

UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA FLORESTAL  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

**ESTIMATIVA DA BIOMASSA NA TRANSIÇÃO AMAZÔNIA/CERRADO UTILIZANDO  
SENSORIAMENTO REMOTO E REDES NEURAS ARTIFICIAIS**

Luana Duarte de Faria

Orientador: Prof. Dr. Eraldo Aparecido Trondoli Matricardi

**Brasília - DF  
Abril de 2023**

UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA FLORESTAL  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

**LUANA DUARTE DE FARIA**

ESTIMATIVA DA BIOMASSA NA ÁREA DE TRANSIÇÃO AMAZÔNIA/CERRADO,  
UTILIZANDO DADOS DE SENSORIAMENTO REMOTO E REDES NEURAIAS  
ARTIFICIAIS

Dissertação de mestrado submetida ao Programa de Pós-Graduação em Ciências Florestais do Departamento de Engenharia Florestal da Universidade de Brasília como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências Florestais.

ORIENTADOR: Dr. ERALDO APARECIDO TRONDOLI MATRICARDI

**DISSERTAÇÃO DE MESTRADO EM CIÊNCIAS FLORESTAIS**

**PUBLICAÇÃO: \_\_\_\_/2023**

**BRASÍLIA/ DF, 28 ABRIL DE 2023**

ESTIMATIVA DA BIOMASSA NA ÁREA DE TRANSIÇÃO AMAZÔNIA/CERRADO,  
UTILIZANDO DADOS DE SENSORIAMENTO REMOTO E REDES NEURAIAS  
ARTIFICIAIS

LUANA DUARTE DE FARIA

Dissertação de mestrado submetida ao programa de pós-graduação em ciências florestais do Departamento de Engenharia Florestal da Faculdade de Tecnologia da Universidade de Brasília como parte dos requisitos necessários para a obtenção do grau de mestre.

APROVADA POR:

Prof. Dr. Eraldo Aparecido Trondoli Matricardi  
(Departamento de Engenharia Florestal, UnB); (Orientador)

Prof. Dr. Eder P. Miguel  
(Departamento de Engenharia Florestal, UnB)

Profa. Dra. Beatriz Schwantes Marimon  
(Examinadora externa – UNEMAT- Nova Xavantina – MT)

Prof. Dr. Ben Hur Marimon Jr.  
(Examinador externo – UNEMAT- Nova Xavantina – MT)- Suplente.

Brasília-DF

8 de maio de 2023

## FICHA CATALOGRÁFICA

Fe Faria, Luana Duarte de  
Estimativa da biomassa na área de transição  
Amazônia/Cerrado, utilizando dados de sensoriamento remoto e  
redes neurais artificiais / Luana Duarte de Faria;  
orientador Eraldo Aparecido Trondoli Matricardi. --  
Brasília, 2023.  
70 p.

Tese(Mestrado em Ciências Florestais) -- Universidade de  
Brasília, 2023.

1. Estoque de biomassa. 2. Ecótono. 3. Índices de  
vegetação. 4. Redes neurais artificiais. 5. Sensoriamento  
remoto. I. Matricardi, Eraldo Aparecido Trondoli, orient.  
II. Título.

## REFERÊNCIA BIBLIOGRÁFICA

FARIA, L.D. 2023. **Estimativa da biomassa na área de transição Amazônia/Cerrado, utilizando dados de sensoriamento remoto e redes neurais artificiais.** Dissertação de Mestrado em Ciências Florestais, Publicação PPGEFL.DM-Agosto/2023. Departamento de Engenharia Florestal, Universidade de Brasília, Brasília, DF, **70p.**

## CESSÃO DE DIREITOS

**AUTOR:** Luana Duarte de Faria

**TÍTULO:** Estimativa da biomassa na área de transição Amazônia/Cerrado, utilizando dados de sensoriamento remoto e redes neurais artificiais.

**GRAU:** Mestre

**ANO:** 2023

É concedido à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem autorização por escrito do autor.

---

Luana Duarte de Faria

luanaduarte005@gmail.com

## **Dedico**

Aos meus pais, Alessandra e Cristiano, a minha companheira, Nathalia  
e minha vizinha  
Horizontalina. Obrigada por sempre  
acreditarem em mim.

## **AGRADECIMENTOS**

Gostaria de agradecer a todos que contribuíram para a realização desta tese de mestrado. Em primeiro lugar, quero expressar minha sincera gratidão ao meu orientador, Eraldo, por sua orientação valiosa e incentivo contínuo durante esta pesquisa. Seu compromisso com minha formação acadêmica e profissional foi fundamental para meu crescimento e desenvolvimento.

Também gostaria de agradecer ao professor Eder pelo suporte prestado durante a pesquisa, pelos ensinamentos preciosos transmitidos e sua disponibilidade e compreensão ao longo deste projeto, que foram fundamentais para seu sucesso.

Sou grato(a) especialmente aos professores e funcionários da universidade, que forneceram os recursos necessários para que eu pudesse concluir esta tese, e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de mestrado.

Por fim, gostaria de expressar minha gratidão a Nathalia, bem como a minha família e amigos, pelo amor e suporte inabaláveis ao longo deste processo, pela paciência e compreensão enquanto me dediquei intensamente a esta pesquisa foram fundamentais para o seu sucesso. Sem o apoio de todos vocês, este trabalho não teria sido possível.

## RESUMO

A área de transição entre os biomas Cerrado e Amazônia tem sido objeto de forte pressão antrópica decorrente, sobretudo, da expansão da agricultura de *commodities* e da pecuária extensiva. Nesta região, a legislação ambiental é considerada menos restritiva em razão da predominância de vegetação do Cerrado, apesar da presença de florestas de transição, que deveriam ser objeto de medidas mais restritivas de proteção aos recursos naturais remanescentes. Dentre os principais impactos ambientais decorrentes da expansão agropecuária nesta região, destacam-se a perda de habitats, a redução da biodiversidade e dos estoques de biomassa, com a consequente emissão de CO<sub>2</sub> para a atmosfera. A presente pesquisa teve como objetivo desenvolver modelos baseados em redes neurais, dados de campo e de sensoriamento remoto, para estimar a biomassa nas áreas de vegetação remanescentes localizadas em uma faixa na região de transição entre os biomas Amazônia-Cerrado, no estado do Mato Grosso. Dados de campo foram obtidos a partir de parcelas permanentes coletadas pelo Laboratório de Ecologia Vegetal da Universidade do Estado de Mato Grosso e índices de vegetação foram calculados a partir das imagens do satélite Sentinel-2. Redes neurais foram treinadas para estimar o estoque de biomassa da área utilizando como referências dados de biomassa coletados em parcelas de campo na área de estudo. A escolha da rede neural mais apropriada foi feita mediante a aplicação de critérios de análise gráfica, erro médio de estimativa e coeficiente de correlação. A validação da rede selecionada foi feita por meio da análise dos resultados do teste *t* de Student e da diferença agregada. Os resultados deste estudo mostraram que as redes neurais artificiais (RNAs), em combinação com índices de vegetação (AFRI, EVI e GNDVI), foram capazes de estimar com precisão a biomassa florestal acima do solo (BAS) em uma área de transição. Os resultados deste estudo são promissores para apoiar a avaliação dos estoques de biomassa e do carbono estocado na área de estudo, podendo apoiar a priorização de áreas para a conservação ambiental e parametrização de pagamento por serviços ambientais decorrentes da manutenção da vegetação nativa na área investigada.

**Palavras-chave:** Estoque de biomassa, área de transição, índices de vegetação, redes neurais artificiais, sensoriamento remoto.

