



INSTITUTO FEDERAL
DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
Bahia

Campus
Vitória da Conquista



COORDENAÇÃO DE ENGENHARIA ELÉTRICA - **COEEL**

PROJETO FINAL DE CURSO - PFC

Modelo de Classificação para Monitoramento de
Desmatamento na Amazônia Brasileira utilizando Redes
Neurais Artificiais

EDSON COSTA OLIVEIRA

Vitória da Conquista-BA
04 de dezembro de 2023

EDSON COSTA OLIVEIRA

**Modelo de Classificação para Monitoramento de
Desmatamento na Amazônia Brasileira utilizando
Redes Neurais Artificiais**

Projeto Final de Curso apresentado ao Curso de Graduação em Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia da Bahia, *campus* Vitória da Conquista, como requisito parcial para obtenção do título de Bacharel em Engenharia Elétrica.

Orientador: Dr. Juan Lieber Marin

Coorientador: Me. Gislân Silveira Santos

Vitória da Conquista-BA

04 de dezembro de 2023

O48m Oliveira, Edson Costa

Modelo de classificação para monitoramento de desmatamento na Amazônia brasileira utilizando redes neurais artificiais. / Edson Costa Oliveira. – Vitória da Conquista-BA : IFBA, 2023.
96 f.il.: color.

Orientador: Prof. Dr. Juan Lieber Marin.

Trabalho Conclusão de Curso (Graduação) Engenharia Elétrica - Instituto Federal de Educação, Ciência e Tecnologia da Bahia - *Campus* de Vitória da Conquista-BA, 2023.

1. Redes neurais. 2. Desmatamento. 3. Geoprocessamento.
4. Amazônia. I. Marin, Juan Lieber. II. Título.

CDD: 621.382



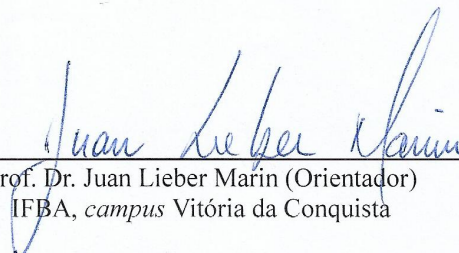
FOLHA DE APROVAÇÃO DO PROJETO FINAL DE CURSO DE
ENGENHARIA ELÉTRICA


**MODELO DE CLASSIFICAÇÃO PARA MONITORAMENTO DE DESMATAMENTO NA
AMAZÔNIA BRASILEIRA UTILIZANDO REDES NEURAIS ARTIFICIAIS**

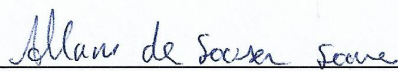
EDSON COSTA OLIVEIRA

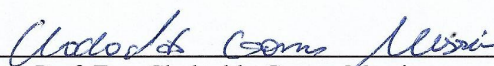
A presente monografia de Projeto Final de Curso (PFC), apresentada em sessão realizada em 04 de dezembro de 2023, foi avaliada como adequada para a obtenção do Grau de Bacharel em Engenharia Elétrica, julgada APROVADA em sua forma final pela Coordenação do Curso de Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia da Bahia, *campus* Vitória da Conquista.

Banca examinadora,


Prof. Dr. Juan Lieber Marin (Orientador)
IFBA, *campus* Vitória da Conquista


Prof. Me. Gislân Silveira Santos (Coorientador)
IFBA, *campus* Vitória da Conquista


Prof. Me. Allan de Sousa Soares
IFBA, *campus* Vitória da Conquista


Prof. Esp. Clodoaldo Gomes Messias
IFBA, *campus* Vitória da Conquista

Vitória da Conquista - Bahia

Dedico esta obra a Deus. Que toda honra e toda glória sejam dadas a Ele. Aos professores Juan Lieber e Gislân Silveira pelo suporte e dedicação na construção do projeto. Ao PET Engenharias pela inspiração na área ambiental. Por fim, à minha família, especialmente a minha mãe, que esteve ao meu lado durante toda a minha caminhada e foi fundamental para a realização desse sonho.

Um pouco de ciência nos afasta de Deus. Muito, nos aproxima. [Louis Pasteur]

AGRADECIMENTOS

Agradeço primeiramente a Deus pela construção dessa obra. A sua bondade e misericórdia me deu forças e capacidade para cumprir mais uma etapa da minha vida. Que toda honra e toda glória sejam dadas ao nosso Deus, o senhor de Abraão, Isaque e Jacó, criador de todas as coisas.

Agradeço a minha família. À minha mãe e rainha, Judite, por estar todos os dias ao meu lado. Por me apoiar e fazer os meus momentos mais difíceis os seus também. Por desejar sempre o meu melhor e me ouvir sempre que precisei. Por isso, muito obrigado, mãe! Sem você, com certeza, esse sonho não seria possível. Agradeço ao meu pai, Denilvado, pelas palavras positivas e pelos momentos que não hesitou em me apoiar quando precisei. Agradeço a minha irmã Josiane que cresceu ao meu lado e me motivou e ajudou ativamente a participar de todas as oportunidades que surgiram até aqui na minha vida. Agradeço minhas outras duas irmãs, Silene e Eliane, e aos meus irmãos, Aparecido, Genilson e Nivaldo, e ao meu primo de sangue e irmão de alma, Milton, por apoiar e ajudar sempre que precisei. Enfim, agradeço a todos os familiares. Cada um foi importante nessa conquista.

Agradeço aos professores Juan Lieber e Gislân Silveira por sua dedicação e entusiasmo na realização do projeto. Suas orientações e apoio foram fundamentais para o desenvolvimento deste trabalho. Estou grato por ter tido a oportunidade de aprender com seus conhecimentos e experiência.

Agradeço ao PET Engenharias por proporcionar os melhores momentos da minha trajetória no IFBA e por me proporcionar uma interação enriquecedora com a engenharia ambiental. Acredito que tenha sido uma das maiores fontes de motivação para a realização deste projeto.

Gostaria de expressar minha gratidão à tutora do PET Engenharias, Joseane da Silva, que acreditou em mim desde a minha entrevista de seleção para o programa. Seu incentivo e apoio foram e continuam sendo fundamentais para o meu

crescimento profissional.

Estendo meu agradecimento a todos os meus amigos do PET Engenharias, em especial ao meu grupo de Engenharia Elétrica, Estefani Montenegro, Filipe Carvalho, Mikelly Anjos e *mi amiga* Giselle Francine, pela amizade e companheirismo ao longo dessa jornada.

Agradeço ao meu amigo e irmão, José Leonardo Marinho. Sua presença e apoio têm sido elementos essenciais na minha trajetória.

Expresso minha gratidão ao meu grupo de trabalhos acadêmicos composto por Anthony Almas, Julianny Oliveira e Tiago Menezes. Foram simplesmente oito semestres enfrentando os desafios da graduação juntos.

Por fim, gostaria de expressar minha gratidão à instituição e a todos os professores que contribuíram para a minha formação acadêmica. As lições aprendidas serão um alicerce sólido para meu futuro.

RESUMO

A floresta amazônica possui uma riqueza exuberante de fauna e flora, sendo reconhecida como a maior biodiversidade do mundo. Além disso, desempenha um papel fundamental no equilíbrio do clima global. No entanto, o desmatamento ilegal na Amazônia tem repercussões significativas em nível internacional, com consequências negativas para a biodiversidade brasileira, as mudanças climáticas, entre outros aspectos. O monitoramento da floresta por meio de satélites permite a visualização de áreas desmatadas. As imagens geradas pelo sensoriamento remoto permitem a classificação dessas áreas e o monitoramento das possíveis causas do desmatamento. Nesse contexto, as redes neurais artificiais desempenham um papel importante e têm sido utilizadas nessa área de pesquisa. Portanto, o objetivo deste trabalho é desenvolver um classificador por meio das redes neurais artificiais capaz de analisar imagens espaciais e identificar áreas desmatadas ou não desmatadas. Foram estudadas técnicas de geoprocessamento, como o Modelo Linear de Mistura Espectral e técnicas avançadas de Rede Neurais Artificiais, como a Fusão de Dados. Os resultados encontrados mostraram que as arquiteturas *Multilayer Perceptron (MLP)* e *Convolutional Neural Networks (CNN)* foram capazes de classificar áreas desmatadas com uma área na curva ROC acima de 95%. Prosseguindo, a fusão de dados trouxe resultados ainda mais significativos, igualando à curva ROC ideal e acertando, em três dos modelos criados, todas as amostras proferidas à rede. Desse modo, é possível dizer que o classificador forneceu resultados precisos, contribuindo assim para a comunidade científica que trabalha em prol do bem-estar da Amazônia brasileira.

Palavras-chave: Redes Neurais, desmatamento, geoprocessamento, Amazônia.

ABSTRACT

The Amazon rainforest boasts a rich abundance of fauna and flora, recognized as the world's greatest biodiversity. Additionally, it plays a crucial role in maintaining global climate balance. Nevertheless, illegal deforestation in the Amazon has significant international repercussions, negatively affecting Brazilian biodiversity, climate change, among other aspects. Forest monitoring through satellites allows the visualization of deforested areas. Remote sensing images enable the classification of these areas and the monitoring of potential causes of deforestation. In this context, artificial neural networks play an important role and have been utilized in this research field. Therefore, the objective of this work is to develop a classifier through artificial neural networks capable of analyzing spatial images and identifying deforested or non-deforested areas. Geoprocessing techniques such as the Linear Spectral Mixture Model were studied, alongside advanced Artificial Neural Network techniques like Data Fusion. The results demonstrated that Multilayer Perceptron (MLP) and Convolutional Neural Networks (CNN) architectures were able to classify deforested areas with a ROC curve area above 95%. Furthermore, data fusion yielded even more significant results, matching the ideal ROC curve and correctly classifying, in three of the created models, all samples presented to the network. Thus, it can be said that the classifier provided accurate results, contributing to the scientific community working for the well-being of the Brazilian Amazon.

Keywords: Neural Networks, deforestation, geoprocessing, Amazon.

Lista de Figuras

| | | |
|------|--|----|
| 2.1 | Etapas de processamento de imagens espaciais utilizando o sensoriamento remoto | 9 |
| 2.2 | Onda Eletromagnética | 10 |
| 2.3 | Espectro eletromagnético em relação ao comprimento e frequência de onda. Ainda é apresentada uma comparação em escala com algumas entidades físicas e químicas. | 11 |
| 2.4 | A luz sendo refratada e resultando em um arco-íris como raio refratado | 12 |
| 2.5 | (A) Reflexão Difusa (B) Reflexão Especular | 13 |
| 2.6 | Gráfico de reflectância da água, do solo e da vegetação dentro do espectro eletromagnético | 15 |
| 2.7 | Espaço geográfico do IFBA campus Vitória da Conquista sendo ilustrado por 6 resoluções espaciais | 17 |
| 2.8 | Gráfico tridimensional contendo informações espaciais e espectrais. Os eixos y e x correspondem aos pixels. O eixo λ corresponde ao comprimento de onda do espectro eletromagnético. | 18 |
| 3.1 | Problema de mistura espectral na formação do pixel em uma imagem digital. É visto a mistura espectral de três componentes: água, solo e vegetação. | 20 |
| 3.2 | (A) Composição Cor Real (B) Fração Água (C) Fração Vegetação (D) Fração Solo | 24 |
| 3.3 | Imagem colorida composta pelas imagens fracionadas de água, solo e vegetação. | 25 |
| 3.4 | Neurônio humano. | 26 |
| 3.5 | Neurônio artificial | 27 |
| 3.6 | Arquitetura MLP | 30 |
| 3.7 | Estrutura CNN | 32 |
| 3.8 | Tipos de fusão de dados. (A) Fusão precoce (B) Fusão intermediária (C) Fusão tardia | 34 |
| 3.9 | Exemplo de curvas ROC | 35 |
| 3.10 | Gráfico de um histograma ilustrativo de um bom classificador | 36 |

| | | |
|------|---|----|
| 3.11 | Gráfico de um histograma ilustrativo de um classificador ruim | 36 |
| 4.1 | Imagens consideradas não desmatadas para o treinamento da rede neural. (A) Floresta Amazônica localizada no estado do Pará. (B) Mina do Salobo localizada no estado do Pará. | 38 |
| 4.2 | Imagens consideradas desmatadas para o treinamento da rede neural. (A) Desmatamento com solo exposto/pastagem no estado do Acre. (B) Garimpo na região indígena de Kayapós, no Pará. | 38 |
| 4.3 | Reflectância das três componentes abordadas para a realização do trabalho | 42 |
| 4.4 | Estrutura montada por meio da fusão tardia | 43 |
| 5.1 | Curvas ROC das arquiteturas MLP e CNN para as imagens composição cor real. | 48 |
| 5.2 | Histograma de separabilidade da arquitetura CNN para as imagens composição cor real | 48 |
| 5.3 | Histograma de Separabilidade da arquitetura MLP para as imagens composição cor real | 49 |
| 5.4 | Gráfico das curvas ROC das arquiteturas MLP e CNN treinadas pelas imagens compostas pelas frações das componentes | 51 |
| 5.5 | Histograma de Separabilidade para a arquitetura CNN treinada com as imagens formadas pelas frações | 51 |
| 5.6 | Histograma de Separabilidade para a arquitetura MLP treinada com as imagens formadas pelas frações | 52 |
| 5.7 | Gráfico comparativo entre as curvas ROC das arquiteturas CNN das imagens composição cor real e das imagens formadas pelas frações e da fusão de ambas arquiteturas. | 54 |
| 5.8 | Histograma da fusão das arquiteturas CNN + CNN | 54 |
| 5.9 | Gráfico comparativo entre as curvas ROC da arquitetura CNN das imagens composição cor real e da arquitetura MLP das imagens formadas pelas frações e da fusão de ambas arquiteturas | 55 |
| 5.10 | Histograma da fusão das arquiteturas CNN + MLP | 56 |
| 5.11 | Gráfico comparativo entre as curvas ROC da fusão de dados, da arquitetura MLP das imagens composição cor real e da arquitetura CNN das imagens formadas pelas frações | 57 |
| 5.12 | Histograma da fusão das arquiteturas MLP + CNN | 57 |

| | |
|--|----|
| 5.13 Gráfico comparativo entre as curvas ROC das arquiteturas MLP das imagens composição cor real e das imagens formadas pelas frações e da fusão de ambas arquiteturas. | 58 |
| 5.14 Histograma da fusão das arquiteturas MLP + MLP | 59 |

Lista de Tabelas

| | | |
|-----|---|----|
| 2.1 | Bandas espectrais trabalhadas no sensoriamento remoto | 16 |
| 4.1 | Câmera Multiespectral e Pancromática de Ampla Varredura (WPM) . | 39 |
| 4.2 | Dados dos mapas multiespectrais criados no software QGIS | 40 |
| 4.3 | Informações da máquina utilizada para o treinamento das redes neurais | 44 |
| 4.4 | Parâmetros da estrutura CNN no treinamento de imagens composição cor real e coloridas formadas pelas imagens-fração | 45 |
| 4.5 | Parâmetros da estrutura MLP no treinamento de imagens composição cor real e coloridas formadas pelas imagens-fração | 45 |
| 4.6 | Parâmetros no treinamento da estrutura fusão de dados | 46 |
| 5.1 | Parâmetros do treinamento das arquiteturas CNN e MLP para as imagens composição cor real | 47 |
| 5.2 | Parâmetros obtidos com o treinamento das redes neurais CNN e MLP para as imagens formadas pelas frações das componentes | 50 |
| 5.3 | Parâmetros do treinamento da Fusão de dados | 53 |

Lista de Códigos

| | | |
|-----|--|----|
| A.1 | Pré-processamento das imagens | 67 |
| A.2 | Treinamento da arquitetura CNN | 69 |
| A.3 | Treinamento da arquitetura MLP | 70 |
| A.4 | Treinamento da Fusão de dados | 71 |
| A.5 | Validação da rede neural utilizando a curva ROC | 73 |
| A.6 | Validação da rede neural utilizando o histograma de separabilidade . | 75 |

Glossário: Símbolos e Siglas

| Notação | Descrição | Páginas |
|----------------------|---|---------|
| F_j | Fração da j-ésima componente no pixel | 21 |
| α | Taxa de aprendizado | 31 |
| β | Vetor $k \times 1$ de valores desconhecidos sujeito a restrições lineares | 23 |
| F_j | Vetor Frações das componentes | 22, 23 |
| X | Matriz $n \times k$ dos valores dos regressores | 23 |
| ρ_{ij} | Matriz Reflectância da componente j na banda i | 22 |
| ρ_i | Vetor Reflectância | 22 |
| e_i | Vetor erro | 22 |
| e | Vetor $n \times 1$ de resíduo | 23 |
| y | Vetor $n \times 1$ dos valores do regressando | 23 |
| \hat{y} | Saída prevista da unidade i na camada de saída | 31 |
| λ | Comprimento de onda | 10 |
| $\phi_{absorvido}$ | Energia absorvida | 13 |
| $\phi_{incidente}$ | Energia incidente | 13 |
| $\phi_{refletido}$ | Energia refletida | 13 |
| $\phi_{transmitido}$ | Energia Transmitida | 13 |
| ρ | Reflectância | 14 |
| ρ_{ij} | Reflectância da componente j na banda i | 21 |
| ρ_i | Reflectância na banda i | 21 |

| Notação | Descrição | Páginas |
|----------------|--|---|
| σ | Absortância | 14 |
| τ | Transmitância | 14 |
| \vec{B} | Campo Magnético | 9 |
| \vec{E} | Campo Elétrico | 9 |
| e_i | Erro na banda i | 21 |
| f | frequência (Hz) | 10 |
| w_{ij} | Peso na conexão entre a unidade i da camada de saída e a unidade j da camada anterior | 31 |
| z_i | Entrada líquida (antes da ativação) da unidade i na camada de saída | 31 |
| c | Velocidade da Luz | 10 |
| CBERS | Satélite Sino-Brasileiro de Recursos Terrestres | 1, 24, 39, 41 |
| CNN | <i>Convolutional Neural Networks</i> | viii-x, xiii, 2-5, 31-33, 43-45, 47-51, 53-57, 60 |
| COEEL | <i>Coordenação do Curso de Engenharia Elétrica do IFBA campus Vitória da Conquista</i> | i |
| DETER | Sistema de Detecção de Desmatamento em Tempo Real | 1, 21 |
| E | Função de erro | 31 |
| i | Classe da saída da rede neural | 28 |

| Notação | Descrição | Páginas |
|----------------|--|--|
| INPE | Instituto Nacional de Pesquisas Espaciais | 1, 2, 5, 21, 39– 41 |
| MLP | <i>MultiLayer Perceptron</i> | viii–x, xiii, xix, 2–5, 29, 30, 33, 43–45, 47, 49, 50, 52, 53, 55, 57, 58, 60 |
| PRODES | Projeto de Monitoramento do Desmata- mento na Amazônia Legal por Satélite | 1, 8, 21 |
| WPM | Câmera Multiespectral e Pancromática de Ampla Varredura | xiii, 39 |

Sumário

| | | |
|----------|--|-----------|
| 1 | Introdução | 1 |
| 1.1 | Conceitos Iniciais | 1 |
| 1.2 | Problema | 3 |
| 1.2.1 | Proposta de solução | 3 |
| 1.3 | Objetivo Geral | 4 |
| 1.3.1 | Objetivos Específicos | 4 |
| 1.4 | Justificativa | 5 |
| 2 | Monitoramento do desmatamento da Amazônia brasileira através de imagens de satélite | 7 |
| 2.1 | Amazônia Brasileira e sua relevância mundial | 7 |
| 2.2 | Sensoriamento Remoto | 9 |
| 2.2.1 | Radiação Eletromagnética | 9 |
| 2.2.2 | Espectro Eletromagnético | 10 |
| 2.2.3 | Emissão de radiação dos corpos | 11 |
| 2.2.4 | Características espectrais dos átomos | 11 |
| 2.2.5 | Assinatura Espectral | 14 |
| 2.2.6 | Bandas Espectrais | 15 |
| 2.2.7 | Resolução de Imagens Espaciais | 16 |
| 2.2.7.1 | Resolução Espacial | 17 |
| 2.2.7.2 | Resolução Espectral | 18 |
| 2.2.8 | Composições de imagens de satélite | 18 |
| 3 | Modelos Matemáticos para Mistura Espectral e Classificação de Imagens | 20 |
| 3.1 | Modelo Linear de Mistura Espectral | 20 |
| 3.1.1 | Seleção dos Endmembers | 23 |
| 3.1.2 | Imagens-fração | 24 |
| 3.1.3 | Composição de imagens-fração | 25 |
| 3.2 | Redes Neurais Artificiais | 25 |

| | | |
|----------|---|-----------|
| 3.2.1 | Neurônio Biológico | 26 |
| 3.2.2 | Neurônio Artificial | 27 |
| 3.2.2.1 | Função de Ativação | 28 |
| 3.2.2.2 | Peso e Bias | 29 |
| 3.2.3 | Perceptron Múltiplas Camadas | 29 |
| 3.2.3.1 | Arquitetura da MLP | 29 |
| 3.2.3.2 | Treinamento da MLP | 30 |
| 3.2.4 | Redes Neurais Convolucionais | 31 |
| 3.2.4.1 | Camadas Convolucionais | 32 |
| 3.2.4.2 | Camadas de Pooling | 32 |
| 3.2.4.3 | Camadas Totalmente Conectadas | 33 |
| 3.2.5 | Fusão de informações | 33 |
| 3.3 | Validação de Classificadores | 34 |
| 3.3.1 | Curva ROC | 34 |
| 3.3.2 | Histograma de Separabilidade | 35 |
| 4 | Metodologia | 37 |
| 4.1 | Divisão das classes | 37 |
| 4.1.1 | Classe de áreas não desmatadas | 37 |
| 4.1.2 | Classe de Desmatamento | 38 |
| 4.2 | Seleção e pré-processamento das imagens | 39 |
| 4.2.1 | Origem das Imagens: Utilização de Imagens do Satélite CBERS | 39 |
| 4.2.2 | Softwares utilizados | 40 |
| 4.2.3 | Banco de dados | 41 |
| 4.3 | Modelagem | 43 |
| 4.4 | Treinamento da Rede Neural | 44 |
| 4.5 | Validação das Redes Neurais | 46 |
| 5 | Resultados e discussões | 47 |
| 5.1 | Treinamento das imagens composição cor real | 47 |
| 5.2 | Treinamento das imagens formadas pelas imagens-fração | 50 |
| 5.3 | Fusão de Informações | 53 |
| 5.3.1 | Fusão CNN + CNN | 53 |
| 5.3.2 | Fusão CNN + MLP | 55 |
| 5.3.3 | Fusão MLP + CNN | 56 |
| 5.3.4 | Fusão MLP + MLP | 58 |
| 6 | Considerações Finais | 60 |

| | |
|--|-----------|
| REFERÊNCIAS | 62 |
| A Códigos em Python | 67 |
| A.1 Pré-processamento das imagens | 67 |
| A.2 Treinamento da arquitetura CNN | 69 |
| A.3 Treinamento das imagens coloridas - MLP | 70 |
| A.4 Treinamento da Fusão de Informações | 71 |
| A.5 Código para validação utilizando a curva ROC | 73 |
| A.6 Código para validação utilizando o histograma de separação | 74 |

Capítulo 1

Introdução

1.1 Conceitos Iniciais

A Amazônia é um patrimônio mundial, sendo considerada a maior floresta tropical do mundo devido à sua abundância de recursos naturais e sua vastidão (MORETO et al., 2021). Como resultado, o bioma amazônico é alvo de atividades ilegais causando repercussões negativas em escala internacional. O interesse econômico na região norte levou ao aumento da população local, ao desenvolvimento da agropecuária e à extração de madeira e minerais, o que tem preocupado órgãos e instituições ambientais em relação ao desmatamento da cobertura vegetal amazônica (ÂNGELO; SÁ, 2007).

