes de realizar inferências precisas em imagens provenientes do Sentinel-2, alcançando um *F-Score* de mais de 80%.

É importante destacar que os modelos desenvolvidos foram treinados inicialmente com informações provenientes do Landsat-8 e posteriormente aplicados com sucesso para a análise das imagens do Sentinel-2.

3.2 Detecção de focos de incêndios

O estudo realizado por Bertoni e Feder (2018.) propôs a identificação de imagens com fogo ativo por meio de uma Rede Neural Convolutiva, que aplica uma série de filtros aos dados brutos dos pixels de uma imagem para extrair e aprender características de nível superior. A função de ativação ReLU (*Rectified Linear Unit*) foi aplicada nas saídas das camadas convolucionais para introduzir não-linearidades no modelo. Também foram utilizadas camadas de agrupamento para reduzir o custo computacional. Para extrair sub-regiões do mapa de características, foi empregado o algoritmo de *pooling* máximo, mantendo o valor máximo e descartando os demais. Na camada densa final, houve um único nó para cada classe alvo no modelo, com

uma função de ativação *softmax* que gera um valor entre 0 e 1 para cada nó. A inserção de inteligência artificial na classificação de imagens foi avaliada como positiva, com o modelo apresentando uma taxa de precisão na detecção de incêndios de 91,67%.

A pesquisa conduzida por Nagai e Sou (2020) descreve um processo de detecção de fogo e fumaça em vídeos, baseado na combinação de métodos de remoção de fundo e redes neurais convolucionais. Os resultados preliminares indicam que o processo proposto alcançou uma precisão de 92,3% ao empregar a arquitetura FSDN (*Fire Smoke Detection Network*) e 94,88% com a arquitetura *Xception*. Essa avaliação foi realizada em um conjunto de 29 vídeos, onde foram selecionados sequencialmente 4.481 quadros. A divisão dos quadros foi feita da seguinte forma: 2.964 para treinamento, 715 para teste e 802 para validação.

No pré-processamento dos dados, foram utilizadas as bibliotecas OpenCV (versão 4.2) e Python (versão 3.6), enquanto para a construção dos modelos CNN, o *framework* Keras (versão 2.3) em conjunto com o TensorFlow (versão 2.2) foram adotados. Durante o treinamento e validação, a arquitetura FSDN foi ajustada com um tamanho de mini-lote de 100, enquanto a arquitetura *Xception* utilizou um tamanho de mini-lote de 16. Como otimizador, foi empregado o SGD, juntamente com a função de perda *categorical crossentropy*, devido a necessidade de lidar com classes desbalanceadas, utilizando pesos calculados proporcionalmente à inversa da quantidade de dados em cada classe.

A arquitetura FSDN foi criada para realizar a classificação em três classes: fogo, fumaça e negativo. Ela é composta por 8 camadas convolucionais residuais, 2 camadas convolucionais convencionais, 22 blocos de *Inception* e 1024 neurônios. Por sua vez, a arquitetura *Xception* é constituída por 36 camadas convolucionais dispostas linearmente, que foram pré-treinadas com a base de dados *ImageNet*.

A análise efetuada por Duarte et al. (2011) propõe um algoritmo para a detecção de incêndios florestais, empregando técnicas de RNA e PCA (*Principal Component Analysis*). O algoritmo, voltado para o reconhecimento de fumaça e fogo, utiliza uma rede neural de múltiplas camadas. A taxa de reconhecimento obtida foi de 72% para a componente vermelha, 32% para a componente verde e 28% para a componente azul. O estudo utilizou um conjunto de 990 imagens de câmeras CCD em formato colorido RGB (*Red, Green, Blue*), divididas por cada um dos componentes de cor. Desse conjunto, 75% das imagens de cada componente foram usadas para treinamento e validação da rede neural, enquanto o restante foi reservado para testes.

A organização dos dados de entrada da rede neural foi realizada no ambiente MATLAB e, posteriormente, aplicados no software SNNS (*Stuttgart Neural Network Simulator*). Foram projetadas três Redes Neurais do tipo MLP (*Multi-Layer Perceptron*), configuradas da seguinte forma: divididas em três camadas, com 14 células sintéticas representando os neurônios na camada de entrada, 10 neurônios na camada intermediária e 2 neurônios na camada de saída, referentes a imagens contendo fumaças/incêndio e ruídos. O número de neurônios determinados na camada de entrada foi obtido por meio da técnica de PCA. Os neurônios na camada escondida foram definidos com base no número de neurônios da camada de entrada e no tipo de aplicação da rede.

A pesquisa empregada por Santos et al. (2019) tem como objetivo aprimorar a automação do processo de classificação de áreas queimadas por meio de dados obtidos por Sensoriamento Remoto. Os resultados mais promissores foram alcançados por meio da implementação dos modelos *Random Forest* e Redes Neurais, que obtiveram acurácias de 96,4% e 99,1%, respectivamente. Esses resultados destacam a eficácia da abordagem no processo de classificação de áreas queimadas.

Para alcançar esses resultados, o estudo utilizou um conjunto de dados composto por 40.726 imagens provenientes dos satélites Terra, Aqua e NPP. Dentre essas imagens, 4.716 correspondiam a áreas queimadas, enquanto 36.010 representavam áreas não queimadas. A avaliação dos modelos foi realizada por meio da média dos valores obtidos em 10 testes de validação cruzada, que indicaram o desempenho de cada modelo gerado. Adicionalmente, outros métodos, como *KNN*, *DT* e *SVN* (*k-nearest neighbors*, *Decision Trees*, *Support Vector Machine*), também foram testados e apresentaram acurácias de 96,4%, 87,9% e 78,4%, respectivamente.

O estudo conduzido por Gontijo et al. (2011) visa validar *hotspots* na detecção de incêndios em duas cenas do satélite Landsat 5, equipado com o sensor *Thematic Mapper*. Para essa validação, foi gerada uma imagem do NDVI (*Normalized Difference Vegetation Index*) com o propósito de utilizá-la no mapeamento das áreas queimadas. A escolha desse índice se deve à sua ampla utilização, simplicidade computacional e sensibilidade comprovada às mudanças na cobertura vegetal.

Posteriormente, uma imagem de diferença entre os índices das duas imagens foi gerada para destacar as mudanças na vegetação. Nessa imagem de diferença, valores próximos de zero indicam áreas onde não ocorreram alterações na cobertura vegetal, valores positivos indicam diminuição na cobertura vegetal, e valores negativos indicam crescimento significativo da cobertura vegetal durante o período considerado.

A análise comparativa entre as imagens revelou que, dentro da cicatriz de queimada, 334 *hotspots* apresentaram uma taxa de acerto de 24,61%. Considerando a distância entre o *hotspot* e a cicatriz, 399 *hotspots* tiveram uma taxa de acerto de 29,40%, considerando a representação de um *pixel*. Além disso, 305 *hotspots*, ao levar em consideração a distância do *hotspot* até a cicatriz com um deslocamento de até um *pixel*, obtiveram uma taxa de acerto de 22,47%.

3.3 Utilização da rede *U-Net*

No estudo conduzido por Oliveira (2020a), a proposta envolve a criação de um modelo de aprendizado profundo baseado na arquitetura *U-Net*, destinado à classificação de uso e ocupação do solo. Para realizar essa tarefa, uma bacia hidrográfica específica foi selecionada, e uma imagem de alta qualidade que cobrisse toda a extensão dessa bacia foi adquirida por meio do satélite Sentinel-2.

Utilizando o software de SIG (Sistema de Informação Geográfica) QGIS, uma máscara foi criada. Essa máscara, juntamente com a imagem de satélite, foi utilizada para gerar recortes que serviram como entrada para a rede neural, possibilitando a geração de parâmetros do modelo. Posteriormente, a acurácia e a perda do modelo foram avaliadas.

Os resultados demonstraram que a introdução de técnicas de inteligência artificial na classificação de imagens de satélite para fins de identificação de uso e ocupação do solo é altamente eficaz, alcançando uma acurácia máxima de até 95%.

No trabalho realizado por Bragagnolo (2021), foi aplicada a arquitetura de Rede Neural Totalmente Convolutiva conhecida como *U-Net* em uma metodologia voltada para a identificação da perda de cobertura florestal em dois biomas brasileiros. O trabalho é apresentado em três artigos distintos.

O primeiro artigo descreve o processo de seleção da FCN (*Full Connected Neural*) e realiza uma avaliação preliminar da sua aplicabilidade na detecção de desmatamentos em uma região da Amazônia. Os resultados indicaram que a *U-Net* obteve as melhores métricas em comparação as arquiteturas *SegNet*, *DeepLabV3+*, *PspNet*, *Vgg-PspNet* e *FCN32*, e resultado similar a *ResNet50SegNet*. Considerando o custo computacional e tempo de processamento a *U-Net* superou as outras arquiteturas com tempo de 45 minutos, frente a *Vgg-PspNet*, com 02:17 horas, o que a tornou a arquitetura escolhida para continuar os estudos.

No segundo artigo, houve uma análise mais aprofundada das capacidades da *U-Net*,

incluindo a identificação da melhor configuração e a avaliação de diferentes combinações de bandas multiespectrais. Esse estudo abrangeu os biomas Mata Atlântica e Amazônia, e revelou que a *U-Net* obteve os melhores resultados na classificação de áreas florestais e não-florestais, especialmente quando se utilizaram quatro bandas espectrais (vermelha, verde, azul e infravermelha-próxima). A *U-Net* foi capaz de mapear as regiões florestais, alcançando elevados valores de acurácia, precisão, *recall* e *F1-Score*, que foram de 0,9880, 0,9871, 0,9882 e 0,9876, respectivamente.

O terceiro artigo apresenta uma metodologia completa e automatizada que utiliza as configurações otimizadas da *U-Net*, obtidas nos estudos anteriores, para identificar áreas desmatadas nos biomas Mata Atlântica e Amazônia por meio de imagens do satélite Sentinel-2. Os resultados demonstraram que essa metodologia é capaz de identificar com alta precisão as áreas que sofreram perda de cobertura vegetal, destacando-se como uma ferramenta relevante para sistemas de monitoramento ou como um complemento eficaz para sistemas já existentes.

Na pesquisa conduzida por Oliveira (2020b), foi abordada a questão da segmentação de áreas de plantação. A fim de solucionar esse desafio, foi desenvolvida a arquitetura de Rede Neural Convolutiva denominada *Two-stage U-Net*. Além disso, o trabalho também envolveu a criação de um conjunto de dados composto por imagens de satélite acompanhadas de anotações referentes às áreas de plantação.

A arquitetura proposta passou por um processo de treinamento, no qual os hiperparâmetros da rede, o otimizador, a função de perda e o tamanho do lote de imagens (*batch size*) foram ajustados e otimizados. Os resultados obtidos a partir da métrica IoU da *Two-stage U-Net* demonstraram um desempenho superior em comparação com os resultados alcançados por outras arquiteturas utilizadas em estudos similares.

No estudo realizado por Souza (2019), foram exploradas alternativas para a classificação automatizada de regiões suscetíveis ao acúmulo de hidrocarbonetos, com base na aplicação de técnicas de aprendizado de máquina destinadas a identificar padrões em imagens sísmicas. O trabalho empregou RNA, CNN e segmentação semântica, esta última utilizando uma arquitetura do tipo *U-Net*.

O conjunto de dados utilizado consistiu em imagens sísmicas provenientes da Bacia de Sergipe-Alagoas. Diversos indicadores de desempenho, como acurácia, precisão, *recall*, *Score*, erro e IoU, foram empregados para avaliar o desempenho das redes durante as fases de treinamento e validação. Os resultados obtidos foram satisfatórios, destacando-se especialmente o desempenho das CNNs e, em particular, da

arquitetura *U-Net*.

3.4 Comparação dos sensores OLI/Landsat-8 e MSI/Sentinel-2

Na análise efetuada por Calixto et al. (2017), foi proposta uma comparação entre os sensores ópticos OLI/Landsat-8 e MSI/Sentinel-2, com o objetivo de determinar qual deles apresenta uma maior capacidade de separação de classes no contexto do mapeamento de uso e cobertura da terra. Nesse estudo, todas as bandas ópticas desses sensores foram empregadas, com os dados expressos em termos de refletância de superfície. Além disso, foram consideradas apenas as bandas ópticas do MSI/Sentinel-2 que correspondiam às bandas do OLI/Landsat-8, as quais foram analisadas por meio de classificação não supervisionada com o algoritmo k-médias.

Os resultados revelaram que as classificações obtidas a partir desses dois sensores apresentaram semelhanças estatisticamente significativas. Portanto, no contexto desse experimento e para as classes mapeadas, não foi observada uma melhora na capacidade de separação das classes de uso e cobertura da terra com o uso do sensor MSI em comparação com o OLI.

Na pesquisa conduzida por Freires et al. (2019), foi realizada uma investigação com o objetivo de aprimorar a identificação e delimitação das diversas classes de cobertura e uso da terra na região do maciço de Uruburetama, no estado do Ceará. Nesse contexto, foram comparadas imagens provenientes dos sensores orbitais OLI/Landsat-8 e MSI/Sentinel-2, visando determinar qual desses produtos oferece melhores resultados para fins de estudos dessa natureza.

A metodologia adotada englobou várias etapas, começando pela aquisição das imagens orbitais da área de interesse. Em seguida, foram realizados procedimentos de pré-processamento, geração do NDVI, segmentação por crescimento de regiões, classificação supervisionada, validação da classificação e produção dos mapas temáticos. Os resultados obtidos revelaram que os produtos NDVI derivados das imagens dos sensores OLI/Landsat-8 e MSI/Sentinel-2 apresentaram uma correlação positiva muito forte, o que indica uma compatibilidade espectral entre esses sensores.

De acordo com as conclusões do estudo, a imagem MSI/Sentinel-2, devido à sua superior resolução espacial, oferece um maior nível de detalhamento dos objetos e uma maior precisão na classificação. Portanto, essa imagem se mostra mais adequada para estudos que envolvem análises em escalas maiores. Por outro lado, a imagem OLI/Landsat-8 demonstrou ser mais apropriada para investigações que demandam

menor nível de detalhamento ou que envolvem alvos mais homogêneos.

O estudo realizado por [Matias \(2019\)](#), tem como principal objetivo explorar o potencial de software como suporte para análises comparativas das capacidades e limitações dos dados provenientes dos satélites Sentinel-2 e Landsat-8 no contexto de planejamento territorial e ambiental. Essa investigação teve como foco a comparação e avaliação de qual conjunto de dados ofereceria uma resposta mais eficaz no cálculo de índices de vegetação, mineralização, água, e LST (*Land Surface Temperature*), bem como nas classificações das áreas. O objetivo final era identificar os conjuntos de dados mais adequados para aplicações relacionadas ao planejamento territorial e ambiental.

No decorrer da pesquisa, foram aplicados métodos e técnicas de detecção remota, juntamente com o uso das imagens dos satélites Landsat-8 e Sentinel-2. Isso permitiu a criação de mapas de uso do solo, com a definição de 9 classes para as classificações realizadas no software *eCognition* 9.0, utilizando o algoritmo multiresolution e 8 classes para as classificações realizadas a nível de *pixel* por *pixel*. Vale destacar que a classificação orientada por objetos apresentou os melhores resultados em termos de exatidão global e coeficiente *Kappa*. Segundo [Matias \(2019\)](#) o coeficiente *Kappa* é uma técnica multivariada discreta utilizada para avaliar a precisão da classificação de uma matriz. Além disso, atua como uma medida de concordância entre os totais das linhas e das colunas, aprimorando a coerência entre os dados classificados e os dados de referência. Para os dados do Landsat-8, a exatidão global atingiu 97% e o coeficiente *Kappa* atingiu 96%. Para os dados do Sentinel-2, esses valores foram de 95% para a exatidão global e 93% para o coeficiente *Kappa*.