## ABSTRACT

The transition area between the Cerrado and Amazon biomes has experienced significant anthropic pressure, primarily due to the expansion of commodity agriculture and extensive livestock farming. Despite the presence of transition forests, which should be afforded stricter protection measures to preserve the remaining natural resources, the environmental legislation in this region is considered less restrictive due to the prevalence of Cerrado vegetation. The expansion of agriculture and cattle ranching in this region has led to several notable environmental impacts, including habitat loss, reduced biodiversity, and diminished biomass stocks, resulting in the emission of CO<sub>2</sub> into the atmosphere. The objective of this research was to develop models using neural networks, field data, and remote sensing to estimate biomass in the remaining vegetation areas situated within a transitional strip between the Amazon-Cerrado biomes in the state of Mato Grosso. Field data were collected from permanent plots by the Plant Ecology Laboratory at Mato Grosso State University, while vegetation indices were derived from Sentinel-2 satellite images. Neural networks were trained to estimate the biomass stock of the area, utilizing field plot biomass data as references. The selection of the most suitable neural network was based on graphical analysis, mean error of estimation, and correlation coefficient criteria. The chosen network was validated through Student's t-test and aggregate difference test analyses. The study's findings indicated that artificial neural networks (ANNs) in conjunction with vegetation indices (AFRI, EVI, and GNDVI) could accurately estimate aboveground forest biomass (BAS) in the transition area. These results hold promise for facilitating assessments of biomass stocks and carbon storage in the study area. Furthermore, they can provide valuable support for prioritizing areas for environmental conservation and establishing parameters for payment for environmental services related to the maintenance of native vegetation within this study region.

**Keywords:** Biomass stock, transition area, vegetation indices, artificial neural networks, remote sensing.



## SUMÁRIO

RESUMO .....	9
ABSTRACT .....	10
SUMÁRIO .....	11
LISTA DE TABELAS .....	13
LISTA DE FIGURAS .....	14
LISTA DE ANEXOS .....	15
1. INTRODUÇÃO .....	16
2. OBJETIVOS.....	18
2.1 Objetivo geral .....	18
2.2 Objetivos específicos.....	19
3. REFERENCIAL TEÓRICO.....	19
3.1. Biomassa Florestal .....	19
3.2. Sensoriamento Remoto para estimar a biomassa .....	20
3.3 Índices de Vegetação.....	21
3.3.1 Normalized Difference Vegetation Index (NDVI).....	22
3.3.2 Enhanced Vegetation Index (EVI) .....	22
3.3.3 Green Normalized Difference Index (GNDVI).....	23
3.3.4 Aerosol Free Vegetation Index (AFRI).....	23
3.3.5 Modified Soil Adjusted Vegetation Index (MSAVI).....	24
3.3.6 Normalized Difference Red Edge Index (NDRE).....	24
3.3.7 Soil-Adjusted Vegetation Index (SAVI) .....	25
3.3.8 Modified Soil Adjusted Vegetation Index aerosol resistant (MSAVIaf) .....	25
3.4. Redes neurais artificiais.....	26
3.5 Plataforma ForestPlots .....	27
4. MATERIAL E MÉTODOS.....	28

4.1	Área de estudo .....	28
4.1.1	Localização.....	28
4.1.2	Características .....	30
4.1.3	Classificação do uso e cobertura do solo.....	32
4.2	Base de dados .....	34
4.2.1	Variáveis dendrométricas do inventário.....	34
4.2.2	Biomassa florestal .....	35
4.3.	Processamento das imagens Sentinel-2.....	36
4.4	Modelagem das redes neurais artificiais (RNAs).....	38
5.	RESULTADOS .....	41
5.2.	Análise de Correlação da Biomassa e Índices de vegetação (IV) .....	43
5.3.	Modelagem da biomassa .....	46
5.3.1.	Treinamento das redes.....	46
5.4.	Análise estatística .....	48
5.5.	Análise da distribuição espacial da biomassa.....	49
6.	DISCUSSÃO.....	50
6.1	Biomassa florestal .....	50
6.2	Seleção das variáveis independentes - Índices de vegetação .....	51
6.3	Treinamento das redes neurais .....	53
7.	CONCLUSÕES.....	55
8.	REFERÊNCIAS BIBLIOGRÁFICAS .....	57
9.	ANEXO.....	69

## LISTA DE TABELAS

Tabela 1- Informações sobre os tipos de uso e cobertura da terra, indicando a área em hectares e a porcentagem.....	34
Tabela 2- Cenas do satélite Sentinel-2 adquiridas através do Google Earth Engine (GEE) usadas para o processamento dos índices de vegetação.....	38
Tabela 3- Bandas do espectro visível que foram aplicadas na confecção dos índices de vegetação da área de estudo.....	38
Tabela 4- Variáveis dendrométricas calculadas a partir de inventário florestal para as áreas das parcelas LABEV- UNEMAT. DAP = diâmetro à altura do peito (cm), Ht = altura total (m), DM = densidade média da madeira (g.cm <sup>3</sup> ), BAS.....	42
Tabela 5- Média das variáveis independentes na área de estudo. AFRI = Aerosol Free Vegetation Index; EVI = Enhanced Vegetation Index; Gndvi = Green Normalized Difference Index; MSAVIaf = Modified Soil Adjusted Vegetation Index aerosol resistant; MSAVI = Modified Soil Adjusted Vegetation Index; NDVI = índice de vegetação da diferença normalizada; NDRE = índice de vegetação da diferença normalizada com a banda red edge; SAVI = Soil-Adjusted Vegetation Index.....	43
Tabela 6- A matriz de correlação de Spearman usada para analisar a relação entre a biomassa acima do solo e os índices de vegetação da área de estudo.....	44
Tabela 7- Estatísticas de precisão das redes neurais artificiais selecionadas para predição da biomassa acima do solo para as parcelas LABEV-UNEMAT.....	47

## LISTA DE FIGURAS

Figura 1- Modelo de uma rede neural artificial. Fonte: Abraham (2006). Legenda: Input layer: camada de entrada, Hidden layer: camada oculta, Output layer: camada de saída... 26	26
Figura 2- Localização da área de estudo e das parcelas de inventário florestal estabelecidas pelo Laboratório de Ecologia Florestal da Universidade do Estado de Mato Grosso..... 29	29
Figura 3- Localização dos biomas Amazônia e Cerrado, Terras Indígenas e parcelas de inventário do Laboratório de Ecologia Vegetal (LBEV) da Universidade do Estado de Mato Grosso. .... 30	30
Figura 4- Mapa de vegetação para a área de estudo. Fonte: RAMBRASIL (2019)..... 31	31
Figura 5- Mapa do relevo da área de estudo. Fonte: IBGE (2019). .... 32	32
Figura 6- Uso e cobertura da Terra na área de estudo para o ano de 2019. Fonte: MAPBIOMAS (2023). .... 33	33
Figura 7-Distribuição das parcelas e seus transectos. .... 35	35
Figura 8- Mosaico de cenas do satélite Sentinel-2, composição R3G2B1, adquirida em 22/08/2019, 19/08/2019, 09/08/2019 e 07/08/2019, das parcelas de monitoramento do Laboratório de Ecologia Vegetal da UNEMAT, no estado do Mato Grosso..... 37	37
Figura 9- Índices de vegetação GNDV, EVI e AFRI derivados de imagem Sentinel-2, adquirida em 2019, para a área de estudo. .... 45	45
Figura 10-Valores observados e estimados (A) e distribuição de resíduos (B) para a RNA 1. .... 47	47
Figura 11- Arquitetura da RNA 1, selecionada para a predição da biomassa acima do solo para a área de estudo. .... 48	48
Figura 12- Distribuição espacial da biomassa florestal estimada para a área de transição Amazônia-Cerrado. As áreas mais escuras indicam maior biomassa acima do solo, enquanto as áreas mais claras indicam menor biomassa. .... 49	49

## **LISTA DE ANEXOS**

Anexo I. Valores de Biomassa estimados por inventario florestal da RAINFOR e índices de vegetação usados como variáveis preditoras.....	69
---	----

## 1. INTRODUÇÃO

Os ecossistemas naturais desempenham um papel fundamental na manutenção da saúde humana e ambiental (COSTANZA et al., 1997). No entanto, as variações naturais e as perturbações antrópicas podem tornar um ecossistema vulnerável e limitar sua capacidade de adaptação às espécies. Dentre os principais fatores que afetam a dinâmica dos ecossistemas, destacam-se o desmatamento, a perda de habitats, a degradação do solo, a contaminação da água, a pesca e a caça excessiva, a introdução de espécies exóticas e invasoras, além do aumento populacional humano (BEDDOE et al., 2009). Estima-se que existem mais de 4.800 milhões de hectares degradados no mundo (NASCIMENTO, 2011). Neste sentido, o grande desafio é restabelecer essas áreas a seus ecossistemas nativos, ou o mais próximo possível deles, para manter a integridade futura do planeta e garantir por mais tempo os seus serviços ecossistêmicos (ARAÚJO, 2022).