Por meio de imagens de satélites, como o Satélite Sino-Brasileiro de Recursos Terrestres CBERS, o Instituto Nacional de Pesquisas Espaciais (INPE) é hoje o principal instituto brasileiro dedicado ao monitoramento da floresta amazônica. Conforme apresentado em sua metodologia para o Cálculo da Taxa Anual de Desmatamento na Amazônia Legal, o INPE conta com dois programas para monitorar o bioma: o Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite (PRODES) e o Sistema de Detecção de Desmatamentos em Tempo Real (DETER) (CÂMARA; VALERIANO; SOARES, 2006). O processamento de imagens espaciais tem evoluído consideravelmente com os avanços tecnológicos. Os satélites modernos, por exemplo, dispõem de diversas bandas espectrais que abrangem informações importantes para pesquisas relacionadas à região Norte.

Um dos desafios relacionados ao processamento de imagens de satélites é a mistura espectral de componentes. O pixel, que é a menor unidade de uma

imagem digital, contém um único espectro de cor, mas a resolução espacial pode variar significativamente, indo de centímetros a quilômetros (QUEIROZ; GOMES, 2006; ZANOTTA; FERREIRA; ZORTEA, 2019). Devido a essa variação, é comum ocorrer misturas espectrais na análise de classificação de pixels, como, por exemplo, a mistura de solo e vegetação ou a presença de sombras, que podem afetar a imagem, mesmo quando aplicada uma alta resolução (SHIMABUKURO; DUTRA; ARAI, 2020).

O Modelo Linear de Mistura Espectral é um método matemático empregado para decompor a mistura de componentes em um pixel. Este modelo produz imagens que representam a proporção de cada elemento presente na superfície, como solo, água, vegetação, entre outros (SHIMABUKURO; PONZONI, 2017). Atualmente, o INPE utiliza essas informações para monitorar e classificar áreas degradadas e desmatadas na Amazônia. Além disso, o INPE disponibiliza gratuitamente na internet o software TerraAmazon, uma ferramenta de geoprocessamento capaz de aplicar essa técnica matemática (CÂMARA; VALERIANO; SOARES, 2006).

A detecção e classificação do desmatamento na Amazônia representam um desafio complexo, devido à vastidão e diversidade desse bioma. Nesse contexto, as redes neurais artificiais emergem como uma ferramenta poderosa para enfrentar essa problemática. Oliveira, Costa e Filho (2017) utilizou redes neurais para o reconhecimento de áreas desmatadas na região sul da Amazônia explorando métodos para a melhoria de generalização. Gonçalves et al. (2016) aborda a técnica como método de classificação de estratos florestais. Todt et al. (2003) propôs um método de identificação de áreas desflorestadas na Amazônia, utilizando o Modelo Linear de Mistura Espectral. Essas pesquisas apontam a crescente aplicação de Redes Neurais Artificiais na abordagem dos desafios relacionados ao desmatamento na Amazônia. A interdisciplinaridade entre as áreas de sensoriamento remoto, aprendizado de máquina e ecologia é importante para desenvolver soluções eficazes na monitorização e combate ao desmatamento na região.

Entre as redes neurais artificiais, destacam-se a *MultiLayer Perceptron* (MLP) e a *Convolutional Neural Networks* (CNN). A MLP é uma arquitetura de rede neural artificial amplamente utilizada em tarefas de classificação. Ela é especialmente eficaz quando se trata de dados estruturados (PINHEIRO et al., 2021). Por outro lado, a CNN é particularmente adequada para o processamento de imagens. Essa arquitetura é um modelo de aprendizado profundo com capacidade de capturar características complexas em dados de imagem (WU, 2017).

A fusão de dados representa um método avançado que visa aprimorar a eficácia dos modelos de classificação ao combinar diferentes arquiteturas de redes neurais. Essa abordagem, também conhecida como fusão de informações, envolve a utilização de múltiplas fontes de dados para enriquecer a representação do modelo. Ao integrar informações provenientes de diversas fontes, como diferentes tipos de sensores ou modalidades de dados, a fusão de dados busca capturar nuances mais complexas, contribuindo para uma classificação mais precisa e robusta (RODRIGUES, 2023).

Portanto, este trabalho explorará as arquiteturas MLP e CNN como método de classificação de áreas desmatadas na região amazônica. Adicionalmente, o trabalho explorará a fusão de dados com o auxílio do Modelo Linear de Mistura Espectral para aprimorar a precisão da classificação. Este modelo contribuirá para um monitoramento mais eficaz do desmatamento na Amazônia, apoiando a conservação do ecossistema e suas funções globais.

1.2 Problema

O problema central desta pesquisa reside na necessidade premente de desenvolver ferramentas eficazes para monitorar e combater o desmatamento na Amazônia. O desafio é classificar, com precisão e eficiência, as áreas desmatadas que serão abordadas durante o trabalho. Nesse aspecto, levantam-se os seguintes questionamentos:

- 1) Como o Modelo Linear de Mistura Espectral pode ajudar na detecção de desmatamento na Amazônia com a implementação de Redes Neurais Artificiais?
- 2) Como as técnicas de Redes Neurais Artificiais, como a Fusão de Dados, podem ser aplicadas para melhorar a detecção de desmatamento na Amazônia?

1.2.1 Proposta de solução

Para a abordagem do problema, foi proposto um modelo baseado na aplicação de redes neurais artificiais. O enfoque do trabalho está na implementação

e avaliação de duas arquiteturas diferentes: *Multilayer Perceptron (MLP)* e *Convolutional Neural Networks (CNN)*. Além disso, foi explorada a fusão de dados, que consiste em uma abordagem de aprimoramento de classificação em comparação com o treinamento individual das arquiteturas neurais. A pesquisa não pretende resolver o problema, uma vez que os tipos de desmatamento na Amazônia são diversos e sua extensão traz um nível de complexidade alto. Por outro lado, a pesquisa fornece uma contribuição significativa, explorando a viabilidade dessas abordagens na melhoria da precisão e eficiência de detecção de desmatamento na região Norte do Brasil.

Hipóteses de pesquisa:

- ▶ **Hipótese 1:** As imagens provenientes do Modelo Linear de Mistura Espectral podem ser eficazmente treinadas, desempenhando um papel significativo na classificação de áreas desmatadas na Amazônia.
- ▶ **Hipótese 2:** As arquiteturas **MLP** e **CNN** podem ser treinadas para identificar com precisão áreas de desmatamentos na Amazônia, oferecendo uma alternativa eficaz às técnicas tradicionais de monitoramento;
- ▶ **Hipótese 3:** A combinação de arquiteturas neurais por meio da fusão de informações pode resultar em um desempenho aprimorado na detecção de desmatamento.

1.3 Objetivo Geral

Desenvolver um modelo de classificação para monitoramento de áreas desmatadas no bioma Amazônia utilizando técnicas de redes neurais artificiais.

1.3.1 Objetivos Específicos

- 1) Coletar um banco de dados composto por imagens renderizadas e imagens-fração, utilizando o Modelo Linear de Mistura Espectral;
- 2) Implementar as arquiteturas **MLP** e **CNN**, como também a fusão de dados, como métodos de classificação;
- 3) Validar e avaliar a precisão do algoritmo de classificação.

1.4 Justificativa

A pesquisa neste projeto, que se concentra na aplicação de redes neurais artificiais para a classificação de desmatamento na Amazônia brasileira, apresenta diversas justificativas que ressaltam sua relevância. Entre elas, cabem ressaltar:

- ▶ **Relevância:** A floresta amazônica é rica em recursos naturais e possui uma longa extensão. Além de possuir uma biodiversidade exuberante, o bioma Amazônia ainda é lar de diversas tribos indígenas e um controlador do clima global (VIEIRA; SILVA; TOLEDO, 2005; MOREIRA, 2009; ISPN, 2023). Por isso, o monitoramento deste ecossistema global é essencial. O desmatamento na região causa perdas inestimáveis não apenas para o Brasil em termos de biodiversidade, mas para o mundo em termos de alterações climáticas que podem ter impactos significativos na vida.
- ▶ **Aplicabilidade:** O projeto pode ser aplicado no acompanhamento em tempo real de desmatamento em institutos como o INPE, permitindo a tomada de medidas imediatas para conter atividades ilegais. Ele pode alertar sobre áreas desmatadas, permitindo a resposta preventiva antes que áreas significativas sejam perdidas. O modelo pode ser ainda uma ferramenta para pesquisadores que estudam ecologia, biologia da conservação, ciências ambientais, elevando ainda mais o poder de conservação da floresta amazônica.
- ▶ **Viabilidade:** A viabilidade do projeto é respaldada pelo rápido desenvolvimento e adoção de tecnologias de redes neurais em várias aplicações. A crescente disponibilidade de *hardware* e *software* especializados torna a implementação de tais abordagens cada vez mais viável.
- ▶ **Diferencial:** O diferencial deste trabalho envolve a abordagem comparativa das redes neurais MLP e a CNN, e a fusão de dados para melhorar a precisão da classificação. Portanto, este trabalho se distingue ao abordar de forma mais abrangente a complexidade do problema de detecção de desmatamento na Amazônia, explorando técnicas avançadas de redes neurais e fusão de dados.
- ▶ **Motivação:** Este projeto está voltado ao impacto negativo do desmatamento na Amazônia, não apenas a nível nacional, como também global. A floresta amazônica desempenha um papel essencial na mitigação das mudanças climáticas e na preservação da biodiversidade. O aumento

do desmatamento na região é considerado uma ameaça a essas funções vitais. Por isso, desenvolver um modelo de classificação eficiente é importante para apoiar os esforços de conservação e monitoramento da Amazônia, contribuindo para a proteção do bioma e o bem-estar global.

Capítulo 2

Monitoramento do desmatamento da Amazônia brasileira através de imagens de satélite

2.1 Amazônia Brasileira e sua relevância mundial

Para que haja uma boa compreensão dos fatores bióticos, o território brasileiro está dividido em biomas. Segundo [Coutinho \(2006\)](#), um bioma pode ser definido como "uma área do espaço geográfico identificado e classificado de acordo com o macroclima, a fitofisionomia, o solo e a altitude".

Essencialmente, define-se o bioma como uma região geográfica que compartilha características climáticas, ecossistemas e habitats semelhantes. A Amazônia, localizada na região norte do Brasil, é o bioma que abriga a maior biodiversidade do mundo ([VIEIRA; SILVA; TOLEDO, 2005](#)). Em termos de fauna e flora, mais de 3 milhões de espécies vivem no local. Adicionalmente, a floresta conta ainda com mais de 2.500 espécies de árvores ([THOMSON, 2020](#)). Além disso, a região é lar de várias tribos indígenas. Segundo o Instituto Sociedade, População e Natureza ([ISPN, 2023](#)), o bioma amazônico é moradia para mais de 180 povos indígenas, acrescentando a isso as tribos isoladas, somando cerca de 440 mil indígenas na região Norte. A Amazônia exerce ainda um papel fundamental na regulação das questões climáticas globais. [Nobre, Sampaio e Salazar \(2007\)](#) enfatizam a importância da floresta amazônica no controle climático global, bem como a influência antropogênica na emissão de gases na atmosfera, resultante de queimadas e des-

matamento. Considerando esses aspectos, a Amazônia é um tesouro natural do planeta, desempenhando um papel insubstituível na biosfera.

Devido à sua exuberância natural, a região é frequentemente alvo de interesses econômicos predominantes, o que resulta na prática ilegal de atividades como o garimpo e o desmatamento. [Homma, HOMMA et al. \(2003\)](#) destaca o extrativismo ao longo da história da floresta amazônica. Durante o período colonial, matérias-primas como o café e a seringueira para a produção de borracha foram de importância primordial. Na década de 80, Serra Pelada, localizada no estado do Pará, se destacou como o maior ponto de garimpo do país.

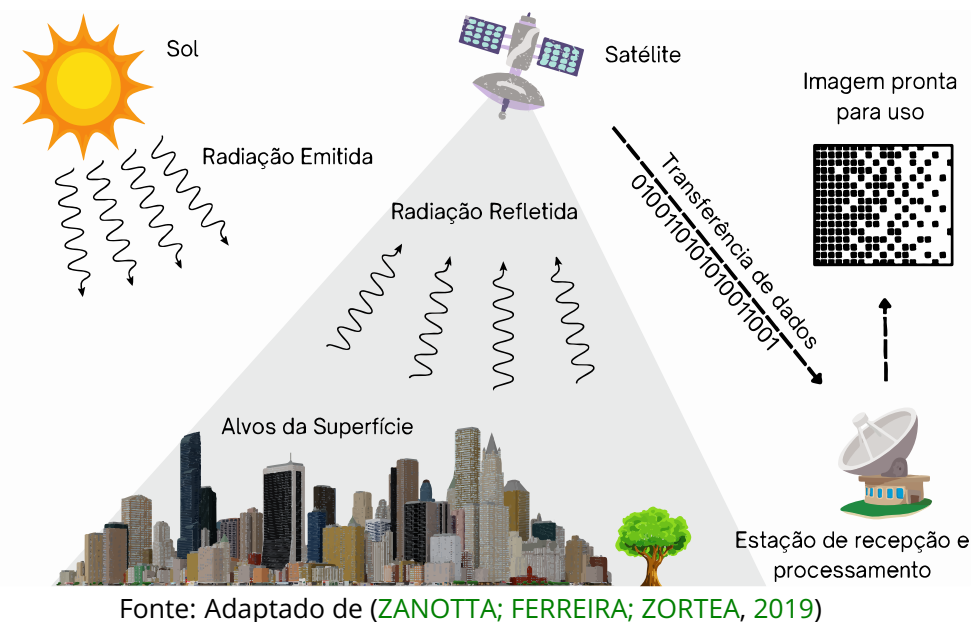
Atualmente, as práticas ilegais de desmatamento persistem na Amazônia. Conforme apresentado pelo [PRODES](#), o índice de desmatamento na Amazônia acumulou 11.600 km² no ano de 2022 e acumula 9.000 km² até o mês de novembro de 2023 ([INPE, 2023b](#)). Uma parcela significativa desse desmatamento, totalizando 7.952 km², representa áreas desmatadas com solo exposto ([INPE, 2023c](#)). O garimpo ilegal, outro tipo de desmatamento, tem crescido nas terras indígenas da Amazônia, com as terras indígenas dos Kayapó, Munduruku e Yanomami sendo as mais afetadas por essa atividade ([GRIESINGER, 2023](#)). Esses números não apenas indicam a perda de cobertura florestal, mas também evidenciam a degradação ambiental associada a essas práticas.

Uma das abordagens amplamente empregadas para monitorar o desmatamento na Amazônia brasileira é o uso de imagens de satélite. O método é aplicado por meio do sensoriamento remoto, utilizando os princípios fundamentais da radiação eletromagnética. Desta maneira, torna-se possível analisar o espaço geográfico em uma área específica por meio da composição das imagens espectrais capturadas pelos satélites, permitindo assim o monitoramento e a proteção do bioma brasileiro.

2.2 Sensoriamento Remoto

O sensoriamento remoto é um método contemporâneo para adquirir imagens geográficas através de satélites. Segundo [Zanotta, Ferreira e Zorteza \(2019\)](#), esse procedimento tem início com a emissão de radiação solar, que ao atingir a superfície terrestre, uma parcela dessa radiação é refletida. Os satélites posicionados em órbita ao redor da Terra registram essa reflexão utilizando sensores especializados em diferentes faixas espectrais. Esses dados são posteriormente transmitidos para uma estação de recepção, onde passam por um processo de processamento de imagens. A Figura 2.1 ilustra essa sequência de eventos.


Figura 2.1 – Etapas de processamento de imagens espaciais utilizando o sensoriamento remoto



2.2.1 Radiação Eletromagnética

A radiação eletromagnética é uma onda que se propaga à velocidade da luz, na qual os campos elétrico (\vec{E}) e magnético (\vec{B}) interagem perpendicularmente entre si, como representado na Figura 2.2. O comportamento das ondas eletromagnéticas pode ser compreendida pelas equações de James Clerk Maxwell (1839 - 1879), um físico e matemático escocês. A sua teoria é fundamental para o entendimento da natureza da luz e a unificação das teorias da eletricidade e do magnetismo, dando origem à teoria eletromagnética e lançando as bases para o desenvolvimento da física moderna ([JR; BUCK, 2013](#)).

Figura 2.2 – Onda Eletromagnética



Fonte: (ROSA, 2019)

Seguindo as características de uma onda, a velocidade de propagação da radiação eletromagnética pode ser obtida por meio da Equação 2.1 (REITZ; MILFORD; CHRISTY, 1988). Como a velocidade da luz é uma constante, é evidente dizer que o comprimento de onda é inversamente proporcional a frequência.

$$c = \lambda \cdot f \quad (2.1)$$

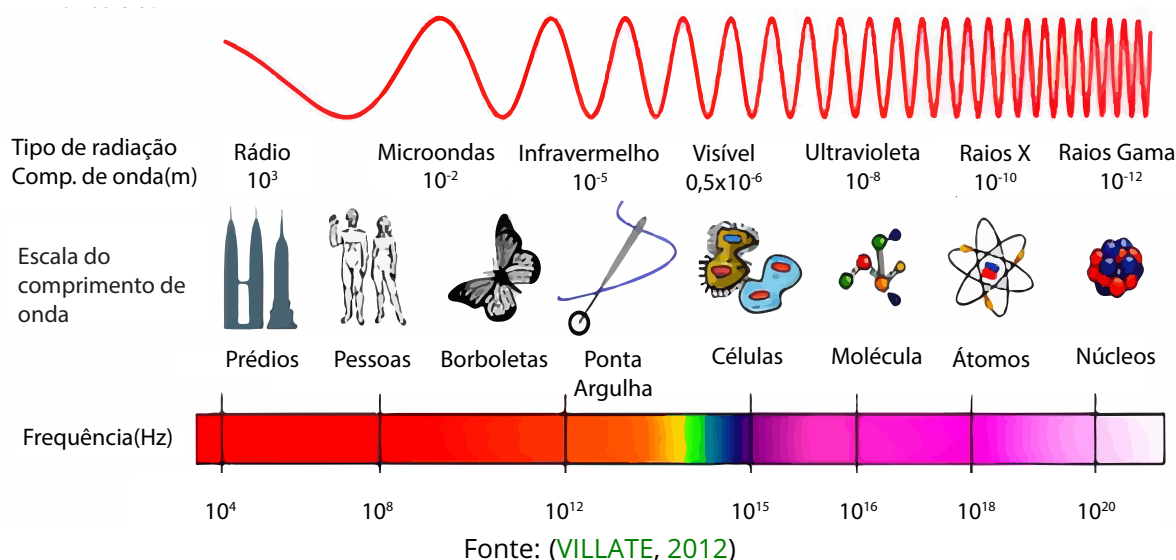
sendo que:

- c ⇒ Velocidade da Luz;
- f ⇒ Frequência;
- λ ⇒ Comprimento.