Outra abordagem que obteve bons resultados foi a classificação orientada por segmentos, principalmente com os dados do Sentinel-2, onde a exatidão global alcançou 84% e o coeficiente *Kappa* foi de 78%. Em relação aos cálculos dos índices, o NDVI foi utilizado para distinguir entre vegetação saudável e vegetação seca. Os resultados indicaram que os dados do Sentinel-2 tiveram um desempenho superior e produziram melhores resultados para os índices NDMI (*Normalized Difference Moisture Index*) e NDWI (*Normalized Difference Water Index*) em comparação com os dados do Landsat-8.

No trabalho desenvolvido por [Braz et al. \(2017\)](#), foram realizadas comparações entre as classificações digitais de imagens provenientes dos satélites Landsat-8 (OLI) e Sentinel-2 (MSI). Essas comparações foram conduzidas utilizando o SIG *SPRING*, e vale ressaltar que não foram realizadas edições pós-classificatórias, mantendo-se,

assim, uma classificação 'crua'. O objetivo era validar os resultados de acordo com o potencial de classificação de uma das imagens de satélite.

Para a condução desse estudo, foram utilizadas imagens de radar dos satélites Landsat-8 (OLI) e Sentinel-2 (MSI), ambas imageadas em 2016. No processo de preparação das imagens, foi realizada uma fusão com a banda 8 (Pancromática) do Landsat-8 (OLI), resultando em uma imagem com resolução espacial de 15 metros. Por outro lado, as imagens do Sentinel-2 (MSI) possuíam uma resolução espacial de 10 metros. Para melhorar a qualidade visual das imagens, foram aplicadas técnicas de PDI (Processamento Digital de Imagens).

Após a classificação das imagens, os resultados foram submetidos à validação por meio dos índices de Exatidão Global e coeficiente *Kappa*. Importante destacar que ambas as classificações apresentaram resultados semelhantes e satisfatórios.

Na literatura, é possível encontrar diversos estudos que realizam comparações entre os sensores OLI/Landsat-8 e MSI/Sentinel-2. No entanto, quando se trata da detecção de fogo ativo em imagens do MSI/Sentinel-2, observa-se uma escassez de técnicas aplicadas até o momento. Na Tabela 3.1, são apresentados os principais trabalhos que se concentram na comparação de imagens obtidas por esses dois sensores, juntamente com informações relacionadas à utilização da rede *U-Net* e à detecção de fogo ativo.

3.5 Considerações finais

Neste capítulo, foram apresentados os principais estudos encontrados na pesquisa bibliográfica, juntamente com suas metodologias e os conjuntos de dados empregados para abordar problemas semelhantes ao que é tratado neste trabalho.

Esta dissertação se diferencia dos trabalhos revisados neste capítulo, pois propõe a utilização de uma rede neural convolucional do tipo *U-Net* para o treinamento com imagens obtidas do satélite Sentinel-2. Posteriormente, essa rede é usada para inferir imagens do satélite Landsat-8, com o objetivo de identificar focos de fogo ativo. Essa abordagem visa reduzir a dependência de um grande volume de imagens para a detecção de incêndios.

O processo é dividido em três etapas. Inicialmente, as classes de fogo ativo e não fogo ativo são segmentadas, e em seguida, a rede é treinada com essas informações. Posteriormente, a rede treinada é aplicada às imagens adquiridas pelo satélite Landsat-8.

Tabela 3.1 - Tópicos relacionados.

Autor	Trabalho	Metodologia	Dataset	Contribuições
Fusioka (2021)	Deteção de fogo ativo por aprendizado profundo em imagens provenientes do satélite Landsat-8	<i>U-Net</i>	220 GB de informação grande parte do globo	Menor dataset com imagens Sentinel-2 e Landsat-8
Pereira et al. (2012)	Estimativa da área de fogo ativo a partir da potência radiativa do fogo	Potência Radioativa do Fogo	79 imagens do Landsat	Utilização de técnica e satélites diferentes para estimar a área de fogo ativo
Bertoni e Feder (2018.)	Rede neural convolucional aplicada à visão computacional para deteção de incêndio	Rede Neural Convolucional (CNN)	500 imagens de fogo	Menor dataset e <i>U-Net</i>
Gontijo et al. (2011)	Deteção de queimadas e validação de focos de calor utilizando produtos de Sensoriamento Remoto	Índice de Vegetação por Diferença Normalizada (NDVI)	2 imagens Landsat 5	Satélites diferentes e <i>U-Net</i>
Nagai e Sou (2020)	Deteção de fogo e fumaça em vídeos usando remoção de fundo e Redes Neurais Convolucionais	Fire Smoke Detection Network arquitetura Xception	4481 quadros	Utilização de satélites e <i>U-Net</i>
Duarte et al. (2011)	Redes Neurais para identificação de padrões na deteção de queimadas na floresta amazônicas	Multi-Layer Perceptron (MLP)	990 imagens de vídeo	Imagens de satélites e <i>U-Net</i>
Santos et al. (2019)	Classificação de áreas queimadas por machine learning usando dados de sensoriamento remoto	RF, NN, KNN, DT e SVN	40.72 imagens de satélites Terra, Aqua e NPP	Menos dataset, satélites diferentes e <i>U-Net</i>
Oliveira (2020a)	Deep learning na segmentação automática de imagens de satélite	<i>U-Net</i>	1 imagem Sentinel-2	Dataset contendo imagens de diferentes biomas
Bragagnolo (2021)	Redes neurais totalmente convolucionais aplicadas à identificação de focos de desmatamento	<i>U-Net</i>	60 Imagens Sentinel-2 da Mata Atlântica e Amazônia	Utilização imagens de diferentes satélites e biomas
Oliveira (2020b)	Segmentação semântica de áreas de plantações agrícolas via <i>U-Net</i> em dois estágios	<i>U-Net</i>	1 imagem Sentinel-2 do Nordeste do Brasil	Dataset com imagens de focos de incêndio de diferentes biomas
Souza (2019)	Classificação de padrões em imagens sísmicas utilizando inteligência artificial	<i>U-Net</i>	Imagens sísmicas da Bacia de Sergipe-Alagoas	Utilização imagens de diferentes satélites e biomas
Calixto et al. (2017)	Análise comparativa em imagens oli/Landsat-8 e msi/Sentinel-2 no mapeamento do uso e cobertura da terra	K-Médias	OLI/Landsat-8 MSI/Sentinel-2	Dataset com imagens de fogo ativo e <i>U-Net</i>
Freires et al. (2019)	Comparação de imagens OLI/Landsat-8 e MSI/Sentinel-2 no mapeamento de cobertura e uso da terra no Maciço de Uruburetama, Ceará.	Algoritmo Bhattacharya	OLI/Landsat-8 MSI/Sentinel-2	Dataset com imagens de diferentes biomas e <i>U-Net</i>
Matias (2019)	Análise comparada das potencialidades e limitações dos dados Sentinel-2 e Landsat 8 para aplicações operacionais em ambiente e planejamento territorial.	NDMI e NDWI	OLI/Landsat-8 MSI/Sentinel-2	Inferir imagens de fogo ativo obtidas com Landsat em <i>U-Net</i> treinada com Sentinel-2
Braz et al. (2017)	Validação das classificações das imagens dos satélites Landsat 8 e Sentinel-2 na bacia hidrográfica do córrego Ribeirãozinho/MS	Processamento Digital de Imagem	OLI/Landsat-8 MSI/Sentinel-2	Inferir imagens de fogo ativo obtidas com Landsat em <i>U-Net</i> treinada com Sentinel-2

Além disso, este estudo se baseia em um conjunto de dados fornecido pelo CENSI-PAM (Centro Gestor e Operacional do Sistema de Proteção da Amazônia), acessado por meio do site Portal do Fogo, que abrange áreas onde ocorrem focos de incêndio.

4 TRABALHO EXPERIMENTAL

Neste capítulo, a metodologia é organizada de maneira sistemática para proporcionar uma compreensão do processo. Na Seção 4.1, contextualizo a área de estudo; a Seção 4.2 aborda o conjunto de dados. Aprofundando-se, a Subseção 4.2.1 descreve o processo de obtenção dos dados; a Subseção 4.2.2 apresenta as imagens da América do Sul, seguida pela Subseção 4.2.3, que destaca as imagens específicas da área de estudo. Detalho a rede implementada na Subseção 4.2.4, enquanto a Subseção 4.2.5 evidencia o procedimento de treinamento e pré-processamento dos dados. A Subseção 4.2.6 concentra-se nos detalhes do treinamento da U-NET. Concluindo, na Subseção 4.2.7, são apresentadas as métricas de avaliação.

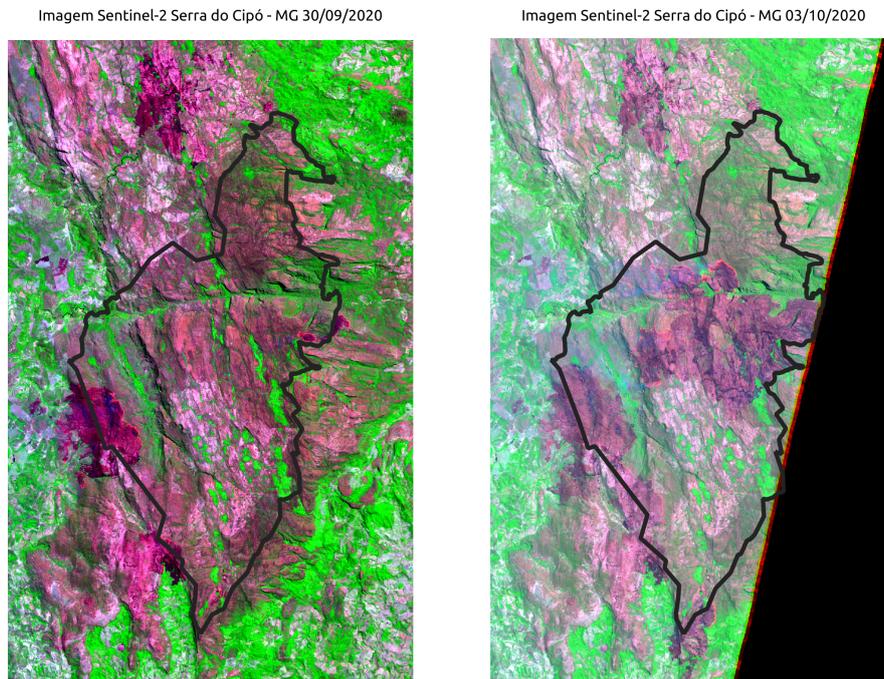
4.1 Área de estudo

O Parque Nacional da Serra do Cipó, localizado em Minas Gerais, teve sua origem em 1978 com o propósito de salvaguardar as nascentes do rio Cipó, preservar a biodiversidade exuberante dos campos rupestres e conter ameaças decorrentes da intervenção humana, como desmatamento, coleta excessiva de sempre-vivas e parcelamento do solo. Inicialmente estabelecido como o Parque Estadual da Serra do Cipó, conforme estipulado no Decreto nº 9.278 de 1978, o parque passou por uma transição e modificações em seus limites, resultando em sua reconfiguração como o Parque Nacional da Serra do Cipó, conforme determinado pelo Decreto nº 90.223 de 1984. Esse período testemunhou um aumento significativo na criação de UCs (Unidades de Conservação) durante a década de 1980 (MITTERMEIER et al., 2005) Figura 4.1.

Na região que abrange o PARNA (Parque Nacional) Serra do Cipó, situado entre as coordenadas 19°10'-19°40'S e 43°30'-43°55'W, estende-se uma extensão total de 31.617 hectares. É importante ressaltar que esse parque encontra-se completamente inserido na APA (Área de Proteção Ambiental) Morro da Pedreira, estabelecida em 1990, em âmbito federal, por meio do Decreto 98.891 de 1990. O decreto que instituiu a APA Morro da Pedreira deixou explícita a sua finalidade de atuar como uma zona de amortecimento destinada a proteger o Parque Nacional.

Em 2005, a UNESCO reconheceu a Reserva da Biosfera da Serra do Espinhaço, na qual o PARNA Serra do Cipó é designado como uma das áreas núcleo, juntamente com outras dez UCs de Proteção Integral. Atualmente, encontra-se em fase de análise um plano de expansão dos limites do parque, sob a jurisdição do ICMBio (Instituto Chico Mendes de Conservação da Biodiversidade) (INSTITUTO CHICO MENDES

Figura 4.1 - Progresso da área de queimada Serra do Cipó.



À esquerda imagem do dia 30/09/2020 ; à direita imagem do dia 03/10/2020.

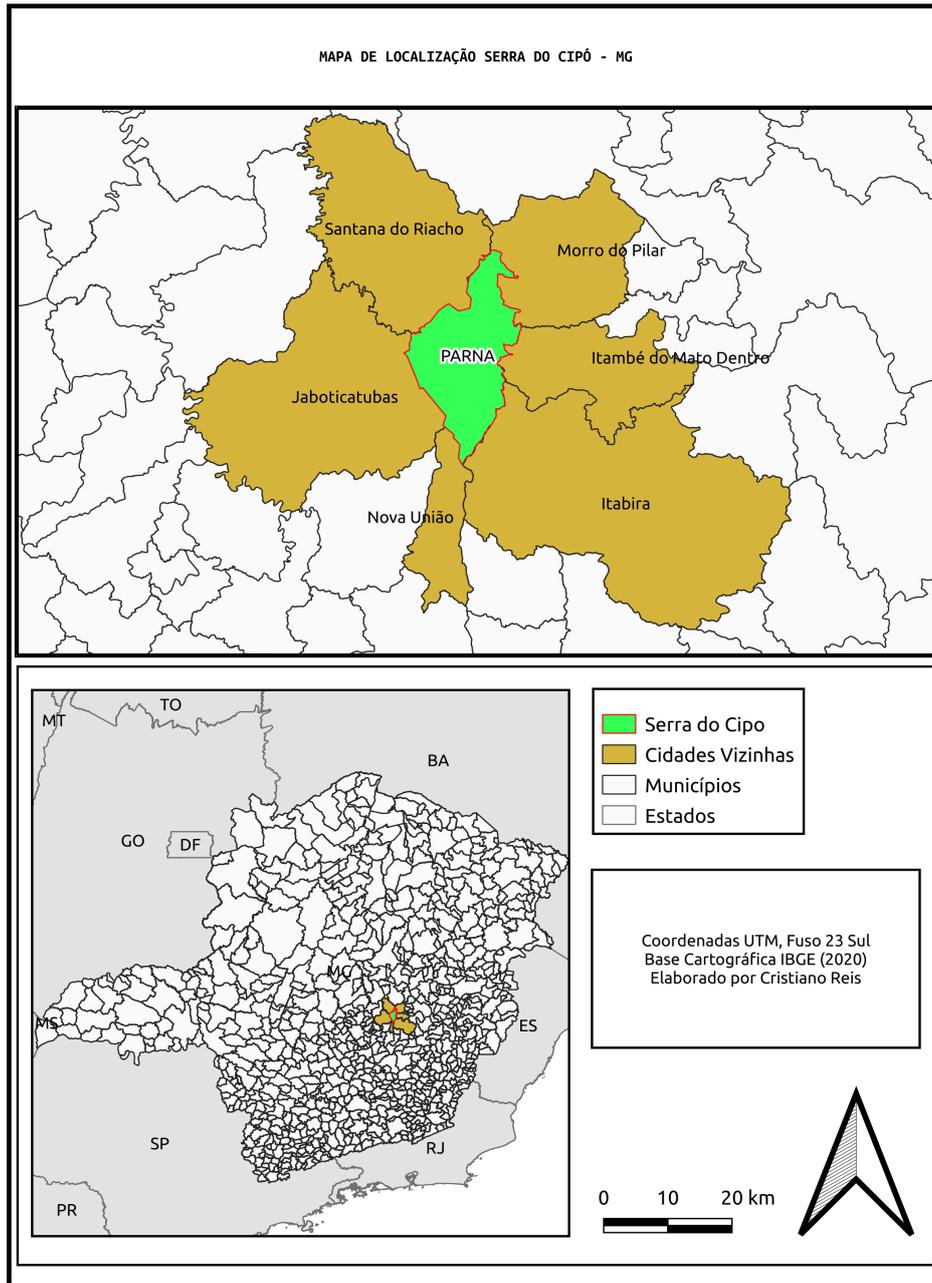
Fonte: Produção do autor.