A mais recente publicação do Relatório Anual de Desmatamento no Brasil (RAD), produzido pelo projeto MapBiomas, indica uma redução de 16.557 km<sup>2</sup> de cobertura de vegetação nativa em todos os biomas brasileiros até 2022, resultando em um acréscimo de 20% comparado ao ano anterior. Isso indica uma tendência do aumento no desmatamento nos últimos três anos, ocasionando a perda de uma área equivalente ao estado do Rio de Janeiro em vegetação nativa (MAPBIOMAS, 2023). Existem 10 municípios localizados na região da Amazônia Legal que apresentaram as maiores taxas de perda de cobertura florestal, destacando-se no topo da lista os municípios de Altamira (PA), São Félix do Xingu (PA), Porto Velho (RO), Lábrea (AM) e Apuí (AM). Os dois últimos estão situados no Sul do Amazonas, que é a região que apresentou os maiores índices de desmatamento em terras públicas, incluindo Unidades de Conservação e Terras Indígenas (WWF, 2021).

O Brasil é um país extremamente rico na sua biodiversidade, estima-se que existem mais de 33 mil espécies de plantas, o que equivale a 26,5% de todas as espécies reconhecidas até o momento no planeta (LIMA, 2022). A redução dos incêndios florestais está ligada com a quantidade de biomassa em uma área florestal, pois o acúmulo do material combustível é o que contribui para o espalhamento do fogo (CUNHA, 1985). De acordo com os estudos de Ribeiro e Walter (2010), as áreas abertas com vegetação herbácea são mais suscetíveis a incêndios devido ao acúmulo de biomassa inflamável durante o período de seca. No entanto, a utilização da biomassa florestal como fonte de energia pode mitigar os riscos de incêndios florestais, representando uma prática sustentável recomendada no Brasil (MAGALHÃES, 2006). Assim, é possível adotar abordagens integradas que combinem prevenção de

incêndios com o uso adequado da biomassa florestal, visando à preservação e sustentabilidade dos ecossistemas florestais.

A região de transição entre os biomas Cerrado e Amazônia é caracterizada por um clima com alta sazonalidade e uma ampla variedade de tipos de vegetação. Esses tipos de vegetação variam desde áreas mais abertas, características das savanas, com alta incidência de radiação solar, até formações florestais com dossel mais fechado e alta umidade. É importante destacar que essa região possui uma grande importância ecológica e biológica, abrigando uma diversidade de espécies que são afetadas pelo desmatamento com o avanço da agricultura nas áreas desse ecótono (RATTER et al., 1973; MARIMON et al., 2006), resultando na redução do estoque de biomassa da vegetação lenhosa (BALCH et al., 2011), inclusive em decorrência de queimadas (NOGUEIRA et al., 2019). Os incêndios florestais são uma das principais fontes antropogênicas de emissão de gases de efeito estufa (GEE) no meio ambiente, incluindo o dióxido de carbono ( $\text{CO}_2$ ), o metano ( $\text{CH}_4$ ) e o óxido nitroso ( $\text{N}_2\text{O}$ ). Esses gases são conhecidos por serem os principais responsáveis pelo aquecimento global, um dos maiores desafios ambientais que a humanidade enfrenta atualmente (FEARNSIDE, 1995).

Nesse contexto, o sensoriamento remoto serve de ferramenta e fonte de informação para o monitoramento das alterações que ocorrem no uso e cobertura do solo, contribuindo com dados quantitativos das alterações que acontecem na vegetação, por efeito das atividades antrópicas que favorecem a degradação da estrutura do solo, seja em larga escala ou em uma escala local (HUETE; JUSTICE; LIU, 1994). O sensoriamento remoto tem sido amplamente utilizado em estudos dos biomas brasileiros (ASNER et al., 2005), pois possibilita uma análise temporal do ambiente e da cobertura da terra (FLORENZANO, 2002) e, no caso das mudanças do uso do solo, auxilia na detecção, quantificação e comportamento da vegetação ao longo dos meses (SILVA et al., 2019). As imagens de satélite são adquiridas através da captura dos níveis de refletância em uma banda espectral, o que viabiliza a análise da interação entre a energia eletromagnética e o objeto em questão, bem como o armazenamento dos dados em forma de atributos espaciais. Essas informações são geradas a partir da vibração das ondas na banda correspondente, resultando em uma representação visual que permite compreender as características físicas do objeto de estudo, observar sua relação com o ambiente e, em alguns casos, diferenciar as diversas classes de uso e cobertura do solo (LOURENÇO; LANDIM, 2004).

A partir de dados de sensoriamento remoto alguns índices de vegetação são obtidos a partir de equações que combinam os níveis de refletância das imagens em razão da vibração

da energia eletromagnética nas bandas do espectro, sendo assim, são criados modelos que auxiliam na tomada de decisão das análises que tem o propósito de preservação ambiental (AQUINO, 2016). Desde algum tempo, índices de vegetação têm sido empregados para investigar a vegetação de forma científica. Um bom exemplo disso é o estudo de Lima et al. (2013) no qual avalia o índice de cobertura vegetal pelo cálculo do Índice de Vegetação por Diferença Normalizada (IVDN), com o objetivo de analisar o vigor vegetativo das culturas e da vegetação natural da área analisada.

No presente estudo, desenvolvemos um modelo para estimar a biomassa acima do solo utilizando dados de campo, sensoriamento remoto e o treinamento de redes neurais artificiais (RNAs) numa área de transição Amazônia/Cerrado, do estado do Mato Grosso. Além do desmatamento, os incêndios florestais têm causado muitos danos ambientais nessa região de estudo. A frequência e duração dos incêndios nas fronteiras entre o Cerrado e a Amazônia, causam impactos na estrutura da vegetação florestal, aumentando o número de espécies herbáceas, as quais estão mais sujeitas ao estresse hídrico e contribuem com a recorrência e intensidade dos eventos de fogo (NOVO, 2005).

O modelo desenvolvido nesta pesquisa é promissor para ser utilizado na estimativa e monitoramento dos estoques de biomassa acima do solo e subsidiar a implementação de políticas de pagamento por serviços ecossistêmicos, representando um avanço tecnológico nas pesquisas de preservação e conservação ambiental em áreas de transição de biomas. Em uma concepção crítica, a conservação da biomassa nesta área de estudo, muito próxima da maior área indígena do Brasil, a Terra Indígena do Xingu, no estado do Mato Grosso, poderá influenciar a dimensão de existência e permanência das populações tradicionais em seus territórios (BERTIER; SILVA; NORA, 2020).

## **2. OBJETIVOS**

### **2.1 Objetivo geral**

Desenvolver modelos de Redes Neurais Artificiais para estimar a biomassa florestal acima do solo em um trecho da zona de transição Amazônia/Cerrado, na borda sul da Terra Indígena do Xingu, utilizando dados de campo e de sensoriamento remoto.



## **2.2 Objetivos específicos**

- Analisar a relação estatística entre dados de biomassa coletados em campo no contexto de inventários florestais realizados em campo e dados derivados de imagens espectrais do satélite Sentinel-2.
- Ajustar modelos em redes neurais para prever a biomassa florestal acima do solo, a partir das variáveis independentes (índices de vegetação derivados de imagens de satélite).
- Indicar o melhor modelo para estimar a biomassa acima do solo a partir de dados de sensoriamento remoto e modelos baseados em redes neurais artificiais para a região de transição Amazônia/Cerrado.

## **3. REFERENCIAL TEÓRICO**

### **3.1. Biomassa Florestal**

O conceito de biomassa florestal está relacionado à quantidade de massa orgânica presente em uma área vegetada ou em uma porção específica com indivíduos arbóreos da mesma espécie. A realização de estudos florestais voltados para a ciclagem de nutrientes, uso energético de recursos, avaliação dendrométrica do crescimento de espécies arbóreas, predição e avaliação de biomassa, entre outros, tem se tornado cada vez mais comum (SANQUETTA et al., 2014). Os estoques de carbono em florestas são subdivididos em biomassa acima e abaixo do solo. A biomassa acima do solo (BAS) engloba o caule, casca, galhos e folhas das espécies, sendo utilizada como variável para estimar os valores de carbono na predição dos modelos. No entanto, a modelagem da biomassa em florestas tropicais apresenta desafios adicionais devido à complexidade de sua estrutura florestal e à grande diversidade de espécies existentes (KRALICEK et al., 2017). A quantificação da biomassa acima do solo é frequentemente obtida por meio da análise de atributos estruturais em múltiplas escalas, incluindo a altura e o diâmetro das árvores em escala individual (CHAVE et al., 2014).