2.2.2 Espectro Eletromagnético

Com o avanço do conhecimento sobre as ondas eletromagnéticas, os seres humanos começaram a explorar uma variedade de frequências. Atualmente, é muito comum o conhecimento de diferentes tipos de ondas, como as de rádio, raios X, micro-ondas, entre outras. Essa diversidade é conhecida como espectro eletromagnético. Conforme explicado por Fontal, Suárez e Reyes (2005), o espectro eletromagnético possui limites máximo e mínimo em termos de frequência, e a luz e a radiação conhecidas representam uma parte desse espectro. A Figura 2.3 ilustra a classificação do espectro eletromagnético.

Figura 2.3 – Espectro eletromagnético em relação ao comprimento e frequência de onda. Ainda é apresentada uma comparação em escala com algumas entidades físicas e químicas.



2.2.3 Emissão de radiação dos corpos

Todos os corpos emitem, absorvem, refletem ou transmitem radiação em relação à sua temperatura e frequência (LAGE, 2020). Uma lâmpada incandescente, com uma temperatura próxima de 120 graus Celsius, emite ondas eletromagnéticas dentro do espectro visível (DALLABRIDA; GONÇALVES; PIOVESAN, 2015). Em contraste, o corpo humano também atua como um emissor de radiação, embora essa radiação não seja visível a olho nu. No entanto, utilizando uma câmera termográfica, um dispositivo capaz de detectar ondas além das cores do espectro visível, é possível identificar regiões de calor associadas a essa emissão (GADE; MOESLUND, 2014).

A maior fonte de radiação dentro do sistema solar é o Sol. Estima-se que a estrela solar emita cerca de $3,86 \times 10^{26}$ W em radiação a uma temperatura de 5.780K (CECATTO, 2006). No entanto, graças à atmosfera terrestre, parte da radiação solar que atinge nosso planeta é filtrada, o que é essencial para garantir a vida dos seres vivos na Terra (DIAS; ANDRADE-NETO; MILTAO, 2007).

2.2.4 Características espectrais dos átomos

Uma das características fundamentais dos átomos é o seu comportamento na interação com radiações eletromagnéticas. De acordo com Zanotta, Ferreira


e Zortea (2019), quando um átomo interage com uma onda eletromagnética, ele pode absorver, refletir ou refratar a energia dessa onda, resultando em um equilíbrio no fluxo de energia incidente. O átomo ainda pode sofrer ionização devido a energia e frequência dos raios gama.

Um átomo absorve energia incidente quando a energia da onda eletromagnética é suficiente para elevar um elétron para um nível de energia mais externo. Quando esse elétron retorna ao seu estado original, ele libera essa energia na forma de calor (ZANOTTA; FERREIRA; ZORTEA, 2019). Um exemplo prático desse processo ocorre com o asfalto, que, por ser preto, não reflete nem transmite a radiação incidente. Portanto, ele absorve essa energia, o que resulta em aquecimento durante o dia.

De acordo com Halliday Robert Resnick (2016), em seu livro "Óptica e Física Moderna", a passagem de um raio incidente por uma superfície que separa dois meios é chamada de refração. Os materiais capazes de refratar o raio incidente são chamados de materiais transparentes, como a água e vidro. Por outro lado, os materiais que não refratam as ondas eletromagnéticas são chamados de materiais opacos.

Um raio incidente, quando refratado, muda a direção. Conforme apresentado por Zanotta, Ferreira e Zortea (2019), o meio ainda pode mudar a velocidade de propagação, mas não muda o comprimento de onda da radiação. A Figura 2.4 ilustra a luz sendo refratada em um prisma. A luz nada mais é que a presença de todas as cores. Quando refratada, cada cor segue uma direção específica, resultando em um arco-íris.

Figura 2.4 – A luz sendo refratada e resultando em um arco-íris como raio refratado




Fonte: Autoria própria

A reflexão ocorre quando o raio incidente é refletido (ou rebatido) da super-

fície. Conforme apresentado por Macêdo et al. (2002), a reflexão pode ocorrer de duas formas distintas: reflexão difusa e reflexão especular. A reflexão difusa ocorre quando o raio refletido é disperso em várias direções. Por outro lado, a reflexão especular acontece quando o raio refletido mantém o mesmo ângulo em relação ao raio incidente (HALLIDAY ROBERT RESNICK, 2016). A Figura 2.5 ilustra os raios incidentes e refletidos na reflexão difusa e especular.

Figura 2.5 – (A) Reflexão Difusa (B) Reflexão Especular



Fonte: Autoria própria

Para que haja o equilíbrio entre a energia incidente e a energia de interação com o átomo, a soma da energia absorvida, da energia refratada e da energia refletida deve ser igual a energia incidente, conforme ilustrada na Equação 2.2.

$$\phi_{incidente} = \phi_{absorvido} + \phi_{refletido} + \phi_{transmitido} \quad (2.2)$$

sendo que:

| | | |
|----------------------|---------------|----------------------|
| $\phi_{incidente}$ | \Rightarrow | Energia Incidente; |
| $\phi_{absorvido}$ | \Rightarrow | Energia absorvida; |
| $\phi_{refletido}$ | \Rightarrow | Energia refletida; |
| $\phi_{transmitido}$ | \Rightarrow | Energia transmitida. |

Ao dividir todos os elementos pela energia incidente, as energias absorvida, refratada e refletida se tornam adimensionais. Esses dados podem ser expressos como reflectância, transmitância e absortância, e a soma desses três componentes deve ser igual a 1, conforme evidenciado na Equação 2.3.

$$\rho + \sigma + \tau = 1 \quad (2.3)$$

sendo que:

- ρ \Rightarrow Reflectância;
- σ \Rightarrow Absortância;
- τ \Rightarrow Transmitância.

2.2.5 Assinatura Espectral

Cada material presente na Terra possui características específicas em relação ao seu comportamento espectral. Por exemplo, uma maçã absorve a maioria das cores visíveis e reflete a cor vermelha, o que resulta na aparência avermelhada da fruta. Conforme destacado por [Zanotta, Ferreira e Zortea \(2019\)](#), esse comportamento está diretamente relacionado às propriedades atômicas de cada material. Cada substância possui arranjos atômicos distintos que determinam a quantidade de radiação que é absorvida, refletida ou refratada.

Para a formação de imagens de satélite, é de grande importância para os pesquisadores conhecer os valores de reflexão dos materiais, uma vez que os sensores estarão capturando as ondas refletidas da superfície. Esses valores são medidos por um dispositivo chamado espectrorradiômetro, que pode ser utilizado tanto em campo quanto em laboratório. A Figura 2.6 ilustra um gráfico de reflectância de três materiais comuns na formação de imagens de satélite: solo, vegetação e água.

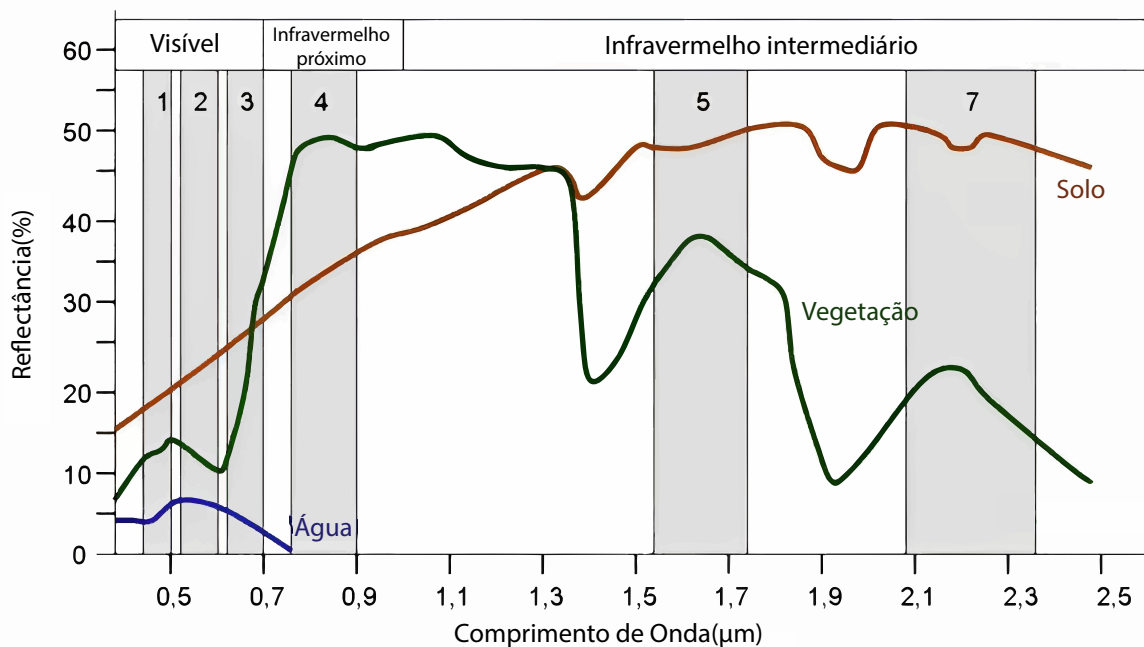
A resposta espectral do solo depende de suas características físicas, químicas, biológicas e mineralógicas. O óxido de ferro, a umidade e os minerais de fração argila são componentes essenciais para a reflectância. O solo com mais óxido de ferro tende a refletir mais no vermelho que em outras cores no visível. Solos mais úmidos tendem ser mais escuros, diminuindo a reflectância do material. Enquanto os minerais de fração argila influencia na reflectância do material na faixa do infravermelho médio ([DALMOLIN et al., 2005](#)).

A vegetação, por sua vez, absorve a energia eletromagnética no espectro visível, graças à clorofila, que a converte em calor ou a transforma em energia armazenada por meio da fotossíntese. Na região do infravermelho próximo, a vegetação absorve quantidades reduzidas de radiação, mas no infravermelho intermediário, devido à absorção da água líquida pela planta, ocorrem vários pontos de absorção

como resultado desse processo (FERREIRA; FILHO, 2009).

Por fim, diferente da vegetação e do solo, a água absorve ou transmite a maior parte da radiação eletromagnética. Na faixa do infravermelho próximo e intermediário, a reflectância é praticamente nula, devido à ausência de matéria orgânica em suspensão. Na faixa do espectro visível, a água reflete mais na cor azul e menos nas cores verde e vermelha (PONZONI; SHIMABUKURO; KUPLICH, 2015).

Figura 2.6 – Gráfico de reflectância da água, do solo e da vegetação dentro do espectro eletromagnético



Fonte: (SIEGMUND; MENZ, 2005)

2.2.6 Bandas Espectrais

Os sensores remotos integrados nos satélites são concebidos para adquirir imagens segmentadas do espectro eletromagnético. De acordo com Zanotta, Ferreira e Zortea (2019), ao contrário dos seres humanos, que têm a capacidade de perceber apenas a faixa visível do espectro (as cores azul, vermelha e verde), os sensores têm a capacidade de registrar informações adicionais desse espectro, resultando em imagens mais ricas em detalhes.

Ainda conforme o autor, os segmentos do espectro eletromagnético para o

uso do sensoriamento remoto pode ser dividida conforme a Tabela 2.1. Nos sensores disponíveis na faixa visível e no infravermelho de ondas curtas, a energia refletida pelos objetos é consideravelmente maior do que a energia emitida pelos mesmos. Em contrapartida, na faixa acima do infravermelho térmico, a energia emitida pelos objetos é consideravelmente maior do que a energia refletida. Por outro lado, na faixa do infravermelho médio, a disponibilidade de sensores é limitada, pois a energia refletida equivale à energia emitida pelos objetos, o que dificulta a captação e a distinção entre esses dois tipos de energia.

Os sensores podem ser ainda classificados em dois tipos: ativos e passivos. Os sensores passivos são aqueles que não geram energia, sendo projetados para captar as ondas refletidas ou emitidas por uma superfície. Por outro lado, os sensores ativos emitem energia, geralmente na forma de micro-ondas. Um exemplo notável desses sensores é o radar, que emite energia para detectar objetos e recebe a energia refletida em retorno (QUARTAROLI; VICENTE; ARAÚJO, 2014).

Tabela 2.1 – *Bandas espectrais trabalhadas no sensoriamento remoto*

| Banda Espectral | Espectro(μm) | Tipo |
|----------------------------|---|-------------|
| Azul | 0,4 - 0,5 | passivo |
| Verde | 0,5 - 0,6 | passivo |
| Vermelho | 0,6 - 0,7 | passivo |
| Infravermelho próximo(NIR) | 0,7 - 1,1 | passivo |
| Infravermelho Curtas(SWIR) | 1,1 - 2,5 | passivo |
| Infravermelho Médio(MIR) | 2,5 - 8 | passivo |
| Infravermelho Termal(TIR) | 8 - 14 | passivo |
| Microondas | 14 - 24000 | ativo |

Fonte: (ZANOTTA; FERREIRA; ZORTEA, 2019)

2.2.7 Resolução de Imagens Espaciais

Conforme Meneses e Almeida (2012), os pesquisadores diferem seus interesses em imagens de satélite. No contexto do monitoramento de desmatamento, por exemplo, é evidente a importância de sensores com uma resolução espacial adequada. Por isso, satélites que dispõem uma boa resolução espacial em suas imagens são comumente usados nessa situação. Por outro lado, para investigar a composição e constituição de minerais, o número de bandas espectrais disponíveis é um fator crítico. Em resumo, ao lidar com imagens de satélite, o tipo de resolu-

ção trabalhada é determinante. Ainda de acordo com [Meneses e Almeida \(2012\)](#), é possível determinar quatro tipos distintos de resolução: resolução térmica, resolução radiométrica, resolução espacial e resolução espectral. A resolução térmica se refere à capacidade de um sensor remoto em obter variações de temperaturas na superfície terrestre, dedicada a trabalhos como a detecção de incêndios florestais. A resolução radiométrica se refere a sensores capazes de diferir diferentes tipos de energia radiante (ou brilho da imagem) emitidos ou refletidos pela superfície. Os próximos tópicos estão dedicados a discutir a resolução espacial e a resolução espectral, dois conceitos fundamentais na construção deste trabalho.

2.2.7.1 Resolução Espacial

O pixel é o menor elemento de uma imagem digital. Conforme explicado nas seções anteriores, as imagens formadas por satélite representam uma cobertura da superfície. Nesse raciocínio, é possível concluir que um pixel de uma imagem de satélite tem um comprimento real. Dessa forma, pode-se afirmar que quanto menor o comprimento do pixel, melhor será a resolução da imagem. A Figura 2.7 ilustra 6 imagens com diferentes resoluções espaciais. Note que a visão espacial do IFBA campus Vitória da Conquista representado em cada imagem fica mais visível conforme a melhora da resolução espacial.

Figura 2.7 – Espaço geográfico do IFBA campus Vitória da Conquista sendo ilustrado por 6 resoluções espaciais




Fonte: ([GOOGLE, 2023b](#))

2.2.7.2 Resolução Espectral

As bandas espectrais do sensoriamento remoto representam segmentos do espectro eletromagnético. É evidente dizer que quanto maior a quantidade de bandas disponibilizadas, melhor a assinatura espectral de um material será representado. Essa metodologia é chamada por resolução espectral. A imagem em duas dimensões que é apresentada nos livros de processamento de imagens agora se torna em informações espectrais e espaciais em 3 dimensões, conforme apresentado na Figura 2.8 (ZANOTTA; FERREIRA; ZORTEA, 2019).

Figura 2.8 – Gráfico tridimensional contendo informações espaciais e espectrais. Os eixos y e x correspondem aos pixels. O eixo λ corresponde ao comprimento de onda do espectro eletromagnético.



Fonte: (ZANOTTA; FERREIRA; ZORTEA, 2019)

2.2.8 Composições de imagens de satélite

As imagens digitais coloridas são compostas por três canais de cores correspondentes ao vermelho, verde e azul, comumente conhecidos por RGB (*red, green e blue*), que, ao se combinarem, formam uma única cor. Geralmente, a resolução dos pixels nesses canais é de 8 bits, o que equivale a 256 níveis de cada cor. Por exemplo, quando os três canais estão preenchidos, a cor resultante é branca, já que o branco é a soma de todas as cores. Por outro lado, quando não há níveis em cada canal, a cor resultante é preta, indicando a ausência de luz e, nesse caso, a ausência de cor.

A análise de imagens de satélites depende fundamentalmente desse processo. Os pesquisadores costumam utilizar várias composições, utilizando as bandas espectrais nesses três canais de cores, como a composição em falsa cor, cor infravermelha e cor real. A última ilustra as cores reais da superfície analisada. Em outras palavras, a banda 3, correspondente à cor vermelha, é colocada no canal 1, correspondente ao canal vermelho da imagem digital. Da mesma forma, a banda 2, correspondente à cor verde, é colocada no canal 2 da imagem digital. Por fim, a banda 1, correspondente à cor azul, é colocada no canal 3 da imagem digital (ZANOTTA; FERREIRA; ZORTEA, 2019).

O próximo capítulo irá explorar dois modelos matemáticos fundamentais no contexto do processamento de imagens de satélite. O primeiro deles é o modelo linear de mistura espectral, uma técnica altamente vantajosa para a combinação de componentes dentro de um pixel. Em seguida, será explorado o conceito de redes neurais, um modelo matemático com diversas aplicações que se mostram especialmente úteis na classificação de imagens.


Capítulo 3

Modelos Matemáticos para Mistura Espectral e Classificação de Imagens

3.1 Modelo Linear de Mistura Espectral

Conforme as diretrizes apresentadas no Capítulo 2, a formação de imagens por satélites ocorre por meio de sensores espectrais que capturam a radiação proveniente dos elementos presentes na superfície terrestre e a traduzem em informações pixelizadas, gerando uma imagem digital. Logo, a informação presente em um pixel corresponde a uma mistura espectral das componentes presentes na superfície. Observe a Figura 3.1.

Figura 3.1 – Problema de mistura espectral na formação do pixel em uma imagem digital. É visto a mistura espectral de três componentes: água, solo e vegetação.



Fonte: Autoria própria

Um sensor de um satélite qualquer responsável pela formação do pixel, com uma certa resolução espacial, ao captar a radiação eletromagnética de uma cobertura vegetal, leva informações advindas do solo, da água e da vegetação. Todavia, o pixel, por apresentar uma única informação em valor binário, não difere a porcentagem de cada componente que foi registrada (ZANOTTA; FERREIRA; ZORTEA, 2019).

Um modelo matemático que vem se mostrando eficaz para o trabalho de processamento de imagens é o Modelo Linear de Mistura Espectral. O INPE, por meio de seus programas de monitoramento da Amazônia, como o DETER e o PRODES, trabalha com essa abordagem matemática para classificar áreas de desmatamento e distinguir as mudanças na cobertura da terra com base em informações espectrais (CÂMARA; VALERIANO; SOARES, 2006). Isso permite uma análise das mudanças na vegetação, auxiliando na identificação de áreas de desflorestamento e fornecendo dados para a gestão ambiental e a tomada de decisões.

O modelo linear em questão calcula a fração de cada componente, também chamada de "endmember", em cada pixel presente na imagem. "A reflectância de cada pixel pode ser considerada como uma combinação linear das reflectâncias de cada componente presente na mistura do pixel" (SHIMABUKURO; DUTRA; ARAI, 2020). Em outras palavras, a soma do produto das frações de todas as componentes da imagem pelas suas respectivas reflectâncias, acrescida de uma parcela de erro, resulta na reflectância no pixel em uma determinada banda. A Equação 3.1 ilustra esse método.

$$\rho_i = F_1 \cdot \rho_{i1} + F_2 \cdot \rho_{i2} + F_3 \cdot \rho_{i3} + \dots + F_j \cdot \rho_{ij} + e_i \quad (3.1)$$

sendo que:

- ρ_i \Rightarrow Reflectância na banda i ;
- ρ_{ij} \Rightarrow Reflectância da componente j na banda i ;
- F_j \Rightarrow Fração da j -ésima componente no pixel;
- e_i \Rightarrow Erro na banda i .

Como um satélite disponibiliza uma quantidade de bandas, é possível montar um sistema de equações por meio da Equação 3.1. As Equações 3.2 a 3.5 associam esse sistema de equações.

$$\rho_1 = F_1 \cdot \rho_{11} + F_2 \cdot \rho_{12} + F_3 \cdot \rho_{13} + \dots + F_j \cdot \rho_{1j} + e_1 \quad (3.2)$$

$$\rho_2 = F_1 \cdot \rho_{21} + F_2 \cdot \rho_{22} + F_3 \cdot \rho_{23} + \dots + F_j \cdot \rho_{2j} + e_2 \quad (3.3)$$

$$\rho_3 = F_1 \cdot \rho_{31} + F_2 \cdot \rho_{32} + F_3 \cdot \rho_{33} + \dots + F_j \cdot \rho_{3j} + e_3 \quad (3.4)$$

...

$$\rho_i = F_1 \cdot \rho_{i1} + F_2 \cdot \rho_{i2} + F_3 \cdot \rho_{i3} + \dots + F_j \cdot \rho_{ij} + e_i \quad (3.5)$$

As equações dispostas podem ainda ser representadas de forma matricial, conforme representa na Equação 3.6.

$$\begin{bmatrix} \rho_1 \\ \rho_2 \\ \rho_3 \\ \dots \\ \rho_i \end{bmatrix} = \begin{bmatrix} \rho_{11} & \rho_{12} & \rho_{13} & \dots & \rho_{1j} \\ \rho_{21} & \rho_{22} & \rho_{23} & \dots & \rho_{2j} \\ \rho_{31} & \rho_{32} & \rho_{33} & \dots & \rho_{3j} \\ \dots & \dots & \dots & \dots & \dots \\ \rho_{i1} & \rho_{i2} & \rho_{i3} & \dots & \rho_{ij} \end{bmatrix} \begin{bmatrix} F_1 \\ F_2 \\ F_3 \\ \dots \\ F_j \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ e_3 \\ \dots \\ e_i \end{bmatrix} \quad (3.6)$$

Logo, a Equação 3.6 pode ser simplificada conforme a Equação 3.7.

$$\rho_i = \rho_{ij} F_j + e_i \quad (3.7)$$

sendo que:

- ρ_i \Rightarrow Vetor Reflectância;
- ρ_{ij} \Rightarrow Matriz Reflectância da componente j na banda i;
- F_j \Rightarrow Vetor Frações das componentes;
- e_i \Rightarrow Vetor erro.

