



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL
CURSO DE GRADUAÇÃO EM ENGENHARIA CIVIL

DANIEL CABRAL DA COSTA

**APLICAÇÃO DE MODELO DE REDE NEURAL CONVOLUCIONAL PARA
DETECÇÃO DE FOGO ATIVO NO PARQUE ESTADUAL ENCONTRO DAS
ÁGUAS**

JOÃO PESSOA

2021

DANIEL CABRAL DA COSTA

**APLICAÇÃO DE MODELO DE REDE NEURAL CONVOLUCIONAL PARA
DETECÇÃO DE FOGO ATIVO NO PARQUE ESTADUAL ENCONTRO DAS
ÁGUAS**

Trabalho de Conclusão de Curso submetido à
Coordenação do Curso de Engenharia Civil da
Universidade Federal da Paraíba, como um
dos requisitos obrigatórios para obtenção do
título de Bacharel em Engenharia Civil.

Orientador: Prof. Dr. Celso Augusto Guimarães
Santos.

JOÃO PESSOA

2021

Catálogo na publicação
Seção de Catalogação e Classificação

C838a Costa, Daniel Cabral da.

Aplicação de modelo de Rede Neural Convolutiva para
detecção de fogo ativo no Parque Estadual Encontro das
Águas / Daniel Cabral da Costa. - João Pessoa, 2021.
51 f. : il.

Orientação: Celso Augusto Guimarães Santos.
TCC (Graduação) - UFPB/CT.

1. Queimadas. 2. Sensoriamento Remoto. 3. Redes
Neurais
Convolutivas. 4. Inteligência Artificial. 5.
Processamento Digital de Imagens. I. Santos, Celso
Augusto Guimarães. II. Título.

UFPB/BSCT

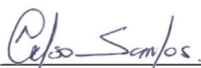
CDU 624 (043.2)

FOLHA DE APROVAÇÃO

DANIEL CABRAL DA COSTA


APLICAÇÃO DE MODELO DE REDE NEURAL CONVOLUCIONAL PARA DETECÇÃO DE FOGO ATIVO NO PARQUE ESTADUAL ENCONTRO DAS ÁGUAS

Trabalho de Conclusão de Curso em 03/12/2021 perante a seguinte Comissão Julgadora:



Prof. Dr. Celso Augusto Guimarães Santos (orientador)
Universidade Federal da Paraíba

APROVADO



Prof. Dr. Leonardo Vidal Batista (examinador)
Universidade Federal da Paraíba

APROVADO



Prof. Dr. Richarde Marques da Silva (examinador)
Universidade Federal da Paraíba

APROVADO



Prof^a. Andrea Brasiliano Silva
Matrícula Siape: 1549557

Coordenadora do Curso de Graduação em Engenharia Civil

AGRADECIMENTOS

A Deus, por todas as bênçãos me concedidas.

Aos meus pais, Fernando e Carol, pelo amor e apoio incondicional desde o meu primeiro dia de vida. Obrigado por sempre estarem ao meu lado, pelos conselhos e por fazerem tudo para me dar as melhores oportunidades possíveis. Essa conquista também pertence a vocês.

Agradeço à minha irmã, Carina, pelo apoio, carinho, confiança e amor.

A Ana Lígia, que é minha madrinha, tia e avó, tudo ao mesmo tempo.

A Ana Beatriz, minha namorada, por ter me dado amor, confiança e companheirismo no último ano.

A todos os meus tios, tias, primos, primas, avôs e avós, tanto os que já foram quanto os que continuam ao meu lado. Cada um de vocês me ajudou a ser quem sou hoje. Obrigado pelo suporte.

A Graça e Vera, por todo o cuidado desde a minha infância.

Aos amigos de faculdade, especialmente Pedro, Igor, João, Thiago e Raul. Obrigado por compartilhar não só dias e noites de estudos e estresse, mas também as conquistas, experiências e bons momentos. Minhas melhores lembranças desse período são com vocês.

Aos amigos de infância e adolescência, que sempre estiveram comigo.

Aos professores, principalmente, Celso, meu orientador, e Leonardo, pela confiança, oportunidades e ensinamentos nos últimos meses.

À Universidade Federal da Paraíba e a Universidad de Cantabria.

E a todos e todas que contribuíram para a minha jornada acadêmica nos últimos anos.

RESUMO

A detecção de fogo ativo através de sensoriamento remoto é uma ferramenta importante para o controle e análise dos impactos dos incêndios florestais, principalmente quando ocorrem em regiões remotas e de difícil acesso. Com o avanço tecnológico, algoritmos de processamento de imagem surgiram e aumentaram as alternativas para se monitorar e analisar esses fenômenos. Desse modo, o objetivo dessa pesquisa é de aplicar uma Rede Neural Convolutiva sobre imagens de uma região de interesse que inclui o Parque Estadual Encontro das Águas entre os meses de agosto a outubro de 2020, período em que a reserva – a segunda maior do Pantanal brasileiro – sofreu com uma quantidade histórica de queimadas. Os dados utilizados no estudo foram adquiridos do satélite Sentinel-2, através da biblioteca *eo-learn* da linguagem Python, resultando num total de quinze imagens de resolução espacial de vinte metros e 2496 x 2489 pixels. Ao fim do pré-processamento, obteve-se 1500 imagens de 256 x 256 pixels que foram processadas pela Rede Neural Convolutiva escolhida. O modelo utilizado correspondeu a uma arquitetura *U-Net*, que possuiu nove blocos de convolução, com 2.164.593 parâmetros pré-treinados. Após o processamento, foram obtidas quinze máscaras de tamanho 2560 x 2560, cada uma correspondente a uma data do período, cujos pixels indicam a presença de fogo ativo, quando *True*, ou não, quando *False*. A análise das máscaras indicou que o pico dos incêndios na região ocorreu no mês de setembro, que é o último do período seco na região. As quatro imagens adquiridas entre 29/08/2020 e 13/09/2020 acumularam 84,7% de todos os pixels ativos no período, com pico no último dia, que contou com 20.177 pixels ativados, equivalente a aproximadamente um terço do total para o período. Após essa data, os fogos detectados por imagem tiveram uma queda brusca, que continuou até o fim do período analisado. Para validar os resultados encontrados, fez-se uma comparação entre as máscaras geradas e os resultados obtidos na plataforma BDQueimadas, para as mesmas datas e área delimitada, que indicou uma maior capacidade de detecção de focos de incêndio menores e mais detalhados por parte da rede estudada. Assim, a ferramenta mostrou-se útil para a análise posterior da evolução e dos impactos do fogo em grandes áreas. Entretanto, ponderou-se que, apesar da maior resolução espacial do Sentinel-2, sua resolução temporal de cinco dias, além do tempo de processamento, inviabilizam seu uso para o monitoramento em tempo real desses fenômenos.

Palavras-chave: Queimadas. Sensoriamento Remoto. Redes Neurais Convolutivas. Inteligência Artificial. Processamento Digital de Imagens.

ABSTRACT

The detection of active fire through remote sensing is an important tool for controlling and analyzing the impacts of forest fires, especially when they occur in remote and difficult-to-access regions. With technological advancement, image processing algorithms emerged and increased the alternatives to monitor and analyze these disasters. Thus, the objective of this research is to apply a Convolutional Neural Network on images of a region of interest that includes the Encontro das Águas State Park from August to October 2020, a period in which the reserve – the second largest in the Brazilian Pantanal – suffered from a historic number of fires. The data used in the experiment was acquired from the Sentinel-2 satellite, through Python's eo-learn library, resulting in a total of fifteen image, with spatial resolution of twenty meters and 2496 x 2489 pixels. At the end of the preprocessing, 1500 images of 256 x 256 pixels were obtained, which were passed through the chosen Convolutional Neural Network. The model used corresponded to a U-Net, which had nine convolution blocks, with 2,164,593 pre-trained parameters. After processing, fifteen masks of size 2560 x 2560 were obtained, each corresponding to a date in the period analyzed, whose pixels indicate the presence of active fire, when True, or not, when False. The analysis of the masks indicated that the peak of the wildfires in the region occurred in September, the last month of the dry period in the region. The four images acquired between 08/29/2020 and 09/13/2020 accumulated 84.7% of all active pixels in the period, with a peak on the last day, which had 20,177 activated pixels, equivalent to approximately one third of the total for the period. After that date, the fires detected by image had a sharp drop, which continued until the end of the analyzed period. To validate the results found, a comparison was made between the generated masks and the results obtained on the BDQueimadas platform, for the same dates and delimited area, which indicated a greater capacity for detecting smaller and more detailed fire spots by the studied network. Thus, the tool proved to be useful for further analysis of the evolution and impacts of fire in large areas. However, it was considered that despite Sentinel-2's higher spatial resolution, its five-day temporal resolution, in addition to its processing time, make it unfeasible to use for real-time monitoring of these phenomena.

Key words: Wildfires. Remote Sensing. Convolutinal Neural Networks. Artificial Intelligence. Digital Image Processing.