DE CONSERVAÇÃO DA BIODIVERSIDADE (ICMBio), 2009).

A Serra do Cipó, ilustrada na Figura 4.2, constitui a seção meridional da Cadeia do Espinhaço, uma extensa cordilheira que abrange aproximadamente 1000 quilômetros, estendendo-se desde a região metropolitana de Belo Horizonte até a Chapada Diamantina, situada no estado da Bahia.

Essa área desempenha o papel de divisor de águas, segregando as bacias hidrográficas dos rios São Francisco e Doce. Na porção ocidental das serras, as escarpas se apresentam de forma linear e predominantemente compostas de quartzitos, e a rede de drenagem nessa região está intrinsecamente ligada à bacia do rio São Francisco. Em contraste, na porção oriental, a Serra do Cipó perde a característica de escarpas contínuas, dando lugar a escarpas descontínuas, como documentado por (ALMEIDA, 2005). Em virtude do relevo altamente acidentado da região, os parâmetros climáticos variam amplamente, com altitudes oscilando entre 800 e 1670 metros.

Figura 4.2 - Localização da área de estudo.



Superior localização regional; inferior localização no estado.

Fonte: Produção do autor.

A região delimitada pelo PARNA exibe características climáticas enquadradas na categoria de clima tropical de altitude com verões amenos, conforme definido pela classificação de Köppen (Cwb). Conseqüentemente, essa área registra verões com

índices pluviométricos consideráveis e invernos caracterizados pela baixa precipitação, com o período de chuvas predominantemente compreendido entre os meses de novembro a março, conforme indicado por (SANTOS et al., 2011b).

Mais precisamente, o clima na região pode ser descrito como subtropical moderado úmido, caracterizado por um déficit hídrico anual que pode atingir até 60 mm durante a estação seca. As médias anuais de temperatura oscilam entre 17 e 18,5 °C, enquanto as médias anuais de precipitação pluviométrica variam entre 1.450 e 1.800 mm, originando uma evapotranspiração potencial anual que se situa entre 700 e 850 mm. Vale mencionar que dados meteorológicos coletados na estação de Conceição do Mato Dentro apontam para uma temperatura média anual de 20,8 °C e uma média anual de precipitação de 1.622 mm (ALMEIDA, 2005).

A rica diversidade vegetal que se desdobra no âmbito do Parque Nacional da Serra do Cipó é uma característica que abarca diversas biocenoses, com especial destaque para a prevalência da formação do cerrado. A paisagem que se desenha na região do Parque é marcada por um extenso mosaico de variados ecossistemas vegetais, que se diferenciam quanto à composição florística, estrutura e aspecto. Essa heterogeneidade é notoriamente influenciada pela elevação altimétrica da área e pela ampla diversidade de tipos de solo que ali se intercalam. Enquanto na porção ocidental do Parque é possível encontrar espécies típicas do Cerrado, na porção oriental, as características assemelham-se à vegetação da Mata Atlântica, conforme documentado por Parque Nacional da Serra do Cipó (2000).

4.2 Conjunto de dados

Foram empregados dois conjuntos de imagens distintos neste estudo: um conjunto que abrange diversas regiões da América do Sul, contendo não apenas as imagens de treinamento, mas também as máscaras de segmentação. A utilização desse conjunto teve como objetivo a construção de um banco de dados sólido que engloba imagens e rótulos de áreas com ocorrências de incêndios em diversos biomas. Além disso, buscou-se validar o processo de geração das máscaras de segmentação. O segundo conjunto de dados consiste em imagens da região da Serra do Cipó e representa o conjunto de dados central desta dissertação.

4.2.1 Obtenção dos dados

Com o objetivo de obter informações de campo precisas, o site <<https://panorama.sipam.gov.br/painel-do-fogo/>> foi utilizado para identificar as coordenadas exatas

de latitude e longitude dos focos de incêndio. Este site fornece dados abrangentes para todo o Brasil e uma parte significativa da América do Sul, possibilitando a aquisição dos dados necessários para a pesquisa.

Para obtenção das imagens, utilizamos o site <<https://www.sentinel-hub.com/>>, que fornece ferramentas para filtrar imagens com base na cobertura de nuvens, pesquisar por coordenadas geográficas e fazer o download apenas das bandas e tamanhos necessários para a realização do experimento. Essa plataforma facilitou uma abordagem eficiente e personalizada na aquisição das imagens necessárias, resultando em uma otimização do conjunto de dados.

Para conduzir os experimentos, foram criados dois conjuntos de dados, totalizando aproximadamente 650 MB de imagens combinadas, abrangendo diversas regiões do Brasil e da América do Sul. Esses conjuntos de dados consistem em fragmentos de imagens adquiridos pelos satélites Sentinel-2 e Landsat-8. Cada imagem original foi dividida em sub-imagens de tamanho 64x64 pixels, sem sobreposição. As sub-imagens estão em formato TIFF (*Tag Image File Format*) de 8 bits e possuem duas bandas, com resolução espacial de 10 metros para imagens do Sentinel-2 e 30 metros para imagens do Landsat-8.

É relevante mencionar que as imagens disponíveis no conjunto de dados correspondem às bandas 11 e 12 do Sentinel-2, bem como às bandas 6 e 7 capturadas pelo satélite Landsat-8. Essas bandas foram escolhidas devido às suas similaridades espectrais.

As imagens referentes à área de estudo, em um total de 40MB, datam do dia 30/09/2020 e foram obtidas por meio do satélite Landsat-8. Este conjunto de dados consiste em recortes das imagens originais, onde cada imagem original foi subdividida em imagens de tamanho 64x64 pixels, sem sobreposição. Essas imagens estão no formato TIFF de 8 bits e possuem as bandas 6 e 7, com uma resolução espacial de 30 metros.

4.2.2 Conjunto de dados: imagens da América do Sul

Para conduzir os experimentos, foram criados dois conjuntos de dados, totalizando aproximadamente 650 MB de imagens combinadas. Visando garantir a representatividade e abrangência do conjunto de dados, selecionamos cuidadosamente diversas imagens. Essas imagens abrangem uma variedade de características de diversos biomas, como Cerrado, Caatinga, Pantanal, Floresta Amazônica, bem como casos de

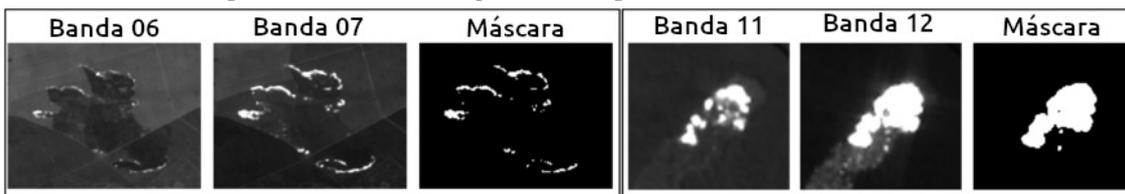
grandes incêndios no Chile e áreas urbanas em desenvolvimento.

Esses conjuntos de dados consistem em fragmentos de imagens adquiridos pelos satélites Sentinel-2 e Landsat-8. Cada imagem original foi dividida em sub-imagens de tamanho 64x64 pixels, sem sobreposição. As sub-imagens estão em formato TIFF de 8 bits e possuem duas bandas, com resolução espacial de 10 metros para imagens do Sentinel-2 e 30 metros para imagens do Landsat-8.

Usando um algoritmo de limiarização, máscaras relacionadas aos focos de incêndio ativos serão geradas a partir do conjunto de dados fornecido. Essas máscaras são obtidas aplicando um limite mínimo de valor de pixel de 140 nas imagens de ambos os satélites, permitindo a identificação e separação das áreas com incêndios ativos nas imagens.

A Figura 4.3 ilustra exemplos de imagens disponíveis no conjunto de dados utilizado, acompanhadas por máscaras geradas pelos algoritmos. Pode-se observar que, embora os algoritmos frequentemente identifiquem a presença de incêndios ativos, existem diferenças significativas em relação à existência de pixels com focos de incêndio e àqueles não identificados nas máscaras. Essa variação nos resultados enfatiza a importância de uma análise minuciosa e compreensão das limitações inerentes aos algoritmos empregados, visando à interpretação adequada das informações relacionadas a incêndios florestais e outras áreas de interesse.

Figura 4.3 - Visualização de imagens de entrada da U-Net.



À esquerda Landsat-8 (bandas 06 e 07), localizadas em (-3.1663, -54.6760), Santa F  no estado do Piau  e sua m scara;   direita Sentinel-2 (bandas 11 e 12), localizadas em (-6,81882, -59,38366), Apu  no estado do Amazonas e sua m scara.

Fonte: Produ o do autor.

Essa abordagem resultou na cria o de um conjunto de dados definitivo, abrangendo um total de 123 imagens capturadas entre 2021 e 2023.

Por meio dessa estrat gia, foi poss vel construir um conjunto de dados que seja

representativo e abrangente, estabelecendo assim uma base sólida para a eficácia e validade dos resultados obtidos em nosso estudo.

4.2.3 Conjunto de dados: área de estudo

O segundo conjunto de dados utilizou imagens da região da Serra do Cipó, situada em Minas Gerais, a qual abrange os municípios de Jaboticatubas, Santana do Riacho, Morro do Pilar e Itambé do Mato Dentro. As imagens foram adquiridas por meio do satélite Landsat-8, acessado no site <<https://www.sentinel-hub.com/>>, com data de aquisição em 29 de Setembro de 2020.

Foram selecionadas e empregadas 15 imagens, com duas bandas espectrais, nomeadamente a B06 e a B07, com uma resolução espacial de 30 metros. Essas imagens foram recortadas em 2330 *patches* de 64x64, sem sobreposição e disponibilizadas em um formato TIFF de 8-bits conforme ilustrado na Figura 4.4. Essas imagens correspondem a aproximadamente 40 MB do conjunto de dados.

Figura 4.4 - Exemplo de imagens de teste da Serra do Cipó.



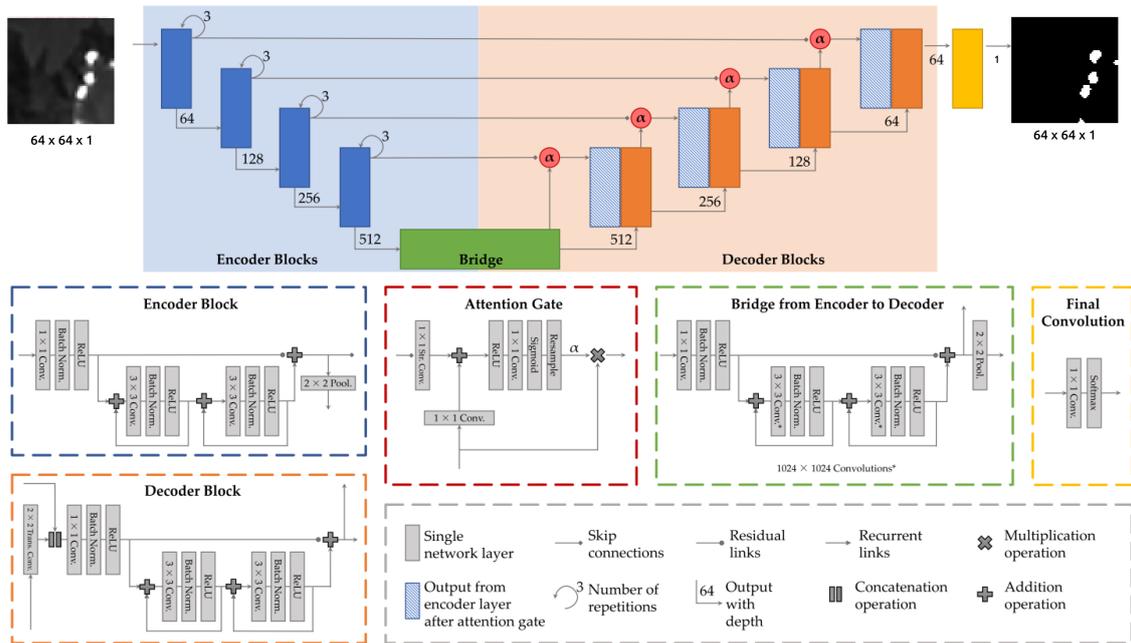
Imagens de teste Landsat-8.

Fonte: Produção do autor.

4.2.4 Descrição da rede implementada

As redes neurais oferecem uma abordagem genérica para encontrar soluções adequadas em problemas de previsão numérica ou classificação categórica. Suas aplicações abrangem uma ampla gama de áreas, desde a biomedicina até o Sensoriamento Remoto, adaptando-se às diversas distribuições numéricas e complexidades estatísticas, como ilustrado na Figura 4.5.

Figura 4.5 - U-Net queimadas.



Fonte: Adaptado de Glänzer et al. (2023).

A arquitetura de CNN proposta foi devidamente implementada e submetida a testes a fim de avaliar sua capacidade de se aproximar dos resultados observados no Painel do Fogo.

Os recortes das imagens do conjunto de dados foram segregados em dois conjuntos distintos. O primeiro conjunto abrangia imagens que representavam uma extensa área da América do Sul e foi empregado para o treinamento, validação e teste da rede *U-Net*. Por outro lado, o segundo conjunto compreendia exclusivamente imagens relacionadas à área de estudo, sendo utilizado para a condução de experimentos de teste.

Os experimentos foram conduzidos em um sistema computacional equipado com um processador Intel Core i5, 22 GB de memória RAM (*Random Access Memory*) e executando um sistema operacional Linux. O desenvolvimento do código foi realizado utilizando a linguagem de programação Python, com a utilização das bibliotecas TensorFlow e Keras. As arquiteturas foram treinadas empregando o otimizador Adam, com uma taxa de aprendizado de 0,001, um tamanho de lote (*batch*) igual a 10, e a função de perda de entropia binária cruzada (*binary cross entropy*). O treinamento foi conduzido ao longo de 20 épocas, ou até que não houvesse melhora na função de perda sobre o conjunto de testes por pelo menos cinco épocas consecutivas.