Um dos princípios matemáticos para abordar a Equação 3.7 é o método dos mínimos quadrados com restrição. Zoia (2003) demonstra o modelo linear e um problema de estimação utilizando o método de multiplicador de Lagrange. A Equação 3.8 ilustra o modelo linear levantado pela autora.

$$y = X\beta + e \quad (3.8)$$

sendo que:

- y ⇒ Vetor $n \times 1$ dos valores do regressando;
- X ⇒ Matriz $n \times k$ dos valores dos regressores;
- β ⇒ Vetor $k \times 1$ de valores desconhecidos sujeito a restrições lineares;
- e ⇒ Vetor $n \times 1$ de resíduo.

Em termos comparativo, o vetor fração da Equação 3.7, representado por F_j , pode ser substituído por β . Esse é o vetor de coeficientes de regressão e descreve a relação linear entre a variável dependente y e as variáveis independentes representadas pela matriz X .

Segundo Bhatti (2005), o método de multiplicador de Lagrange é uma abordagem em matemática complexa para resolver problemas de estimação sujeitos a restrições. Ele permite incorporar restrições específicas nas estimativas dos coeficientes de regressão, garantindo que o modelo se ajuste de maneira apropriada aos dados observados.

Portanto, a utilização do método dos mínimos quadrados com restrição se torna interessante para a abordagem do modelo linear de mistura espectral, garantindo um ajuste mais preciso do modelo aos dados observados.


3.1.1 Seleção dos Endmembers

O termo "*endmember*" (do inglês, membro final) refere-se à assinatura espectral pura ou representativa de um material ou alvo específico em uma cena ou imagem. Conforme mencionado por Shimabukuro, Dutra e Arai (2020), os endmembers podem ser selecionados de duas maneiras distintas: por meio de coleta de dados de campo ou diretamente a partir da imagem. No primeiro método, os pesquisadores procuram o material de interesse no campo ou em laboratório utilizando espectrorradiômetros. Já o segundo método, conhecido como seleção de endmembers de imagem, envolve a escolha direta na própria imagem. Uma vantagem dessa abordagem é que não requer a calibração de equipamentos.

3.1.2 Imagens-fração

As imagens-fração são os resultados obtidos por meio do modelo linear de mistura espectral. Em cada pixel da imagem, o valor representado, geralmente em escala de cinza, corresponde à fração que cada componente representa naquele pixel. Esse tipo de imagem é amplamente utilizado em sensoriamento remoto e processamento de imagens para representar a contribuição relativa de diferentes materiais ou endmembers em cada localização da cena. A análise das imagens-fração é fundamental para extrair informações valiosas sobre a composição e distribuição de elementos na superfície da Terra, sendo uma ferramenta importante em diversas aplicações, desde a detecção de mudanças ambientais até o monitoramento de áreas urbanas e agrícolas (SHIMABUKURO; DUTRA; ARAI, 2020). A Figura 3.2 ilustra as imagens-fração de uma área localizada no leste do Acre capturadas por meio do satélite CBERS, que dispõe de 4 bandas espectrais com resolução espacial de 8 metros.

Figura 3.2 – (A) Composição Cor Real (B) Fração Água (C) Fração Vegetação (D) Fração Solo




Fonte: (INPE, 2023a)

3.1.3 Composição de imagens-fração

Cada imagem-fração é representada em escala de cinza. No caso de uma imagem digital colorida, ela é composta por três canais de cores RGB, conforme explicado no Capítulo 2. Portanto, ao utilizar os valores correspondentes de cada imagem fracionada, é possível compor uma imagem colorida. A Figura 3.3 exemplifica esse processo ao utilizar as componentes de água, solo e vegetação de uma imagem de satélite utilizando o software TerraAmazon. A fração de água é atribuída ao canal vermelho, a fração de solo ao canal verde e a fração de vegetação ao canal azul.

Figura 3.3 – Imagem colorida composta pelas imagens fracionadas de água, solo e vegetação.



Fonte: Autoria própria

3.2 Redes Neurais Artificiais

As redes neurais artificiais é um dos pilares para a inteligência computacional e aprendizagem de máquina. Inspirado no funcionamento do sistema nervoso humano, a história das redes neurais pode ser traçada pelo trabalho pioneiro de Warren McCulloch e Walter Pitts em 1943. Eles desenvolveram o conceito de neurônios artificiais, que são a unidade básica de processamento das redes neurais. Essa ideia foi posteriormente desenvolvida por Frank Rosenblatt, que criou o Perceptron em 1957, um dos primeiros modelos de rede neural. No entanto, o Perceptron possuía limitações que restringiam sua capacidade de resolver problemas complexos (KOVÁCS, 2002).

A história das redes neurais artificiais tomou um novo rumo na década de 1980, com a descoberta do algoritmo de retropropagação (*backpropagation*), que

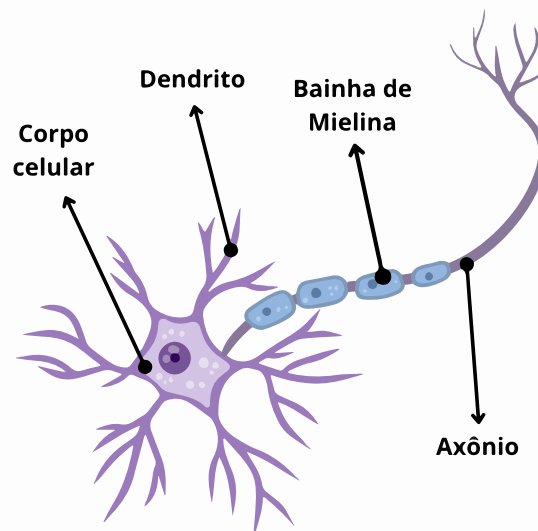
permitiu o treinamento eficiente de redes neurais multicamadas (POPESCU et al., 2009).

Desde então, as redes neurais artificiais evoluíram significativamente devido ao aumento da potência computacional e grandes volumes de dados disponíveis. Atualmente, as redes neurais profundas, como as redes neurais convolucionais, são amplamente utilizadas em uma variedade de aplicações, como reconhecimento de imagem, jogos de vídeo, medicina, entre outros.

3.2.1 Neurônio Biológico

O neurônio biológico é a inspiração para o estudo das redes neurais artificiais. A célula nervosa é a unidade funcional básica do sistema nervoso nos organismos vivos, incluindo os seres humanos. Ela desempenha um papel crucial na transmissão de informações dentro do corpo e é fundamental para processos como a percepção, o pensamento, a coordenação muscular, entre outras funções vitais. A Figura 3.4 ilustra um neurônio. Sua composição básica pode ser dividida em corpo celular, dendrito, bainha de Mielina e o axônio (BEAR; CONNORS; PARADISO, 2017).

Figura 3.4 – Neurônio humano.



Fonte: Autoria própria

- **Corpo Celular:** Conhecido também por "soma", é a parte central da célula nervosa. Contém o núcleo, que abriga o material genético do neurônio e é responsável pela integração de sinais provenientes dos dendritos e pela geração de sinais elétricos conhecidos como potenciais de ação.

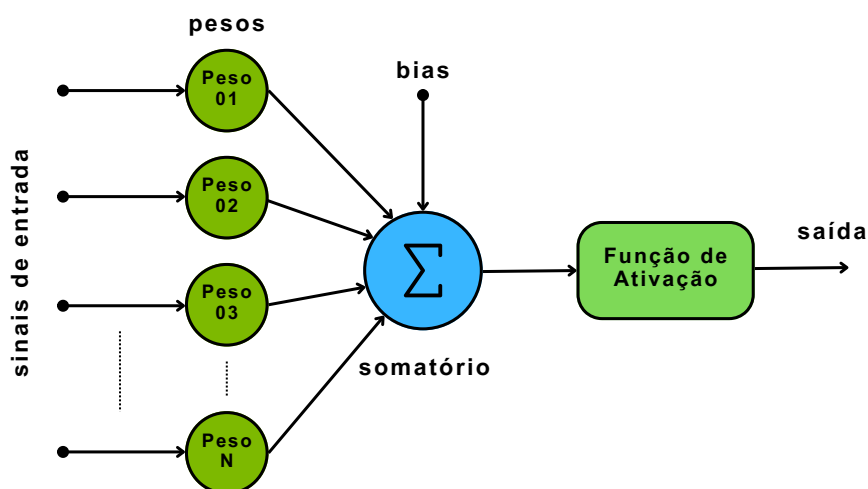
As proteínas e organelas estão presentes no corpo celular (BEAR; CONNORS; PARADISO, 2017).

- ▶ **Dendrito:** Os dendritos são prolongamentos ramificados e curtos que se estendem a partir do corpo celular. A entrada de sinais ocorre nos dendritos, onde as sinapses (conexões entre neurônios) são formadas (BEAR; CONNORS; PARADISO, 2017).
- ▶ **Bainha de Mielina:** A bainha de mielina é uma camada isolante que envolve partes do axônio em muitos neurônios no sistema nervoso. Atua como um isolante elétrico, permitindo a condução saltatória de sinais elétricos ao longo do axônio. Isso acelera a transmissão de informações (BEAR; CONNORS; PARADISO, 2017).
- ▶ **Axônio:** O axônio é um prolongamento único e longo que se estende a partir do corpo celular. É responsável por transmitir os sinais elétricos gerados no corpo celular até as terminações axônicas, que podem estar em contato com dendritos de outros neurônios ou com células efetoras, como células musculares ou glandulares (BEAR; CONNORS; PARADISO, 2017).

3.2.2 Neurônio Artificial

O neurônio artificial foi inspirado no neurônio biológico. Observe a Figura 3.5.

Figura 3.5 – Neurônio artificial



Fonte: Adaptado de (SOARES; SILVA, 2011)

O neurônio artificial possui m entradas que são ponderadas por pesos, desempenhando uma função semelhante àquela dos dendritos em um neurônio real. Em seguida, essas informações são somadas juntamente com o bias, que é uma constante ajustável influenciando a saída do neurônio, chegando assim à função de ativação. Essa função de processamento da informação é análoga ao corpo de um neurônio biológico.

Por fim, essa informação é encaminhada para a frente, podendo ser a resposta final do neurônio artificial ou a entrada para o próximo neurônio, funcionando de maneira semelhante ao axônio. Além disso, otimizações ou técnicas de pré-processamento de dados na rede neural afetam a eficiência do neurônio, desempenhando um papel comparável ao da bainha de Mielina.

3.2.2.1 Função de Ativação

Conforme apresentado por Haykin (2001), a função de ativação de um neurônio define a saída de um neurônio em função da resposta do somatório. Algumas funções de ativação são estudadas e comumente utilizadas na prática. Nos tópicos a seguir serão apresentadas dois tipos de funções de ativação utilizadas na aplicação de imagens: a função ReLU e a função Softmax.

- ▶ **Função ReLU:** A função ReLU é uma função de ativação que mantém a saída caso o valor de entrada for positivo, e, caso contrário, a saída é transformado em zero (CECCON, 2020). A função pode ser vista na Equação 3.9.

$$f(x) = \max(0, x) \quad (3.9)$$

- ▶ **Função Softmax:** A função Softmax é uma função que converte um vetor em uma distribuição de probabilidades, comumente utilizada em saídas de redes neurais que trabalham como classificadores (CECCON, 2020). A função pode ser vista na Equação 3.10.

$$\text{softmax}(x)_i = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (3.10)$$

sendo que:

$i \Rightarrow$ Classe da saída da rede neural.

3.2.2.2 Peso e Bias

Os pesos e o bias são medidas essenciais em uma rede neural artificial. Os pesos são valores de ajuste dados nas entradas do neurônio. Essas entradas podem vir da análise de dados (*dataset*) ou de outros neurônios. Valores maiores de ajuste indicam que as conexões entre os neurônios são mais fortes, enquanto valores menores indicam conexões mais fracas.

Na composição de um neurônio, ilustrada na Figura 3.5, a saída é formada pela combinação linear dos pesos e das entradas somado ao bias antes de passar pela função de ativação. O bias permite que a rede faça ajustes adicionais para se adaptar aos dados. O bias controla o limiar de ativação de um neurônio, afetando como o neurônio responde a diferentes entradas. Ele é útil para permitir que a rede aprenda funções mais complexas e não lineares (HAYKIN, 2001).


3.2.3 Perceptron Múltiplas Camadas

A Perceptron de Múltiplas Camadas, comumente conhecida como *Multilayer Perceptron* (MLP), é uma arquitetura avançada em aprendizagem de máquina inspirada no funcionamento do cérebro humano. Ao contrário do perceptron simples, que é uma estrutura limitada em termos de aplicabilidade, a MLP demonstra grande utilidade em diversas áreas, incluindo o reconhecimento de padrões, que será essencial para a classificação do desmatamento ocorrente na região Norte brasileira.

3.2.3.1 Arquitetura da MLP

A arquitetura da MLP é formada por vários neurônios, organizados conforme ilustrado na Figura 3.6. Em sua composição, possui um total de m entradas de sinal, as quais serão ajustadas pelos respectivos pesos antes de serem somadas e submetidas à função de ativação de cada neurônio. A saída da arquitetura é composta por m neurônios, que serão responsáveis em identificar um elemento de saída específico. Além disso, a MLP oferece camadas intermediárias, conhecidas como camadas escondidas, e cada uma delas é composta por um número n de neurônios.

Figura 3.6 – Arquitetura MLP



Fonte: (GOMIDE, 2012)

3.2.3.2 Treinamento da MLP

Conforme mencionado por Gomide (2012), o treinamento de uma rede neural MLP ocorre em duas fases: *Forward* e *Backward*. Na primeira fase, conhecida também como "Propagação adiante", a rede é treinada no sentido convencional, utilizando o sinal de entrada para obter uma primeira resposta de saída da rede neural, sem que haja alteração nos pesos. Nessa primeira etapa, é feito o cálculo do erro entre as saídas previstas da rede e os valores reais dos dados de treinamento. Idealmente, o objetivo é que esse erro seja reduzido a zero, indicando que as saídas previstas pela rede coincidem precisamente com os valores reais. Uma função de erro abordada para classificação é a *Sparse Categorical Cross-Entropy*, ou em português, Entropia Cruzada Categórica Esparsa. Essa resposta é posteriormente comparada com a resposta desejada, uma vez que a rede MLP opera sob supervisão.

Na segunda fase, conhecida em português como "propagação reversa", os pesos sinápticos da rede são ajustados com base nos erros encontrados na primeira fase. O backpropagation começa na camada de saída da rede e calcula o gradiente do erro em relação aos pesos dessa camada usando a derivada da função de erro em relação à saída da rede, conforme ilustrado na Equação 3.11.

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial \hat{y}_i} \cdot \frac{\partial \hat{y}_i}{\partial z_i} \cdot \frac{\partial z_i}{\partial w_{ij}} \quad (3.11)$$

sendo que:

- E \Rightarrow Função de erro;
- w_{ij} \Rightarrow Peso na conexão entre a unidade i da camada de saída e a unidade j da camada anterior;
- \hat{y} \Rightarrow Saída prevista da unidade i na camada de saída;
- z_i \Rightarrow Entrada líquida (antes da ativação) da unidade i na camada de saída.

Em seguida, o gradiente é propagado de volta para as camadas ocultas, calculando os gradientes em relação aos pesos de todas as camadas. Isso é feito usando a regra da cadeia.

Após o cálculo dos gradientes, os pesos são então atualizados com o auxílio de uma taxa de aprendizado para que seja viável controlar a magnitude das atualizações. A regra de atualização dos pesos pode ser vista na Equação 3.12.

$$w_{ij}^{(nova)} = w_{ij}^{(antiga)} - \alpha \frac{\partial E}{\partial w_{ij}} \quad (3.12)$$

sendo que:

- α \Rightarrow Taxa de aprendizado.

Esse processo de *forward pass*, *backward pass* e atualização de pesos é repetido para muitas iterações, conhecida por épocas, até que o erro da rede convirja para um mínimo global ou local. A convergência ocorre quando o erro não diminui significativamente após cada iteração. A escolha da taxa de aprendizado é crucial, pois uma taxa muito alta pode fazer com que a rede oscile e uma taxa muito baixa pode levar a convergência lenta.

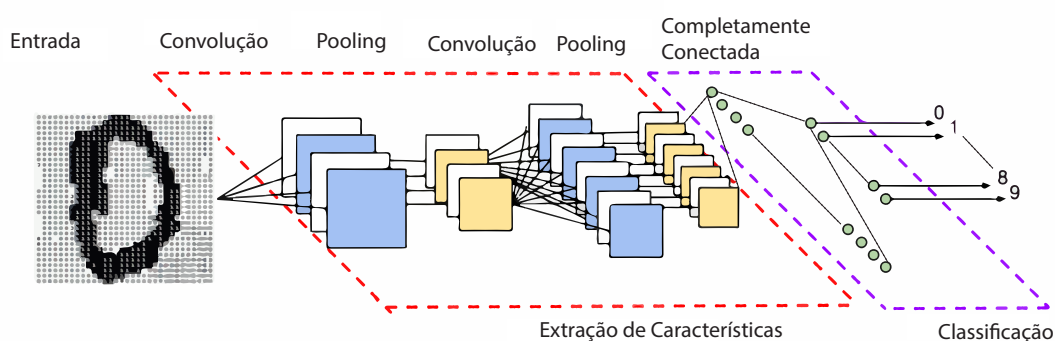
3.2.4 Redes Neurais Convolucionais

As redes neurais convolucionais, conhecidas simplesmente por **CNN**, são uma classe de redes neurais profundas que foram projetadas especialmente para tarefas de visão computacional, como reconhecimento de imagens, detecção de objetos e segmentação de imagem. A **CNN** foi introduzida por Yann LeCun e colaboradores no final da década de 1990 (LECUN et al., 1998). Atualmente, apresenta

um desempenho excepcional em uma variedade de tarefas em processamento de imagem.

O funcionamento das redes neurais convolucionais pode ser dividido em três etapas: camadas convolucionais, camadas de Pooling e camadas totalmente conectadas. A Figura 3.7 ilustra cada fase. Os próximos tópicos estão dedicados a trabalhar com cada etapa.

Figura 3.7 – Estrutura CNN



Fonte: (VARGAS; PAES; VASCONCELOS, 2016)

3.2.4.1 Camadas Convolucionais

A primeira etapa da estrutura da CNN é formada pelas camadas convolucionais. Elas extraem as principais características das imagens disponibilizadas no dataset. Essa abordagem é realizada por uma série de filtros denominados filtros kernels, uma matriz de menor proporção (por exemplo, 3x3), que deslizam pela imagem e realizam operações de convolução, resultando em mapas de características.

Os filtros kernels são aprendidos durante a fase de treinamento da rede neural e capturam padrões como bordas, texturas e formas em diferentes partes da imagem.

3.2.4.2 Camadas de Pooling

A segunda etapa da estrutura da CNN é formada pelas camadas de pooling. A função dessas camadas consiste em reduzir a dimensionalidade dos mapas de características, resultando em uma redução no número de parâmetros na rede neural. Essa é uma abordagem importante para evitar o *overfitting*, que ocorre quando o modelo se ajusta aos dados treinados, contudo é ineficiente para prever

novos dados.

A camada de pooling realiza uma operação de agregação em uma região local dos mapas de características, mantendo as características mais importante. As operações comumente utilizadas são a média ou o máximo. A média calcula a média dos valores em uma região, enquanto o máximo retém o valor máximos dos valores.

3.2.4.3 Camadas Totalmente Conectadas

A terceira e última etapa da **CNN** é composta pelas camadas totalmente conectadas, que são usadas para realizar a classificação final. É uma camada similar a **MLP**. A diferença entre ambas é que a **MLP** é uma rede neural por si só, já as camadas totalmente conectadas são apenas uma parte de uma estrutura.

As camadas totalmente conectadas consistem em neurônios que estão totalmente conectados aos neurônios da camada anterior. Por meio da camada flatten, o tensor em três dimensões é transformado em um vetor. Logo, esses valores são passados pelas camadas densas ou camadas escondidas da rede neural, até chegar na camada final, onde ocorre a classificação do modelo. Com isso, a rede aprende a combinação das características extraídas, sendo capaz de fazer a previsão.