Em um incêndio florestal de causas naturais ou antrópicas, acontece a queima de material inflamável, no caso, a biomassa florestal, e isso contribui com o aumento da liberação de carbono no ar e afeta diretamente na emissão de gases de efeito estufa na atmosfera (ANDERSON et al., 2005). A capacidade de sequestro de carbono de uma floresta está diretamente relacionada ao seu volume por unidade de área. Assim, a estratégia mais

eficaz para aumentar o estoque de carbono consiste no desenvolvimento de árvores com maior diâmetro e longevidade. Essas árvores têm a capacidade de acumular maior quantidade de biomassa e persistir por mais tempo no ecossistema, o que contribui significativamente para um maior sequestro de carbono. Dessa forma, essa estratégia desempenha um papel fundamental na mitigação das mudanças climáticas (ZHANG, 2023). Assim, as florestas são consideradas importantes reservatórios de biomassa a nível mundial, devido ao seu papel crucial de estoque de carbono, sendo fundamentais para os ecossistemas terrestres, e tendo impacto significativo no ciclo global de carbono (PIETRZYKOWSK et al., 2021). Ao utilizarmos a biomassa florestal de maneira racional e sustentável na Amazônia, atribuiremos valor à floresta em pé e, como resultado, contribuiremos para sua preservação. (NUNES, 2022).

### **3.2. Sensoriamento Remoto para estimar a biomassa**

A avaliação da biomassa florestal acima do solo (BAS) requer abordagens eficientes em termos de custo operacional e alta precisão, a fim de possibilitar um monitoramento eficaz dos impactos das mudanças climáticas globais. Existem métodos diretos e indiretos para estimar a biomassa florestal. A medição tradicional em campo é precisa, porém demorada, trabalhosa e onerosa. Além disso, esse processo resulta na destruição de parte da biomassa, uma vez que é necessário cortar árvores para realizá-lo (BULUT, 2023). Os estudos sobre previsão de biomassa usam dados coletados em campo para ajustar modelos estatísticos ou de aprendizado de máquina. Esses modelos são usados para estimar a biomassa com base em informações coletadas por meio de sensoriamento remoto. A maioria dos estudos aponta para uma precisão satisfatória na estimativa da biomassa obtida por esta abordagem (FASSNACHT et al., 2014).

A utilização de dados obtidos por meio do sensoriamento remoto apresenta vantagens significativas em razão da capacidade de fornecer informações temporais com alta resolução, visão sistêmica dos dados e formato digital que possibilita a realização do processamento de forma eficiente em grande volume de dados (AHAMED et al., 2011). Dessa forma, é observado um aumento na tendência de utilizar dados coletados por sensores em diferentes períodos para produzir informações dos atributos das florestas, bem como para detectar alterações na cobertura florestal (NAIK; DALPONTE; BRUZZONE, 2021).

Zhao et al. (2009) buscaram desenvolver métodos para estimar a biomassa florestal, independentemente da escala, utilizando dados coletados com tecnologia LIDAR. Huimian

et al. (2023), conseguiram prever o Índice de Área Basal da Copa (AGC) de uma floresta urbana de Xangai usando dados de sensoriamento remoto Landsat 8 e Sentinel-2. Para realizar isso, utilizaram quatro métodos de aprendizado de máquina, como Regressão Vetorial de Suporte (SVR), Floresta Aleatória (RF), XGBoost e CatBoost. Os resultados mostraram que é possível prever de forma precisa o AGC e a distribuição espaço-temporal daquela floresta usando dados separados dos satélites Landsat 8 e Sentinel-2.

O monitoramento preciso da degradação florestal usando técnicas de sensoriamento remoto com sensores óticos, também é um grande desafio. No entanto, pesquisas têm mostrado que é possível utilizar a estrutura da vegetação, séries temporais de imagens de satélites óticos e algoritmos de aprendizado de máquina para estimar a biomassa acima do solo (BAS) em áreas degradadas (CITAR ESSES ESTUDOS AQUI..., pelo menos uns três...). Essas técnicas possibilitam a reconstrução da retrospectiva da dinâmica da degradação florestal, preenchendo as lacunas de informação e permitindo uma melhor compreensão da evolução das áreas afetadas (LIANG, 2023).

### **3.3 Índices de Vegetação**

O uso de imagens de satélites para a produção de índices tem sido cada vez mais comum para o acompanhamento das práticas e mudanças causadas pelo uso antrópico, em razão da agilidade de aquisição dessas informações, seja a análise feita em uma pequena ou em uma larga escala, facilitando obter dados de áreas de difícil acesso (MOREIRA, 2003). Sendo assim, é possível avaliar as mudanças que ocorrem no uso e cobertura do solo, quantificar e monitorar o estado da vegetação através dos índices de vegetação (LEIVAS, 2014).

Nas análises temporais, os índices de vegetação permitem a identificação de fenômenos e padrões sazonais a partir de imagens de sensores orbitais que facilitam no monitoramento de anomalias, mudanças climáticas e ambientais (KUPLICH, 2013). Esses índices espectrais têm auxiliado também nos estudos de avaliação da biomassa, uso da água, estresse hídrico, saúde das plantas e nas produtividades das safras (JACKSON; HUETE, 1991).

Os índices de vegetação são obtidos a partir de equações que fazem a combinação dos níveis de reflectância das imagens em razão da vibração de energia eletromagnética nas bandas do espectro, sendo assim são criados modelos que auxiliam na tomada de decisão das análises que tem o propósito de preservação ambiental (AQUINO, 2016). No entanto, há outros estudos que fazem o uso dos índices para as análises de áreas antrópicas no meio

urbano, na avaliação de vegetação sadia, na estimativa de área foliar, na predição da biomassa e da radiação fotossintética ativa (RODRIGUES et al, 2012). Um bom exemplo seria o estudo de Lima et al. (2013) que avaliaram o índice de cobertura vegetal pelo cálculo do Índice de Vegetação por Diferença Normalizada (IVDN) com o objetivo de analisar a atividade fotossintética de culturas e áreas florestais.

### 3.3.1 Normalized Difference Vegetation Index (NDVI)

O índice empregado no presente estudo é o NDVI, cuja fórmula é baseada na relação entre a diferença de reflectância entre as bandas do infravermelho próximo e a banda do visível, mais precisamente a banda do vermelho, com a soma da reflectância dessas duas bandas (JENSEN, 1996). A atividade fotossintética da vegetação é avaliada por esta equação e os valores podem variar de -1 a 1, ao contrário das superfícies de água ou nuvens, que possuem valores menores que 0 (BORATTO, 2013).

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad \text{Rouse et al. (1974)} \quad \text{Eq. 01}$$

Onde:

$\rho_{NIR}$  = reflectâncias na banda do infravermelho próximo;

$\rho_{RED}$  = reflectâncias na banda do vermelho

### 3.3.2 Enhanced Vegetation Index (EVI)

O uso do índice EVI, em alguns casos, apresenta vantagens em relação ao Índice de Vegetação da Diferença Normalizada (NDVI), que é um dos indicadores mais comuns utilizados em pesquisas com índices de vegetação, especialmente em relação à classificação dos tipos de cobertura vegetal e às estimativas da biomassa vegetal. Essa superioridade do EVI decorre de sua maior sensibilidade em análises de áreas florestais densas (YAN et al., 2015).

$$EVI = G * \frac{(\rho_{NIR} - \rho_{RED})}{\rho_{NIR} + (C1 * \rho_{RED} - C2 * \rho_{BLUE}) + L} (1+L) \quad \text{Huete et al. (1994)} \quad \text{Eq. 02}$$

Onde:

$\rho$  = reflectâncias da superfície corrigidas ou parcialmente corrigidas para efeitos atmosféricos;

$\rho_{NIR}$  e  $\rho_{RED}$  = reflectâncias na banda do infravermelho próximo e do vermelho, respectivamente. As reflectâncias da superfície são corrigidas total ou parcialmente para efeitos atmosféricos;

G = fator de ganho;

L = fator de ajuste para o substrato;

C1 e C2 = coeficientes para correção de aerossóis.