Para avaliar a extensão da área afetada pelo incêndio, conduzimos uma contagem dos *pixels* com valor igual a 1, multiplicando o resultado por 10, considerando que cada *pixel* da imagem representa 10 metros quadrados.

Quanto à identificação do ponto central da região afetada pelo fogo, calculamos a latitude e a longitude de todos os pontos com registros de incêndio e, em seguida, calculamos a média dessas coordenadas.

4.2.5 Tratamento e pré-processamento dos dados

O sistema é composto por três fases distintas: inicialmente, montamos um conjunto de dados com 70 imagens de alta resolução espacial da banda *SWIR* do satélite Sentinel-2 para treinar o modelo *U-Net*. Além disso, selecionamos 30 imagens do Sentinel-2 para testes, juntamente com 23 cenas da banda *SWIR* do satélite Landsat-8 para validar o modelo.

Durante a fase de pré-processamento, foi realizada a extração das imagens para um diretório designado, tomando o cuidado de renomear cada imagem para evitar possíveis conflitos de nomes. Após a conclusão dessa etapa, procedemos com a criação de máscaras, utilizando a análise da banda 12 do Sentinel-2 e da banda 7 do Landsat-8, aplicando um limiar de 140 para esse fim.

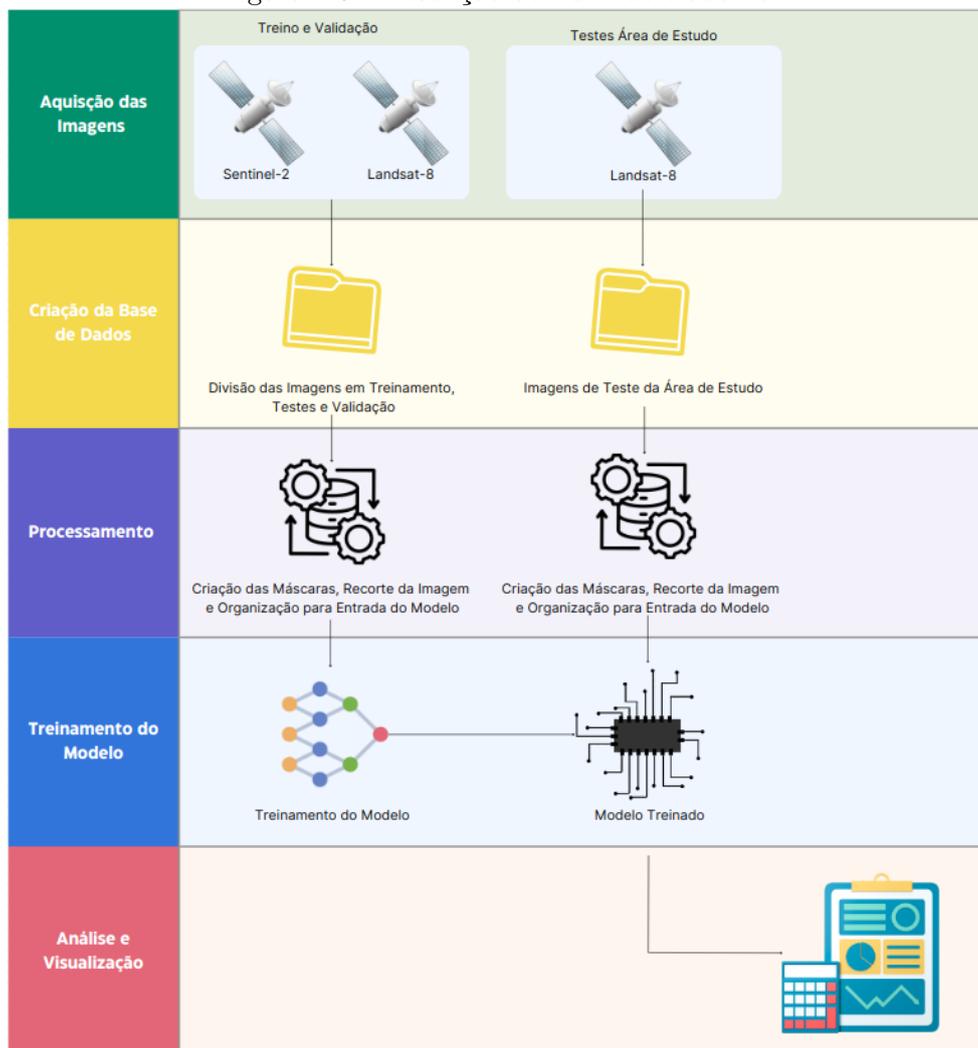
Após a etapa de geração das máscaras, foi realizada uma operação de binarização das imagens, identificando *pixels* relacionados a focos de incêndio, marcados com o valor 1, enquanto toda a área restante da imagem recebeu o valor 0.

A conclusão da fase de pré-processamento envolve o recorte das imagens, preservando os dados de georreferenciamento. A fim de garantir uniformidade no tamanho das imagens, foi necessário realizar o redimensionamento para um formato de 64x64 *pixels*, assegurando uma análise coerente e consistente, como ilustrado na Figura 4.6.

4.2.6 Treinamento da *U-Net*

Para treinar o modelo *U-Net*, utilizou-se um conjunto de dados composto por 2069 imagens (471 da classe 0 e 1598 da classe 1). Iniciamos dividindo aleatoriamente o conjunto de imagens de focos de incêndio obtido do Sentinel-2 em três subconjuntos independentes: um conjunto de treinamento, um conjunto de validação (que compreende 70% das imagens) e um terceiro conjunto designado para testes (30%).

Figura 4.6 - Descrição do fluxo de trabalho.



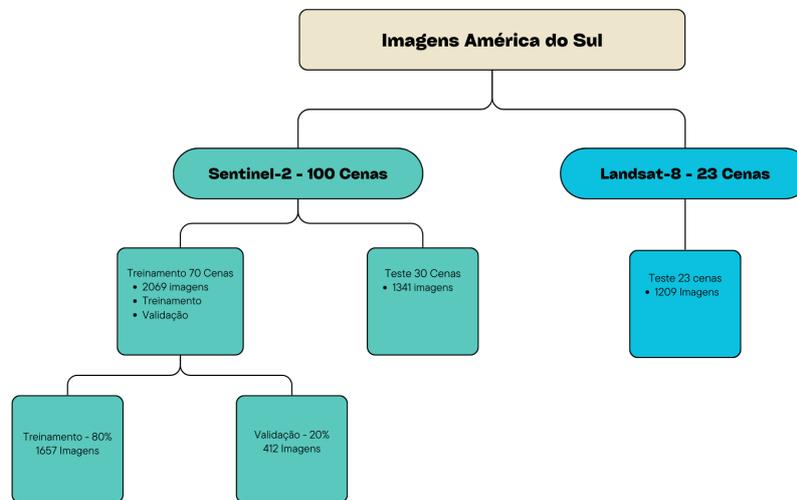
Fonte: Produção do autor.

O conjunto de treinamento é essencial para que o modelo aprenda padrões e relações nos dados. O conjunto de validação desempenha um papel crítico na avaliação dos resultados durante o treinamento e no ajuste dos hiperparâmetros. Por fim, o último subconjunto é reservado para testar o modelo com imagens que não foram vistas durante o treinamento. Este conjunto de testes é fundamental para avaliar como o modelo se comporta em cenários do mundo real.

Para a fase de testes do modelo *U-Net*, utilizamos 1657 imagens para o conjunto de treinamento (representando 80% do conjunto de dados total), 412 imagens para o conjunto de validação (20% do conjunto de dados total) e 1341 imagens para o conjunto de teste (30% do total de imagens disponíveis), conforme ilustrado na

Figura 4.7.

Figura 4.7 - Divisão das imagens de treinamento.



Fonte: Produção do autor.

4.2.7 Experiências para afinar a rede

No estágio inicial da busca pela estrutura ideal de rede para a segmentação, uma série de experimentos foi conduzida visando otimizar a eficácia da rede. Variações dos parâmetros, como otimizador, taxa de aprendizagem e tamanho do batch, foram avaliadas.

Essas experimentações foram realizadas utilizando o conjunto de dados proveniente do satélite Sentinel-2, com imagens capturadas na região da América do Sul. O conjunto de treinamento foi especificamente empregado para avaliar a capacidade da rede em identificar focos de incêndio. Dessa forma, foi possível selecionar os valores mais apropriados para os diversos parâmetros, aprimorando assim o desempenho global da rede.

Em relação ao número de épocas empregadas no processo de treinamento, foi implementado o mecanismo de Early Stopping. Esse método consiste em encerrar o processo de treino quando não há diminuição na validação do erro de reconstrução após um determinado número de épocas, N . Para este estudo, definiu-se que, caso a validação não apresentasse redução ao longo de 5 épocas consecutivas, o treinamento seria interrompido. Além disso, se essa condição não fosse atendida após 150 épocas,

o treinamento seria finalizado.

É importante ressaltar que esse mecanismo não foi aplicado nas experimentações destinadas à determinação do otimizador e da taxa de aprendizagem ideais. Nesse contexto, optou-se por um treinamento de 15 épocas, considerando a possibilidade de a rede exigir um tempo prolongado para convergir, o que resultaria em um investimento excessivo de tempo em parâmetros que eventualmente não seriam adotados.

Nas próximas seções, serão detalhadas as experimentações realizadas com o intuito de refinar a rede da forma mais eficaz, incluindo os valores selecionados que resultaram na otimização da rede.

4.2.7.1 Tamanho do lote

O tamanho do lote (batch) está diretamente relacionado ao número de exemplos do conjunto de dados utilizados em cada iteração do ciclo de treino. Quanto menor esse valor, maior é o número de exemplos por iteração, resultando em um tempo mais extenso para cada ciclo. Diversas experimentações foram conduzidas, variando o tamanho do lote para observar os efeitos dessas alterações nos resultados da rede. Contudo, os resultados obtidos revelaram-se bastante similares, tanto no que diz respeito às imagens de reconstrução quanto às imagens segmentadas. A principal diferença observada estava no tempo de treinamento da rede; ou seja, com um valor de lote maior, a rede exigia menos tempo para treinar, conforme era previsto.

Testes foram realizados com diferentes tamanhos de lote, incluindo 2, 4, 8, 10 e 16. O valor selecionado para este parâmetro da rede foi 10. Limitações de hardware impediram a utilização de um valor ainda maior, no entanto, é recomendável, sempre que possível, aumentar esse valor.

4.2.7.2 Otimizador e taxa de aprendizagem

Os otimizadores desempenham um papel fundamental na adaptação dos atributos da rede neural, como os pesos (parâmetros da rede adquiridos durante o treinamento), com o objetivo de minimizar a função de perda, proporcionando assim uma melhoria na eficiência do aprendizado. Em contrapartida, a taxa de aprendizagem é um hiperparâmetro associado ao otimizador, desempenhando o papel de regulador na velocidade com que a rede absorve conhecimento. Portanto, trata-se de um valor predefinido antes do início do treinamento, permanecendo constante durante todo o processo. Conseqüentemente, a avaliação conjunta do otimizador e da taxa de aprendizagem foi conduzida, considerando que a segunda é um hiperparâmetro

intrínseco ao primeiro.

Esta fase experimental teve como meta identificar o otimizador e a taxa de aprendizagem que melhor se adequassem aos dados em análise. Dois otimizadores distintos foram selecionados para comparação: Adam e SGD com momentum. A escolha primária do Adam baseou-se em sua eficiência. Contudo, em situações em que o Adam pode apresentar desafios de convergência, o SGD com momentum demonstra, uma capacidade superior, requerendo apenas um aumento no tempo de treinamento. Assim, o SGD com momentum foi escolhido como o segundo otimizador.

O momentum tem como objetivo principal acelerar o processo de treinamento do modelo e atenuar oscilações. Para este hiperparâmetro, foram considerados dois valores: 0.5 e 0.9. Embora seja possível ajustar o momentum no otimizador Adam, optou-se por não o fazer.

Por fim, foram selecionados os seguintes valores para a taxa de aprendizagem: 0.005, 0.003, 0.001, 0.05, 0.03, 0.01, 0.1, 0.3, 0.5, 0.9.

Tabela 4.1 - Resultados - Otimizador e Taxa de Aprendizagem

SGD		Adam	Sentinel-2	Canais
Taxa de Aprendizagem	Momento	Taxa de Aprendizagem	Função de Perda de Reconstrução	Função de Perda de Reconstrução
0.01	0.9	0.01	1.0562	-
0.1	0.9	0.1	67.32	-
0.5	0.9	0.5	34.75	-
0.9	0.9	0.9	37.47	-
0.1	0.5	0.1	20.9	-
0.5	0.5	0.5	53.75	-
0.9	0.5	0.9	56.80	-
0.005	-	0.005	0.5375	1.547
0.003	-	0.003	0.2784	0.4668
0.001	-	0.001	0.1458	0.4354
0.05	-	0.05	2.073	0.933
0.03	-	0.03	0.8558	-
0.01	-	0.01	0.7325	0.6871
0.1	-	0.1	5.414	-
0.3	-	0.3	54.74	-

Fonte: Produção do autor.

Nessas experiências, ao invés de adotar a técnica de Early Stopping mencionada anteriormente, foi estabelecido o número de épocas como sendo igual a 50. Essa escolha decorre da preocupação de que, ao empregar o Early Stopping, a rede poderia não atingir a convergência devido a inadequações no otimizador ou na taxa de aprendizagem. Portanto, optou-se por garantir que o treinamento não se prolongasse desnecessariamente ao tentar ajustar uma rede que não convergiria. Durante este conjunto de experimentos, os demais parâmetros permaneceram inalterados: o

número de classes foi fixado em 2, os filtros utilizados foram 64, 128, 256 e 512, e o tamanho do lote (batch) foi mantido constante em 10 imagens.

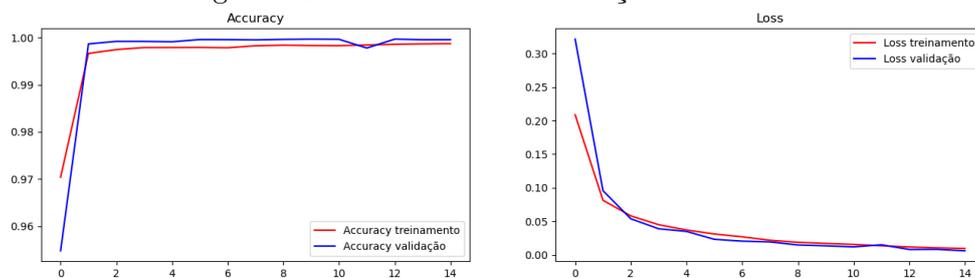
Na Tabela 4.1, encontram-se os valores obtidos da função de perda de reconstrução obtidos após 50 épocas com os diferentes conjuntos de dados, otimizadores, taxas de aprendizagem e momentum selecionados.

Após 50 épocas, a rede treinada com o otimizador SGD com momentum demonstrou uma aprendizagem limitada, evidenciada pela leve redução na função de perda de reconstrução ao longo das épocas. Em contraste, ao empregar o otimizador Adam, a rede exibiu um progresso significativo, refletido na diminuição da função de perda de reconstrução.