LISTA DE FIGURAS

Figura 1 – Vista aérea de uma queimada	15
Figura 2 - Satélites usados pelo INPE no monitoramento de fogo.....	16
Figura 3 - Satélite Landsat 8.....	17
Figura 4 – Esquema de um neurônio artificial	20
Figura 5 - Perceptron Multi-camada.....	21
Figura 6 - Processo de convolução sobre uma matriz	22
Figura 7 - Exemplo de <i>Max Pooling</i> (MP) e <i>Average Pooling</i> (AP)	23
Figura 8 - Mapa de localização do Pantanal.....	24
Figura 9 - Mapa de localização da reserva e da área delimitada	26
Figura 10 - Imagem do dia 13/09/2020 em RGB, à esquerda, e das bandas selecionadas, à direita	28
Figura 11 - Imagem do dia 13/09/2020 após o processo de preenchimento	30
Figura 12 - Imagem do dia 13/09/2020 com grade sinalizando as imagens obtidas após o fim do pré-processamento	31
Figura 13 – Quantidade de pixels ativados por dia	33
Figura 14 – Quantidade acumulada de pixels ativados para o período analisado	33
Figura 15 - Imagens das bandas selecionadas, à esquerda, e da máscara produzida, à direita.....	34
Figura 16 - Máscara produzida, à esquerda, e imagem de validação, à direita	40

LISTA DE TABELAS

Tabela 1 – Vista aérea de uma queimada	17
Tabela 2 – Bacias Hidrográficas da Unidade de Conservação	25
Tabela 3 – Métricas de avaliação dos algoritmos comparados com máscaras manualmente anotadas	27
Tabela 4 – Coeficientes usados para a regressão linear de ajuste.....	29

LISTA DE ABREVIATURAS E SIGLAS

CNN – Redes Neurais Convolucionais – *Convolutional Neural Networks*

Embrapa – Empresa Brasileira de Pesquisa Agropecuária

ESA – Agência Espacial Europeia – *European Space Agency*

INPE – Instituto Nacional de Pesquisas Espaciais

MSI – Instrumento Multiespectral - *Multispectral Instrument*

NASA – Administração Nacional de Aeronáutica e Espaço - *National Aeronautics and Space Administration*

NIR – Infravermelho Próximo - *Near Infrared*

OLI – *Operational Land Imager*

RGB – Vermelho, Verde, Azul – *Red, Green, Blue*

RNA – Rede Neural Artificial

SAR – Radar de Abertura Sintética - *Synthetic Aperture Radar*

SWIR – Infravermelho de Ondas Curtas – *Short-wave Infrared*

SUMÁRIO

1	INTRODUÇÃO	11
2	OBJETIVO	13
2.1	OBJETIVO GERAL.....	13
2.2	OBJETIVOS ESPECÍFICOS	13
3	REFERENCIAL TEÓRICO	14
3.1	QUEIMADAS	14
3.2	SENSORIAMENTO REMOTO	15
3.3	SENTINEL 2	17
3.4	ALGORITMOS DE DETECÇÃO DE QUEIMADAS ATIVAS	18
3.5	REDES NEURAIS ARTIFICIAIS E <i>DEEP LEARNING</i>	19
3.6	REDES NEURAIS CONVOLUCIONAIS	21
3.6.1	Camada de Convolução	21
3.6.2	Camada de Pooling	22
4	PROCEDIMENTOS METODOLÓGICOS	24
4.1	ÁREA DE ESTUDO	24
4.2	MODELO	26
4.3	MATERIAL	27
4.3.1	Google Colab	27
4.3.2	Python	27
4.4	IMAGENS	28
4.5	PRÉ-PROCESSAMENTO	29
4.6	VALIDAÇÃO	31
5	ANÁLISE DOS RESULTADOS	32
5.1	MÁSCARAS PRODUZIDAS	32
5.2	COMPARATIVO COM O BDQUEIMADAS	39
5.3	DISCUSSÕES	45
6	CONSIDERAÇÕES FINAIS	47
	REFERÊNCIAS	48
	APÊNDICE	52

1 INTRODUÇÃO

Os cuidados com as mudanças climáticas estão no centro das discussões, seja em encontros governamentais, no planejamento de empresas, protestos estudantis, como o Fridays for Future, e até na tomada de decisão dos maiores fundos de investimento do mundo. Nesse contexto, a preservação do meio ambiente se torna uma pauta de extrema importância para toda a sociedade. No Brasil, dois dos principais responsáveis pela degradação ambiental são o desmatamento e as queimadas (NOBRE, 2008) (ALBUQUERQUE et al., 2020).

Segundo o INPE (2021), apenas na Amazônia Legal foram desmatados 10.851 km² de floresta no ano de 2020, o que representa um aumento de 44% em relação a 2018. Além disso, 2020 também representou o ano com o maior número de focos de queimada da década, com destaque para o Pantanal, que apresentou o maior número desde o começo da série histórica, em 1998. A devastação do bioma foi tão grande que repercutiu internacionalmente, assim como as queimadas na Floresta Amazônica de 2019.

Como consequência do aumento dos focos, estima-se que cerca de 30% da área total do Pantanal tenha sido queimada, sendo que desse total, 43% tenham sido em áreas que não haviam sido afetadas desde 2003 (GARCIA et al., 2020). Dentre as regiões afetadas, pode-se destacar o Parque Estadual Encontro das Águas, área de estudo do presente trabalho, que até 16 de setembro de 2020 era reportado pela imprensa como a reserva pantaneira mais atingida pelo fogo, tendo perdido até 86% da sua vegetação (SOARES, 2020; MENEGASSI, 2020).

Tendo em vista os dados apresentados, fica explícita a importância de se desenvolver e utilizar ferramentas que auxiliem na identificação e análise desses fenômenos destrutivos. Dessa forma, aliar o uso de imagens de satélite com algoritmos avançados de processamento de imagens, como as Redes Neurais Convolucionais, surge como uma alternativa para que seja possível um monitoramento de grandes áreas e com grande precisão. Assim, o presente estudo se propõe a aplicar um modelo de CNN proposto por Pereira et al. (2021) para a detecção de fogo ativo em imagens do Parque Estadual Encontro das Águas, no período entre agosto e outubro de 2020.

Na segunda seção desta monografia, são apresentados os objetivos a serem alcançados ao final do estudo. Em seguida, são introduzidos os conceitos necessários para a compreensão do experimento e da problemática analisada, como as queimadas, sensoriamento remoto, aprendizagem de máquina e Redes Neurais Convolucionais. Na metodologia, são apresentadas a área de estudo, as ferramentas utilizadas, as etapas de pré-processamento, o modelo aplicado sobre as imagens e a plataforma utilizada para a validação dos dados. Nos

resultados são analisadas as máscaras produzidas pelo algoritmo e os dados obtidos através delas e comparadas às imagens de validação. Por fim, é feito um resumo da análise e considerações sobre o tema e o estudo.

2 OBJETIVO

2.1 OBJETIVO GERAL

O objetivo geral dessa pesquisa é aplicar uma Rede Neural Convolucional para a detecção de fogo ativo em uma região de interesse que envolve o Parque Estadual Encontro das Águas, para o período entre 01/08/2020 e 31/10/2020.

2.2 OBJETIVOS ESPECÍFICOS

- Comparar o desempenho do algoritmo utilizado na pesquisa com o da plataforma BDQueimadas, disponibilizada pelo Instituto Nacional de Pesquisas Espaciais (INPE).
- Analisar o avanço do fogo sobre a região através das máscaras produzidas pelo modelo para cada uma das imagens.

3 REFERENCIAL TEÓRICO

3.1 QUEIMADAS

“Queimada é uma combustão incompleta ao ar livre, e depende do tipo de matéria vegetal que está sendo queimada, de sua densidade, umidade etc., além de condições ambientais, em especial a velocidade do vento.” (RIBEIRO e ASSUNÇÃO, 2002, p. 129). Esse fenômeno pode ser natural, iniciado por meio de quedas de raios ou de fagulhas surgidas através de ventos em áreas secas e quentes. Ou pode ser antrópico, surgido através de ações humanas. Segundo Santos et al. (1992), as queimadas antrópicas são usadas como forma de manejo do solo desde os primórdios da agricultura, utilizadas como técnica de renovação de pastagens e de limpeza de terreno.

A queima controlada é utilizada de forma racional, com controle de intensidade e limitada a uma área predeterminada, e com fins agrícolas e florestais. Essa técnica pode ser utilizada inclusive no manejo de unidades de conservação, visando evitar o acúmulo de combustível e, conseqüentemente, a ocorrência de incêndios de difícil controle. Já o incêndio florestal é todo fogo sem controle que ocorra sobre uma vegetação, independentemente de sua origem (ICMBio, 2010).

Segundo Luciardo, Cunha e Júnior (2004), os incêndios florestais provocam prejuízos de âmbito ambiental, econômico e social. No primeiro, pode-se destacar problemas de degradação do solo, aumento de poluição do ar, liberação de gases do efeito estufa, instabilidade das chuvas, mudanças climáticas, destruição da fauna e flora local, desequilíbrio ecológico etc. Já nos dois últimos, pode ocorrer perda de qualidade de vida devido as mudanças ambientais, aumento de doenças respiratórias, escassez de alimento, destruição de casas, fechamentos de aeroportos e estradas etc.