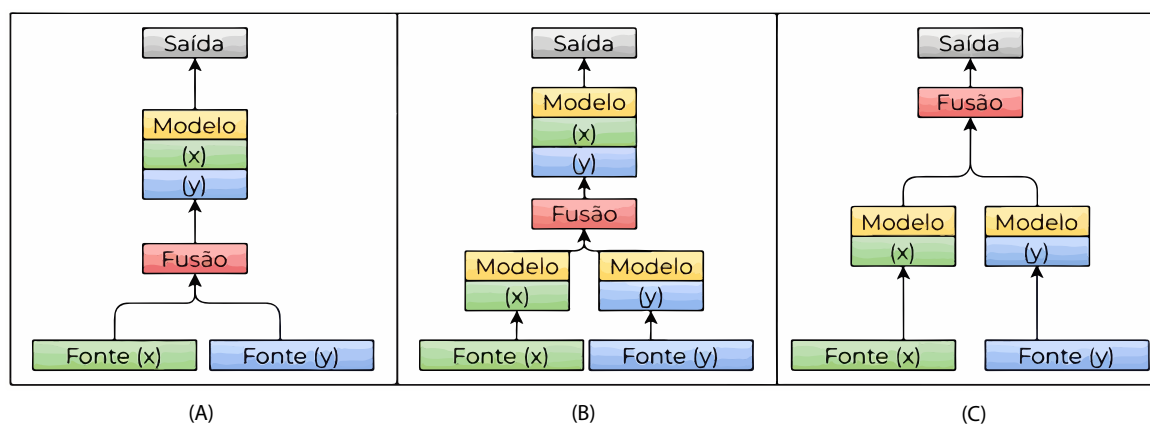
3.2.5 Fusão de informações

Conforme destacado por **Rodrigues (2023)**, a fusão de dados em redes neurais é crucial para o aprendizado de máquina multimodal, visando combinar diversas modalidades de dados para uma visão mais precisa do problema em estudo. Essa abordagem busca oferecer uma representação abrangente, assim como os sentidos humanos se complementam para uma percepção completa do ambiente. No aprendizado multimodal, a concatenação é uma técnica comum, mas outras operações aritméticas, como soma e multiplicação, também podem ser exploradas para a fusão de modalidades.

Existem três tipos populares de fusão de dados em aprendizado de máquina multimodal: fusão precoce, fusão intermediária e fusão tardia. No primeiro caso, os dados são fundidos na entrada para aplicação de um único modelo de redes neurais, como **CNN** ou **MLP**. Na fusão intermediária, os dados passam por uma ar-

quitetura de aprendizado de máquina antes de serem fundidos e passarem novamente por outra arquitetura. A fusão tardia ocorre após o treinamento dos dados nos modelos iniciais, com a saída (classificador) diretamente resultante da fusão. A Figura 3.8 ilustra esses três tipos de fusão de dados.

Figura 3.8 – Tipos de fusão de dados. (A) Fusão precoce (B) Fusão intermediária (C) Fusão tardia



Fonte: (RODRIGUES, 2023)

3.3 Validação de Classificadores

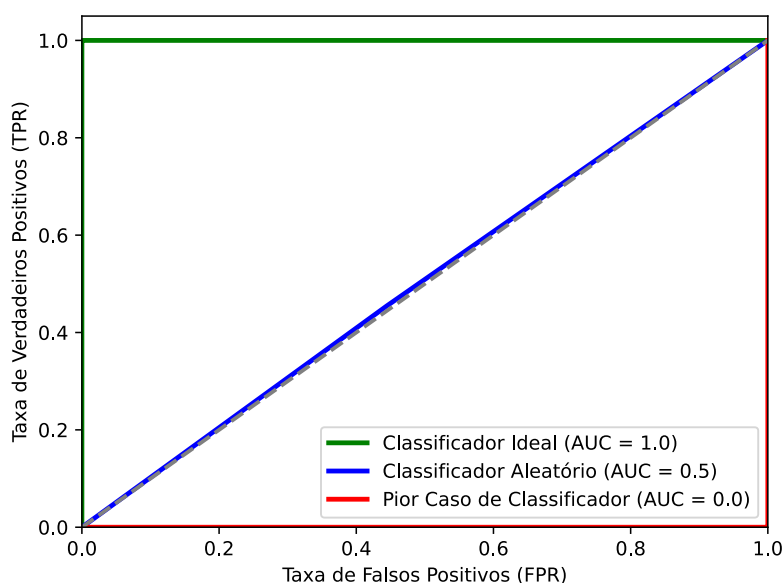
Os classificadores, em geral, precisam ser validados após o treinamento para uso prático. A acurácia, uma métrica presente na biblioteca de código aberto *TensorFlow*, que avalia a precisão da rede em cada época durante o treinamento da rede neural, indicando a proporção de acertos da rede neural em relação ao número total de imagens. Assim, quanto mais próximo de 1, maior a precisão da rede. Além disso, a curva ROC e o histograma de separação são dois métodos comumente aplicados em classificadores binários.

3.3.1 Curva ROC

Conforme apresentado por [Faceli et al. \(2021\)](#), a curva ROC é uma ferramenta gráfica usada para avaliar o desempenho de classificadores. Essa curva representa a taxa de verdadeiros positivos em relação à taxa de falsos positivos em diferentes pontos de corte (limiar de decisão), sendo especialmente útil para classificação binária e extensível para problemas multi-classe. A Área sob a Curva ROC (AUC) é crucial, indicando que um modelo com AUC igual a 1 representa uma classificação perfeita, denominado pelo autor como "céu-ROC", enquanto AUC igual a 0.5 equi-

vale a uma classificação aleatória. Quanto maior a AUC, melhor o desempenho do modelo, ao passo que AUC igual a 0 representa o pior desempenho, denominado como "inferno-ROC". O gráfico da Figura 3.9 ilustra três tipos de classificadores: perfeito, aleatório e o pior caso.

Figura 3.9 – Exemplo de curvas ROC

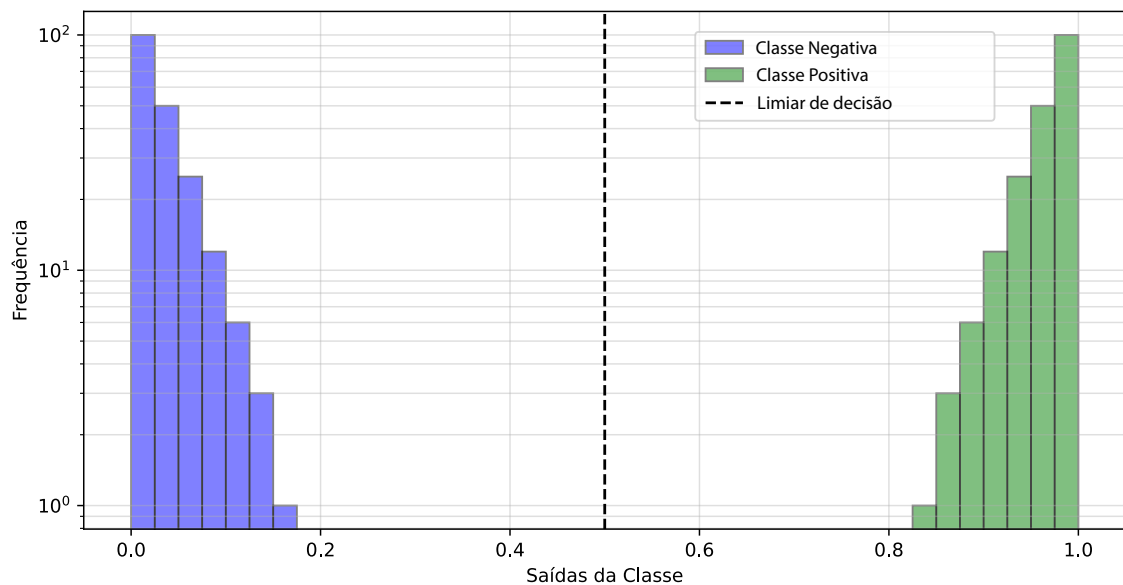


Fonte: Autoria própria

3.3.2 Histograma de Separabilidade

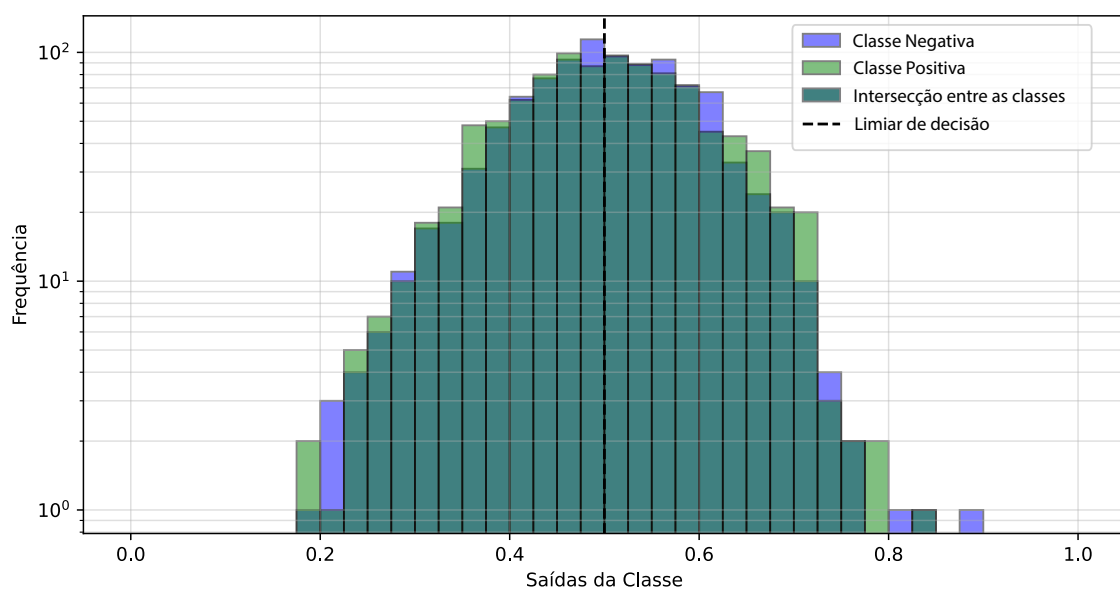
O histograma de separabilidade é uma visualização da distribuição dos dados previstos pela rede neural treinada para duas classes de dados, fornecendo uma compreensão da separabilidade das classes e da qualidade das previsões da rede neural. Os dados da classe negativa e da classe positiva são representadas como histogramas sobrepostos em um espaço unidimensional. Uma linha de separação indica o limiar de decisão em que as classes podem ser consideradas separadas. A Figura 3.10 ilustra um histograma de separabilidade de um bom classificador onde a saída da rede neural é dada pela função Softmax, ou seja, uma saída que fornece uma distribuição de probabilidades.

As probabilidades no histograma são distribuídas de modo que todos os dados se enquadrem em uma das classes. Portanto, ao considerar que a classe em questão é a classe positiva, uma imagem pertencente à classe negativa com uma probabilidade de 0% indica que ela não pertence à classe positiva, ou seja, pertence à classe negativa.

Figura 3.10 – Gráfico de um histograma ilustrativo de um bom classificador

Fonte: Autoria própria

Por outro lado, se as distribuições das probabilidades se sobrepõem consideravelmente, o classificador pode estar com dificuldade em distinguir as classes, indicando a necessidade de melhorias no modelo treinado. A Figura 3.11 ilustra um exemplo de um classificador ruim, onde a rede neural teve dificuldades de classificar a maioria das amostras.

Figura 3.11 – Gráfico de um histograma ilustrativo de um classificador ruim

Fonte: Autoria própria

Capítulo 4

Metodologia

Este trabalho foi organizado em seis etapas: (I) divisão das classes, (II) seleção e pré-processamento das imagens, (III) modelagem, (IV) treinamento e (V) validação da rede neural, e (VI) interpretação dos resultados.

4.1 Divisão das classes

A técnica empregada neste trabalho envolve a categorização desse problema em duas classes distintas: desmatamento e não desmatamento. As duas próximas subseções são dedicadas a abordar esses dois temas.

4.1.1 Classe de áreas não desmatadas

As imagens consideradas para a categoria de áreas não desmatadas correspondem à vegetação primária, ou seja, áreas na região amazônica onde a floresta permanece intacta, com intervenção humana mínima.

Outra região considerada neste contexto são as áreas de mineração em grande escala, como as minas de Carajás e as minas do Azul, localizadas no leste do Pará. Esses tipos de mineração são supervisionados pelo governo brasileiro, tornando desnecessário que o sistema emita alertas de desflorestamento para essas áreas. A Figura 4.1 ilustra dois exemplos da classe "não desmatamento" para o treinamento da rede neural.

Figura 4.1 – *Imagens consideradas não desmatadas para o treinamento da rede neural. (A) Floresta Amazônica localizada no estado do Pará. (B) Mina do Salobo localizada no estado do Pará.*




Fonte: (GOOGLE, 2023a)

4.1.2 Classe de Desmatamento

Nesta categoria, foram considerados dois tipos de desmatamento, conforme ilustrados na Figura 4.2.

Figura 4.2 – *Imagens consideradas desmatadas para o treinamento da rede neural. (A) Desmatamento com solo exposto/pastagem no estado do Acre. (B) Garimpo na região indígena de Kayapós, no Pará.*



Fonte: (GOOGLE, 2023b)

O primeiro é o desmatamento com solo exposto, que implica na perda total da vegetação primária. As pastagens são classificadas como vegetação secundária e frequentemente são identificadas nas imagens em conjunto com o solo exposto,

logo, elas também foram tratadas como uma forma de desmatamento. O segundo tipo de desmatamento abordado nesta categoria é o garimpo.

4.2 Seleção e pré-processamento das imagens

A criação do banco de dados desempenha um papel crucial em projetos envolvendo redes neurais, uma vez que as informações assimiladas pelos neurônios têm origem nessa etapa. Nas próximas subseções, os métodos empregados na elaboração do banco de dados que foi utilizado no projeto serão detalhados.

4.2.1 Origem das Imagens: Utilização de Imagens do Satélite CBERS

O banco de dados foi constituído com imagens do Satélite Sino-Brasileiro de Recursos Terrestres 04A (CBERS), disponibilizadas pelo Instituto Nacional de Pesquisas Espaciais (INPE). Optou-se pela utilização da Câmera Multiespectral e Pancromática de Ampla Varredura (WPM), que possui quatro bandas espectrais (*Blue, Green, Red, NIR*) com uma resolução de 8 metros, além de uma banda pancromática (PAN) com uma resolução de 2 metros. Os principais dados da câmera estão detalhados na Tabela 4.1, conforme disponibilizados pelo INPE (INPE, 2019).

Tabela 4.1 – Câmera Multiespectral e Pancromática de Ampla Varredura (WPM)

| Característica | Dado |
|---------------------------|--------------------------|
| Largura da Faixa Imageada | 92km |
| Visada Lateral de Espelho | não |
| Revisita | 31 dias |
| Quantização | 10bits |
| Taxa de Dados Bruta | 1800.8 Mbps e 450.2 Mbps |

Fonte: (INPE, 2019)

Ao todo, foram selecionadas onze regiões geográficas na Amazônia para a elaboração do banco de dados. As principais características dessas regiões estão descritas na Tabela 4.2.

Tabela 4.2 – Dados dos mapas multiespectrais criados no software QGIS

| Mapa | Data de visita | Tipo |
|-------------------------------------|----------------|-----------------------|
| Região Indígena Munduruku - Mapa 01 | 26/06/2023 | Garimpo |
| Região Indígena Munduruku - Mapa 02 | 26/07/2020 | Garimpo |
| Região Indígena Munduruku - Mapa 03 | 22/07/2023 | Garimpo |
| Região Indígena Kayapó | 23/06/2022 | Garimpo |
| Serra dos Carajás - Mapa 01 | 29/07/2022 | Mineração |
| Serra dos Carajás - Mapa 02 | 21/06/2021 | Mineração |
| Região Sul do Amazonas | 30/09/2021 | Vegetação primária |
| Região Norte do Pará - Mapa 01 | 10/07/2022 | Vegetação primária |
| Região Leste do Acre | 12/07/2022 | Solo exposto/pastagem |
| Região Norte do Pará - Mapa 02 | 25/07/2022 | Solo exposto/pastagem |
| Região Sudeste do Amazonas | 30/06/2022 | Solo exposto/pastagem |

Fonte: (INPE, 2019)

4.2.2 Softwares utilizados

Para a seleção e o pré-processamento das imagens, foram necessários três *softwares*: TerraAmazon, QGIS e Visual Studio Code. Os tópicos abaixo abordarão cada um desses programas.

- ▶ **TerraAmazon:** O TerraAmazon é um *software* gratuito de geoprocessamento desenvolvido pelo INPE, com o objetivo de permitir que o público trabalhe com dados georreferenciados.
- ▶ **QGIS:** O QGIS é um *software* gratuito desenvolvido pela *Open Source Geospatial Foundation* e disponibilizado na internet. Este *software* oferece diversas funcionalidades na geração de mapas e análise geográfica, sendo um dos *softwares* mais conhecidos e utilizados para processamento de dados georreferenciados.
- ▶ **Visual Studio Code:** É um editor de código-fonte de código aberto desenvolvido pela Microsoft. o *software* disponibiliza editores avançados utilizando diversas linguagens de programação, como Python, C++, HTML, CSS, Javascript, entre outras.

4.2.3 Banco de dados

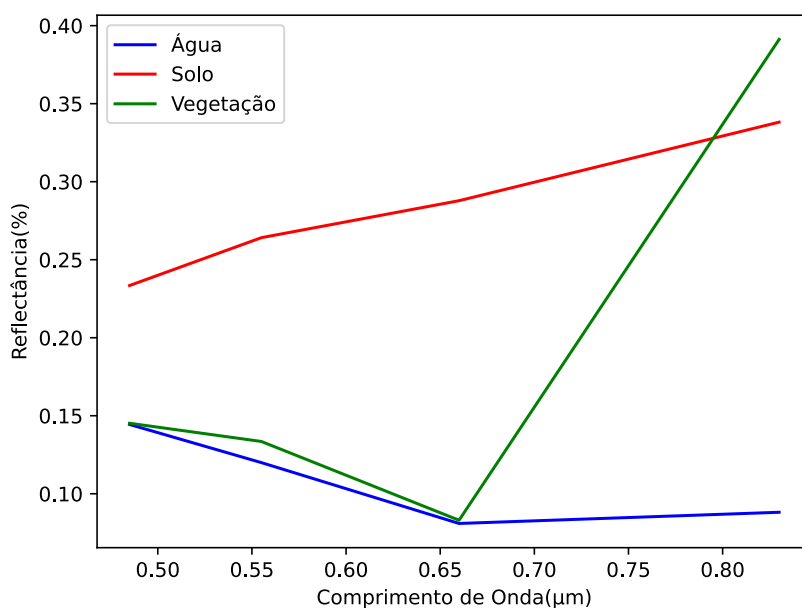
A construção dos mapas multiespectrais foi realizada utilizando a ferramenta de Mosaico do *software* QGIS. Essa ferramenta combina as diversas bandas espectrais disponíveis em um satélite em um único mapa multiespectral. No caso deste trabalho, a ferramenta combina as quatro bandas espectrais do satélite [CBERS](#) retiradas no Catálogo de Imagens do [INPE](#).

O banco de dados foi dividida em duas partes: (I) imagens composição cor real e (II) imagens coloridas formadas pelas imagens-fração. As imagens foram exportadas do *software* QGIS, que permite baixar imagens georreferenciadas no formato TIF, com um tamanho máximo de 529 x 637 pixels. Dado que a resolução espacial fornecida pelo satélite [CBERS](#) é de 8 metros, as imagens exportadas abrangiam uma extensão territorial de 4.232 x 5.096 metros.

Para obter as imagens composição cor real, foi necessário usar as cores reais do mapa multiespectral. Para isso, a composição de cores escolhida para o mapa foi a composição cor real 3-2-1 (banda 3 no canal 1, banda 2 no canal 2 e banda 1 no canal 3).

Para a exportação das imagens coloridas formadas pelas imagens-fração, o mapa multiespectral inicialmente criado no QGIS foi transferido para o TerraAmazon. A utilização desse *software* foi crucial para aplicar o método do modelo linear de mistura espectral. O *software* oferece três princípios matemáticos para desenvolver o modelo linear: mínimos quadrados, mínimos quadrados com restrições lineares e análise das componentes principais.

O método escolhido foi o princípio dos mínimos quadrados com restrições lineares uma vez que o *software* disponibiliza a opção de quatro bandas espectrais e três componentes, diferente dos demais métodos, onde o número de bandas deve ser igual ao número de componentes. Isso é importante uma vez que o satélite utilizado disponibiliza quatro bandas espectrais. No mapa, três componentes foram escolhidas para realizar o trabalho: água, solo e vegetação. A Figura 4.3 ilustra um dos gráficos de reflectância gerados após a escolha das três componentes selecionadas diretamente no mapa espectral. Observe a semelhança desse gráfico com aquele presente na literatura, ilustrado na Figura 2.6.

Figura 4.3 – Reflectância das três componentes abordadas para a realização do trabalho

Fonte: Autoria própria

Na faixa espectral considerada, observa-se um crescimento contínuo na assinatura espectral do solo. Em contrapartida, a assinatura espectral da água tende a diminuir, uma vez que a radiação incidente no elemento é absorvida ou transmitida. Por fim, a vegetação destaca-se ao absorver a energia da radiação no espectro visível para a realização da fotossíntese, enquanto não absorve radiação no infravermelho. Esse comportamento específico resulta em um notável aumento no gráfico de reflectância da vegetação. Por isso, é possível afirmar que a seleção dos *endmembers* está de acordo com os valores apresentados na literatura.