Ao comparar os valores da função de perda de reconstrução obtidos com o SGD e o Adam, notamos que os resultados alcançados com o primeiro otimizador são superiores em comparação com o segundo. Dessa forma, concluímos que, para o contexto específico desta dissertação, o otimizador Adam se adapta de maneira mais eficaz aos dados em consideração, sendo, portanto, a escolha preferencial.

Ao analisar os resultados apresentados pela rede e na Tabela 4.1 em relação à taxa de aprendizagem, concluímos que, para uma taxa de aprendizagem de 0.001, alcançamos o valor mais baixo entre todas as taxas consideradas. Por essa razão, essa taxa de aprendizagem foi selecionada como a mais apropriada. Juntamente com o tamanho de lote de 64 imagens e 15 épocas para o teste após a escolha dos hiperparâmetros. A escolha de 15 épocas foi feita considerando um equilíbrio entre a complexidade do algoritmo e a qualidade do modelo, uma vez que um número maior de épocas não resultou em melhorias significativas no desempenho em relação à complexidade, conforme ilustrado na Figura 4.8.

Figura 4.8 - Treinamento e validação do modelo.



À esquerda acurácia; à direita a perda
Fonte: Produção do autor.

Na Tabela 4.2 estão presentes os hiperparâmetros adotados para os testes e caracterização da rede.

Tabela 4.2 - Valores dos hiperparâmetros do modelo de classificação.

Hiperparâmetros de Teste	Valores
Épocas	15
Tamanho do Lote	10
Função de Perda	Binary Cross Entropy
Optimizador	Adam
Inicializador dos Pesos	He normal
Tamanho das Imagens	64 x 64
Função de Ativação	ReLU / Sigmoid
Dimensões do Filtro	3 x 3
Padding	Same

Fonte: Produção do autor.

4.2.8 Métricas de avaliação

O modelo foi submetido à avaliação, na qual foi comparado o resultado final da segmentação com a classificação de focos de incêndio em imagens em que o classificador não havia visto previamente.

Nessa avaliação, cada *pixel* pode ser categorizado como verdadeiro positivo (VP) ou falso positivo (FP), quando é classificado corretamente ou incorretamente como pertencente à classe em questão. Em relação aos *pixels* de fundo, eles podem ser denominados verdadeiros negativos (VN) ou falsos negativos (FN).

Foram utilizadas métricas específicas para realizar essa avaliação, incluindo o *F1-score*, *recall* e precisão. Essas métricas foram obtidas por meio do método *classification-report* da biblioteca Scikit-Learn, que calcula essas métricas em nível de *pixel* e fornece os resultados na forma de um relatório.

O *F1-Score* exemplificado na fórmula (4.1), é uma média ponderada da precisão e do *recall*, atribuindo igual peso a ambos os valores. Ele varia de 0 a 1, sendo que valores mais próximos de 1 indicam uma segmentação mais próxima do resultado esperado.

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4.1)$$

A métrica de *recall* avalia diretamente a semelhança entre a segmentação obtida e a máscara previamente definida. Isso ocorre porque, ao interpretar a fórmula de cálculo (4.2), o *recall* é a fração dos verdadeiros positivos (VP) em relação à união dos verdadeiros positivos (VP) e dos falsos negativos (FN). Portanto, o *recall* mensura a capacidade do modelo em identificar todos os verdadeiros positivos.

$$Recall = \frac{VP}{VP + FN}. \quad (4.2)$$

A métrica de precisão (4.3) avalia a habilidade do modelo em classificar um pixel positivo como negativo, ou seja, corresponde à fração dos verdadeiros positivos (VP) em relação à união dos verdadeiros negativos (VN) e dos falsos negativos (FN).

$$Precision = \frac{VP}{VP + FP}. \quad (4.3)$$

Além disso, foi empregada a métrica de Intersecção Sobre União, também conhecida como *Intersection Over Union* (IoU) (SAUL et al., 2005) ou índice de Jaccard. Essa métrica é definida por:

$$IoU = \frac{VP}{VP + FN + FP}. \quad (4.4)$$

5 RESULTADOS E DISCUSSÃO

O modelo *U-Net*, treinado com imagens do Sentinel-2, demonstrou equilíbrio entre eficiência de treinamento e precisão na detecção de pontos de calor de incêndio, como ilustrado nas Figuras 5.1 e 5.2. Avaliamos o desempenho da rede em conjuntos de dados de teste que incluíam imagens do Sentinel-2, Landsat-8 e TERRA/AQUA, realizando 15 execuções do modelo para criar um classificador de conjunto. Os testes do conjunto produziram resultados significantes, com *precision* média de 97,98%, embora tenham ocorrido cinco classificações incorretas entre as 15 execuções. A precisão final para as imagens do Sentinel-2 alcançou 97,73%, com um *Recall* de 88,18% e um *F1-Score* de 92,71%.

Para os testes com imagens do Landsat-8, a *precision* geral atingiu 90,22%, enquanto o modelo de conjunto alcançou um *Recall* de 90,24% e um *F1-Score* de 90,14%, enfatizando a alta confiabilidade do modelo. Os resultados da análise baseados nas métricas de desempenho estão apresentados nas Tabelas 5.1, 5.2 e 5.3.

Tabela 5.1 - Resultados obtidos na validação e no teste do modelo.

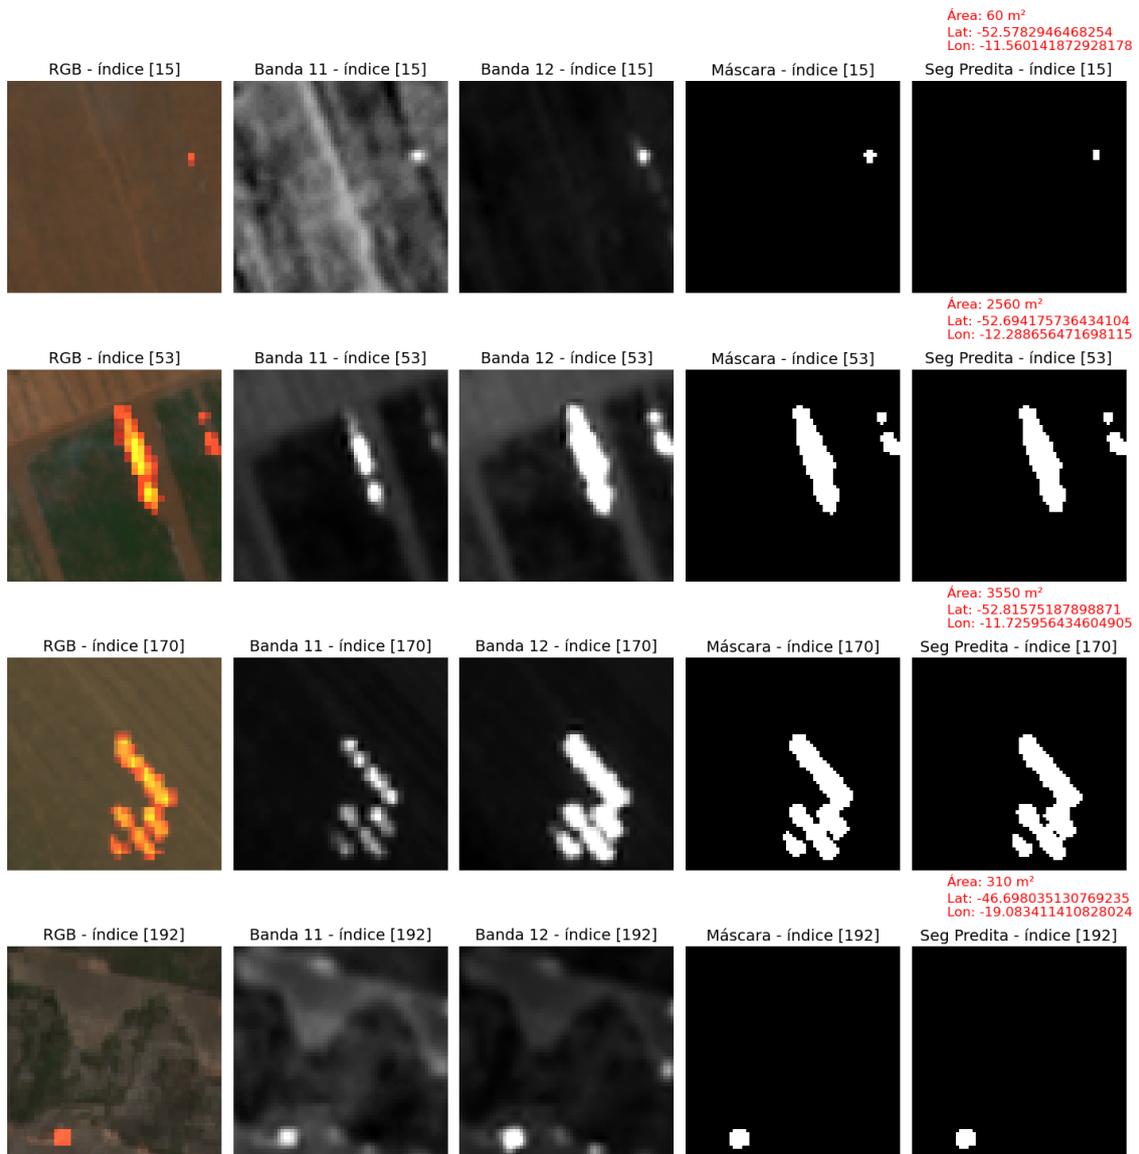
Sentinel-2			
Métricas	Pr	Re	F1
Validação	0.9798	0.9155	0.9466
Teste	0.9773	0.8818	0.9271

Tabela 5.2 - Resultados obtidos nos testes do modelo.

Métricas	Landsat-8			Sentinel-2 / Landsat-8		
	Pr	Re	F1	Pr	Re	F1
Teste	0.9022	0.9038	0.9030	0.9003	0.9024	0.9014

Os erros de classificação podem decorrer da variação inerente nas cenas dentro da mesma classe, abrangendo diferentes tipos de anomalias de incêndio e áreas sem tais anomalias. É importante notar que essas cenas são selecionadas aleatoriamente para compor o conjunto de treinamento, o que pode levar a desequilíbrios nos dados de treinamento, como uma representação desproporcional de anomalias de incêndio na classe 1 ou uma prevalência de imagens com iluminação mais intensa do que condições nubladas na classe 0, influenciando assim o desempenho do modelo *U-Net*. Portanto, adotamos a abordagem de conjunto, que permite resultados mais

Figura 5.1 - Imagens de teste com Sentinel-2.



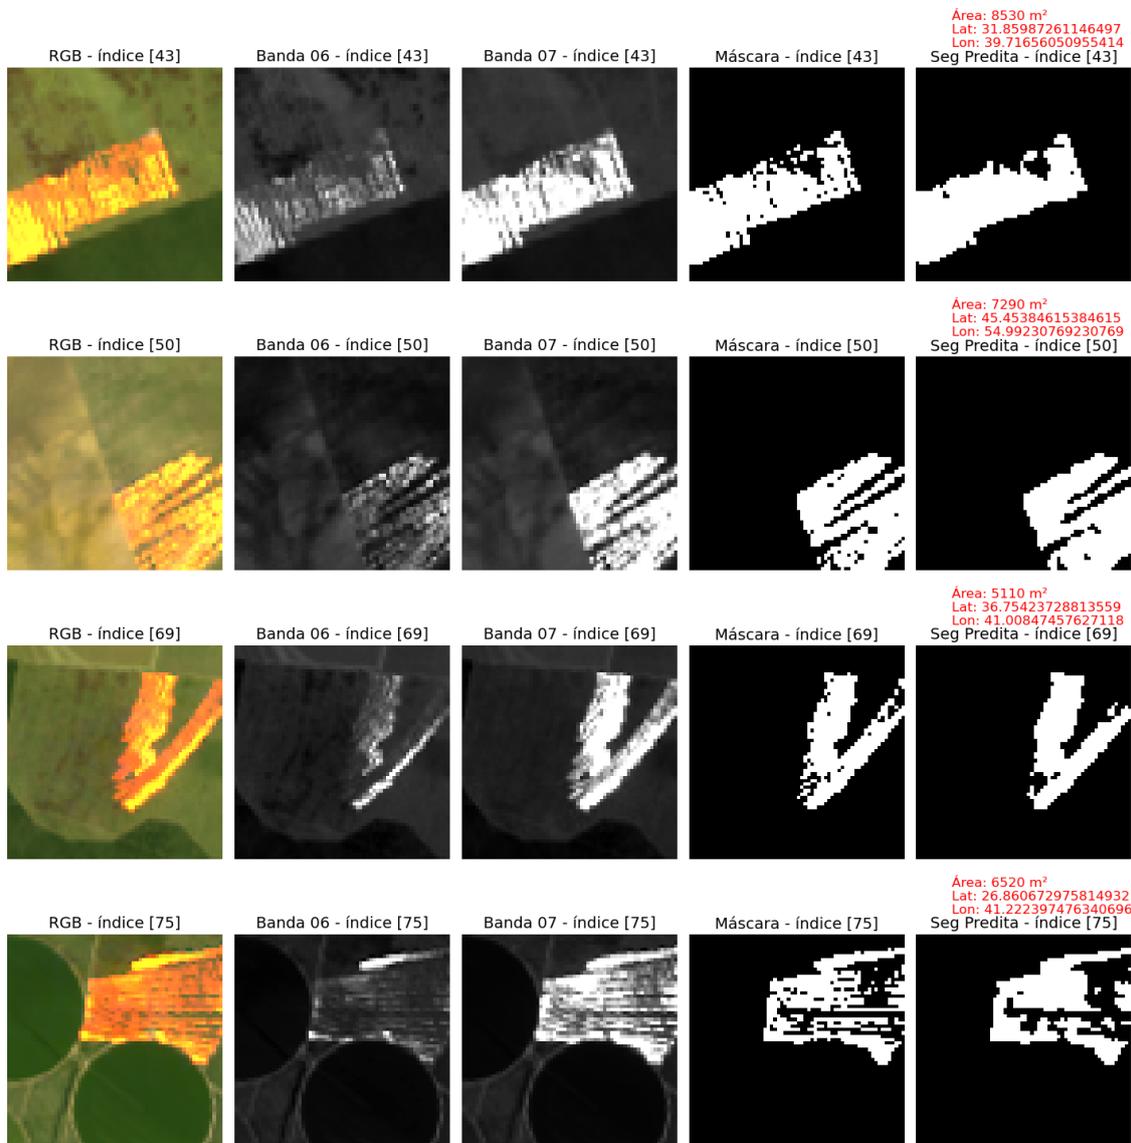
Conjunto de imagens: entrada e previsão da Rede Neural para Sentinel-2, juntamente com a localização e área da frente de fogo.

Fonte: Produção do autor.

robustos com um conjunto de dados reduzido, mantendo, ao mesmo tempo, uma alta capacidade de generalização.

Ao considerar os resultados do conjunto *U-Net*, apenas as cenas nas Figuras 5.4 e 5.5 permanece classificada incorretamente. Contudo, é importante ressaltar que essa imprecisão está relacionada à presença de cobertura de nuvens, e não à fumaça ge-

Figura 5.2 - Imagens de teste com Landsat-8.