Devido ao alto potencial destrutivo, é essencial que haja meios eficientes e contínuos de prevenção, detecção e combate aos incêndios. Dada a extensa área do território brasileiro e a dificuldade de se monitorar o avanço desses fenômenos em terra, o uso de imagens de satélites tem surgido como um grande aliado no monitoramento das queimadas e de seus impactos ambientais (figura 1).

Figura 1 – Vista aérea de uma queimada



Fonte: Agência Espacial Europeia, 2021

3.2 SENSORIAMENTO REMOTO

“Sensoriamento remoto é uma ciência que visa o desenvolvimento da obtenção de imagens da superfície terrestre por meio da detecção e medição quantitativa das respostas das interações da radiação eletromagnética com os materiais terrestres.” (MENEZES; ALMEIDA, 2012, p.3). A partir da análise dessas imagens é possível retirar informações – por vezes, em tempo real – para monitorar fenômenos terrestres, incluindo queimadas.

Um dos meios de monitoramento por sensoriamento remoto é através da detecção de focos de calor, que são pontos geográficos de temperatura maior que 47°C e 900 m^2 (Gontijo et al, 2011). No Brasil, esse trabalho é feito pelo INPE (Instituto Nacional de Pesquisas Espaciais), que utiliza diversos satélites, como: TERRA, AQUA, GOES, NOAA, MSG, METOP e NPP (figura 2). Uma das ferramentas desenvolvidas é o BDQueimadas, que permite visualizar os focos através de um mapa interativo on-line, a filtrar os focos por períodos, locais, satélites etc. e exportar os dados em formato csv, shapefile e kml (INPE, 2021). Esse sistema foi escolhido para validar os resultados encontrados pelo experimento desta monografia.

Figura 2 – Satélites usados pelo INPE no monitoramento de fogo



Fonte: INPE, 2021

Um dos sensores mais utilizados para monitoramento de queimadas é o sensor MODIS (*Moderate Resolution Imaging Spectrometer*), que está a bordo dos satélites AQUA e TERRA citados anteriormente. Esse instrumento percorrem toda a superfície terrestre a cada um ou dois dias, fornecendo dados em trinta e seis bandas diferentes (NASA). Sua tecnologia permite a geração de imagens de resolução espacial 250 m, que vão das regiões visíveis até o infravermelho próximo, e de 1000 m, que vão do infravermelho médio até o distante. Outra inovação é que a própria equipe técnica do projeto já disponibiliza um produto contendo a localização de focos de calor captados pelo sensor e tratados através de técnicas estatísticas (Piromal et al, 2008).

Outro grande projeto voltado para o sensoriamento remoto é o Landsat (*Land Remote Sensing Satellite*), mostrado na figura 3, desenvolvido pela Agência Espacial Americana a partir da metade dos anos 60 e que teve seu primeiro satélite lançado em 1972, resultando num acervo de quase cinquenta anos de imagens globais. O último lançamento da série ocorreu em 2013, com o Landsat 8 (figura 3), que contém os instrumentos OLI (*Operational Land Imager*), capaz de gerar imagens de resolução de 15m a 30m, e TIRS (*Thermal Infrared*

Sensor), com resolução de 100m, e com resolução temporal de aproximadamente dezesseis dias. (EMBRAPA, 2021).

Figura 3 – Satélite Landsat 8



Fonte: NASA, 2021

3.3 SENTINEL 2

As missões Sentinel são compostas por uma série de pares de satélites lançadas pela *European Space Agency* (ESA) e a *European Commission*, através da iniciativa Copernicus. Seu objetivo é de monitorar os recursos naturais terrestres, o uso e ocupação de terras, os ambientes marinhos e desastres naturais (Embrapa, 2021). O primeiro satélite lançado foi o Sentinel-1A, em 03 de abril de 2014, levando consigo um radar de abertura sintética (SAR), que captura imagens na banda C e independente das condições meteorológicas. Seu par, Sentinel-1B, foi lançado em 22 de abril de 2016.

A missão seguinte, batizada de Sentinel-2, é composta por outro par de satélites, chamados Sentinel-2A e Sentinel-2B. Seu objetivo envolve a aquisição sistemática e global de imagens multiespectrais, de alta resolução e alta frequência de revisita (ESA, 2021). Para isso, os satélites contam com um sensor multiespectral, capaz de captar amostras de treze bandas diferentes, sendo quatro bandas visíveis com resolução de 10 m, seis bandas infravermelhas com resolução de 20 m e mais três bandas para correção atmosférica de resolução de 60 m, como indicado na tabela 1.

Tabela 1 – Bandas do Sentinel-2

Número da Banda	Nome da Banda	Comprimento de Onda Central (nm)	Resolução (m)
B01	Aerossol	443	60
B02	Azul	490	10
B03	Verde	560	
B04	Vermelho	665	
B05	<i>Red Edge 1</i>	705	20
B06	<i>Red Edge 2</i>	740	
B07	<i>Red Edge 3</i>	783	
B08	NIR (Infravermelho Próximo)	842	10
B08A	<i>Red Edge 5</i>	865	20
B09	Vapor de Água	940	60
B10	Cirrus	1375	
B11	SWIR1	1610	20
B12	SWIR2	2190	

Fonte: Agência Espacial Europeia

Os dois satélites voam em órbita polar, com diferença de fase de 180°, o que proporciona uma frequência de revisita de cinco dias na linha do Equador. Essas características tornam a missão útil para atividades como o monitoramento de uso de terra, agricultura e de desastres naturais, como as queimadas.

Os dados do Sentinel-2 são pré-processados e disponibilizados para os usuários em forma de dois produtos:

- Level-1C: representando as reflectâncias para o topo da atmosfera.
- Level-2A: representando as reflectâncias para a superfície.

3.4 ALGORITMOS DE DETECÇÃO DE QUEIMADAS ATIVAS

Segundo San-Miguel-Ayanz et al. (2005), a detecção de fogo através de Sensoriamento Remoto geralmente é baseada em três métodos:

- Através da determinação de limiares para encontrar pontos de alta temperatura.

- Detecção de altas temperaturas através de métodos contextuais.
- Detecção de nuvens de fumaça produzidas pelo incêndio.

Schroeder et al (2016) propõem uma série de condições a serem testadas num pixel envolvendo as sete primeiras bandas do sensor OLI, do Landsat-8, que, quando verdadeiras, sinalizam a existência de fogo ativo. As regras foram definidas de modo que o contexto dos pixels vizinhos também seja considerado. Algoritmos semelhantes para o sensor OLI foram propostos por Murphy et al. (2016), usando as bandas cinco, seis e sete, e Kumar e Roy (2018), que utilizam as bandas dois até sete.

O algoritmo utilizado pela equipe técnica do MODIS na produção do seu produto para detecção de fogos ativos também estabelece testes a serem feitos com os pixels (GIGLIO et al, 2016). Métodos semelhantes também foram propostos para os sensores VIIRS e ASTER (GIGLIO et al, 2008; SCHROEDER et al., 2014). Já Lin et al. (2018) segue no mesmo caminho, mas introduz uma análise multi-temporal dos dados coletados através do satélite FengYun-3C.

Diferentemente dos algoritmos anteriores, elaborados à mão por especialistas, as técnicas de Aprendizagem Profunda são capazes de extrair e aprender atributos complexos de um problema de maneira automática. Em especial, as Redes Neurais Convolucionais (CNNs) têm sido utilizadas com sucesso para tarefas relacionadas a visão computacional (BARMPOUTIS et al., 2020).

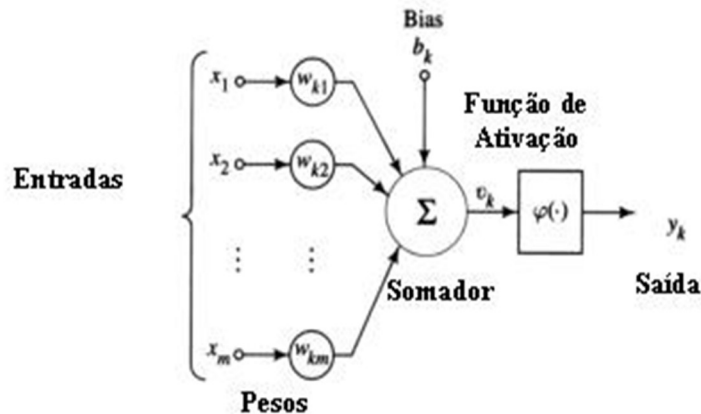
Para a detecção de queimadas ativas, Pereira et al (2021) propõe o uso de redes neurais com arquiteturas baseadas em CNNs com desempenho similar aos algoritmos artesanais. Um desses modelos, batizado de U-Net-light (3c), foi escolhido para ser utilizado nessa monografia. Outro algoritmo recente baseado em CNNs e com a mesma finalidade foi proposto por Hu et al. (2021), dessa vez utilizando imagens multiespectrais do satélite Sentinel-2 Level-1C, especificamente as bandas Vermelho, SWIR 1 e SWIR 2 e parametrizado com base em diferentes biomas para a minimização de erros.