O *software* TerraAmazon também possibilita a criação de composições coloridas a partir das informações das três frações, conforme explicado na seção 3.1.3. Utilizando essa abordagem, a composição colorida foi reintroduzida no QGIS para permitir a exportação das imagens coloridas formadas pelas frações.

O banco de dados consistiu em 4000 imagens, divididas em 2000 imagens composição cor real e 2000 imagens coloridas formadas pelas imagens-fração. De ambos os subgrupos, 1000 imagens são da classe "desmatamento" e 1000 imagens são da classe "não desmatamento".

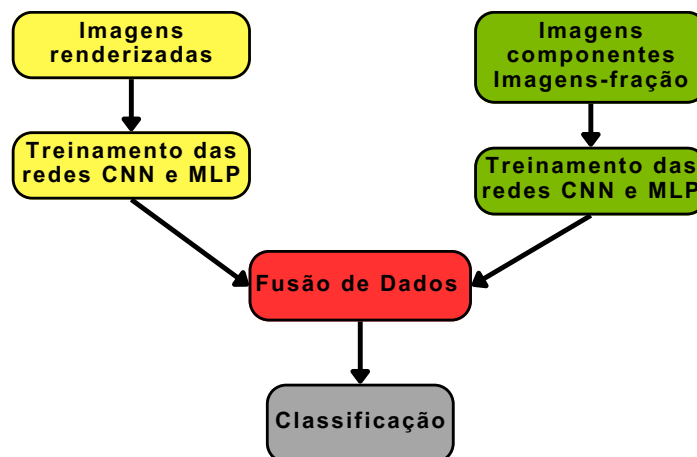
A última etapa do pré-processamento das imagens foi realizada no *software* Visual Studio Code. Para treinar redes neurais, é necessário pré-processar as imagens antes de alimentá-las na rede neural. O código para o pré-processamento

das imagens pode ser visto no Apêndice A.1. Em linguagem Python, as imagens foram transformadas em listas, arrays, classificadas e embaralhadas. A técnica do embaralhamento das imagens é essencial para que a máquina não tenha um aprendizado por sequência de dados iguais. As bibliotecas cv2, os, numpy e pandas foram fundamentais nessa etapa do projeto.

4.3 Modelagem

O modelo neural foi construído utilizando uma abordagem de fusão tardia, ilustrado na Figura 4.4. As imagens composição cor real e as imagens compostas pelas imagens-fração foram treinadas em duas arquiteturas de redes neurais diferentes: a CNN e a MLP. Após a validação das redes neurais, foi realizado um processo de fusão de dados. Nesse caso, dado que se tem duas arquiteturas de rede para cada tipo de imagem, é possível criar quatro combinações de fusão de dados, as quais foram exploradas. Finalmente, a arquitetura resultante da fusão de dados foi responsável por classificar as duas classes possíveis: desmatamento ou ausência de desmatamento. O código para o treinamento da Fusão de Dados pode ser visto no Apêndice A.4.

Figura 4.4 – Estrutura montada por meio da fusão tardia



Fonte: Autoria própria

4.4 Treinamento da Rede Neural

O treinamento de redes neurais apresenta desafios significativos. O primeiro desafio está relacionado à capacidade de processamento do computador utilizado. Treinar uma rede neural pode demandar várias horas, ou até mesmo dias, de processamento intensivo. Em muitos casos ainda, a máquina pode não possuir memória suficiente devido à complexidade da estrutura da rede neural.

Neste estudo, o treinamento foi conduzido em um notebook Lenovo Ideapad Gaming. As principais especificações dessa máquina estão disponíveis na Tabela 4.3.

Tabela 4.3 – Informações da máquina utilizada para o treinamento das redes neurais

| Característica | Dado |
|----------------|--------------------------------------|
| Processador | Intel Core i7-11370H |
| Núcleos | 4 |
| Memória RAM | 16GB |
| GPU | Dedicada NVIDIA GeForce GTX 1650 4GB |

Fonte: Autoria própria

O Visual Studio Code foi ambiente escolhido para o treinamento das redes neurais utilizando a linguagem Python para a programação. A biblioteca Keras, comumente empregada no aprendizado profundo de máquina e pertencente à TensorFlow, foi utilizada para criar os modelos neurais do projeto. Os códigos do treinamento podem ser visualizados no apêndice A.

Os parâmetros das redes neurais foram encontrados por meio de tentativa e erro. Cada rede neural foi testada repetidas vezes até que a mesma obtivesse um bom desempenho. As redes neurais CNN e MLP, tanto para as imagens composição cor real quanto para as imagens compostas pelas imagens-fração, foram treinadas com 1.800 imagens. As outras 200 imagens restantes foram separadas para futuros testes na rede neural.

A Tabela 4.4 mostra os parâmetros utilizados na estrutura CNN para os dois tipos de imagens utilizadas no trabalho.

Tabela 4.4 – Parâmetros da estrutura **CNN** no treinamento de imagens composição cor real e coloridas formadas pelas imagens-fração

| Característica | Dado |
|---|---------------------------------|
| Camadas convolucionais (Conv2D) | 2 |
| Função de ativação nas camadas convolucionais | 2 |
| Camadas de Pooling | 2 |
| Operação da camada de Pooling | Máximo |
| Entrada da rede neural | 1 Imagem 529x637x3 |
| Camadas escondidas (Totalmente interligada) | 1 |
| Neurônios nas camadas escondidas | 128 |
| Função de ativação das camadas escondidas | ReLU |
| Neurônios na camada de saída | 2 |
| Função de ativação da camada de saída | softmax |
| Função de erro da rede | sparse-categorical-crossentropy |
| Taxa de aprendizado | 0,0001 |
| Épocas | 15 |

Fonte: Autoria própria

A Tabela 4.5 mostra os parâmetros utilizados para na estrutura **MLP** para os dois tipos de imagens utilizadas no trabalho.

Tabela 4.5 – Parâmetros da estrutura **MLP** no treinamento de imagens composição cor real e coloridas formadas pelas imagens-fração

| Característica | Dado |
|---|---------------------------------|
| Épocas | 30 |
| Entrada da rede neural | 1 imagem 529x637x3 |
| Camadas escondidas | 1 |
| Neurônios nas camadas escondidas | 512 |
| Função de ativação das camadas escondidas | ReLU |
| Neurônios na camada de saída | 2 |
| Função de ativação da camada de saída | softmax |
| Função de erro da rede | sparse-categorical-crossentropy |
| Taxa de aprendizado | 0,00001 |

Autoria própria

Finalmente, após a preparação das estruturas, procede-se à montagem da fu-

são de dados. Inicialmente, as camadas finais de cada modelo da fusão de dados foram retiradas. Em seguida, foi necessário congelar as camadas restantes para evitar o retrabalho das camadas previamente treinadas. Posteriormente, a técnica de concatenação de camadas é usada nas saídas resultantes de cada rede neural. Logo, uma camada densa pode ser acrescentada, que corresponde à camada de saída, contendo 2 neurônios para a classificação dos dados. Devido a restrições de memória na máquina, foi necessário reduzir o número de imagens utilizadas, assim como o número de patches, para treinar a estrutura de fusão de informações. A rede foi treinada com 480 imagens em cada lado da fusão de dados, enquanto 200 imagens para cada lado da fusão foram reservadas para testes futuros. Os parâmetros da estrutura de fusão de dados estão detalhados na Tabela 4.6.

Tabela 4.6 – Parâmetros no treinamento da estrutura fusão de dados

| Característica | Dado |
|---------------------------------------|---------------------------------|
| Entrada da rede neural | 2 imagens 529x637x3 |
| Épocas | 30 |
| Neurônios na camada de saída | 2 |
| Função de ativação da camada de saída | softmax |
| Função de erro da rede | sparse-categorical-crossentropy |
| Taxa de aprendizado | 0,0005 |

Fonte: Autoria própria

4.5 Validação das Redes Neurais

A validação das redes neurais treinadas neste estudo foi realizada por meio da acurácia, da curva ROC e do histograma de separabilidade. Esses métodos são amplamente empregados em classificadores binários, neste contexto, para discernir entre áreas de desmatamento e não desmatamento. O tamanho dos intervalos do histograma foi fixado em 2,5% e o limiar de decisão escolhido foi 0,5 para manter uma abordagem equivalente para ambas as classes.

Capítulo 5

Resultados e discussões

5.1 Treinamento das imagens composição cor real

A Tabela 5.1 ilustra os dados obtidos no treinamento das imagens composição cor real utilizando as arquiteturas CNN e MLP. A perda próxima a zero indica que a função de perda *Sparse Categorical Cross-Entropy* utilizada no processo de treinamento foi eficaz na minimização da diferença entre as saídas previstas pela rede neural e os valores reais dos dados de treinamento. Além disso, as acurácias obtidas indicam uma boa precisão das redes neurais ao avaliar a proporção de imagens corretamente classificadas pela rede em relação ao total de imagens. Cada treinamento durou no mínimo 2 horas de esforço intensivo da máquina.

Tabela 5.1 – Parâmetros do treinamento das arquiteturas CNN e MLP para as imagens composição cor real


| Parâmetro | CNN | MLP |
|------------------------|-----------|-------------|
| Acurácia | 1,0000 | 0,9994 |
| Loss (Perda) | 0,0012 | 0,0203 |
| Duração do treinamento | ≈ 2 horas | ≈ 2,5 horas |

Fonte: Autoria própria

As curvas ROC obtidas nesse processo podem ser visualizadas na Figura 5.1. Inicialmente, os valores obtidos apontam uma boa capacidade das redes neurais de distinguir as classes uma vez que as áreas sob a curva estão próximos a 1. Pelo gráfico, é possível afirmar ainda que a arquitetura CNN demonstra um desempenho de classificação superior à arquitetura MLP, uma vez que a área sob a curva da CNN é maior do que a da MLP. O gráfico também corrobora essa observação,

uma vez que a curva azul está mais próxima da curva ideal do que a curva laranja.


Figura 5.1 – Curvas ROC das arquiteturas MLP e CNN para as imagens composição cor real.



Fonte: Autoria própria

O histograma de separabilidade é outra abordagem apresentada para validar as informações. A Figura 5.2 representa o histograma gerado pela arquitetura CNN.

Figura 5.2 – Histograma de separabilidade da arquitetura CNN para as imagens composição cor real

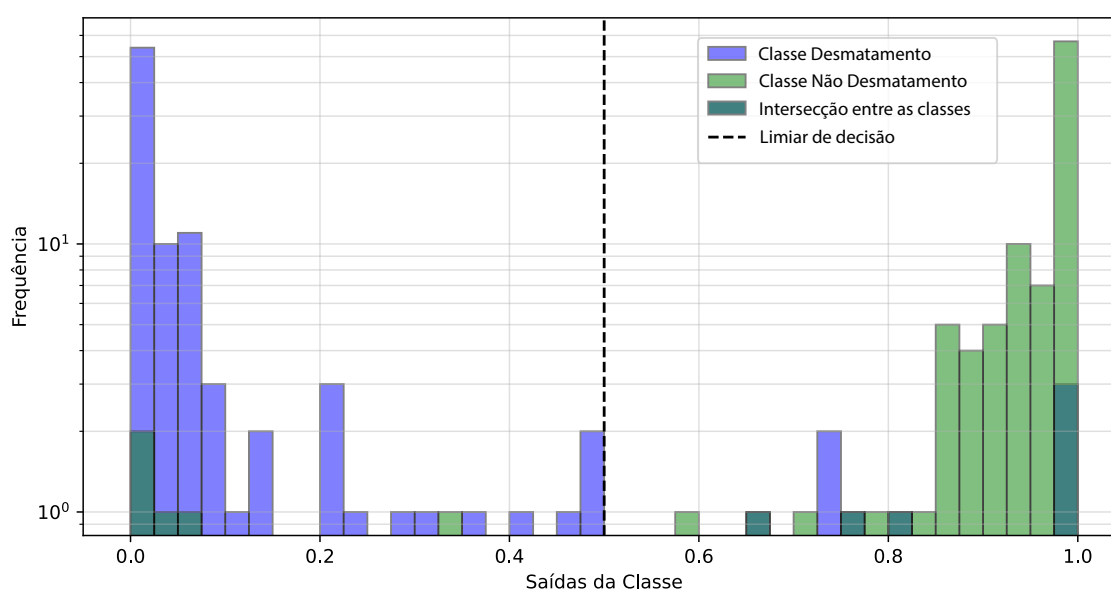


Fonte: Autoria própria

A rede neural classificou incorretamente três imagens que pertenciam à classe de desmatamento como não sendo de desmatamento. A rede neural também classificou erroneamente duas imagens que pertenciam à classe de não desmatamento como pertencentes à classe de desmatamento. Esses dados juntamente com o gráfico da curva ROC indicam a presença de falsos positivos e falsos negativos na saída da CNN. Em outras palavras, a distribuição aponta a dificuldade da rede neural em classificar algumas imagens em ambas as classes.

O gráfico na Figura 5.3 representa o histograma gerado pela arquitetura MLP.

Figura 5.3 – Histograma de Separabilidade da arquitetura MLP para as imagens composição cor real



Conforme observado, a rede neural cometeu erros de classificação, identificando incorretamente 6 imagens que pertenciam à classe de desmatamento como não sendo de desmatamento. Além disso, a rede também classificou erroneamente 4 imagens que pertenciam à classe de não desmatamento como pertencentes à classe de desmatamento.

Os resultados dos treinamentos das imagens composição cor real indicam que ambas as arquiteturas, embora mantenham uma alta precisão, enfrentam dificuldades para realizar uma distinção precisa entre as classes. Mesmo com um desempenho superior da arquitetura CNN em ambas as validações, ainda ocorrem erros de classificação entre as classes.

5.2 Treinamento das imagens formadas pelas imagens-fração

A Tabela 5.2 ilustra os dados obtidos no treinamento das imagens compostas pelas imagens-fração utilizando as arquiteturas CNN e MLP. A perda no processo novamente próxima a zero indica que a função de perda *Sparse Categorical Cross-Entropy* foi eficaz na minimização da diferença entre as saídas previstas pela rede neural e os valores reais dos dados de treinamento. As acurácias apontam também que as redes neurais obtiveram uma boa precisão durante o processo ao avaliar a proporção de imagens corretamente classificadas pela rede em relação ao total de imagens. O treinamento durou no mínimo 1,5 hora de esforço intensivo da máquina.

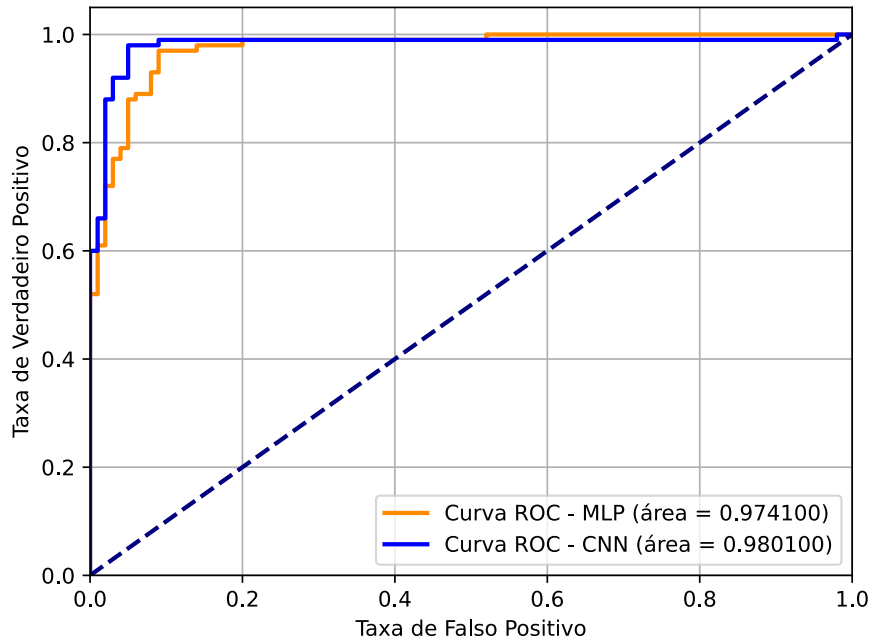
Tabela 5.2 – Parâmetros obtidos com o treinamento das redes neurais CNN e MLP para as imagens formadas pelas frações das componentes

| Parâmetro | CNN | MLP |
|------------------------|----------------------|---------------------|
| Acurária | 1,0000 | 1,0000 |
| Loss (Perda) | $3,14 \cdot 10^{-4}$ | 0,0022 |
| Duração do treinamento | $\approx 1,5$ hora | $\approx 2,5$ horas |

Fonte: Autoria própria

As curvas ROC obtidas pelas arquiteturas CNN e MLP para as imagens composição cor real podem ser visualizadas na Figura 5.4. Os valores da área sob a curva próximos a 1 apontam que as redes neurais treinadas tem uma taxa alta de verdadeiros positivos e uma taxa baixa de falsos positivos, refletindo uma boa capacidade de distinguir as classes de desmatamento e não desmatamento. Pelo gráfico, apesar da arquitetura CNN exibir um desempenho de classificação superior à arquitetura MLP, devido à maior área sob a curva da CNN, é possível afirmar que o desempenho de classificação das duas arquiteturas é similar. Isso ocorre porque as áreas sob as curvas de ambas as redes são próximas, diferindo apenas em 0,006.

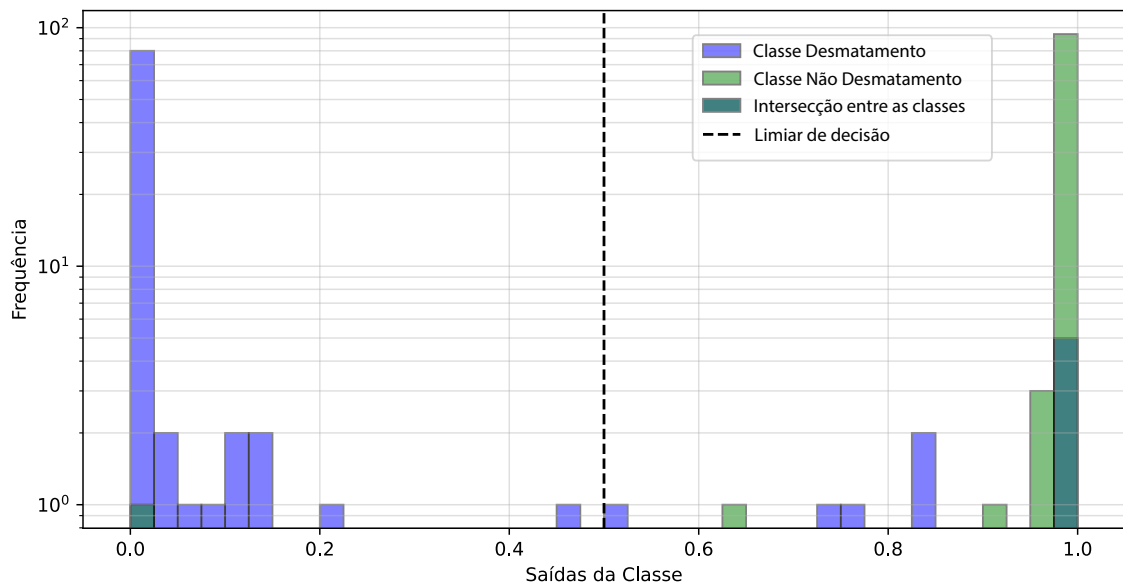
Figura 5.4 – Gráfico das curvas ROC das arquiteturas MLP e CNN treinadas pelas imagens compostas pelas frações das componentes



Fonte: Autoria própria

A Figura 5.5 representa o histograma gerado pela arquitetura CNN.

Figura 5.5 – Histograma de Separabilidade para a arquitetura CNN treinada com as imagens formadas pelas frações

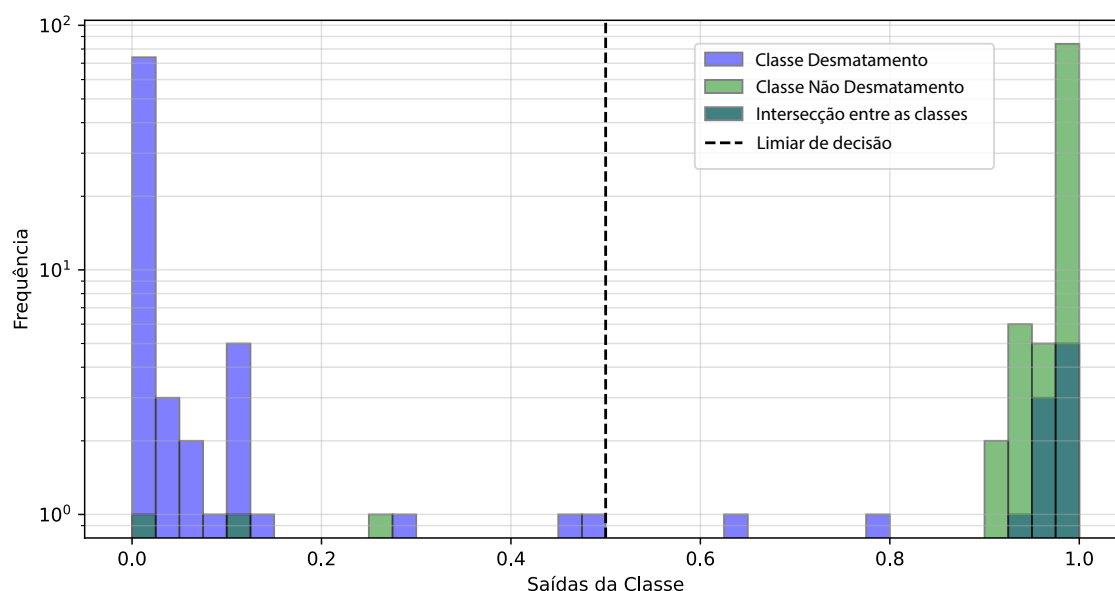


Fonte: Autoria própria

Conforme observado, a rede neural classificou incorretamente dez imagens que pertenciam à classe de desmatamento como não sendo de desmatamento. Por outro lado, a rede neural também classificou erroneamente uma imagem que pertencia à classe de não desmatamento como pertencente à classe de desmatamento.