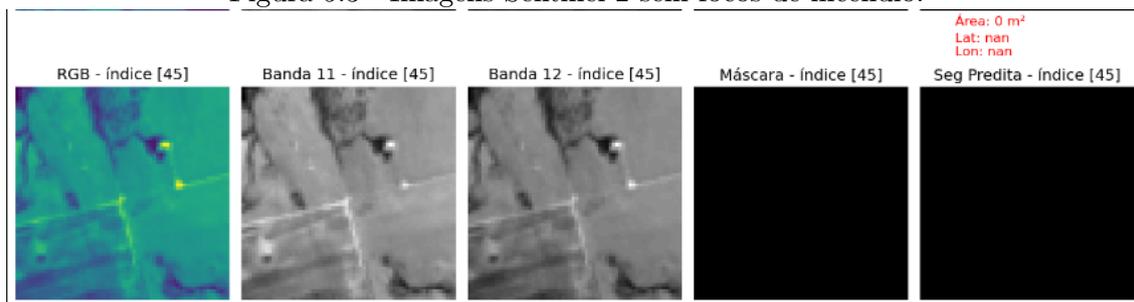
Conjunto de imagens: entrada e previsão da rede neural para Landsat-8, juntamente com a localização e área da frente de fogo.

Fonte: Produção do autor.

rada pelo incêndio. Isso sugere uma complexidade adicional quando há interferência de cobertura de nuvens.

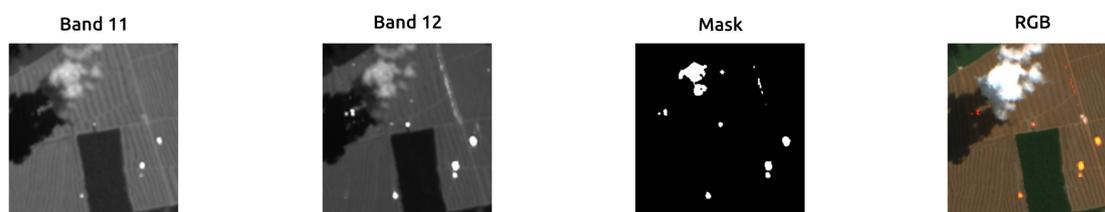
A U-Net empregada também demonstra a capacidade de não identificar focos de incêndio na ausência de ocorrências dos mesmos, conforme evidenciado na Figura 5.3.

Figura 5.3 - Imagens Sentinel-2 sem focos de incêndio.



Fonte: Produção do autor.

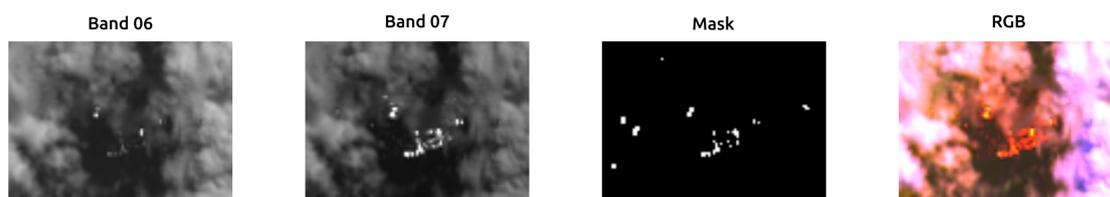
Figura 5.4 - Imagens Sentinel-2 com nuvens.



Imagens Sentinel-2 ilustram erro na criação da máscara atribuível à cobertura de nuvens na região.

Fonte: Produção do autor.

Figura 5.5 - Imagem Landsat-8 com nuvens.



Imagens Landsat-8 ilustram erro na criação da máscara atribuível à cobertura de nuvens na região.

Fonte: Produção do autor.

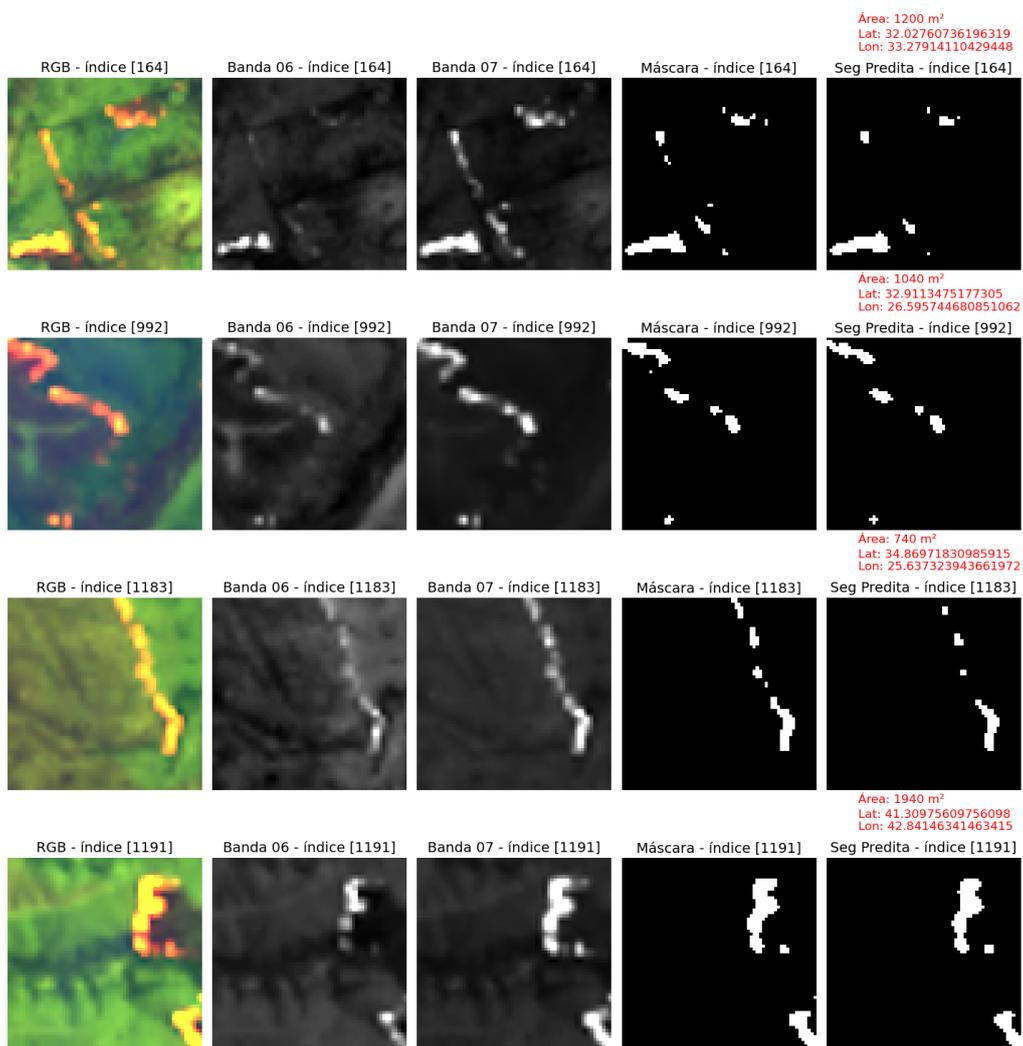
Para os testes com imagens do Landsat-8 referente as imagens da Serra do Cipó, a *precision* geral atingiu 93,34%, enquanto o modelo de conjunto alcançou um *Recall* de 86,26% e um *F1-Score* de 89,66%, enfatizando a alta confiabilidade do modelo. Os resultados da análise baseados nas métricas de desempenho estão apresentados

nas Tabelas 5.3, e visualizado na Figura 5.6.

Tabela 5.3 - Resultados obtidos com testes do modelo com imagens da área de estudo.

Landsat-8 Área de Estudo				
Métricas	Pr	Re	F1	
Teste	0.9334	0.8626	0.8966	

Figura 5.6 - Imagens de teste com Landsat-8, Serra do Cipó.



Fonte: Produção do autor.

6 CONCLUSÃO

Nos últimos anos, as Redes Neurais Convolucionais emergiram como um dos métodos de aprendizado profundo mais amplamente adotados para classificação de imagens em diversas áreas. Diante disso, exploramos as capacidades de um modelo de CNN profundo, incorporando recursos avançados de processamento de imagens, para detectar automaticamente incidentes de incêndio em uma variedade de biomas. Enquanto as aplicações atuais de processamento de sensoriamento remoto baseadas em CNNs profundas frequentemente abordam a classificação de uso da terra e o reconhecimento de alvos, apenas um número limitado de estudos se concentrou na monitorização e previsão de incêndios. No entanto, a crescente aplicação de aprendizado profundo na detecção de incêndios está se expandindo, apesar da restrição significativa imposta pela disponibilidade limitada de conjuntos de dados de treinamento amplamente rotulados, o que permanece como um problema central para melhorar o desempenho das CNNs em cenários de incêndio.

As CNNs demonstraram sua capacidade de superar as limitações inerentes às abordagens baseadas em intensidade, aprimorando a detecção de incêndios. Nossa CNN foi exclusivamente treinada com imagens do Sentinel-2, com o objetivo de desenvolver um modelo robusto capaz de detectar objetos e classificar imagens com alto desempenho. Esse conhecimento é transferível para novos domínios por meio da aprendizagem por transferência, ajustando parâmetros com novas imagens. Essa abordagem permite que o modelo seja reconfigurado para a mesma tarefa de classificação ou detecção em um novo conjunto de imagens, sem a necessidade de tempo ou recursos computacionais adicionais.

Utilizamos dados de satélite de alta resolução espacial, essenciais para monitorar eventos de incêndio, e optamos por treinar nossa rede neural com as imagens coletadas, acelerando e aprimorando a adaptação do modelo ao contexto de incêndio. O treinamento foi realizado com um conjunto de dados composto por imagens do satélite Sentinel-2.

Coletamos 4.396 imagens de diversas áreas da América do Sul e 76 imagens referentes a Serra do Cipó, que representam duas classes: pontos de incêndio ativos e ausência de pontos de incêndio, resultando em um modelo capaz de detectar com precisão a presença de pontos de incêndio nas imagens analisadas.

Os resultados obtidos demonstram uma alta precisão na detecção de pontos de incêndio, alcançando 98,3% usando dados do Sentinel-2 e 99,3% usando dados do

Landsat-8. O treinamento com imagens coletadas pelo Sentinel-2 não apenas reduziu os custos computacionais e o tempo necessário, mas também melhorou a precisão do modelo.

Entretanto, é importante observar que cenas com anomalias sutis, muitas vezes ocultas por nuvens, podem ser classificadas erroneamente como "Sem Anomalias", apresentando desafios adicionais na classificação precisa da atividade de incêndio. Abordagens futuras serão direcionadas para aprimorar esse aspecto, potencialmente incorporando técnicas de segmentação de imagem para lidar com cenários mais complexos.

É relevante destacar que a decisão de não empregar as bandas térmicas 10 e 11 do Landsat-8 decorreu da falta de correspondência espectral no satélite Sentinel-2. Essa disparidade impossibilitou o treinamento da *U-Net* para assimilar as características do pixel que corresponde ao foco de incêndio.

Os resultados obtidos na área de estudo, por meio das imagens do Landsat-8, demonstraram uma precisão de 93,3%. Foi possível estimar a extensão do fogo ao multiplicar a quantidade de *pixels* pela resolução espacial de cada satélite. Além disso, extraiu-se a localização geográfica do *pixel* central do incêndio, proporcionando um suporte à brigada de incêndio. Essas informações contribuíram para o planejamento e deslocamento da equipe até o local do fogo.

As recentes evoluções nos *frameworks* de aprendizado profundo, aliadas à expansão das constelações de satélites e melhorias na tecnologia de sensores, abrem novas possibilidades para aprimorar a detecção de pontos de incêndio por meio de observações espaciais. A implementação do modelo *U-Net* possibilita a análise automatizada de imagens em escala global, permitindo a extração eficiente de características e rápida notificação de operadores sobre pontos de incêndio ativos. Essas descobertas destacam a viabilidade de estabelecer sistemas automatizados de análise de focos de incêndio em escala global, utilizando dados de missões planejadas ou processamento a bordo de satélites.

7 TRABALHOS FUTUROS

Considerando a metodologia proposta, é evidente que há margem para aprimoramentos significativos, especialmente visando a identificação mais eficaz de focos de incêndio. Dessa forma, apresentam-se sugestões para trabalhos futuros:

- a) Explorar a possibilidade de incorporar imagens de outros satélites, aprimorando assim o processo de aquisição de dados.
- b) Implementar processamentos destinados a aprimorar a qualidade das imagens, com foco na redução de ruídos e na minimização de interferências atmosféricas.
- c) Testar e avaliar arquiteturas mais recentes, à medida que são publicadas, direcionadas à segmentação de imagens, buscando potenciais avanços em desempenho e eficiência.
- d) Expandir o conjunto de dados utilizado, explorando possibilidades de inclusão de mais imagens e propondo testes adicionais de pré-processamento, considerando, por exemplo, o uso de imagens série-temporais.

Essas sugestões visam aprimorar a efetividade da metodologia, abrindo caminho para avanços na detecção de focos de incêndio a partir de imagens de sensoriamento remoto.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABRAM, N. J.; HENLEY, B. J.; GUPTA, A. S.; LIPPMANN, T. J.; CLARKE, H.; DOWDY, A. J.; SHARPLES, J. J.; NOLAN, R. H.; ZHANG, T.; WOOSTER, M. J. Connections of climate change and variability to large and extreme forest fires in southeast Australia. **Communications Earth & Environment**, v. 2, n. 1, p. 1–17, 2021. 38
- ADAM: a method for stochastic optimization. n. 2, p. 137–162, 2005. 25
- AGENCY, E. S. **Sentinel-2 User Handbook**. [S.l.]: ESA, 2015. 10
- ALMEIDA, A. A. **Diagnóstico ambiental em trilhas ecoturísticas: estudo de caso no Parque Nacional da Serra do Cipó, MG**. 2005. 45f. Monografia (Graduação em Ciências Biológicas, Ambientais e da Saúde) — Centro Universitário de Belo Horizonte, Belo Horizonte, 2005. 54, 56
- AQUILUÉ, N.; FORTIN, M.-J.; MESSIER, C.; BROTONS, L. The potential of agricultural conversion to shape forest fire regimes in mediterranean landscapes. **Ecosystems**, v. 23, n. 1, p. 34–51, 2020. 39
- BARMPOUTIS, P.; PAPAIOANNOU, P.; DIMITROPOULOS, K.; GRAMMALIDIS, N. A review on early forest fire detection systems using optical remote sensing. **Sensors**, v. 20, n. 22, p. 6442, 2020. 41
- BATISTA, A. C. Detecção de incêndios florestais por satélites. **Floresta**, v. 34, n. 2, p. 237–241, 2004. 9
- BERLINCK, C. N.; BATISTA, E. K. Good fire, bad fire: It depends on who burns. **Flora**, v. 268, p. 151610, 2020. 36
- BERTONI, A. L.; FEDER, D. V. d. S. **Rede neural convolucional aplicada à visão computacional para detecção de incêndio**. 2018. Monografia (Graduação em Engenharia Eletronica) — Universidade Tecnológica Federal do Parana, Curitiba, 2018. 44, 52
- BEZERRA, U. A.; OLIVEIRA, L. M. M. de; CANDEIAS, A. L. B.; SILVA, B. B. da; LEITE, A. C. L. de S.; SILVA, L. T. M. de S. Comparativo do índice de vegetação de diferença normalizada (ndvi) entre os sensores oli-satélite landsat-8 e msi-satélite sentinel-2 em região semiárida. **Anuário do Instituto de Geociências**, v. 41, n. 3, p. 167–177, 2018. 10
- BORGES, K. M. R.; OROZCO FILHO, J. C.; COAN, G. P. de O.; VASCONCELOS, T. M. M. Sensoriamento remoto e geoprocessamento como subsídio ao manejo do fogo e ao combate aos incêndios florestais em unidades de conservação federais. **Biodiversidade Brasileira**, v. 11, n. 2, p. 168–178, 2021. 40
- BRAGA, A. d. P.; LUDERMIR, T. B.; CARVALHO, A. C. P. d. L. F. **Redes neurais artificiais: teoria e aplicações**. [S.l.: s.n.], 2000. 16