3.5 REDES NEURAIAS ARTIFICIAIS E *DEEP LEARNING*

As RNAs são modelos de aprendizagem de máquina inspirados no funcionamento dos neurônios dos cérebros. Em 1943, McCulloch e Pitts modelaram um neurônio artificial por meio de um discriminador linear de entradas binárias. O neurônio de McCulloch-Pitts funciona a partir de dados de entrada (X) que alimentam o modelo e são, cada um deles, multiplicados a um peso (w). Os resultados dessas multiplicações são somados entre si e a um

valor de *bias* (tendência) e então passam por uma função de ativação, geralmente não-linear, e, por fim, por uma função de saída, que gera um resultado booleano. A figura 4 representa o modelo:

Figura 4 – Esquema de um neurônio artificial



Fonte: Zambiasi, 2011


Inspirado pelos neurônios, Rosenblatt cria no final dos anos 1950 uma rede contendo uma camada de neurônios artificiais conectados e a batizou de Perceptron (KOVÁCS, 2006). Devido a sua simplicidade, o Perceptron só é capaz de realizar tarefas que envolvam a classificação entre classes binárias linearmente separáveis. Junto desse modelo foi proposta uma técnica para a atualização dos pesos dos neurônios de modo a minimizar o erro entre as respostas calculadas e as desejadas (RAUBER, 2005). Entretanto, o Perceptron e seu variante ADALINE tinham limitações claras devido a incapacidade de resolver equações não-lineares, como o XOR (ou-exclusivo).

Esse problema foi resolvido por Rumelhart et al (1986), através dos Perceptrons Multi-camadas (figura 5), onde foram adicionadas camadas internas de neurônios ao Perceptron, que tinham seus pesos atualizados através da técnica de retropropagação de erros.

De maneira geral, as camadas podem ser divididas em:

- Camada de entrada: recebe os dados de entrada do sistema
- Camadas ocultas/intermediárias: onde ocorre a maior parte do processamento e extração das informações.
- Camada de saída: apresenta o resultado.

Figura 5 – Perceptron Multi-camada



Fonte: Machine Learning Geek, 2021

Quanto maior o número de neurônios e de camadas intermediárias, mais complexo o modelo se torna, sendo capaz de generalizar tarefas de perfil altamente não-lineares, como o processamento de linguagem natural e a visão computacional. Porém, a construção de modelos baseados em RNAs demandam uma quantidade de dados e poder computacional que só se tornaram viáveis a partir da década de 2010, com o avanço dos processadores e da produção em massa de dados (*Big Data*). Desde então, a área de Aprendizagem Profunda tem avançado exponencialmente, tendo as RNAs como um dos seus pilares.

3.6 REDES NEURAIAS CONVOLUCIONAIS

As redes convolucionais são modelos especializados para o processamento de dados estruturados em forma de matrizes múltiplas, como imagens, séries temporais e áudios. Uma imagem colorida, por exemplo, é formada por três matrizes de duas dimensões cada (LeCUN et al., 1989; LeCUN et al., 2015). As CNNs possuem dois tipos de camada básicas:

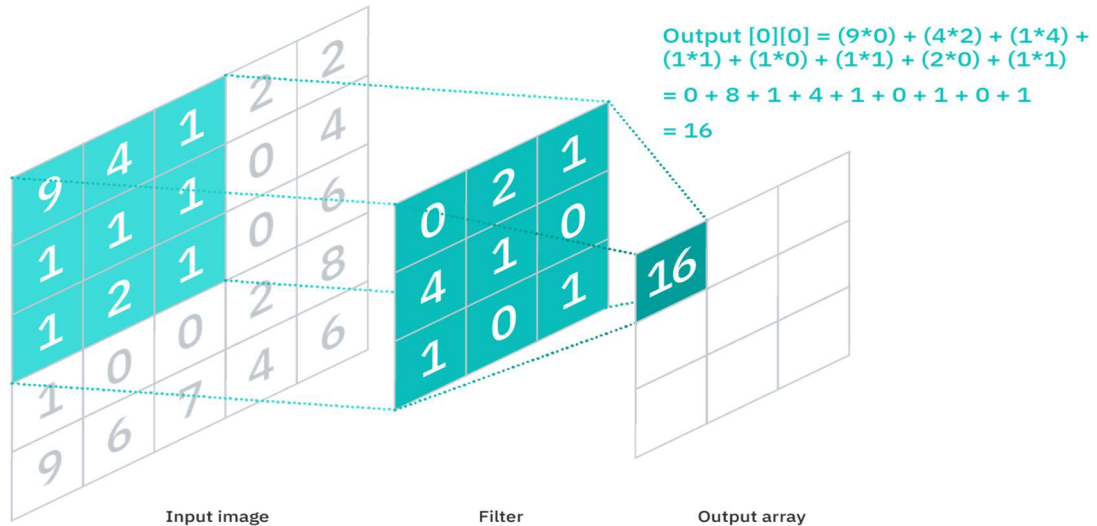
3.6.1 Camada de Convolução

Nessas camadas da rede, são aplicados filtros por toda a imagem com a função de mapear características. Esses filtros são formados por pesos organizados em matrizes de duas dimensões e que são atualizados de forma a aperfeiçoar o processo de extração de informação. Para fazer o mapeamento, os filtros percorrem a imagem multiplicando seus pesos pelos valores de entrada, como mostrado na figura 6, que então passam por uma função de ativação e, por fim, geram mapas de atributos (*feature maps*). A vantagem de ter filtros especializados

percorrendo toda a imagem é que dessa maneira facilita-se a detecção de características que estejam presentes em locais diferentes.

Numa imagem, por exemplo, os primeiros filtros de convolução são responsáveis pela detecção de atributos simples como bordas, luminosidade e textura. Já nas camadas mais profundas, é possível extrair características mais complexas, como faces e objetos.

Figura 6 – Processo de convolução sobre uma matriz




Fonte: IBM, 2020

3.6.2 Camada de Pooling

Essa camada ocorre após o processo de convolução. Nela, também são aplicados filtros por toda a imagem, já processada em mapas de características, porém, sua função é a de unir características semelhantes semanticamente em um só atributo (LeCUN et al, 2015). Para realizar essa tarefa, os filtros percorrem a imagem e resumem suas regiões aos seus pixels de maior valor, no caso do método *Max Pooling*, ou de seu valor médio, no método de *Average Pooling*, como exemplificado na figura 7.

Outra vantagem desse processo é o de diminuir as dimensões dos *inputs* para as próximas camadas, o que diminui a necessidade de poder computacional para a execução do modelo.

Figura 7 – Exemplo de *Max Pooling* (MP) e *Average Pooling* (AP)

Fonte: Wang et al., 2018

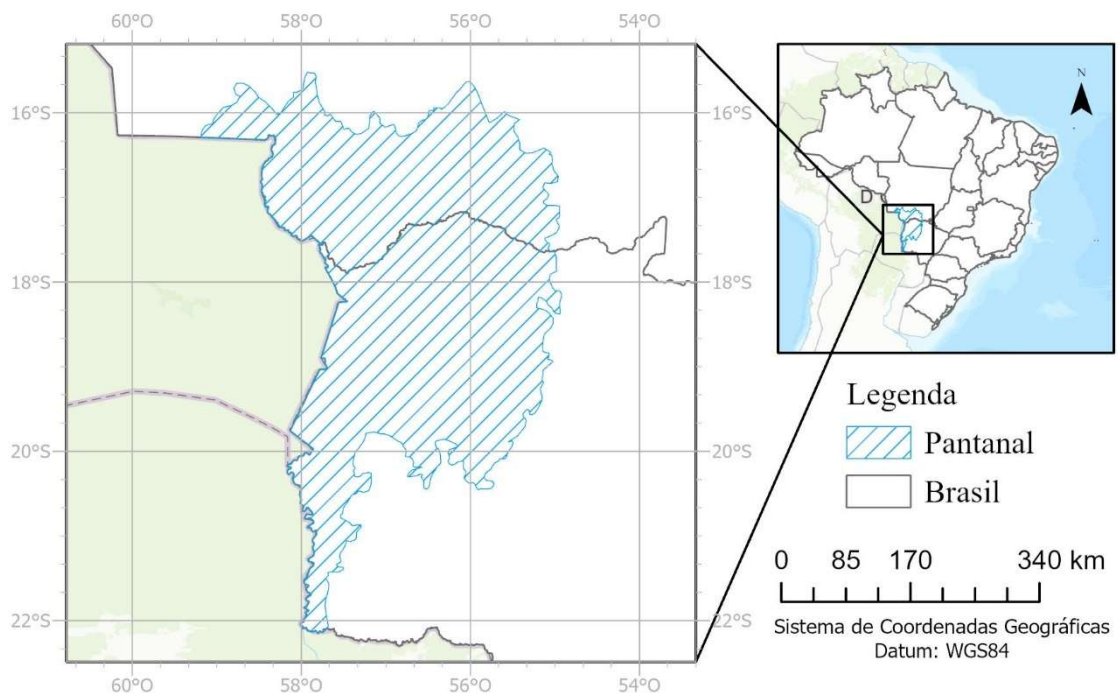
4 PROCEDIMENTOS METODOLÓGICOS

4.1 ÁREA DE ESTUDO

Segundo a Embrapa, o Pantanal brasileiro (figura 8) abrange uma área de 138.183 km², que corresponde a aproximadamente 2% do território nacional. O bioma está dividido entre os estados do Mato Grosso, que contém 35% do total, e do Mato Grosso do Sul, onde estão os outros 65%. A região está localizada na bacia hidrográfica do Alto Paraguai e é considerada uma das maiores extensões úmidas contínuas do planeta, estendendo-se também pelo Paraguai e pela Bolívia.