O gráfico na Figura 5.6 representa o histograma gerado pela arquitetura MLP. Conforme observado, a rede neural identificou incorretamente 11 imagens que pertenciam à classe de desmatamento como não sendo de desmatamento. Além disso, a rede também classificou erroneamente 3 imagens que pertenciam à classe de não desmatamento como pertencentes à classe de desmatamento.

Figura 5.6 – Histograma de Separabilidade para a arquitetura MLP treinada com as imagens formadas pelas frações



Fonte: Autoria própria

Mais uma vez, assim como ocorreu no treinamento das imagens composição cor real, os resultados apontam que ambas as arquiteturas encontram desafios para efetuar uma distinção precisa entre as classes, mesmo apresentando uma boa precisão nos resultados.

5.3 Fusão de Informações

Foram treinados quatro tipos de fusão de dados, combinando as arquiteturas CNN e MLP previamente treinadas. As arquiteturas de fusão de dados apresentadas nesta seção serão referidas como "Arquitetura 01 + Arquitetura 02", indicando a fusão de dados entre duas arquiteturas. A primeira corresponde à arquitetura usada no treinamento das imagens composição cor real, enquanto a segunda arquitetura corresponde àquela utilizada no treinamento das imagens compostas pelas imagens-fração.

A Tabela 5.3 ilustra os dados obtidos no treinamento das fusões de dados. Como pode ser visto, a perda no processo próxima a zero indica novamente que a função de erro *Sparse Categorical Cross-Entropy* foi eficaz na minimização da diferença entre as saídas previstas pela rede neural e os valores reais dos dados de treinamento. As acurácias indicam que as arquiteturas combinadas alcançaram uma boa precisão ao avaliar a proporção de imagens corretamente classificadas pela rede em relação ao total de imagens. Como houve uma redução no número de dados devido a complexidade da rede e o poder computacional utilizado, o treinamento foi considerado rápido, com uma duração máxima de 20 minutos de esforço intensivo da máquina.

Tabela 5.3 – Parâmetros do treinamento da Fusão de dados

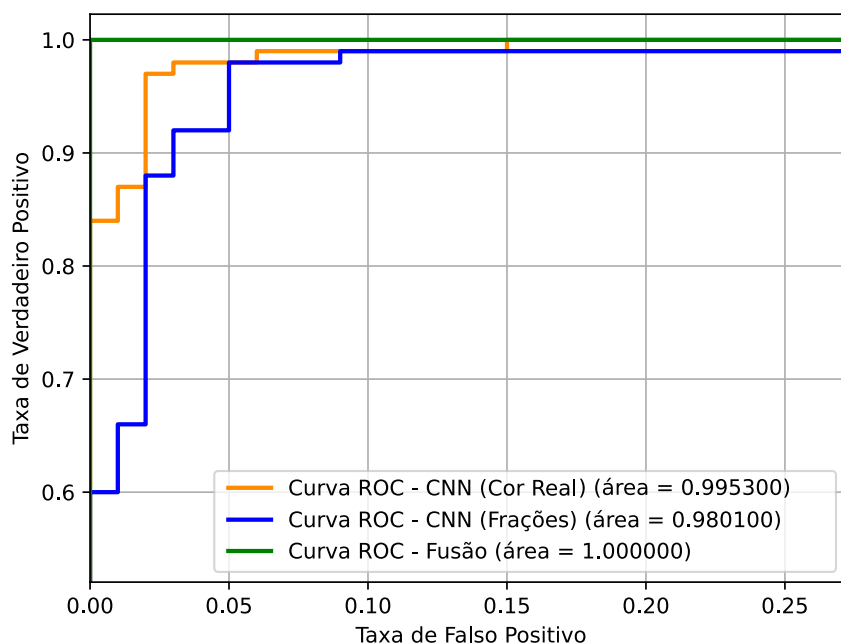
| Parâmetro | CNN/CNN | CNN/MLP | MLP/CNN | MLP/MLP |
|--------------|---------|----------|----------|---------|
| Acurária | 1,0000 | 1,0000 | 0,9979 | 1,0000 |
| Loss (Perda) | 0,0075 | 0,0041 | 0,0099 | 0,0087 |
| Duração | ≈ 20min | ≈ 15 min | ≈ 15 min | ≈ 5 min |

Fonte: Aatoria própria

5.3.1 Fusão CNN + CNN

O gráfico na Figura 5.7 apresenta uma comparação entre a curva ROC obtida pela fusão CNN + CNN e as curvas ROC das arquiteturas citadas pré-treinadas. É notável que a fusão de dados resultou em um aprimoramento na precisão da rede neural em comparação com as arquiteturas treinadas individualmente. Esse ganho sugere um desempenho mais robusto da rede neural, capturando melhor as nuances dos dados.


Figura 5.7 – Gráfico comparativo entre as curvas ROC das arquiteturas CNN das imagens com composição cor real e das imagens formadas pelas frações e da fusão de ambas arquiteturas.



Fonte: Autoria própria

O histograma da fusão de dados CNN + CNN é representado no gráfico da Figura 5.8.

Figura 5.8 – Histograma da fusão das arquiteturas CNN + CNN




Fonte: Autoria própria

Como é evidente, a rede neural treinada acertou todas as amostras fornecidas. Como o valor do bin equivale a 2,5%, é notório que a rede está identificando as imagens da classe não desmatamento com uma precisão igual ou maior a 95%. Isso ilustra uma melhoria significativa na performance da rede neural por meio da fusão de dados, uma vez que as redes neurais individuais anteriormente treinadas encontravam dificuldades na interpretação de algumas imagens fornecidas à rede.

5.3.2 Fusão CNN + MLP

O gráfico na Figura 5.9 apresenta uma comparação entre a curva ROC obtida pela fusão das redes CNN + MLP e as curvas ROC das arquiteturas pré-treinadas. Mais uma vez, a fusão de dados conduziu a um aprimoramento na precisão da rede neural, uma vez que a área sob a curva da fusão é superior àquela das redes individuais. Esta constatação é ainda confirmada pelo gráfico, onde a curva verde, que representa a resposta da fusão de dados, representa o padrão ideal, enquanto as curvas laranja e azul se encontram mais afastadas dessa curva.

Figura 5.9 – Gráfico comparativo entre as curvas ROC da arquitetura CNN das imagens composição cor real e da arquitetura MLP das imagens formadas pelas frações e da fusão de ambas arquiteturas

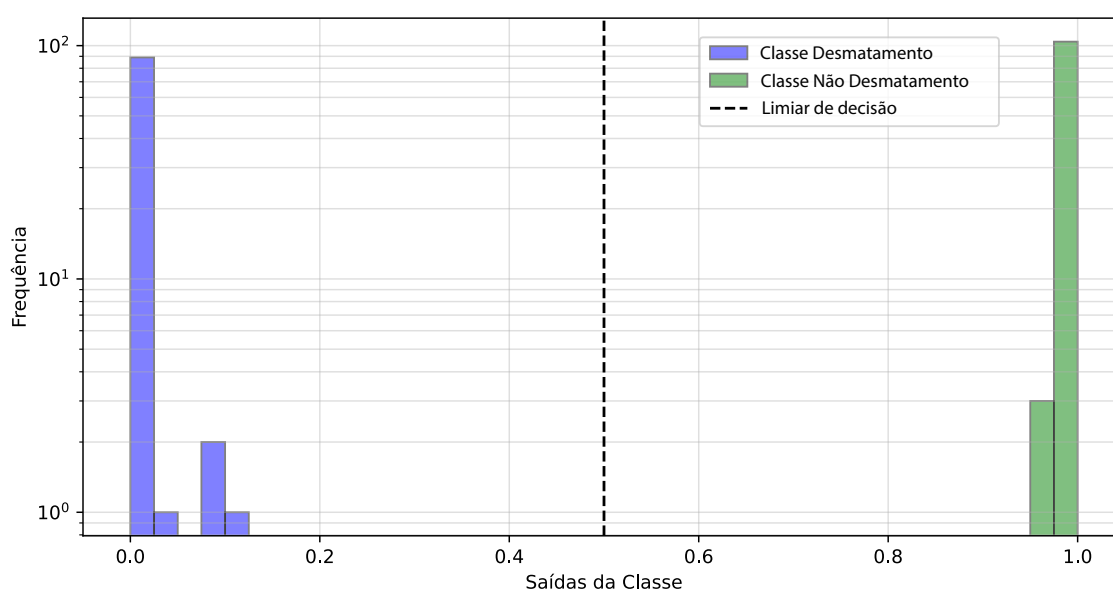


Fonte: Autoria própria

O histograma da fusão de dados CNN + MLP é representado no gráfico da

Figura 5.10. Como é visto, a fusão treinada acertou todas as amostras fornecidas com uma boa precisão. Para a classe não desmatamento, a rede acertou todos os dados com uma precisão maior ou igual a 95%. Para a classe desmatamento, a rede acertou todos os dados com uma precisão superior a 87,5%. Isso aponta novamente um aprimoramento significativo na performance da rede neural por meio da fusão de dados, uma vez que as redes neurais individuais anteriormente treinadas encontravam dificuldades na interpretação de algumas imagens.

Figura 5.10 – Histograma da fusão das arquiteturas CNN + MLP




Fonte: Autoria própria

5.3.3 Fusão MLP + CNN

O gráfico na Figura 5.11 apresenta uma comparação entre a curva ROC obtida pela fusão das redes CNN + CNN e as curvas ROC das arquiteturas pré-treinadas. O aprimoramento na precisão da rede neural por meio da fusão de dados é novamente visível. A área da curva ROC da fusão é igual a área da curva ideal, indicando uma eficácia alta da rede neural treinada e superior àquelas treinadas individualmente.


Figura 5.11 – Gráfico comparativo entre as curvas ROC da fusão de dados, da arquitetura MLP das imagens composição cor real e da arquitetura CNN das imagens formadas pelas frações



Fonte: Autoria própria

O histograma da fusão de dados **MLP + CNN** é representado no gráfico da Figura 5.12.

Figura 5.12 – Histograma da fusão das arquiteturas MLP + CNN



Fonte: Autoria própria

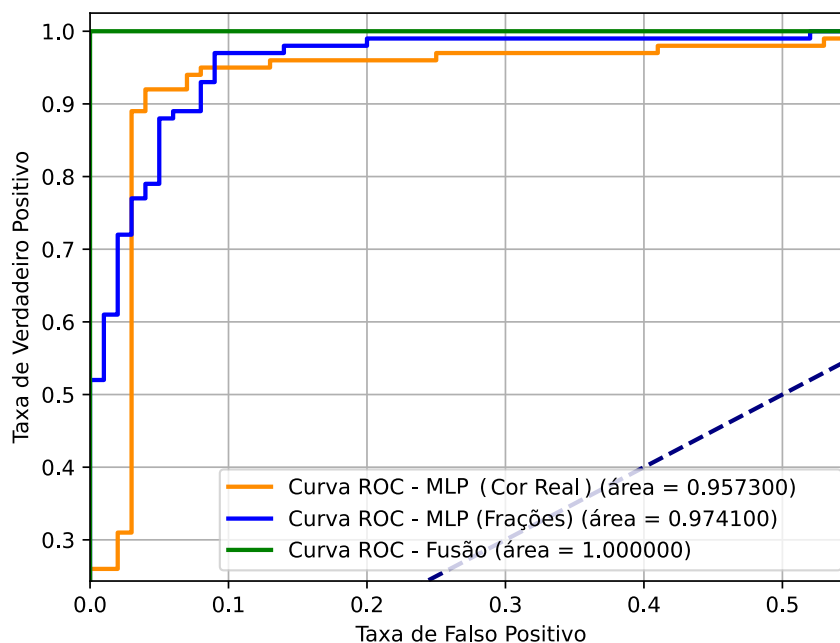
Como visualizado, a rede neural treinada acertou todas as amostras forne-

cidas para a classe não desmatamento. Todavia, a rede neural classificou erroneamente uma amostra da classe desmatamento como não desmatamento. Esse resultado indica que a rede ainda trabalha com uma precisão alta e melhor que as redes neurais treinadas com arquiteturas individualizadas, uma vez que a rede teve dificuldade de distinguir apenas uma amostra de todas àquelas apresentadas para a arquitetura.

5.3.4 Fusão MLP + MLP

O gráfico na Figura 5.13 apresenta uma comparação entre a curva ROC obtida pela fusão das redes MLP + MLP e as curvas ROC das arquiteturas pré-treinadas. É observável que a fusão de dados resultou mais uma vez em um aprimoramento na precisão da rede neural uma vez que a curva sob a área da fusão de dados é maior que àquela apresentada pelas arquiteturas individuais. O gráfico ainda corrobora essa visão quando a curva verde, que representa a curva ROC da fusão de dados, se mostra igual à curva ideal, diferente das demais arquiteturas ilustradas no gráfico.

Figura 5.13 – Gráfico comparativo entre as curvas ROC das arquiteturas MLP das imagens composição cor real e das imagens formadas pelas frações e da fusão de ambas arquiteturas.




Fonte: Autoria própria

O histograma da fusão de dados MLP + MLP é representado no gráfico da

Figura 5.14. O gráfico mais uma vez evidencia o aprimoramento da fusão de dados no desempenho, quando comparado às redes neurais treinadas individualmente. Em apenas um caso, embora corretamente classificado, persiste uma indecisão em relação à classificação.

Figura 5.14 – Histograma da fusão das arquiteturas MLP + MLP



Fonte: Autoria própria

Este resultado destaca a relevância da escolha do limiar de decisão. Por exemplo, um limiar de 0,6 classificaria a imagem próxima de 0,5 da Figura 5.14 como desmatamento, enquanto um limiar de 0,2 tornaria a rede mais sensível na detecção das classes de não desmatamento. Em outras palavras, o ajuste do limiar determina a sensibilidade do sistema. Portanto, a análise ambiental desempenha um papel crucial na definição da sensibilidade da rede para a detecção e classificação de uma classe de desmatamento, podendo torná-la mais ou menos sensível conforme necessário.

Capítulo 6

Considerações Finais

A vastidão e a diversidade da Amazônia tornam a tarefa de monitoramento de desmatamento extremamente complexa, exigindo abordagens avançadas para alcançar resultados eficazes. Esta pesquisa abordou a classificação de desmatamento na floresta amazônica utilizando a comparação de desempenho de duas arquiteturas de redes neurais artificiais e a fusão de dados para o aprimoramento dos resultados.

A metodologia empregada demonstrou eficiência no desenvolvimento do projeto e na obtenção de resultados. No entanto, é importante destacar que o poder computacional utilizado no trabalho impôs limitações ao tamanho do banco de dados que a máquina poderia manipular. Diante dessa limitação, mesmo com uma metodologia adequada, recomenda-se a utilização de clusters para possibilitar a expansão do banco de dados, visando obter resultados com uma quantidade mais expressiva de informações disponíveis. Isso é particularmente relevante devido à complexidade da floresta amazônica e à necessidade de lidar com conjuntos de dados mais abrangentes.

O Modelo Linear de Mistura Espectral desempenhou um papel fundamental no cálculo das frações das componentes presentes na imagem. Como evidenciado pelos resultados apresentados, tanto a arquitetura [MLP](#) quanto a arquitetura [CNN](#) demonstraram habilidade na classificação das áreas desmatadas usando as imagens formadas a partir das frações das componentes.

Os resultados indicaram também um desempenho sólido das arquiteturas [MLP](#) e [CNN](#) na tarefa de classificação de áreas desmatadas em imagens de satélite, mesmo diante das dificuldades de classificação de algumas imagens. Todavia,

recomenda-se a análise das imagens pertencentes a uma classe que foram classificadas erroneamente como pertencentes a outra classe. Essa abordagem científica busca compreender as razões pelas quais a rede neural comete erros, examinando os aspectos das imagens incorretamente classificadas e propondo possíveis soluções para o problema por meio da aplicação de novos métodos.

Os resultados apontaram ainda o aprimoramento da classificação das imagens por meio da fusão de dados. Em todos os cenários de fusão de dados avaliados, observou-se uma melhoria significativa em comparação com o desempenho das redes neurais individuais. Esse aprimoramento sugere que a abordagem de fusão de dados não apenas potencializou a sinergia entre diferentes arquiteturas, mas também ressaltou a importância da complementaridade entre os conjuntos de dados utilizados.

Um aspecto crucial neste trabalho é a definição do limiar de decisão. Nesta pesquisa, optou-se por um limiar de decisão estabelecido em 0,5, visando manter uma abordagem equivalente na atribuição das classes. Contudo, é importante salientar que este ajuste geralmente fica a cargo do operador responsável por conduzir o trabalho. Em outras palavras, todo trabalho de engenharia está intrinsecamente ligado ao custo associado a uma decisão, principalmente a uma resposta equivocada. Uma classificação incorreta implica em despesas, e, por isso, é necessário refletir o quão preciso o limiar deve ser ajustado para que a rede sinalize o sistema acerca de possíveis áreas de desmatamento.

É fundamental ressaltar que os desafios inerentes ao monitoramento do desmatamento na Amazônia brasileira são complexos. A diversidade de tipos de desmatamento na região Norte, aliada à vastidão do bioma, torna a detecção e o monitoramento uma tarefa contínua e intrincada. Assim, faz-se necessária uma constante evolução das técnicas de aprendizado de máquina para assegurar a precisão e a eficácia contínuas na vigilância do desmatamento na região amazônica.

Em resumo, este trabalho demonstrou que o uso de redes neurais artificiais, a fusão de informações espectrais e espaciais e o Modelo Linear de Mistura Espectral têm o potencial de melhorar significativamente a detecção de desmatamento na Amazônia. É esperado que este estudo contribua para o avanço das tecnologias de monitoramento ambiental e, assim, auxilie na proteção desse ecossistema vital para o planeta.

REFERÊNCIAS

- ÂNGELO, H.; SÁ, S. P. P. d. O desflorestamento na amazônia brasileira. *Ciência Florestal*, SciELO Brasil, v. 17, p. 217–227, 2007. (Citado na página 1.)
- BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. *Neurociências: desvendando o sistema nervoso*. [S.l.]: Artmed editora, 2017. (Citado 2 vezes nas páginas 26 and 27.)
- BHATTI, M. A. Fundamental finite element analysis and applications: with mathematica and matlab computations. (*No Title*), 2005. (Citado na página 23.)
- CÂMARA, G.; VALERIANO, D. d. M.; SOARES, J. V. Metodologia para o cálculo da taxa anual de desmatamento na amazônia legal. *São José dos Campos: INPE*, 2006. (Citado 3 vezes nas páginas 1, 2, and 21.)
- CECATTO, J. R. O sol. *Curso de Introdução à Astronomia e Astrofísica*, v. 9, 2006. (Citado na página 11.)
- CECCON, D. Funções de ativação: definição, características, e quando usar cada uma. <<https://iaexpert.academy/2020/05/25/funcoes-de-ativacao-definicao-caracteristicas-e-quando-usar-cada-uma/>> [Acessado em 10 de novembro de 2023]. 2020. (Citado na página 28.)
- COUTINHO, L. M. O conceito de bioma. *Acta botanica brasílica*, SciELO Brasil, v. 20, p. 13–23, 2006. (Citado na página 7.)
- DALLABRIDA, E. C.; GONÇALVES, C. M.; PIOVESAN, T. R. Análise comparativa da eficiência energética em lâmpadas incandescentes, fluorescentes e led 1. *Salão do Conhecimento*, 2015. (Citado na página 11.)
- DALMOLIN, R. S. D. et al. Relação entre os constituintes do solo e seu comportamento espectral. *Ciência Rural*, SciELO Brasil, v. 35, p. 481–489, 2005. (Citado na página 14.)
- DIAS, A. A. C.; ANDRADE-NETO, A.; MILTAO, M. A atmosfera terrestre: Composição e estrutura. *Caderno de Física da UEFS*, v. 5, p. 21–40, 2007. (Citado na página 11.)
- FACELI, K. et al. Inteligência artificial: uma abordagem de aprendizado de máquina. 2021. (Citado na página 34.)