BRAGAGNOLO, L. **Redes neurais totalmente convolucionais aplicadas à identificação de focos de desmatamento**. 2021. Dissertação (Mestrado em Tecnologia Ambiental) — Universidade Tecnológica Federal do Paraná, Erechim, Rio Grande do Sul, 2021. 47, 52

BRAZ, A. M.; BRAZ, A. M.; BARROS, M. H. S.; GARCIA, P. H. M. Validação das classificações das imagens dos satélites landsat 8 e sentinel-2 na bacia hidrográfica do córrego Ribeirãozinho/MS. **Revista Eletrônica da Associação dos Geógrafos Brasileiros, Seção Três Lagoas**, v. 14, n. 26, p. 47–58, 2017. 50, 52

BRUSCHI, M. **Deep learning aplicada a segmentação semântica semiautomática de cicatrizes de deslizamentos de terra**. 2022. Monografia (Graduação em Engenharia Sanitária e Ambiental) — Universidade Federal da Fronteira Sul, Erechim, 2022. 18, 34

BUI, D. T.; BUI, Q.-T.; NGUYEN, Q.-P.; PRADHAN, B.; NAMPAK, H.; TRINH, P. T. A hybrid artificial intelligence approach using gis-based neural-fuzzy inference system and particle swarm optimization for forest fire susceptibility modeling at a tropical area. **Agricultural and Forest Meteorology**, v. 233, p. 32–44, 2017. 37

CALIXTO, D. D.; GUIMARÃES, F. D.; CALIXTO, L. D.; CREMON, É. H. Análise comparativa em imagens oli/landsat-8 e msi/sentinel-2 no mapeamento do uso e cobertura da terra. In: SIMPÓSIO BRASILEIRO DE GEOMÁTICA, 4., 2017, São Paulo. **Anais...** [S.l.], 2017. p. 180–185. 49, 52

CAMARGO, L. de S.; SILVA, R. W. da; AMARAL, S. S. do; SILVA, A. P. da; FERRELI, T.; SILVA, M. P. D. da. Mapeamento de áreas susceptíveis a incêndios florestais do município de petrópolis-rj. **Anuário do Instituto de Geociências**, v. 42, n. 1, p. 630–641, 2019. 38

CAMILLO, A. B. J. **Manual de prevenção e combate a incêndios**. [S.l.]: 15.ed. São Paulo: Senac, 1999. 37

CAMPOS, B. P. F.; SILVA, G. F. da; BINOTI, D. H. B.; MENDONÇA, A. R. de; LEITE, H. G. Descrição do perfil do tronco de árvores em plantios de diferentes espécies por meio de redes neurais artificiais. **Pesquisa Florestal Brasileira**, v. 37, n. 90, p. 99–107, 2017. 17

CARDIL, A.; MONEDERO, S.; RAMÍREZ, J.; SILVA, C. A. Assessing and reinitializing wildland fire simulations through satellite active fire data. **Journal of Environmental Management**, v. 231, p. 996–1003, 2019. 2

CENTENO, J. A. S. **Sensoriamento remoto e processamento de imagens digitais**. 2003. Dissertação (Mestrado em Ciências Geodésicas) — Universidade Federal do Paraná, Curitiba, 2003. 39

CHUVIECO, E.; MOUILLOT, F.; WERF, G. R. Van der; MIGUEL, J. S.; TANASE, M.; KOUTSIAS, N.; GARCÍA, M.; YEBRA, M.; PADILLA, M.; GITAS, I. Historical background and current developments for mapping burned

area from satellite earth observation. **Remote Sensing of Environment**, v. 225, p. 45–64, 2019. 37

CONFERÊNCIA INTERNACIONAL SOBRE INTELIGÊNCIA ARTIFICIAL E ESTATÍSTICA. Redes neurais retificadoras esparsas profundas. In: **Anais...** [S.l.], 2011. p. 315–323. 18

CORRÊA, C. R.; ALENCAR, R. C. C. Focos de queimadas em unidades de conservação. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** São José dos Campos, 2013. 9

DUARTE, L. P. N.; NAKAYAMA, L. Y.; BAZZO, J. J. Redes neurais para identificação de padrões na detecção de queimadas na floresta amazônica. In: JORNADA DE INICIAÇÃO CIENTÍFICA PIBIC INPA, 20., 2011. **Anais...** [S.l.], 2011. 45, 52

DUCHI, J.; HAZAN, E.; SINGER, Y. Adaptive subgradient methods for online learning and stochastic optimization. **Journal of Machine Learning Research**, v. 12, n. 7, 2011. 24

DUMOULIN, V.; VISIN, F. A guide to convolution arithmetic for deep learning. **arXiv preprint arXiv:1603.07285**, 2016. 29

DWYER, E.; PINNOCK, S.; GRÉGOIRE, J.-M.; PEREIRA, J. Global spatial and temporal distribution of vegetation fire as determined from satellite observations. **International Journal of Remote Sensing**, v. 21, n. 6-7, p. 1289–1302, 2000. 1, 2

ELHAMRAOUI, Z. **Introduction to convolutional neural network**. [S.l.]: Medium.com, 2020. 27

ESCALONA URIEL E ARCE, F. Z. E. H. S. Fully convolutional networks for automatic pavement crack segmentation. **Computación y Sistemas**, v. 23, n. 2, p. 451–460, 06 2019. 29

FALK, T.; MAI, D.; BENSCH, R.; ÇIÇEK, Ö.; ABDULKADIR, A.; MARRAKCHI, Y.; BÖHM, A.; DEUBNER, J.; JÄCKEL, Z.; SEIWALD, K. U-net: deep learning for cell counting, detection, and morphometry. **Nature Methods**, v. 16, n. 1, p. 67–70, 2019. 30

FERNANDES, M.; NETO, A.; BEZERRA, J. **Redes neurais artificiais aplicadas à detecção inteligente de sinais**. [S.l.]: LECA-DEE-UFRN, RN, 1999. 15

FLORENNO, T. G. **Iniciação em sensoriamento remoto**. [S.l.]: 3.ed. São Paulo: Oficina de Textos, 2007. 7

FRANÇA, D. d. A.; FERREIRA, N. J. Considerações sobre o uso de satélites na detecção e avaliação de queimadas. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005. **Anais...** São José dos Campos, INPE, 2005. p. 3017–3023. 8

FREIRES, E. V.; SILVA NETO, C. Â. d.; CUNHA, D. S. R.; DUARTE, C. R.; VERÍSSIMO, C. U. V.; GOMES, D. D. M. Comparação de imagens oli/landsat-8 e msi/sentinel-2 no mapeamento de cobertura e uso da terra no maciço de Uruburetama, Ceará. **Anuário do Instituto de Geociências-UFRJ**, v. 42, n. 4, p. 427–442, 2019. 49, 52

FURTADO, M. I. V. **Redes neurais artificiais: uma abordagem para sala de aula**. [S.l.]: Ponta Grossa: Atena, 2019. 17

FUSIOKA, A. M. **Detecção de fogo ativo por aprendizado profundo em imagens provenientes do satélite Landsat-8**. 2021. Dissertação (Mestrado em Computação Aplicada) — Universidade Federal do Parana, Curitiba, 2021. 43, 52

GALLO, K.; JI, L.; REED, B.; EIDENSHINK, J.; DWYER, J. Multi-platform comparisons of modis and avhrr normalized difference vegetation index data. **Remote Sensing of Environment**, v. 99, n. 3, p. 221–231, 2005. 2

GIGLIO, L.; CSISR, I.; JUSTICE, C. O. Global distribution and seasonality of active fires as observed with the terra and aqua moderate resolution imaging spectroradiometer (modis) sensors. **Journal of Geophysical Research: Biogeosciences**, v. 111, n. G2, 2006. 1, 2

GIGLIO, L.; DESCLOITRES, J.; JUSTICE, C. O.; KAUFMAN, Y. J. An enhanced contextual fire detection algorithm for modis. **Remote Sensing of Environment**, v. 87, n. 2-3, p. 273–282, 2003. 40

GIGLIO, L.; LOBODA, T.; ROY, D. P.; QUAYLE, B.; JUSTICE, C. O. An active-fire based burned area mapping algorithm for the modis sensor. **Remote Sensing of Environment**, v. 113, n. 2, p. 408–420, 2009. 1

GLÄNZER, L.; MASALKHI, H. E.; ROETH, A. A.; SCHMITZ-RODE, T.; SLABU, I. Vessel delineation using u-net: a sparse labeled deep learning approach for semantic segmentation of histological images. **Cancers**, v. 15, n. 15, 2023. ISSN 2072-6694. Disponível em: <<<https://www.mdpi.com/2072-6694/15/15/3773>>>. 30, 32, 60

GOMES, L.; MIRANDA, H. S.; SILVÉRIO, D. V.; BUSTAMANTE, M. M. Effects and behaviour of experimental fires in grasslands, savannas, and forests of the brazilian cerrado. **Forest Ecology and Management**, v. 458, p. 117804, 2020. 39

GONTIJO, G.; PEREIRA, A. A.; OLIVEIRA, E. D. S. d.; Acerbi Júnior, F. W. Detecção de queimadas e validação de focos de calor utilizando produtos de sensoriamento remoto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** São Jose dos Campos: INPE, 2011. p. 7966–7973. 46, 52

GONZALEZ RAFAEL C.; WOODS, R. E. **Digital image processing**. [S.l.]: 3.ed. Pearson Prentice Hall, 2008. 32, 33

- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. [S.l.]: MIT Press, 2016. <<http://www.deeplearningbook.org>>. 19
- _____. _____. [S.l.]: The Mit Press, 2016. 30
- HAYKIN, S. **Redes neurais: princípios e prática**. [S.l.]: Bookman, 2001. 14
- HINTON, G. E.; SRIVASTAVA, N.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. R. Improving neural networks by preventing co-adaptation of feature detectors. **arXiv**, v. 1, n. 1207.0580, 2012. 24
- ICHOKU, C.; GIGLIO, L.; WOOSTER, M. J.; REMER, L. A. Global characterition of biomass-burning patterns using satellite measurements of fire radiative energy. **Remote Sensing of Environment**, v. 112, n. 6, p. 2950–2962, 2008. 1, 2
- INACIO, G. d. O. **Mapeamento do uso e cobertura do solo utilizando imagens WPM/CBERS-4A, MSI/SENTINEL-2 e OLI/LANDSAT-8 para o município de Seropédica, RJ**. 2022. 49f. Monografia (Graduação em Engenharia Florestal) — Universidade Federal Rural do Ro de Janeiro, RJ, 2022. 2, 3
- INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA BIODIVERSIDADE (ICMBio). **Plano de manejo do Parque Nacional da Serra do Cipó**. [S.l.]: ICMBio Brasília, 2009. 54
- KAUFMAN, Y. J.; JUSTICE, C. O.; FLYNN, L. P.; KENDALL, J. D.; PRINS, E. M.; GIGLIO, L.; WARD, D. E.; MENZEL, W. P.; SETZER, A. W. Potential global fire monitoring from eos-modis. **Journal of Geophysical Research: Atmospheres**, v. 103, n. D24, p. 32215–32238, 1998. 40
- KIM, S.; JANG, Y.; KIM, S.-E. Image-based tf colorization with cnn for direct volume rendering. **IEEE Access**, v. 9, p. 124281–124294, 2021. 26
- KONDRATYEV, K. Y.; DYACHENKO, L.; BINENKO, V.; CHERNENKO, A. Detection of small fires and mapping of large forest fires by infrared imagery. **Remote Sensing of Environment**, V.8, p. 1297, 1972. 40
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. **Advances in Neural Information Processing Systems**, v. 25, 2012. 26
- _____. _____. **Communications of the ACM**, v. 60, n. 6, p. 84–90, may 2017. ISSN 0001-0782. Disponível em: <<<https://doi.org/10.1145/3065386>>>. 4
- LASHOF, D. The contribution of biomass burning to global warming: an integrated assessment. In: LEVINE, J. S. E. (Ed.). **Global biomass burning. Atmospheric, climatic, and biospheric implications**. [S.l.: s.n.], 1991. 1
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015. 26, 30

LEMOS, A.; JUNIOR, E.; BEZERRA, F.; ZALUAR, H.; DAU, J.; FARIA, L.; MOTTA, M.; WILLMERSDORF, O. **Manual para formação de brigadista de prevenção e combate aos incêndios florestais**. [s.n.], 2021. Disponível em: <<<https://www.icmbio.gov.br/portal/images/stories/servicos/sejaumbrigadista.pdf>>>. 36

LEUENBERGER, M.; PARENTE, J.; TONINI, M.; PEREIRA, M. G.; KANEVSKI, M. Wildfire susceptibility mapping: deterministic vs. stochastic approaches. **Environmental Modelling & Software**, v. 101, p. 194–203, 2018. 38

LI, P.; XIAO, C.; FENG, Z.; LI, W.; ZHANG, X. Occurrence frequencies and regional variations in visible infrared imaging radiometer suite (viirs) global active fires. **Global Change Biology**, v. 26, n. 5, p. 2970–2987, 2020. 40

LI, S.; GANGULY, S.; DUNGAN, J. L.; WANG, W.; NEMANI, R. R. Sentinel-2 msi radiometric characterization and cross-calibration with landsat-8 oli. **Advances in Remote Sensing**, v. 6, n. 2, p. 147–159, 2017. 3

LOPES, E. R. do N.; SILVA, A. P. P.; PERUCHI, J. F.; LOURENÇO, R. W. Zoneamento de risco de incêndio e queimadas na cidade de Sorocaba–São Paulo. **Revista do Departamento de Geografia**, v. 36, p. 117–129, 2018. 36

MA, J. Segmentation loss odyssey. **arXiv**, v. 4, n. 2005.13449, 2020. 19, 20

MACHADO, W. C.; Fonseca Júnior, E. S. d. Redes neurais artificiais aplicadas na previsão do vtec no Brasil. **Boletim de Ciências Geodésicas**, v. 19, p. 227–246, 2013. 15

MACHKOUR, Z.; ORTIZ-ARROYO, D.; DURDEVIC, P. Monocular based navigation system for autonomous ground robots using multiple deep learning models. **International Journal of Computational Intelligence Systems**, v. 16, n. 1, p. 79, 2023. 26

MAIER, S. W.; RUSSELL-SMITH, J.; EDWARDS, A. C.; YATES, C. Sensitivity of the modis fire detection algorithm (mod14) in the savanna region of the northern territory, Australia. **ISPRS journal of photogrammetry and remote sensing**, v. 76, p. 11–16, 2013. 40