O clima predominante da região é o Tropical, de duas estações bem definidas: o inverno, período seco e que ocorre entre abril e setembro, e o verão, período entre outubro e março, quando ocorrem as chuvas e o ápice dos alagamentos, que, segundo a WWF, chegam a cobrir até 80% do bioma. Segundo a Secretária de Turismo do Mato Grosso do Sul, o ápice da seca ocorre entre os meses de agosto e setembro.

Figura 8 – Mapa de localização do Pantanal brasileiro



Fonte: Autor

Atualmente existem 34 Unidades de Conservação do Pantanal, que correspondem a apenas 5,34% da área total do bioma (CHAVES e SILVA, 2018). A segunda maior delas, o Parque Estadual Encontro das Águas, é o objeto de estudo dessa pesquisa. Ela cobre uma área de 1089,6 km², foi criada em 2004 pelo Governo do Mato Grosso, através do decreto 4.881, em 22 de dezembro de 2004 e está localizada no sul do estado, entre os municípios de Barão de Melgaço e Poconé. Desde 2014 o parque está sob gestão da Secretaria do Meio Ambiente do Mato Grosso através de um conselho consultivo.

A unidade de conservação está localizada sobre quatro bacias hidrográficas, como mostra o quadro 2:

Tabela 2 - Bacias Hidrográficas da Unidade de Conservação

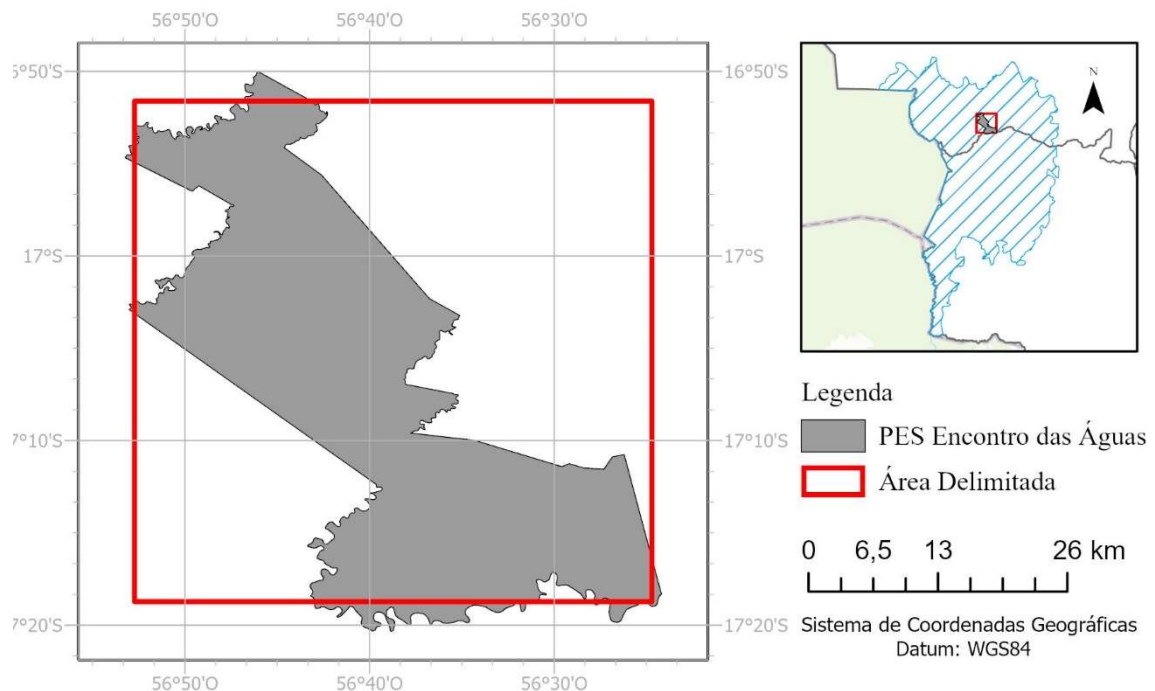
Bacia Hidrográfica	% na UC
Cuiabá	59,09
São Lourenço	19,34
Itiquira	18,40
Paraguai Médio	3,17

Fonte: Adaptado de socioambiental, 2021

Além disso, rios importantes, como o Cuiabá, Piquiri, Pirigara, Cassange, Três Irmãos e Alegre cortam a região, o que reforça a importância da preservação do parque para o ecossistema local.

Para delimitar a região, foi determinada uma área em forma de retângulo de coordenadas 56,4118°O a 56,8788°O e 16,8602°S a 17,3122°S, como indicado na figura 9, de modo que foi possível encaixar o máximo possível do parque sem que se excedesse o limite de pixels por imagem da API do Sentinel-2, de 2500 x 2500.

Figura 9 – Mapa de localização da reserva e da área delimitada



Fonte: Autor

4.2 MODELO

O modelo escolhido para a segmentação de queimadas ativas foi o *U-Net-Light (3c)*, desenvolvido por Pereira et al. (2021). A Rede Neural Artificial segue a arquitetura U-Net, contendo quatro blocos de convolução, cada uma delas seguida por uma camada de *Max Pooling*, na etapa de contração, um bloco de convolução na camada média, e mais quatro blocos de convolução na etapa de expansão, precedidos por uma camada de Convolução Transposta. Por fim, a máscara segmentada é produzida após uma camada de convolução com função de ativação sigmoideal. Foi definido o valor de 0.25 como limiar para definir um pixel como Verdadeiro, quando maior, ou Falso, quando menor ou igual, seguindo o que foi feito pelos criadores do modelo.

Os pesos da rede estão disponibilizados na plataforma GitHub de Pereira et al. (2021) e podem ser importadas por meio de download. A base de imagens utilizada no treinamento foi obtida a partir de imagens do Landsat-8 e contém 146.214 imagens, cada uma com 256 x 256 pixels, resultando em 192 GB. As máscaras utilizadas como *target* do modelo foram produzidas através da junção dos algoritmos propostos por Schroeder et al. (2016), Murphy et al (2016) e Kumar e Roy (2018), em que foi adotado um sistema de votação para definir o

valor do pixel. O valor que pelo menos dois dos algoritmos detectassem para um local era o valor assinalado para aquele pixel na máscara final.

A tabela 3 demonstra o desempenho dos algoritmos utilizados para a produção de máscaras e das redes neurais treinadas quando comparadas com 9.044 imagens manualmente segmentadas por especialistas. Nota-se que o modelo de CNN treinado utilizando máscaras geradas pelo sistema de votação teve um desempenho geral melhor que as alternativas.

Tabela 3 – Métricas de avaliação dos algoritmos comparados com máscaras manualmente anotadas

Máscara	Algoritmo	Métricas (%)			
		Precisão	Recall	IoU	F
Schroeder et al.	Original	88,1	70,2	64,1	78,1
	CNN	89	78,8	71,8	83,6
Murphy et al.	Original	76,6	96,1	74,3	85,2
	CNN	75,5	96,9	73,7	84,9
Kumar-Roy	Original	82,3	68,4	59,7	74,7
	CNN	78,8	96,9	76,9	86,9
Interseção	CNN	90,8	72,8	67,8	80,8
Votação	CNN	87,2	92,4	81,4	89,7

Fonte: adaptado de Pereira et al. (2021)

O modelo final possui 2.164.593 parâmetros, sendo 2.161.649 treináveis e 2.944 não-treináveis, usa “Entropia Cruzada Binária” como função de custo e ADAM como método de otimização.

4.3 MATERIAL

4.3.1 Google Colab

A plataforma escolhida para o desenvolvimento do projeto foi o Google Colab, um ambiente Python disponibilizado pela Google através de processamentos na nuvem. Além de ser um serviço gratuito, rápido e de fácil aprendizado, o Colab disponibiliza a sincronização com o Google Drive e o uso de *Graphic Processing Units* (GPUs) e *Tensor Processing Units* (TPUs) da empresa de modo online, embora seja de forma limitada.