- FERREIRA, A. B.; FILHO, W. P. Avaliação da reflectância espectral de corpos d'água em santa maria-rs por meio de espectrorradiometria de campo. *Geoambiente On-line*, n. 13, p. 01–14, 2009. (Citado na página 15.)
- FONTAL, B.; SUÁREZ, T.; REYES, M. El espectro electromagnético y sus aplicaciones. *Escuela de la Ingeniería*, v. 1, p. 24, 2005. (Citado na página 10.)
- GADE, R.; MOESLUND, T. B. Thermal cameras and applications: a survey. *Machine vision and applications*, Springer, v. 25, p. 245–262, 2014. (Citado na página 11.)
- GOMIDE, F. A. *Redes neurais artificiais para engenharia e ciências aplicadas: curso prático*. [S.l.]: SciELO Brasil, 2012. (Citado na página 30.)
- GONÇALVES, W. G. et al. Classificação de estratos florestais utilizando redes neurais artificiais e dados de sensoriamento remoto. *Revista Ambiente & Água*, SciELO Brasil, v. 11, p. 612–624, 2016. (Citado na página 2.)
- GOOGLE. Amazônia. <<https://www.google.com/maps/@-4.5638566,-61.8162827,1721902m/data=!3m1!1e3?entry=ttu>> [Acessado em 10 de novembro de 2023]. 2023. (Citado na página 38.)
- GOOGLE. Ifba campus vitória da conquista. <<https://www.google.com/maps/@-14.8411793,-40.8765575,18.75z?entry=ttu>> [Acessado em 10 de novembro de 2023]. 2023. (Citado 2 vezes nas páginas 17 and 38.)
- GRIESINGER, D. Amazônia: garimpo ilegal em terras indígenas subiu 1.21735 anos. <<https://agenciabrasil.ebc.com.br/geral/noticia/2023-02/amazonia-garimpo-ilegal-em-terras-indigenas-subiu-1217-em-35-anos>> [Acessado em 23 de outubro de 2023]. 2023. (Citado na página 8.)
- HALLIDAY ROBERT RESNICK, J. W. D. *Óptica e Física Moderna*. [S.l.]: LTC — Livros Técnicos e Científicos Editora Ltda, 2016. (Citado 2 vezes nas páginas 12 and 13.)
- HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2001. (Citado 2 vezes nas páginas 28 and 29.)
- HOMMA, A. K. O.; HOMMA, A. K. O. et al. História da agricultura na amazônia: da era pré-colombiana ao terceiro milênio. Brasília, DF: Embrapa Informação Tecnológica, 2003., 2003. (Citado na página 8.)
- INPE. Câmeras Imageadoras CBERS 04A. <<http://www.cbbers.inpe.br/sobre/cameras/cbbers04a.php>> [Acessado em 03 de setembro de 2023]. 2019. (Citado 2 vezes nas páginas 39 and 40.)
- INPE. Catálogo de Imagens. <<http://www.dgi.inpe.br/catalogo/explore>> [Acessado em 09 de novembro de 2023]. 2023. (Citado na página 24.)
- INPE. Projeto de monitoramento do desmatamento na amazônia legal por satélite (prodes). <http://terrabrasilis.dpi.inpe.br/app/dashboard/deforestation/biomes/legal_amazon/rates> [Acessado em 09 de novembro de 2023]. 2023. (Citado na página 8.)

INPE. Sistema de detecção de desmatamentos em tempo real (deter). <<http://terrabrasilis.dpi.inpe.br/app/dashboard/alerts/legal/amazon/aggregated/>> [Acessado em 09 de novembro de 2023]. 2023. (Citado na página 8.)

ISPEN. Os povos da floresta. <<https://ispen.org.br/biomas/amazonia/povos-e-comunidades-tradicionais-da-amazonia/>> [Acessado em 06 de setembro de 2023]. 2023. (Citado 2 vezes nas páginas 5 and 7.)

JR, W. H. H.; BUCK, J. A. *Eletromagnetismo*. [S.l.]: Bookman Editora, 2013. (Citado na página 9.)

KOVÁCS, Z. L. *Redes neurais artificiais*. [S.l.]: Editora Livraria da Física, 2002. (Citado na página 25.)

LAGE, E. A radiação térmica. *Revista de Ciência Elementar*, Casa das Ciências, v. 8, n. 3, 2020. (Citado na página 11.)

LECUN, Y. et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, IEEE, v. 86, n. 11, p. 2278–2324, 1998. (Citado na página 31.)

MACÊDO, C. C. d. et al. Análise do desempenho térmico e luminoso de sistemas de iluminação natural que utilizam a luz direta do sol. Florianópolis, SC, 2002. (Citado na página 13.)

MENESES, P. R.; ALMEIDA, T. d. Introdução ao processamento de imagens de sensoriamento remoto. *Universidade de Brasília, Brasília*, 2012. (Citado 2 vezes nas páginas 16 and 17.)

MOREIRA, H. M. A importância da Amazônia na definição da posição brasileira no regime internacional de mudanças climáticas. *Programa de Pós-Graduação em Relações Internacionais-San Tiago Dantas. UNESOP, UNICAMP, PUC-SP. São Paulo*, 21p, 2009. (Citado na página 5.)

MORETO, R. F. et al. Potencial das geotecnologias para monitoramento do impacto da colonização na floresta nativa na microbacia do rio enganado, Amazônia ocidental, Brasil. *RECIMA21-Revista Científica Multidisciplinar-ISSN 2675-6218*, v. 2, n. 7, p. e27588–e27588, 2021. (Citado na página 1.)

NOBRE, C. A.; SAMPAIO, G.; SALAZAR, L. Mudanças climáticas e Amazônia. *Ciência e Cultura*, Sociedade Brasileira para o Progresso da Ciência, v. 59, n. 3, p. 22–27, 2007. (Citado na página 7.)

OLIVEIRA, J. P.; COSTA, M. G.; FILHO, C. F. C. Detecção de áreas desmatadas utilizando redes neurais artificiais associados a métodos para melhoria da generalização. *XIII Encontro Anual de Computação*, 2017. (Citado na página 2.)

PINHEIRO, M. D. M. et al. Perceptron multicamadas: uma ferramenta de aprendizado supervisionado. Niterói, 2021. (Citado na página 2.)

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. *Sensoriamento remoto da vegetação*. [S.l.]: Oficina de textos, 2015. (Citado na página 15.)

- POPESCU, M.-C. et al. Multilayer perceptron and neural networks. *WSEAS Transactions on Circuits and Systems*, World Scientific and Engineering Academy and Society (WSEAS) Stevens Point . . . , v. 8, n. 7, p. 579–588, 2009. (Citado na página 26.)
- QUARTAROLI, C. F.; VICENTE, L. E.; ARAÚJO, L. S. de. Sensoriamento remoto. *Embrapa Monitoramento por Satélite-Capítulo em livro técnico-científico (ALICE)*, 2014. (Citado na página 16.)
- QUEIROZ, J. E. R. de; GOMES, H. M. Introdução ao processamento digital de imagens. *Rita*, v. 13, n. 2, p. 11–42, 2006. (Citado na página 2.)
- REITZ, J.; MILFORD, F.; CHRISTY, R. *Fundamentos da Teoria Eletromagnética. 3ª edição*. [S.l.]: Editora Campus Ltda, 1988. 494–495 p. (Citado na página 10.)
- RODRIGUES, L. de S. Abordagens multimodais com fusão de dados em aprendizado profundo. Fundação Universidade Federal de Mato Grosso do Sul, 2023. (Citado 3 vezes nas páginas 3, 33, and 34.)
- ROSA, J. Ondas eletromagnéticas. <<https://www.educamaisbrasil.com.br/enem/fisica/ondas-eletromagneticas>> [Acessado em 09 de novembro de 2023]. 2019. (Citado na página 10.)
- SHIMABUKURO, Y. E.; DUTRA, A. C.; ARAI, E. Modelo linear de mistura espectral: Conceitos teóricos, algoritmos e aplicações em estudos na amazônia legal. *Revista Brasileira de Cartografia*, v. 72, n. Esp., p. 1140–1169, 2020. (Citado 4 vezes nas páginas 2, 21, 23, and 24.)
- SHIMABUKURO, Y. E.; PONZONI, F. J. *Mistura Espectral: modelo linear e aplicações*. [S.l.]: Oficina de Textos, 2017. (Citado na página 2.)
- SIEGMUND, A.; MENZ, G. Fernes nah gebracht–satelliten-und luftbildeinsatz zur analyse von umweltveränderungen im geographieunterricht. *Geographie und Schule*, v. 154, n. 4, p. 2–10, 2005. (Citado na página 15.)
- SOARES, P. L. B.; SILVA, J. P. da. Aplicação de redes neurais artificiais em conjunto com o método vetorial da propagação de feixes na análise de um acoplador direcional baseado em fibra ótica. *Revista Brasileira de Computação Aplicada*, v. 3, n. 2, p. 58–72, 2011. (Citado na página 27.)
- THOMSON, A. Biodiversity and the amazon rainforest. <<https://www.greenpeace.org/usa/biodiversity-and-the-amazon-rainforest/>> [Acessado em 06 de setembro de 2023]. 2020. (Citado na página 7.)
- TODT, V. et al. Identificação de áreas desflorestadas na amazônia através de uma rede neural artificial utilizando imagens fração derivadas dos dados do ir-mss/cbers. *XI Simpósio Brasileiro de Sensoriamento Remoto*, INPE Belo Horizonte, MG, Brazil, p. 2697–2704, 2003. (Citado na página 2.)
- VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: SN. *Proceedings of*

the xxix conference on graphics, patterns and images. [S.l.], 2016. v. 1, n. 4. (Citado na página 32.)

VIEIRA, I. C. G.; SILVA, J. M. C. d.; TOLEDO, P. M. d. Estratégias para evitar a perda de biodiversidade na amazônia. *Estudos Avançados*, SciELO Brasil, v. 19, p. 153–164, 2005. (Citado 2 vezes nas páginas 5 and 7.)

VILLATE, J. E. Física 2. eletricidade e magnetismo. 2012. (Citado na página 11.)

WU, J. Introduction to convolutional neural networks. *National Key Lab for Novel Software Technology. Nanjing University. China*, v. 5, n. 23, p. 495, 2017. (Citado na página 2.)

ZANOTTA, D. C.; FERREIRA, M. P.; ZORTEA, M. *Processamento de imagens de satélite*. [S.l.]: Oficina de Textos, 2019. (Citado 9 vezes nas páginas 2, 9, 12, 14, 15, 16, 18, 19, and 21.)

ZOIA, M. G. Restricted least squares revisited. *Journal of Statistics and Management Systems*, Taylor & Francis, v. 6, n. 1, p. 95–100, 2003. (Citado na página 22.)

APÊNDICE A

Códigos em Python

A.1 Pré-processamento das imagens

Para realizar o pré-processamento das imagens, inicialmente, um arquivo foi criado no computador contendo duas pastas correspondentes às classes das imagens. Em seguida, essas imagens foram redimensionadas no código e as armazenadas em uma variável chamada "data". Além disso, outra variável foi criada chamada "label" para armazenar as classes correspondentes a cada imagem na forma de strings.

Posteriormente, a biblioteca `sklearnprocessing` foi utilizada para processar os valores contidos na lista "label" e convertê-los em números inteiros, uma vez que temos duas classes, "0" ou "1". Por fim, os dados foram embaralhados e separados em duas partes: uma para o treinamento da rede neural e outra para a validação da rede.

Código A.1 – *Pré-processamento das imagens*

```
1
2 import cv2
3 import os
4 import numpy as np
5
6 directory = "caminho//do//arquivo"
7
8 categories = ['desmatamento', 'naodesmatamento']
```

```
9
10 data = []
11 label = []
12 im_size_l = 637
13 im_size_h = 529
14
15 for category in categories:
16     folder = os.path.join(directory, category)
17     for img in os.listdir(folder):
18         img_path = cv2.imread(os.path.join(
19             folder, img))
20         img_path = cv2.resize(img_path, (
21             im_size_l, im_size_h))
22         img_path = img_path.astype('float32') /
23             255.0
24         data.append(img_path)
25         label.append(category)
26
27 images = np.array(data)
28
29 from sklearn.preprocessing import LabelEncoder,
30     OneHotEncoder
31
32 y_labelencoder = LabelEncoder()
33 label = y_labelencoder.fit_transform(label)
34
35 from sklearn.utils import shuffle
36 from sklearn.model_selection import
37     train_test_split
38
39 images, label = shuffle(images, label, random_state
40     =1)
41
42 train_x, test_x, train_y, test_y =
43     train_test_split(images, label, test_size=
44     porcentagem_das_imagens_para_testes,
45     random_state=415)
```


A.2 Treinamento da arquitetura CNN

O treinamento da rede neural CNN, tanto para as imagens renderizadas quanto para as imagens compostas pelas frações das componentes, foi conduzido através do código abaixo, utilizando a biblioteca Keras. Inicialmente, foram incorporadas duas camadas convolucionais, acompanhadas por uma camada de pooling. Em seguida, foram acrescentadas duas camadas densas, uma camada oculta e outra camada de saída. Por fim, a rede foi compilada, estabelecendo parâmetros como a função de perda e o otimizador, sendo então treinada e salva no sistema.

Código A.2 – *Treinamento da arquitetura CNN*

```
1
2 import keras
3 from keras.models import Sequential
4 from keras.layers import Conv2D, MaxPooling2D,
   Flatten, Dense
5
6 model = Sequential()
7
8 model.add(Conv2D(64, (3,3), activation='relu'))
9 model.add(MaxPooling2D((2,2)))
10
11 model.add(Conv2D(64, (3,3), activation='relu'))
12 model.add(MaxPooling2D((2,2)))
13
14 model.add(Flatten())
15
16 model.add(Dense(128, input_shape=(529, 637, 3),
   activation='relu'))
17
18 model.add(Dense(2, activation='softmax'))
19
20 #taxa de aprendizado
21 learning_rate = 0.0001
22
23 # otimizador
24 optimizer = keras.optimizers.Adam(learning_rate
```

```
    =learning_rate)
25
26 model.compile(optimizer=optimizer, loss='
    sparse_categorical_crossentropy', metrics=['
    accuracy'])
27
28 model.fit(train_x, train_y, epochs= 15)
29
30 # Salve a arquitetura do modelo aqui
```

A.3 Treinamento das imagens coloridas - MLP

Para a arquitetura MLP, aplicada tanto às imagens renderizadas quanto às imagens compostas pelas frações das componentes, foi utilizada a biblioteca Keras. Inicialmente, a estrutura da rede foi definida, especificando a camada de entrada, seguida por duas camadas densas, uma correspondente à camada oculta e outra à camada de saída. Posteriormente, a rede foi compilada, configurando os parâmetros cruciais, como a função de perda e o otimizador, seguindo assim ao treinamento e salvamento no sistema.

Código A.3 – Treinamento da arquitetura MLP

```
1
2 import keras
3 import tensorflow as tf
4
5 model = keras.Sequential([
6     keras.layers.Flatten(input_shape
7     =(529,637,3)),
8     keras.layers.Dense(512, activation=tf.nn.
9     relu),
10    keras.layers.Dense(2, activation=tf.nn.
11    softmax)
12 ])
13
14 # Defina a taxa de aprendizado desejada
```

```
12 learning_rate = 0.00001
13
14 # Crie o otimizador com a taxa de aprendizado
15 optimizer = keras.optimizers.Adam(learning_rate
    =learning_rate)
16
17 model.compile(optimizer=optimizer, loss='
    sparse_categorical_crossentropy', metrics=['
    accuracy'])
18
19 model.fit(train_x, train_y, epochs=30)
20
21 # Salve a arquitetura aqui
```

A.4 Treinamento da Fusão de Informações

Para o treinamento da fusão de dados, inicialmente foi necessário remover a última camada de cada arquitetura. Em seguida, as camadas que restaram foram congeladas para não serem treinadas novamente. As camadas finais de cada modelo foram concatenadas. Por fim, foi adicionada uma camada densa com dois neurônios para a classificação. Assim, a rede foi compilada, treinada e salva.

Código A.4 – *Treinamento da Fusão de dados*

```
1
2 import tensorflow as tf
3 from tensorflow.keras.models import Model
4 from tensorflow.keras.layers import Input,
    Dense, concatenate
5 import keras
6
7 # Carregue a Arquitetura 01 para a fusão de
    dados aqui
8
9 # Remova a última camada do model1
10 model1 = Model(inputs=model1.input, outputs=
```

```
    model1.layers[-2].output)
11
12 # Congele as camadas do model1
13 for layer in model1.layers:
14     layer.trainable = False
15
16 # Carregue a arquitetura 02 para a fusão de
    dados aqui
17
18 # Remova a última camada do model2
19 model2 = Model(inputs=model2.input, outputs=
    model2.layers[-2].output)
20
21 # Congele as camadas do model1
22 for layer in model2.layers:
23     layer.trainable = False
24
25 # Mude o nome da camada de entrada do modelo 2
26 input_layer_model2 = Input(shape=model2.
    input_shape[1:], name='input_model2')
27
28 output2 = model2(input_layer_model2)
29
30 # Concatene as saídas de cada modelo
31 merged = concatenate([model1.output, output2])
32
33 final_output = Dense(2, activation='softmax',
    name='output')(merged)
34
35 new_model = Model(inputs=[model1.input,
    input_layer_model2], outputs=final_output)
36
37 # Taxa de aprendizado
38 learning_rate = 0.0005
39
40 # Otimizador com a taxa de aprendizado
41 optimizer = keras.optimizers.Adam(learning_rate
```

```
    =learning_rate)
42
43 # Compile o modelo
44 new_model.compile(optimizer=optimizer, loss='
    categorical_crossentropy', metrics=['
    accuracy'])
45
46 new_model.fit([primeiros_valores,
    segundo_valores], train_y_encoded, epochs=30,
    batch_size = 16)
47
48 # Salve a arquitetura do modelo aqui
```

A.5 Código para validação utilizando a curva ROC

Para a validação utilizando a curva ROC, a biblioteca "sklearn.metrics" foi empregada. Inicialmente, as probabilidades dos dados carregados foram compiladas. A partir dessas probabilidades e da lista das classes verdadeiras, as taxas de verdadeiros positivos e falsos positivos foram calculadas. Com esses resultados, a curva ROC foi representada em um gráfico utilizando a biblioteca "matplotlib".

Código A.5 – Validação da rede neural utilizando a curva ROC

```
1
2 from sklearn.metrics import roc_curve,
    roc_auc_score
3 import matplotlib.pyplot as plt
4
5 # Carregue o modelo e os dados aqui
6
7 # Calcular as probabilidades previstas pelo
    modelo
8 predicted_probabilities01 = loaded_model.
    predict(data)
9
10 # Calcular a curva ROC
```

```
11 fpr, tpr, thresholds = roc_curve(label,
    predicted_probabilities[:, 1])
12
13 # Calcular a área sob a curva ROC (AUC)
14 roc_auc = roc_auc_score(label,
    predicted_probabilities[:, 1])
15
16 # Plote a curva ROC
17 plt.figure()
18 plt.plot(fpr01, tpr01, color='darkorange', lw
    =2, label='Curva ROC - MLP (área = {:.6f})'.
    format(roc_auc01))
19 plt.plot(fpr02, tpr02, color='blue', lw=2, label
    ='Curva ROC - CNN (área = {:.6f})'.format(
    roc_auc02))
20 plt.plot([0, 1], [0, 1], color='navy', lw=2,
    linestyle='--')
21 plt.xlim([0.0, 1.0])
22 plt.ylim([0.0, 1.05])
23 plt.xlabel('Taxa de Falso Positivo')
24 plt.ylabel('Taxa de Verdadeiro Positivo')
25 plt.title('Curva ROC')
26 plt.legend(loc="lower right")
27 plt.grid(True)
28 plt.show()
```

A.6 Código para validação utilizando o histograma de separação

O histograma de separabilidade foi construído utilizando a biblioteca "matplotlib". Com as probabilidades compiladas, as classes foram organizadas de acordo com as respostas probabilísticas apresentadas pela rede neural e plotadas no gráfico.

Código A.6 – Validação da rede neural utilizando o histograma de separabilidade

```
1
2 import numpy as np
3 import matplotlib.pyplot as plt
4 import tensorflow as tf
5
6 # Carregue a arquitetura neural aqui juntamente
   com os dados salvos
7
8 # Obtenha as previsões da rede neural
9 predictions = loaded_model.predict(data)
10
11 # Separe as saídas das duas classes
12 class_0_outputs = predictions[:, 1]
13
14 a = 0
15 classe01 = []
16 classe00 = []
17
18 for i in label:
19     if i == 0:
20         classe00.append(class_0_outputs[a])
21     else:
22         classe01.append(class_0_outputs[a])
23     a=a+1
24
25 classe00 = np.array(classe00)
26 classe01 = np.array(classe01)
27
28 # Crie um histograma de separabilidade para
   ambas as classes
29 limites_bins = [i * 0.025 for i in range(0, 41)
30 ]
31 plt.figure(figsize=(10, 5))
32 plt.hist(classe00, bins=limites_bins, edgecolor
   ='black', alpha=0.50, color='blue', label='
   Classe Desmatamento')
```

```
32 plt.hist(classe01, bins=limites_bins, edgecolor
           ='black', alpha=0.50, color='green', label='
           Classe Não Desmatamento')
33 plt.yscale('log')
34 plt.xlabel('Saídas da Classe')
35 plt.ylabel('Frequência')
36 plt.legend()
37 plt.title('Histograma de Separabilidade')
38 plt.axvline(x=0.5, color='k', linestyle='--',
              label='Limiar de decisão')
39 plt.legend()
40 plt.grid(True, which='both', alpha = 0.4)
41 plt.show()
```