MALENOVSKÝ, Z.; ROTT, H.; CIHLAR, J.; SCHAEPMAN, M. E.; GARCÍA-SANTOS, G.; FERNANDES, R.; BERGER, M. Sentinels for science: potential of sentinel-1,-2, and-3 missions for scientific observations of ocean, cryosphere, and land. **Remote Sensing of environment**, v. 120, p. 91–101, 2012. 9

MARLON, J. R.; BARTLEIN, P. J.; DANIAU, A.-L.; HARRISON, S. P.; MAEZUMI, S. Y.; POWER, M. J.; TINNER, W.; VANNIÉRE, B. Global biomass burning: a synthesis and review of holocene paleofire records and their controls. **Quaternary Science Reviews**, v. 65, p. 5–25, 2013. 37, 38, 39

MASCARENHAS, S.; AGARWAL, M. A comparison between vgg16, vgg19 and resnet50 architecture frameworks for image classification. In: INTERNATIONAL CONFERENCE ON DISRUPTIVE TECHNOLOGIES FOR MULTI-DISCIPLINARY RESEARCH AND APPLICATIONS. **Proceedings...** [S.l.], 2021. p. 96–99. 4

MATIAS, J. M. J. E. **Análise comparada das potencialidades e limitações dos dados Sentinel-2 e Landsat 8 para aplicações operacionais em ambiente e planeamento territorial. Caso de estudo: os municípios de Catumbela e Lobito, Angola.** Tese (Doutorado) — Faculdade de Ciências Sociais e Humanas - Universidade Nova de Lisboa, 2019. 50, 52

MATSON, M.; HOLBEN, B. Satellite detection of tropical burning in Brazil. **International Journal of Remote Sensing**, v. 8, n. 3, p. 509–516, 1987. 40

MIRANDA, F. A.; FREITAS, S. R. C. D.; FAGGION, P. L. Integração e interpolação de dados de anomalias ar livre utilizando-se a técnica de rna e krigagem. **Boletim de Ciências Geodésicas**, v. 15, n. 3, p. 428–443, 2009. 14

MIRANDA, M. d. P. **Imagens sentinel-2a (msi) aplicadas ao mapeamento geológico, Região de Itaitaia, Santa Quitéria, CE.** 2019. Dissertação (Mestrado em Geologia) — Universidade Federal do Ceará, Fortaleza, 2019. 2, 12, 13

MITTERMEIER, R. A.; FONSECA, G. A. D.; RYLANDS, A. B.; BRANDON, K. A brief history of biodiversity conservation in Brazil. **Conservation Biology**, p. 601–607, 2005. 53

MUELLER, C. S. Earthquake catalogs for the usgs national seismic hazard maps. **Seismological Research Letters**, v. 90, n. 1, p. 251–261, 2019. 11, 12

NAGAI, M. T.; SOU, B. M. Detecção de fogo e fumaça em vídeos usando remoção de fundo e redes neurais convolucionais. In: CONFERENCE ON GRAPHICS, PATTERNS AND IMAGES, 33., 2020. **Abstratcs...** [S.l.], 2020. p. 203–206. 45, 52

NOVO, E. M. de M. **Sensoriamento remoto: princípios e aplicações.** [S.l.]: Blucher, 2010. 8

OLIVEIRA, P. Á. d. **Deep learning na segmentação automática de imagens de satélite.** 2020. Monografia (Graduação em Engenharia Agrícola e Ambiental) — Universidade Federal de Viçosa, Viçosa, 2020. 47, 52

OLIVEIRA, W. C. d. S. **Segmentação semântica de áreas de plantações agrícolas via U-Net em dois estágios.** 2020. Dissertação (Mestrado em Ciência da Computação) — Universidade Federal do Maranhão, São Luís, 2020. 48, 52

OLIVEIRA, W. C. d. S. **Avaliação do desempenho de índices de vegetação para análise do estado da vegetação antes da ocorrência de incêndios florestais no Parque Estadual do Itacolomi.** 2022. 91f. Dissertação (Mestrado

em Engenharia Ambiental) — Universidade Federal de Ouro Preto, Ouro Preto, 2022. 40

Organização das Nações Unidas (ONU). **Painel intergovernamental sobre mudanças climáticas**. ONU: [s.n.], 2008. 37

PADILLA, M.; OLOFSSON, P.; STEHMAN, S. V.; TANSEY, K.; CHUVIECO, E. Stratification and sample allocation for reference burned area data. **Remote Sensing of Environment**, v. 203, p. 240–255, 2017. 1

PAOLETTI, M. E.; HAUT, J. M.; PLAZA, J.; PLAZA, A. A new deep convolutional neural network for fast hyperspectral image classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, p. 120–147, 2018. 16

Parque Nacional da Serra do Cipó. **Portaria do Parque Nacional**. abril 2000. Disponível em: <http://www.serradocipo.com/atratpasseios/show/id/5/0/parque_nacional.html>. Acesso em set/2022. 56

PEREIRA, G.; CARDOZO, F.; SHIMABUKURO, Y. E.; MORAES, E. C.; FREITAS, S. Estimativa da área de fogo ativo a partir da potência radiativa do fogo. **Revista Brasileira de Cartografia**, v. 4, p. 419–428, 2012. 43, 52

PEREIRA, G. H. d. A. **Detecção de incêndios em imagens de sensoriamento remoto: um estudo integrando os satélites Landsat-8, Sentinel-2 e inteligência artificial**. 2021. Dissertação (Mestrado em Computação Aplicada) — Universidade Tecnológica Federal do Paraná, Curitiba, 2021. 44

PEREIRA, J.; CHUVIECO, E.; BEUDOIN, A.; DESBOIS, N. Remote sensing of burned areas: a review. a review of remote sensing methods for the study of large wildland fires [S.I.]. **Universidad de Alcal**, p. 127±184, 1997. 8

PHAM, T. D. Classification of covid-19 chest x-rays with deep learning: new models or fine tuning? **Health Information Science and Systems**, v. 9, p. 1–11, 2021. 4

PINHEIRO, P. S.; BORGES, E. F. quantificação e análise da distribuição espacial dos focos de calor na sub-bacia do Rio Grande-BA. In: SIMPÓSIO REGIONAL DE GEOPROCESSAMENTO E SENSORIAMENTO REMOTO, 2014, Aracaju. **Anais...** [S.l.], 2014. p. 553–557. 8

POURGHASEMI, H. R.; GAYEN, A.; LASAPONARA, R.; TIEFENBACHER, J. P. Application of learning vector quantition and different machine learning techniques to assessing forest fire influence factors and spatial modelling. **Environmental Research**, v. 184, p. 109321, 2020. 37, 39

QIAN, N. On the momentum term in gradient descent learning algorithms. **Neural Networks**, v. 12, n. 1, p. 145–151, 1999. 23

RICHARDS, G. **The logistic sigmoid function**. [S.l.]: MIT Press, 2016.
Disponível em: <<https://commons.wikimedia.org/wiki/File:Logistic-curve.svg>>.
18

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: **International Conference on Medical image computing and computer-assisted intervention**. [S.l.]: NAVAB, N.; HORNEGGER, J; WELLS, W. FRANGI, A.[ed.], 2015. p. 234–241. 4, 30, 31, 33, 34, 35

ROY, D. P.; JIN, Y.; LEWIS, P.; JUSTICE, C. Prototyping a global algorithm for systematic fire-affected area mapping using modis time series data. **Remote Sensing of Environment**, v. 97, 2022. 1

RUDER, S. An overview of gradient descent optimization algorithms. **arXiv**, v. 2, n. 1609.04747, 2016. 22

SALES, G. M.; PEREIRA, J. L. G.; THALÊS, M. C.; CHAPUIS, R. P.; ALMEIDA, A. S. de. Emprego dos focos de calor na avaliação das áreas queimadas e em incêndios florestais em Paragominas, Pará, Brasil. **Boletim Museu Paraense Emílio Goeldi Ciências Naturais**, v. 14, n. 1, 2019. 36

SANTOS, C. A. J.; BITTENCOURT, O. O.; MORELLI, F.; SANTOS, R. Classificação de áreas queimadas por machine learning usando dados de sensoriamento remoto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019, Santos. **Anais...** São José dos Campos: INPE, 2019. p. 180–185. 46, 52

SANTOS, C. A. P. dos; SOUZA, U. B. de; SILVA, W. L. Quantificação dos focos de calor na meso-região do extremo oeste baiano. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** São José dos Campos, INPE, 2011. p. 7929–7933. 8

SANTOS, M. F.; HERBERT; SANO, P. T. Fisionomia e composição da vegetação florestal na Serra do Cipó, MG, Brasil. **Acta Botanica Brasilica**, v. 25, p. 793–814, 2011. 56

SATO, L. Y. **Tecnologia lidar para quantificação dos impactos de incêndios na estrutura florestal no sudeste da Amazônia**. 2016. Tese (Doutorado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016. 1

SAUL, L. K.; WEISS, Y.; BOTTOU, L. **Advances in neural information processing systems 17: proceedings of the 2004 conference**. [S.l.]: MIT press, 2005. 68

SCHROEDER, W.; OLIVA, P.; GIGLIO, L.; QUAYLE, B.; LORENZ, E.; MORELLI, F. Active fire detection using landsat-8/oli data. **Remote Sensing of Environment**, v. 185, p. 210–220, 2016. 3

- SHE, X.; ZHANG, L.; CEN, Y.; WU, T.; HUANG, C.; BAIG, M. H. A. Comparison of the continuity of vegetation indices derived from landsat 8 oli and landsat 7 etm+ data among different vegetation types. **Remote Sensing**, v. 7, n. 10, p. 13485–13506, 2015. 2
- SHI, J.; ZHAO, X. Anti-leakage method of network sensitive information data based on homomorphic encryption. **Journal of Intelligent Systems**, v. 32, n. 1, p. 20220281, 2023. 19
- SILVA, C. A.; SANTILLI, G.; SANO, E. E.; LANEVE, G. Fire occurrences and greenhouse gas emissions from deforestation in the brazilian Amazon. **Remote Sensing**, v. 13, n. 3, p. 376, 2021. 1
- SILVA, C. Q. **Redes neurais aplicadas no reconhecimento de símbolos matemáticos manuscritos online**. São Paulo: Universidade de São Paulo, 2019. 23, 24
- SILVA, T. B.; ROCHA, W.; ANGELO, M. Quantificação e análise espacial dos focos de calor no Parque Nacional da Chapada Diamantina–BA. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2013, Foz do Iguaçu. **Anais...** São José dos Campos, INPE, 2013. p. 180–185. 9
- SLATER, P. N. **Remote sensing: optics and optical systems**. [S.l.]: Addison-Wesley, 1980. 8
- SOTHE, C.; ALMEIDA, C. M. d.; LIESENBERG, V.; SCHIMALSKI, M. B. Evaluating sentinel-2 and landsat-8 data to map sucessional forest stages in a subtropical forest in southern Brazil. **Remote Sensing**, v. 9, n. 8, p. 838, 2017. 3
- SOUSA, I. I. B. Previsão de focos de calor na região metropolitana de Maceió utilizando rede neural artificial. **Revista Brasileira de Geografia Física**, v. 15, n. 05, p. 2313–2326, 2022. 17
- SOUZA, F. R. de; MAGALHÃES, P. A. A. J. Mathematical methods applied in image enhancement using matlab. **International Journal of Advanced Engineering Research and Science**, v. 5, n. 5, p. 305–307, 2018. 27
- SOUZA, J. F. L. d. **Classificação de padrões em imagens sísmicas utilizando inteligência artificial**. 2019. Tese (Doutorado em Engenharia Mecânica) — Universidade Federal da Paraíba, João Pessoa, 2019. 26, 48, 52
- SPÖRL, C.; CASTRO, E.; LUCHIARI, A. Aplicação de redes neurais artificiais na construção de modelos de fragilidade ambiental. **Revista do Departamento de Geografia**, v. 21, p. 113–135, 2011. 14
- TEDIM, F.; CARVALHO, S. Vulnerabilidade aos incêndios florestais: reflexões em torno de aspetos conceptuais e metodológicos. **Territorium**, n. 20, p. 85–99, 2013. 36
- TIWARI, S. Activation functions in neural networks. **geeksforgeeks.org**, 2020. 16

- VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: CONFERENCE ON GRAPHICS, PATTERNS AND IMAGES, 29., 2016. **Proceedings...** [S.l.], 2016. p. 1–4. 17
- VENKATESH, K.; PREETHI, K.; RAMESH, H. Evaluating the effects of forest fire on water balance using fire susceptibility maps. **Ecological Indicators**, v. 110, p. 105856, 2020. 36, 38, 39
- WANG, Q.; SHI, W.; LI, Z.; ATKINSON, P. M. Fusion of sentinel-2 images. **Remote Sensing of Environment**, v. 187, p. 241–252, 2016. 9
- YANI, M.; IRAWAN S, S. M. B.; SETININGSIH ST, M. C. Application of transfer learning using convolutional neural network method for early detection of terry's nail. **Journal of Physics: Conference Series**, v. 1201, n. 1, p. 012052, 2019. 28
- ZEILER, M. D.; FERGUS, R. Visualizing and understanding convolutional networks. In: COMPUTER VISION EUROPEAN CONFERENCE, 13. **Proceedings...** [S.l.]: Springer, 2014. p. 818–833. 35
- ZHANG, H.; HAN, X.; DAI, S. Fire occurrence probability mapping of northeast china with binary logistic regression model. **Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 6, n. 1, p. 121–127, 2013. 8
- ZHU, Z.; WOODCOCK, C. E. Continuous change detection and classification of land cover using all available landsat data. **Remote Sensing of Environment**, v. 144, p. 152–171, 2014. 3

PUBLICAÇÕES TÉCNICO-CIENTÍFICAS EDITADAS PELO INPE

Teses e Dissertações (TDI)

Teses e Dissertações apresentadas nos Cursos de Pós-Graduação do INPE.

Manuais Técnicos (MAN)

São publicações de caráter técnico que incluem normas, procedimentos, instruções e orientações.

Notas Técnico-Científicas (NTC)

Incluem resultados preliminares de pesquisa, descrição de equipamentos, descrição e ou documentação de programas de computador, descrição de sistemas e experimentos, apresentação de testes, dados, atlas, e documentação de projetos de engenharia.

Relatórios de Pesquisa (RPQ)

Reportam resultados ou progressos de pesquisas tanto de natureza técnica quanto científica, cujo nível seja compatível com o de uma publicação em periódico nacional ou internacional.

Propostas e Relatórios de Projetos (PRP)

São propostas de projetos técnico-científicos e relatórios de acompanhamento de projetos, atividades e convênios.

Publicações Didáticas (PUD)

Incluem apostilas, notas de aula e manuais didáticos.

Publicações Seriadas

São os seriados técnico-científicos: boletins, periódicos, anuários e anais de eventos (simpósios e congressos). Contam destas publicações o Internacional Standard Serial Number (ISSN), que é um código único e definitivo para identificação de títulos de seriados.

Programas de Computador (PDC)

São a seqüência de instruções ou códigos, expressos em uma linguagem de programação compilada ou interpretada, a ser executada por um computador para alcançar um determinado objetivo. Aceitam-se tanto programas fonte quanto os executáveis.

Pré-publicações (PRE)

Todos os artigos publicados em periódicos, anais e como capítulos de livros.