4.3.2 Python

A linguagem de programação utilizada no projeto foi o Python versão 3.9.0. A biblioteca NumPy foi utilizada para as operações com matrizes, o Matplotlib para a

impressão de imagens e gráficos, o Keras para a implementação do modelo e o eo-learn para a obtenção das imagens do Sentinel-2.


4.4 IMAGENS

As imagens foram obtidas através da coleção de dados do produto Level-1C, com medidas fornecidas em reflectâncias *Top Of Atmosphere*, semelhantes as imagens utilizadas do Landsat-8 utilizadas no treinamento da Rede Neural Artificial. Já as bandas selecionadas foram: Azul (B02), SWIR1 (B11) e SWIR2 (B12), que foram utilizadas no treinamento do modelo.

As datas escolhidas foram entre 01/08/2020 e 01/11/2020, de modo a recolher informações do período crítico de seca da região (agosto e setembro) e o início da estação de chuvas (outubro). Outro parâmetro definido foi o de recolher apenas imagens cobertas com, no máximo, 50% dos pixels cobertos por nuvens. Dada essas limitações e o período de cinco dias de revisita do Sentinel-2, foram obtidas quinze imagens da área de estudo de resolução 2496 x 2489 pixels.

A partir da figura 10, nota-se como as bandas selecionadas destacam o fogo ativo e limpam parte das nuvens e fumaça da imagem em comparação com imagens obtidas nas bandas RGB.

Figura 10 – Imagem do dia 13/09/2020 em RGB, à esquerda, e das bandas selecionadas, à direita



Fonte: Autor

4.5 PRÉ-PROCESSAMENTO

Para servirem de entrada para o modelo, as imagens precisaram passar por etapas de pré-processamento de modo a se tornarem compatíveis com os dados utilizados para o treinamento da RNA. Por isso, após a coleta, foi utilizada a biblioteca NumPy para manipular as matrizes contendo as bandas das imagens. Visto que o treinamento do modelo ocorreu com imagens derivadas do Landsat-8, o primeiro passo foi o de ajustar os valores das bandas fornecidas pelo Sentinel-2, que usa o sensor MSI, para valores equivalentes para o sensor OLI. Para isso, foram utilizadas equações de 1º grau fornecidas por Claverie et al. (2018), com coeficientes indicados na tabela 4:


Tabela 4 – Coeficientes usados para a regressão linear de ajuste

			Sentinel-2A	
Nome da banda	Nome no OLI	Nome no MSI	Coefficiente Angular	Coefficiente Linear
Azul	2	2	0.9778	-0.004
SWIR 1	6	11	0.9987	-0.0011
SWIR 2	7	12	1.003	-0.0012

Fonte: Adaptado de Claverie et al. (2018)

Em seguida, foi aplicada uma técnica de preenchimento das matrizes, adicionando linhas, na parte inferior, e colunas, na parte direita, com valores zero de modo que as imagens tivessem resolução múltipla de 256 no eixo de altura e de largura. Assim, foram obtidas imagens de 2560 x 2560 pixels, como a figura 11.


Figura 11 – Imagem do dia 13/09/2020 após o processo de preenchimento



Fonte: Autor

Depois, as imagens preenchidas foram recortadas em matrizes de 256x256, resolução exigida como entrada do modelo. Desse modo, foram obtidas 1500 imagens de resolução 256 x 256 e três bandas (Azul, SWIR1 e SWIR2). A figura 12 mostra como ocorreu o corte de uma das imagens obtidas.

Figura 12 – Imagem do dia 13/09/2020 com grade sinalizando as imagens obtidas após o fim do pré-processamento



Fonte: Autor

Após o processamento das imagens obtidas, as saídas do modelo foram recoladas na mesma sequência que foram cortadas, de modo que foram produzidas máscaras com a mesma resolução das imagens preenchidas antes do recorte, com resolução 2560x2560 cujos pixels representassem o mesmo local que na imagem original.

4.6 VALIDAÇÃO

A ferramenta escolhida para a validação dos dados obtidos pelo modelo foi o BDQueimadas. Foram tiradas impressões de tela da plataforma na mesma região de interesse e nas mesmas datas que as imagens obtidas para o estudo. Além disso, foram delimitadas detecções de focos ativos apenas do satélite AQUA para o período da tarde, que é o de referência do programa e que passa na região ao redor das 14 horas, próximo do horário do Sentinel-2. As impressões são colocadas lado a lado com as máscaras produzidas pelo algoritmo para comparação visual.

5 ANÁLISE DOS RESULTADOS


5.1 MÁSCARAS PRODUZIDAS

Após todo o processo descrito no capítulo anterior, são produzidas quinze máscaras, cujos pixels são representados por valores booleanos, sendo *True* o indicativo para pixel contendo fogo ativo e *False* para quando não. Para todo o período, foram detectados 68967 pixels ativos. A resolução espacial das imagens foi definida em 20 m, conseqüentemente, cada pixel representa uma área de 400 m², ou 0,0004 km². Desse modo, deriva-se que foram detectados 27,59 km² de fogo ativo nas imagens coletadas para o projeto.

A partir do gráfico na figura 13, observa-se que o momento mais crítico dos incêndios na região foi entre o fim de agosto (29/08/2020) até a metade de setembro (13/09/2020). As quatro imagens nesse período concentraram 84,66% de todos os pixels detectados em todo período analisado. Dentre as imagens adquiridas, o pico do incêndio ocorreu em 13/09/2020, quando 20.772 pixels ativos foram detectados, o equivalente a 8,3 km² de fogo ativo e a 30,12% do total observado. Esse período de pico é coerente com Menegassi (2020), que no dia 16/09/2020 noticiava uma perda de 85% da vegetação do parque até aquele momento devido aos incêndios.

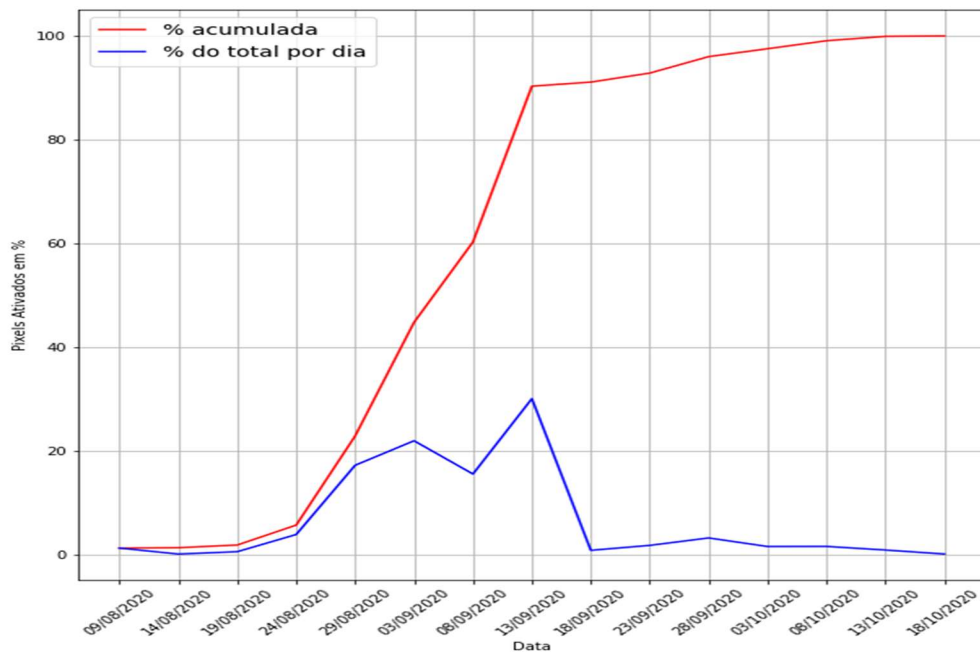
Já observando-se o gráfico da figura 14, vê-se que após o momento de pico, ocorre uma grande queda na detecção de queimadas ativas por parte do algoritmo, a partir da imagem retirada no dia 18/09/2020, que se mantém até o fim do período observado, com um breve momento de alta no dia 28/09. Os dados apresentados nos gráficos são coerentes com as características climáticas da área, onde o período seco mais forte se dá entre agosto e setembro, com a estação úmida e de chuvas começando em outubro.

Figura 13 – Quantidade de pixels contendo fogo ativo por dia



Fonte: Autor

Figura 14 – Quantidade acumulada de pixels ativados para o período analisado



Fonte: Autor

As máscaras produzidas no processamento são mostradas na figura 15, ao lado de suas imagens de origem.

Figura 15 – Imagens das bandas selecionadas, à esquerda, e da máscara produzida, à direita



a) 09/08/2020




b) 14/08/2020





c) 19/08/2020




d) 24/08/2020



e) 29/08/2020




f) 03/08/2020





g) 08/09/2020





h) 13/09/2020





i) 18/09/2020





j) 23/09/2020




k) 28/09/2020




l) 03/10/2020




m) 08/10/2020



n) 13/10/2020



o) 18/10/2020



Fonte: Autor

Comparando as imagens da região de interesse nas bandas vermelho, SWIR1 e SWIR2 às máscaras produzidas pelo modelo, observa-se que os fogos ativos mais evidentes são facilmente detectados pelo algoritmo. Alguns pixels ativos isolados são detectados em todas as imagens, o que pode indicar um pequeno foco de incêndio ou erro do algoritmo.