### 3.3.3 Green Normalized Difference Index (GNDVI)

O GNDVI é uma modificação do NDVI, onde a banda do vermelho foi substituída pela banda do verde, para diminuir os efeitos de saturação da vegetação em uma condição mais densa (NAVARRO et al., 2017). Por ter essa banda do verde como diferencial, este índice foi considerado mais sensível as concentrações de clorofila no estudo de Gitelson et al. (1996), sendo útil para diferenciar a vegetação senescente da vegetação que passou por algum tipo de estresse hídrico.

$$GNDVI = \frac{\rho_{NIR} - \rho_G}{(\rho_{NIR} + \rho_G)} \quad \text{Gitelson; Merzlyak (1996)} \quad \text{Eq. 03}$$

Onde:

$\rho_{NIR}$  = reflectâncias na banda do infravermelho próximo;

$\rho_G$  = reflectâncias na banda do verde.

### 3.3.4 Aerosol Free Vegetation Index (AFRI)

Pesquisas indicam que o AFRI apresenta um desempenho excepcional, destacando-se como uma alternativa eficiente em relação a outros índices (citar aqui algumas dessas pesquisas que vc mencionou no início da frase). O *Aerosol Free Vegetation Index* (AFRI) é capaz de penetrar a atmosfera e fornecer informações precisas sobre a vegetação e outras características do solo, mesmo em condições adversas, como em situações de incêndios florestais com presença de fumaça. Uma das principais vantagens desse índice, é que ele não é afetado pela interferência da fumaça na captação dos dados, o que o diferencia de outros índices convencionais (KARNIELI et al., 2001).

$$AFRI = \frac{\rho_{NIR} - 0,5\rho_{SWIR}}{(\rho_{NIR} + 0,5\rho_{SWIR})} \quad \text{Karnieli et al. (2001)} \quad \text{Eq 04}$$

Onde:

$\rho_{NIR}$  = reflectância na banda do infravermelho próximo;

$\rho_{SWIR}$  = reflectância na banda do vermelho termal.

### 3.3.5 Modified Soil Adjusted Vegetation Index (MSAVI)

Tanto o *Modified Soil-Adjusted Vegetation Index* (MSAVI) quanto o *Soil-Adjusted Vegetation Index* (SAVI) são índices de vegetação que utilizam fatores de ajustamento do solo, o MSAVI é uma opção mais conveniente e eficaz em termos de tempo e recursos, especialmente em áreas onde a densidade da vegetação é desconhecida ou varia consideravelmente (QI, 1994).

$$MSAVI = \frac{(\rho_{NIR} - \rho_{RED})}{\rho_{NIR} + \rho_{RED} + L} * (1 + L) \quad \text{Barnes, (2000)} \quad \text{Eq. 05}$$

Onde:

$\rho_{NIR}$  = reflectância na banda do infravermelho próximo;

$\rho_{RED}$  = reflectância na banda do vermelho;

L = constante de ajuste ao solo.

### 3.3.6 Normalized Difference Red Edge Index (NDRE)

Evidências científicas indicam que os aspectos fenológicos e as características de borda vermelha do objeto em estudo, quando observados nas séries temporais do NDRE (*Normalized Difference Red Edge Index*) apresentam um papel significativo na identificação e classificação de culturas (KANG, 2021).

$$NDRE = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad \text{Fitzgerald et al. (2010)} \quad \text{Eq. 06}$$

Onde:

$\rho_{NIR}$  = reflectância na banda do infravermelho próximo;

$\rho_{RED}$  = reflectância na banda do vermelho;

### 3.3.7 Soil-Adjusted Vegetation Index (SAVI)

O *Soil Adjusted Vegetation Index* (SAVI) foi desenvolvido com o propósito de reduzir as interferências do solo na medição dos espectros do dossel. Este índice pode ser calibrado para que essas variações do substrato do solo sejam normalizadas nas estimativas da vegetação (HUETE, 1988).

$$SAVI = \frac{(\rho_{NIR} - \rho_{RED})}{\rho_{NIR} + \rho_{RED} + L} \quad \text{HUETE, 1988} \quad \text{Eq. 07}$$

Onde:

$\rho_{NIR}$  = reflectância na banda do infravermelho próximo;

$\rho_{RED}$  = reflectância na banda do vermelho;

L = constante de ajuste do solo.

### 3.3.8 Modified Soil Adjusted Vegetation Index aerosol resistant (MSAVIaf)

Alguns estudos com o MSAVIaf indicam que este índice é um estimador confiável da área de cobertura do dossel da floresta, tanto sob céu claro quanto em condições de fumaça. Em algumas condições atmosféricas anômalas, este índice provou, em alguns estudos, ser mais sensível às variações da vegetação que o *Aerosol Free Vegetation Index* (AFRI) (MATRICARDI et al., 2010).

$$MSAVIaf = \frac{(\rho_{NIR} - 0.5\rho_{SWIR})}{\rho_{NIR} + 0.5\rho_{SWIR} + L} * (1 + L) \quad \text{Matricardi et al. (2010)} \quad \text{Eq. 08}$$

Onde:


$\rho_{NIR}$  = reflectância na banda do infravermelho próximo;

$\rho_{SWIR}$  = reflectância na banda do infravermelho de ondas curtas;

L = constante de ajuste ao solo.

### 3.4. Redes neurais artificiais

A origem das RNA's se assemelha ao modelo matemático do neurônio biológico proposto por McCulloch e Pitts (1943); essa estrutura artificial tem a mesma arquitetura do sistema nervoso humano, tendo como objetivo prever o comportamento de uma determinada função ou tarefa no qual é representado por uma série de entradas (HAYKIN, 2001), cada uma multiplicada por um peso específico e, posteriormente, somadas e comparadas a um limiar, conforme representado na Figura 1 (NIED, 2007). Essas redes trabalham com métodos que criam um padrão de interconexão para a resolução dos problemas por meio do treinamento de amostras, sendo uma etapa determinante para o sucesso ou fracasso dos modelos estudados (FURTADO, 2019).



**Figura 1-** Modelo de uma rede neural artificial. **Fonte:** Abraham (2006). Legenda: Input layer: camada de entrada, Hidden layer: camada oculta, Output layer: camada de saída.

A inteligência artificial tem sido vista como uma valiosa ferramenta na construção de confiáveis modelos não lineares e na obtenção de informações úteis de previsão a partir das variáveis de entrada. Em suma, as redes neurais artificiais (RNA's) tem vantagens comparadas aos métodos tradicionais, pela sua capacidade de generalizar os dados ruidosos ou incompletos em relações não lineares entre as variáveis de entrada e saída ou pela sua capacidade de aprender sem a necessidade de uma especificação prévia ou transformação de variáveis (GÜNER et al., 2022). As RNA's se diferenciam dos sistemas computacionais convencionais pela capacidade de aprender através da exposição dos dados, por representar e armazenar o conhecimento (HAYKIN, 2001). Essas redetêm se tornado significativamente importantes no setor florestal, por alcançarem resultados positivos, como no estudo de Reis et al. (2019), da modelagem da vegetação no recrutamento das espécies,



no qual as análises em redes permitiram estimar com precisão a regeneração do estoque de crescimento da floresta.

Nesta pesquisa, estimamos a biomassa com a aplicação do algoritmo matemático de Modelagem com Perceptron Multicamadas (MLP), que permite estabelecer correlações entre as variáveis dependentes e independentes (KUNG, 1993). Este é um dos modelos preditivos dotado de capacidade de generalização e alta capacidade de armazenamento de informações (GUIJAN et al., 2021). Os modelos MLP tem a capacidade de aquisição de conhecimento por meio das técnicas de treinamento das redes, o processo de aprendizado requer uma base de dados para compor as camadas de entrada com suas respectivas saídas, e ao determinar uma combinação adequada de pesos de ligação das variáveis e funções, é estimado o erro, que representa a discrepância entre a saída desejada e a saída real.. O processo de treinamento utiliza a magnitude deste erro para avaliar a contribuição dos pesos na rede e busca determinar a combinação ótima de pesos que minimize o erro (GARDNER; DORLING, 1998).