A figura 15i e, principalmente, figura 15j foram as que mais tiveram interferências devido as nuvens, mesmo com a filtragem de bandas. As duas figuras correspondem com a queda abrupta na detecção de pixels ativos observada no Gráfico 1, após o pico detectado na figura 15h.


Quanto a análise do avanço dos incêndios a partir das máscaras geradas, percebe-se que num primeiro momento são detectados pequenos focos na parte de cima da imagem, como nas figuras 15a e 15c. A partir da figura 15d e 15e, observa-se um aumento gradual dos focos detectados, até que em 15f são detectados os primeiros grandes focos na parte de baixo. As figuras 15g e 15h já mostram o fogo tomando conta de toda a região de interesse, apresentando focos em todas as áreas da imagem. A partir da figura 15k, depois das figuras afetadas pelas nuvens, já se observa uma queda no número de pixels ativados, com pequenos focos espalhados pela região que vão decrescendo até a última captura do período analisado, na figura 15o, que já apresenta uma máscara quase limpa.

5.2 COMPARATIVO COM O BDQUEIMADAS

Na figura 16, as máscaras são colocadas ao lado das imagens obtidas através da plataforma BDQueimadas.

Figura 16 – Máscara produzida, à esquerda, e imagem de validação, à direita


a) 09/08/2020




b) 14/08/2020





c) 19/08/2020





d) 24/08/2020



e) 29/08/2020



f) 03/09/2020




g) 08/09/2020




h) 13/09/2020




i) 18/09/2020




j) 23/09/2020





k) 28/09/2020




l) 03/10/2020



m) 13/10/2020



n) 18/10/2020



Fonte: Autor

Em comparação com o Aqua-Tarde, satélite de referência utilizado pelo BDQueimadas, a Rede Neural Convolutiva aplicada detecta focos de calor semelhantes para as mesmas datas. Além disso, devido a maior resolução espacial do Sentinel-2, consegue dar mais detalhes quanto a extensão e formato dos incêndios. Entretanto, a plataforma utilizada pelo INPE é capaz de fornecer dados diários de detecção de fogo, enquanto o Sentinel-2 só consegue fazer o monitoramento a cada cinco dias.

Para as figuras 16j e 16h, por exemplo, que correspondem às datas de pico do incêndio dentre os dias analisados, as máscaras produzidas pela CNN aplicada detectam mais focos de queimadas que o algoritmo do INPE. Na figura 16j tem-se a impressão de que o fogo está concentrado apenas na parte de baixo da imagem, enquanto a CNN mostra que o fogo estava generalizado na região, com focos menores por toda área da imagem.

A evolução dos incêndios que foi captada pela rede neural também é corroborada pelo algoritmo da plataforma BDQueimadas, com focos crescentes sendo detectados na parte de cima da imagem, até que o incêndio migra para a parte de baixo e, na figura 16h, toma conta de toda a região. Após o pico, há a mesma queda brusca a partir da figura 16i e a quantidade de focos continua a diminuir até o final do período analisado.

5.3 DISCUSSÕES

Observa-se que as máscaras geradas pelo algoritmo foram capazes de, no geral, detectar focos ativos de incêndio, sejam de grande ou pequena magnitude. Os contornos das frentes do incêndio são bem definidos e indicam com precisão quais partes da região de interesse estão sendo mais afetadas no momento, o que pode auxiliar no estudo da evolução da degradação causada pelo fogo. Entretanto, a média ou alta resolução espacial de um satélite está geralmente associada com uma baixa resolução temporal, como acontece com Sentinel-2. Além disso, ainda há o tempo para a processamento e disponibilização das imagens ao público. Esses fatores inviabilizam o uso desses satélites para acompanhamento de fenômenos em tempo real.

O fato de a Rede Neural Artificial ter sido treinada a partir de uma base de dados gerada por imagens do Landsat-8, de resolução espacial de trinta metros também é digno de atenção. Embora a resolução espectral seja semelhante à utilizada nessa monografia, essa diferença entre as fontes das imagens utilizadas para treinamento e para a aplicação do modelo causam distorções no funcionamento do algoritmo. Para garantir um melhor desempenho sobre as imagens utilizadas, deveria ter sido feito uma recalibragem dos pesos através de um novo treinamento a partir de imagens e máscaras obtidas do Sentinel-2. Entretanto, devido às limitações de tempo e de equipamento, optou-se por utilizar os pesos originais.

Outra limitação do modelo é que as máscaras utilizadas para seu treinamento foram geradas a partir de algoritmos pré-existentes. Desse modo, dificulta-se o aprendizado supervisionado de padrões que não são detectados por métodos mais arcaicos e restringe-se o potencial da ferramenta. O ideal seria utilizar máscaras anotadas por especialistas humanos, que é o padrão ouro para a segmentação. Contudo, a necessidade de se formar um grande banco de dados para aumentar a capacidade de generalização da rede faz com que seja necessária uma grande mão de obra desses profissionais, o que dificulta o seu uso.

Mesmo assim, as CNNs ainda são capazes de superar os algoritmos em que foram baseadas quando comparadas a máscaras anotadas por especialistas, como é mostrado no quadro 3. Isso reforça o alto potencial dessa técnica de aprendizagem de máquina para tarefas de segmentação semântica e a importância de que mais máscaras produzidas por especialistas sejam disponibilizadas para o público em geral, seja por meio de órgãos governamentais, como a USGS e INPE, ou pelos pesquisadores e pesquisadores da área.

6 CONSIDERAÇÕES FINAIS

O modelo aplicado nesse estudo se mostrou capaz de detectar focos de queimadas ativas e de produzir máscaras de segmentação indicando sua localização na imagem. Em comparação com o algoritmo utilizado pela plataforma BDQueimadas sobre imagens retiradas pelo satélite de referência Aqua-Tarde, a CNN apontou focos em locais semelhantes, porém com maior riqueza de detalhes, visto que as imagens do Sentinel-2 utilizadas possuem resolução espacial de 20 m, enquanto a do Aqua é de 250 a 1000 m. Por esse motivo, também foi capaz de detectar focos menores e isolados.

Através das máscaras geradas, foi possível acompanhar a evolução dos incêndios na região de interesse, que, no período analisado, aparecem primeiro em pequena escala na parte de cima da imagem, se alastram gradativamente até que, no dia 03/09/2020, são detectados grandes focos na parte de baixo da imagem. Nas duas próximas imagens, a quantidade de pixels ativados cresce, atingindo um pico de 20772 em 13/09/2020. A partir da imagem seguinte, em 18/09/2020, a quantidade de focos encontrados tem uma queda brusca, que pode ter sido causado pela presença de nuvens na imagem. Porém, a tendência de queda continua até o fim do período estudado.

No momento, a aplicação de CNNs para a detecção de fogo ativo em imagens de alta resolução espacial é útil como parte de uma análise posterior da evolução e dos impactos de incêndios florestais em grandes áreas. O nível de detalhes refletidos nas máscaras, como a extensão, formato e localização de focos isolados, é uma vantagem em relação aos satélites utilizados atualmente pelo INPE, por exemplo. Contudo, para um monitoramento em tempo real, é importante que haja uma alta resolução temporal, com satélites capazes de passar quase que diariamente sobre uma região. Para esse fim, satélites como o MODIS, combinado com outros programas como o VIIRS, mesmo com baixa resolução espacial, podem ser mais úteis.

Entretanto, levando em conta os rápidos avanços tecnológicos, pode-se vislumbrar para o futuro o aparecimento de satélites que aliem a alta resolução espacial e temporal, ampliando o leque de utilidades de modelos para detecção em tempo real em imagens como as utilizadas nesse estudo. Assim, é importante que sejam disponibilizados bancos de imagem de queimadas geradas por especialistas para que o treinamento de modelos ainda mais eficientes seja facilitado.

REFERÊNCIAS

- ALBUQUERQUE, I. et al. Análise das emissões brasileiras de gases de efeito estufa e suas implicações para as metas de clima do Brasil. 1970 – 2019. Observatório do Clima. 2020.
- BARMPOUTIS, P. A Review on Early Forest Fire Detection Systems Using Optical Remote Sensing. **Sensors**, vol. 20 (22), 2020.
- CHAVES, J. V. B. SILVA, J. S. V. Evolução das unidades de conservação no Pantanal no período de 1998 a 2018. **Anais 7º Simpósio de Geotecnologias no Pantanal**, p. 676-685, Jardim, 2018.
- CLAVERIE, M. et al. The Harmonized Landsat and Sentinel-2 surface reflectance data set. **Remote Sensing of Environment**, vol. 219, 15 de nov. de 2018, p. 145-161.
- Embrapa Pantanal. O Pantanal. Corumbá, 2021. Disponível em: <https://www.embrapa.br/pantanal/apresentacao/o-pantanal>. Acesso em: 20 de set. de 2021.
- Embrapa. Missões, Campinas. Disponível em: <https://www.embrapa.br/satelites-de-monitoramento/missoes>. Acesso em: 29 de set. de 2021.
- ENGESAT. SENTINEL-2. Disponível em: <http://www.engesat.com.br/sentinel-2/>. Acesso em 02 de out. de 2021.
- ESA – Agência Espacial Europeia. Sentinel-2. Disponível em: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>. Acesso em: 04 de out. de 2021.
- GARCIA, L. C. et al. Record-breaking wildfires in the world's largest continuous tropical wetland: Integrative fire management is urgently needed for both biodiversity and humans. **Journal of Environmental Management**, vol. 293, 1 de set. de 2021.
- GIGLIO, L. et al. Active fire detection and characterization with the advanced spaceborne thermal emission and reflection radiometer (ASTER). **Remote Sensing of Environment**, vol. 112, 2008, p. 3055-3063.
- GIGLIO, L.; SCHROEDER, W.; JUSTICE, C., O. The collection 6 MODIS active fire detection algorithm and fire products. **Remote Sensing Environment**, vol. 178, 1 de jun. de 2016, p. 31-41.

GONTIJO, J. et al. Detecção de queimadas e validação de focos de calor utilizando produtos de Sensoriamento Remoto. **Simpósio Brasileiro de Sensoriamento Remoto – SBSRA**t, Curitiba, vol. 15, abr. de 2011.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep Learning – An MIT Press book. **MIT Press**, 2016. Disponível em: <https://www.deeplearningbook.org/>. Acesso em 27 de out. de 2021.

HU, X.; YIFANG, B. Sentinel-2 MSI data for active fire detection in major fire-prone biomes: A multi-criteria approach. **International Journal of Applied Earth Observation and Geoinformation**, vol. 101, set. de 2021

IBM Cloud Education. Convolutional Neural Network, 20 de out. de 2020. Disponível em: <https://www.ibm.com/cloud/learn/convolutional-neural-networks>. Acesso em 05 de nov. de 2021.

ICMBio. Manual para Formação de Brigadista de Prevenção e Combate aos Incêndios Florestais. Instituto Chico Mendes de Conservação da Biodiversidade, Brasília.

INPE – Instituto Nacional de Pesquisas Espaciais. BDQueimadas. Disponível em: <https://queimadas.dgi.inpe.br/queimadas/bdqueimadas/>. Acesso em: 01 de nov. de 2021.

INPE – Instituto Nacional de Pesquisas Espaciais. Manual de Referência de Queimadas. Disponível em: <https://queimadas.dgi.inpe.br/queimadas/portal/outros-produtos/manual>. Acesso em 06 de nov. de 2021.

ISA – Instituto Socioambiental. Parque Estadual Encontro das Águas. **Unidades de Conservação no Brasil**. Disponível em: <https://uc.socioambiental.org/pt-br/arp/4253>. Acesso em: 02 de out. de 2021.

KOVÁCS, Z. L. **Redes Neurais Artificiais**. São Paulo: Editora Livraria da Física, 2006.

KUMAR, S. S.; ROY, D. P. Global operational land imager Landsat-8 reflectance-based active fire detection algorithm. **International Journal of Digital Earth**, vol. 11, 2018, p. 157-178.

LeCUN, Y. et al. Backpropagation Applied to Handwritten Zip Code Recognition. **Neural Computation**, vol. 1, dez. de 1989.

- LeCUN, Y.; BENGIO, Y.; HINTON, G. Deep Learning. **Nature**, vol 521, 2015, p. 436-444.
- LIN, Z. et al. An active fire detection algorithm based on multi-temporal FengYun-3C VIRR data. **Remote Sensing of Environment**, vol. 211, 15 de jun. de 2018, p. 376-387.
- LUCIARDO, R., O.; CUNHA, N., R., S.; JUNIOR, A., G., S. Identificação e proposição de métodos de valoração econômica dos efeitos das queimadas no estado de Mato Grosso. **XLII Congresso da SOBER**, Cuiabá, MT, Vol. 10, p. 14, 2004
- MENEGASSI, D. Mais de 80% da área do Parque Estadual Encontro das Águas já foi atingida pelo fogo. **(o) eco**. 16 de set. de 2020. Disponível em: <https://www.oeco.org.br/reportagens/mais-de-80-da-area-do-parque-estadual-encontro-das-aguas-ja-foi-atingida-pelo-fogo/>. Acesso em: 21 de set. de 2021.
- MURPHY, S. W. et al. HOTMAP: Global hot target detection at moderate spatial resolution. **Remote Sensing of Environmet**, vol. 177, mai. de 2016, p. 78-88.
- NASA - Administração Nacional da Aeronáutica e Espaço. Band Pass Adjustment. **Harmonized Landsat Sentinel-2**, 19 de set. de 2018. Disponível em: <https://hls.gsfc.nasa.gov/algorithms/bandpass-adjustment/>. Acesso em: 19 de nov. de 2021.
- NASA - Administração Nacional da Aeronáutica e Espaço. Landsat 8 Overview. **Landsat Science**. Disponível em: <https://landsat.gsfc.nasa.gov/landsat-8/landsat-8-overview>. Acesso em: 10 de out. de 2021.
- NOBRE, C. A. Mudanças climáticas e o Brasil – Contextualização. **Parcerias Estratégicas**, vol. 27, Brasília, dez. de 2008.
- PEREIRA, G. H. A. et al. ISPRS Journal of Photogrammetry and Remote Sensing, vol. 178, 2021, p. 171-186.
- PIROMAL, R., A., S. et al. Utilização de dados MODIS para a detecção de queimadas na Amazônia. **Acta Amazonica**, vol 38(1), 2008.
- RAUBER, T. W. Redes Neurais Artificiais. 23 de mai. de 2013.
- RIBEIRO, H; ASSUNÇÃO, J. V. Efeitos das queimadas na saúde humana. **Estudos Avançados** 16. 2002.

SAHA, S. A Comprehensive Guide to Convolutional Neural Networks – the ELI5 way. **Towards Data Science**, 15 de dez. de 2018. Disponível em: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>. Acesso em: 07 de out. de 2021.

SAN-MIGUEL-AYANZ, J.; RAVAIL, N. Active Fire Detection for Fire Emergency Management: Potential and Limitations for the Operational Use of Remote Sensing. **Natural Hazards**, vol. 35, jul. de 2005, p. 361-375.

SANTOS, D.; TEIXEIRA, W. G; BAHIA, V. G. Queimadas e Erosão do Solo. **Inf. Agropec.**, Belo Horizonte, v. 16, n. 176, p 62-68.

SCHROEDER, W. et al. Active fire detection using Lansat-8/OLI data. **Remote Sensing of Environment**, vol. 185, 16 de nov. de 2016, p. 210-220.

SEMAGRO/MS – Secretaria de Estado de Meio Ambiente, Desenvolvimento Econômico, Produção e Agricultura Familiar. Pantanal. Campo Grande, 2021. Disponível em: <https://www.turismo.ms.gov.br/conheca-ms/pantanal/>. Acesso em: 20 de set. de 2021.

SOARES, D. 85% de parque no Pantanal de MT que abriga maior refúgio de onças-pintadas no mundo foi destruído por incêndios. G1 MT, 16 de set. de 2020. Disponível em: <https://g1.globo.com/mt/mato-grosso/noticia/2020/09/16/85percent-de-parque-no-pantanal-de-mt-que-abriga-maior-refugio-de-oncas-pintadas-no-mundo-foi-destruido-por-incendios.ghtml>. Acesso em: 21 de set. de 2021.

WANG, S. Multiple Sclerosis Identification by 14-Layer Convolutional Neural Network With Batch Normalization, Dropout, and Stochastic Pooling. **Front. Neurosci.**, nov. de 2018.

WWF. Pantanal. Disponível em: https://www.wwf.org.br/natureza_brasileira/areas_prioritarias/pantanal/. Acesso em 14 de out. de 2021.

ZAMBIASI, S. P. O neurônio artificial. Universidade Federal de Santa Catarina, 2011.

APÊNDICE

Apêndice A – Pixels ativados por data e no acumulado total

Data	Pixels Ativados	% do total	% acumulada
09/08/2020	840	1,22	1,22
14/08/2020	50	0,07	1,29
19/08/2020	361	0,52	1,81
24/08/2020	2647	3,84	5,65
29/08/2020	11856	17,19	22,84
03/09/2020	15117	21,92	44,76
08/09/2020	10693	15,51	60,27
13/09/2020	20722	30,05	90,32
18/09/2020	543	0,79	91,11
23/09/2020	1200	1,74	92,85
28/09/2020	2189	3,17	96,02
03/10/2020	1051	1,52	97,54
08/10/2020	1062	1,54	99,08
13/10/2020	582	0,84	99,92
18/10/2020	54	0,08	100
Total	68967	100	