### **3.5 Plataforma ForestPlots**

A expansão das áreas protegidas e a consequente conservação da biodiversidade na Amazônia são maneiras de mitigar os impactos em um dos biomas mais importantes do mundo. Existe a necessidade de investir em novas técnicas de manejo para maximizar o potencial de proteção dessas áreas e diminuir a pressão para abrir novas áreas protegidas, para priorizar o gerenciamento das já existentes (SIQUEIRA, 2022). A restauração completa de todas as tipologias de florestas em áreas consideradas como mosaicos de vegetação heterogênea é crucial para fomentar a atividade restauradora. Ademais, existem *hotposts* de destaque que foram identificados como pontos críticos para a restauração na região do Cerrado-Amazônia, nos quais pode-se maximizar os benefícios associados ao sequestro de carbono na biomassa vegetal e à diversidade de espécies vegetais (MARIMON et al., 2014; REIS et al., 2022; LEWIS, 2023).

Atualmente, há diversas iniciativas brasileiras para o monitoramento permanente das florestas da Amazônia. Destacamos o Programa de Pesquisas Ecológicas de Longa Duração (PELD) financiado pelo CNPq, que agrega diversos projetos que monitoram florestas em longo prazo e mantém uma imensa rede de parcelas permanentes na borda sul e em áreas mais remotas e centrais da Amazônia (BRASIL, 2023). Na região de abrangência da área avaliada nesse estudo, na transição entre os biomas Amazônia e Cerrado, está o PELD-Transição (TRAN), que vem monitorando parcelas permanentes de formações florestais e savânicas há quase 30 anos (MARIMON et al., 2014; MORANDI et al., 2016; NOGUEIRA et al., 2019; REIS et al., 2022).

Outra iniciativa de sucesso, em uma escala mais ampla e que envolve todos os países da

Amazônia, é a Rede Amazônica de Inventários Florestais (RAINFOR), uma parceria internacional para estudos da dinâmica espaço-temporal dos ecossistemas do bioma, atuando no Brasil desde o ano 2000. Dentre os objetivos da rede estão o monitoramento da saúde das florestas na Amazônia, a compreensão de como o ambiente natural e os humanos influenciam no ciclo do carbono, como as mudanças climáticas impactam o bioma e como as espécies buscam para se adaptar. A RAINFOR também fornece dados e metodologias para novas pesquisas, contribui com a calibração de modelos referentes a dinâmica da vegetação, entre outros (<https://rainfor.org/pt/>). As áreas da rede são representadas por parcelas permanentes, com medições consistentes de árvores e de espécies individuais em estudo, com breves repetições e que são comparadas para observar as mudanças em longo prazo (PHILLIPS et al., 2021; RAINFOR, 2023).

Por meio da plataforma ForestPlots.net, são armazenados e gerenciados, de maneira eficiente, os dados obtidos dos inventários florestais periódicos, que fornecem informações detalhadas sobre a estrutura da vegetação, a composição do solo e outros atributos relevantes das florestas (LOPEZ-GONZALEZ et al., 2011). O ForestPlots.net representa uma plataforma singular que engloba todas as demandas para a mensuração, monitoramento e compreensão das florestas mundiais, sobretudo as tropicais. Por meio da colaboração, o projeto abrange mais de seis mil áreas com vegetação florestal e savânica em 62 países, com a adesão de mais de 2.500 parceiros (FORESTPLOTS.NET et al., 2021; FORESTPLOTS, 2023).

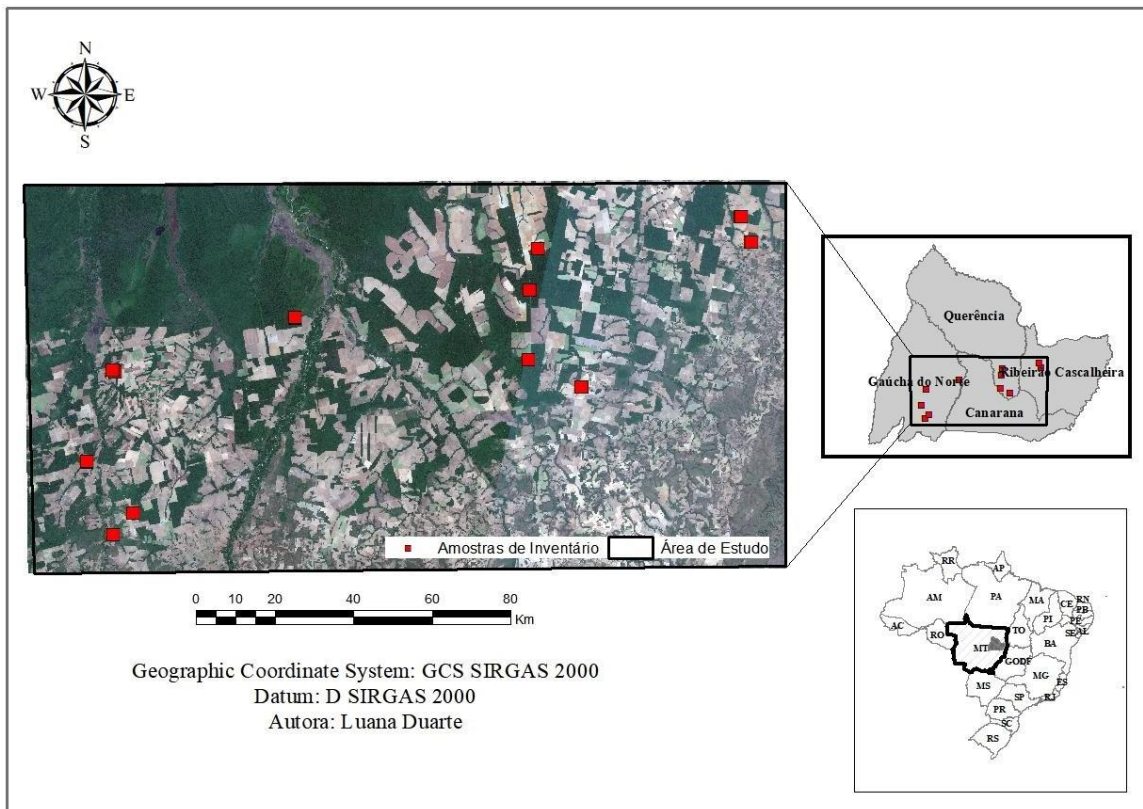
## **4. MATERIAL E MÉTODOS**

### **4.1 Área de estudo**

#### **4.1.1 Localização**

No presente estudo, selecionamos algumas parcelas permanentes de medições a longo prazo que foram instaladas e são monitoradas periodicamente pela equipe de pesquisadores do Laboratório de Ecologia Vegetal (LABEV) da Universidade do Estado de Mato Grosso (UNEMAT), *campus* de Nova Xavantina, localizadas no estado de Mato Grosso, nos municípios de Gaúcha do Norte, Querência e Ribeirão Cascalheira (Figura 2). A área de estudo foi escolhida pela relevância de sua localização na zona de transição entre os biomas Cerrado e Amazônia, pela proximidade com as terras indígenas Pimental Barbosa (etnia Xavante), Pequizal do Naruvôto (etnia Nambikwara) e da porção sul da Terra Indígena do Xingu, que abriga 16 etnias (Figura 3), localizadas na parte nordeste de Mato Grosso e pelas características do intenso processo de expansão do desmatamento observado nas últimas décadas, coincidindo com parte da região conhecida como ‘arco do desmatamento’ (MARQUES et al., 2020). Somente na Amazônia, as pastagens aumentaram em 200% e as

áreas de pastagens severamente degradadas diminuíram pela metade em todo o Brasil nos últimos 36 anos (MAPBIOMAS, 2023).

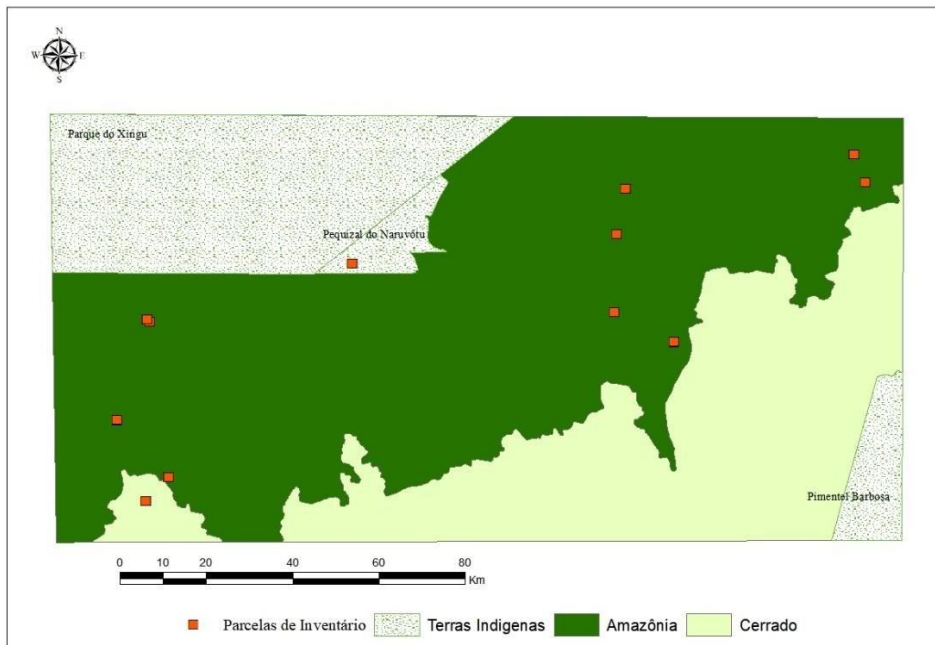


**Figura 2-** Localização da área de estudo e das parcelas de inventário florestal estabelecidas pelo Laboratório de Ecologia Florestal da Universidade do Estado de Mato Grosso.

Na região de estudo, foi observado um intenso processo de ocupação humana e transformação da paisagem natural nas últimas décadas, como resultado da expansão e intensificação agrícola e pecuária nas fronteiras destes biomas (PITTA; VEGA, 2017; MARQUES et al., 2020). O processo de ocupação humana e expansão agrícola resulta na diminuição de áreas de vegetação nativa e aumenta a pressão antrópica sobre as Unidades de Conservação e Terras Indígenas, que ficam circundadas por áreas desmatadas e fragmentadas pela substituição dessas manchas naturais por extensas pastagens e plantios agrícolas, especialmente soja, o algodão e o milho (LIRA; ROSSETTO, 2020).

A partir da década de 80, observou-se um processo em que grandes áreas de florestas nativas foram convertidas em pastagens e plantações ao longo da borda sul, na região de transição com o bioma Cerrado, estima-se que quase metade da cobertura florestal original dessa região já tenha sido destruída, representando um ritmo de desaparecimento das florestas que não encontra precedentes em escala global. A vegetação nesta área está se

transformando em um mosaico, no qual sofre influência das características ambientais e das medidas legais (e ilegais) de uso. (BONINI, 2019).



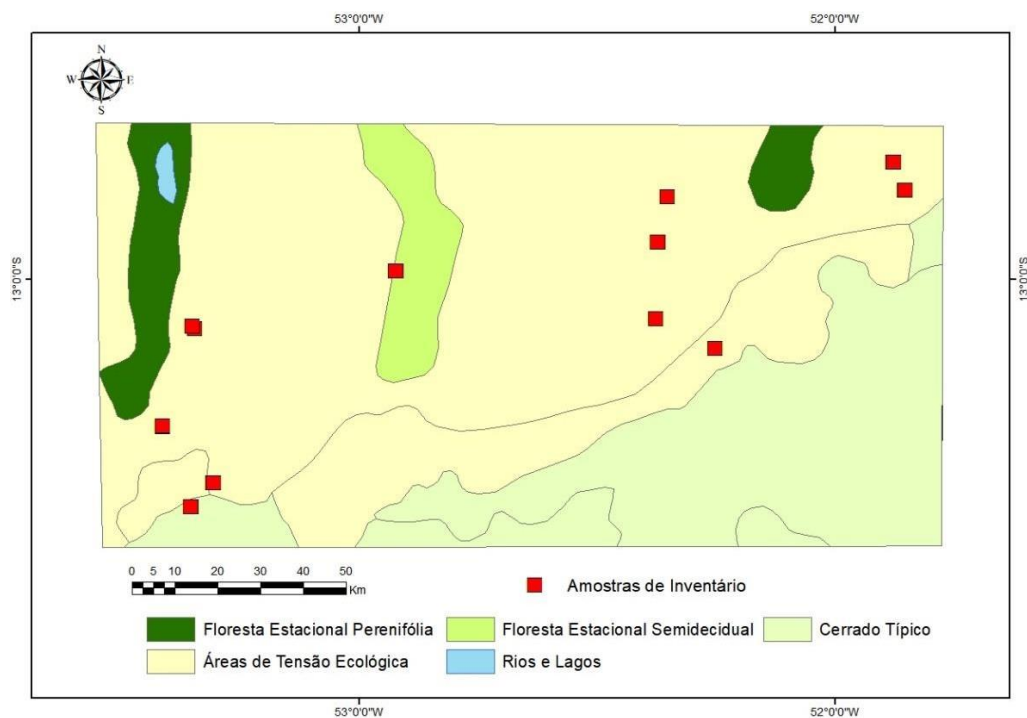
**Figura 3-** Localização dos biomas Amazônia e Cerrado, Terras Indígenas e parcelas de inventário do Laboratório de Ecologia Vegetal (LABEV) da Universidade do Estado de Mato Grosso.

#### 4.1.2 Características

A região de estudo apresenta solos com características distintas. Esses solos são caracterizados pela baixa disponibilidade de nutrientes e alta toxidez devido à presença de alumínio. No entanto, nas áreas de interflúvio, onde predominam os latossolos vermelho-amarelos de textura média, são encontradas condições mais favoráveis para o crescimento das florestas. Esses latossolos também exibem manchas de "terra preta de índio", que se destacam por apresentarem uma maior concentração de matéria orgânica na superfície e um pH mais elevado, especialmente em camadas mais profundas. Por outro lado, nas várzeas, é observada a presença de neossolos flúvicos de textura argilosa, que possuem uma maior quantidade de potássio, porém enfrentam problemas relacionados à drenagem e altos teores de alumínio (IVANAUSKAS; MONTEIRO; RODRIGUES, 2004).

Para as áreas onde estão posicionadas as parcelas permanentes monitoradas pelo Laboratório de Ecologia Vegetal da UNEMAT, a vegetação apresenta uma predominância de Floresta Estacional (Fse) e Cerrado Típico (Sd), típicos da região Centro-Oeste do Brasil (RADAMBRASIL, 1979). Adicionalmente, esta é uma área de tensão ecológica (Figura 4), o conceito de "Áreas de tensão ecológica", refere-se a regiões onde diferentes tipos de vegetação se encontram e se misturam. Nessas áreas, ocorre uma sobreposição das espécies

vegetais, resultando na formação de comunidades que não podem ser facilmente diferenciadas como pertencentes a uma única tipologia. Em outras palavras, são zonas de transição onde as floras das diferentes tipologias se entrelaçam, criando um ambiente complexo e único. Tais áreas são particularmente interessantes para estudos de ecologia e biodiversidade, uma vez que podem apresentar uma diversidade de espécies e características que refletem a interação entre os biomas envolvidos (SNIF, 2023). Essas informações são relevantes para a compreensão da distribuição da vegetação na região em questão e podem ser úteis para a gestão ambiental e conservação da biodiversidade.



**Figura 4-** Mapa de vegetação para a área de estudo. **Fonte:** RAMBRASIL (2019).

De acordo com a classificação climática de Köppen (PEEL et al., 2007), a região possui um clima do tipo Aw, caracterizado como tropical estacional com duas estações bem definidas: uma estação seca que ocorre de maio a outubro, e outra estação chuvosa que ocorre de novembro a abril (BRASIL, 2014). O relevo varia de plano a suave-ondulado (IVANAUSKAS et al, 2004) com uma morfologia predominantemente de planaltos e planícies no centro, com uma disposição de serras a leste e a presença de depressões residuais ao sul da área (IBGE, 2023) (Figura 5). Os rios da região de estudo, estão localizados em uma das principais bacias hidrográficas do país, a do Rio Amazonas (IBGE, 2023).

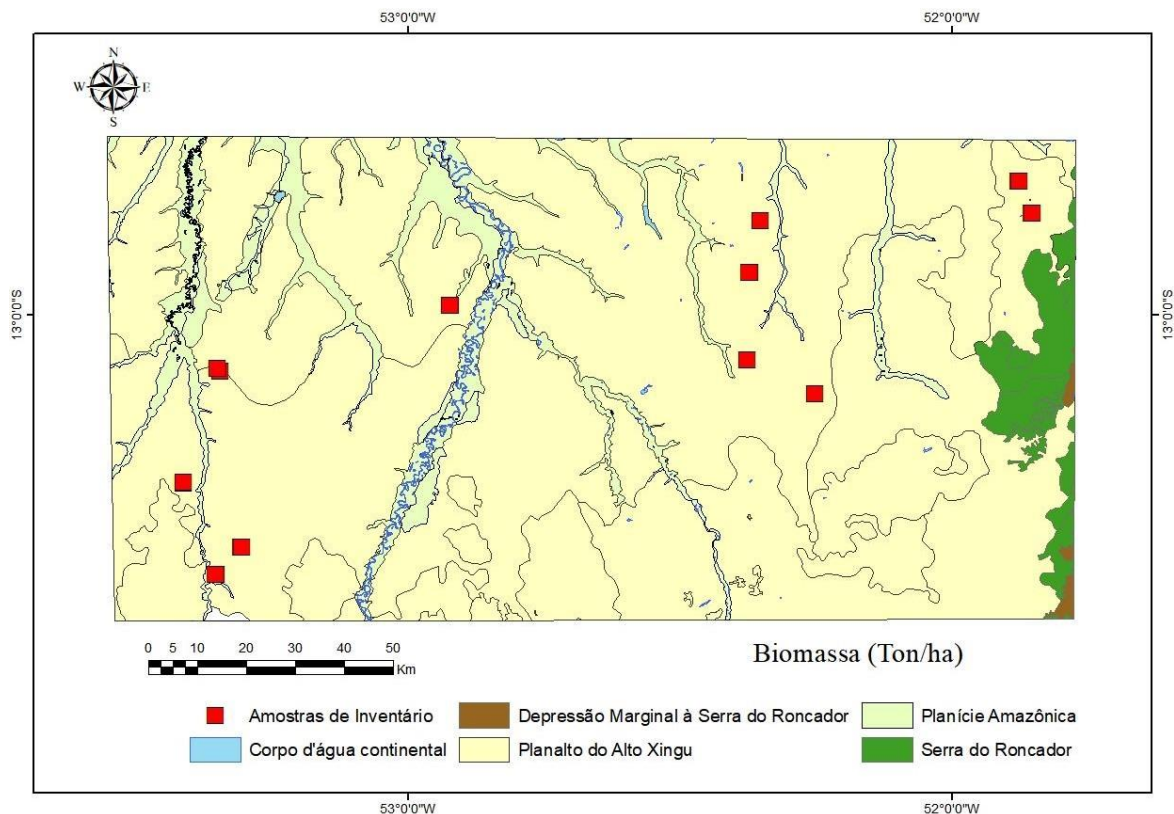


Figura 5- Mapa do relevo da área de estudo. Fonte: IBGE (2019).

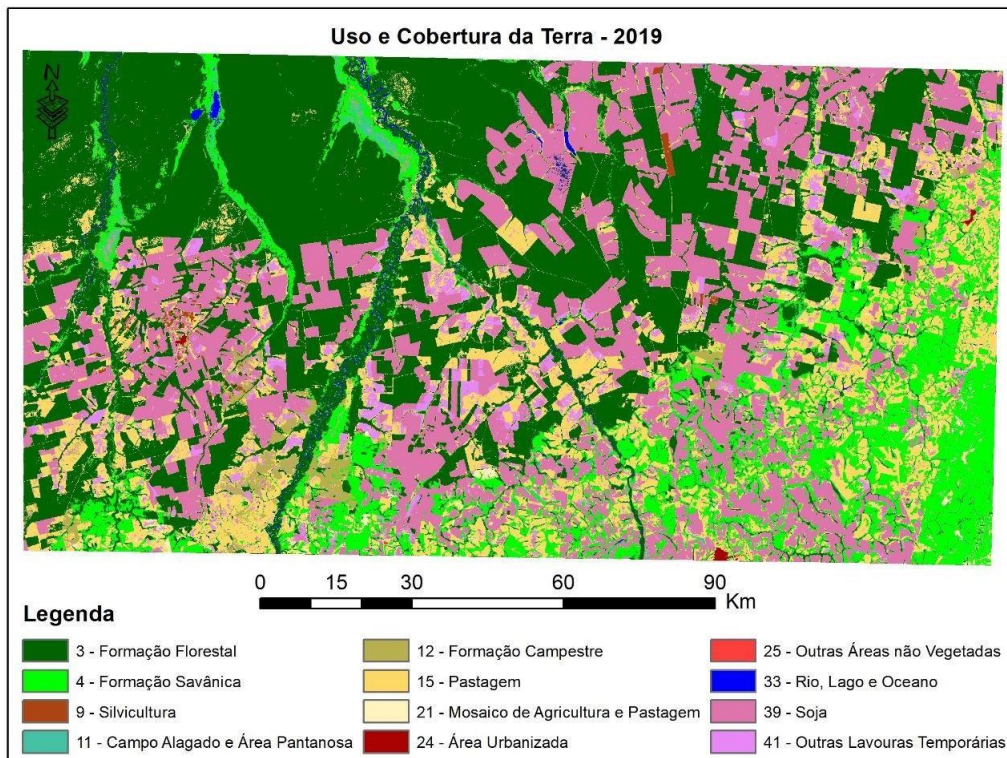
#### 4.1.3 Classificação do uso e cobertura do solo

Com o propósito de delinear as áreas cobertas por florestas e formações savânicas naturais e as áreas que sofreram desmatamento na região de estudo, executamos uma classificação utilizando a base de dados de uso e cobertura do Projeto de Mapeamento Anual da Cobertura e Uso do Solo do Brasil (MapBiomias). Os mapas anuais de uso e cobertura da terra, produzidos pelo MapBiomias, resultam de um procedimento de classificação pixel a pixel de imagens de satélites Landsat. Esse processo é conduzido por meio de algoritmos de aprendizagem de máquina, amplamente empregados no campo da ciência de dados, que viabilizam a extração de informações relevantes a partir de grandes conjuntos de dados. O procedimento em questão foi realizado mediante a utilização da plataforma *Google Earth Engine*, a qual proporciona a capacidade de processamento necessária para executar essa tarefa de maneira eficiente, por meio de recursos de computação em nuvem (MAPBIOMAS, 2023).

Para obter informações precisas e confiáveis sobre o uso e cobertura da Terra na área de estudo, utilizamos técnicas de processamento digital de imagens e análise espacial. Classificamos os distintos tipos de cobertura para o ano de 2019 mediante a sobreposição



dos dados geoespaciais do MapBiomas com a área de interesse, geramos um mapa que permitiu identificar as diferentes categorias de cobertura, como Formação Florestal, Formação Savânica, Pastagens, Cultivo de Soja e outras categorias de menor expressão (Figura 6).



**Figura 6-** Uso e cobertura da Terra na área de estudo para o ano de 2019. **Fonte:** MAPBIOMAS (2023).

Na região estudada, constatou-se que a Formação Florestal é o tipo de cobertura predominante, seguido pela Formação Savânica (Tabela 1). Além disso, observou-se uma extensa área de pastagem e uma significativa atividade agrícola relacionada ao cultivo de soja. As lavouras temporárias ocupam uma parcela menor da área total. Outros usos da terra, como Silvicultura, Campo Alagado, Formação Campestre, Área Urbanizada, Áreas Não Vegetadas e Corpos de Água, também foram identificados na região, embora com proporções menores. É possível consultar a tabela para obter uma descrição mais detalhada.

**Tabela 1-** Informações sobre os tipos de uso e cobertura da terra, indicando a área em hectares e a porcentagem.

<b>Uso e Cobertura da Terra</b>	<b>Área (ha)</b>	<b>%</b>
Formação florestal	778.787,0	39,9
Formação savânica	265.678,0	13,6
Silvicultura	4.333,5	0,2
Campo alagado	16.655,0	0,9
Formação campestre	32.101,5	1,6
Pastagem	310.163,0	15,9
Agricultura e Pastagem	15.942,8	0,8
Área urbanizada	1.222,5	0,1
Áreas não vegetadas	676,6	0,0
Corpos de água	9.853,8	0,5
Soja	441.221,0	22,6
Lavouras temporárias	72.196,8	3,7
Algodão	668,6	0,0
<b>Total</b>	<b>1.949.500,1</b>	<b>100</b>

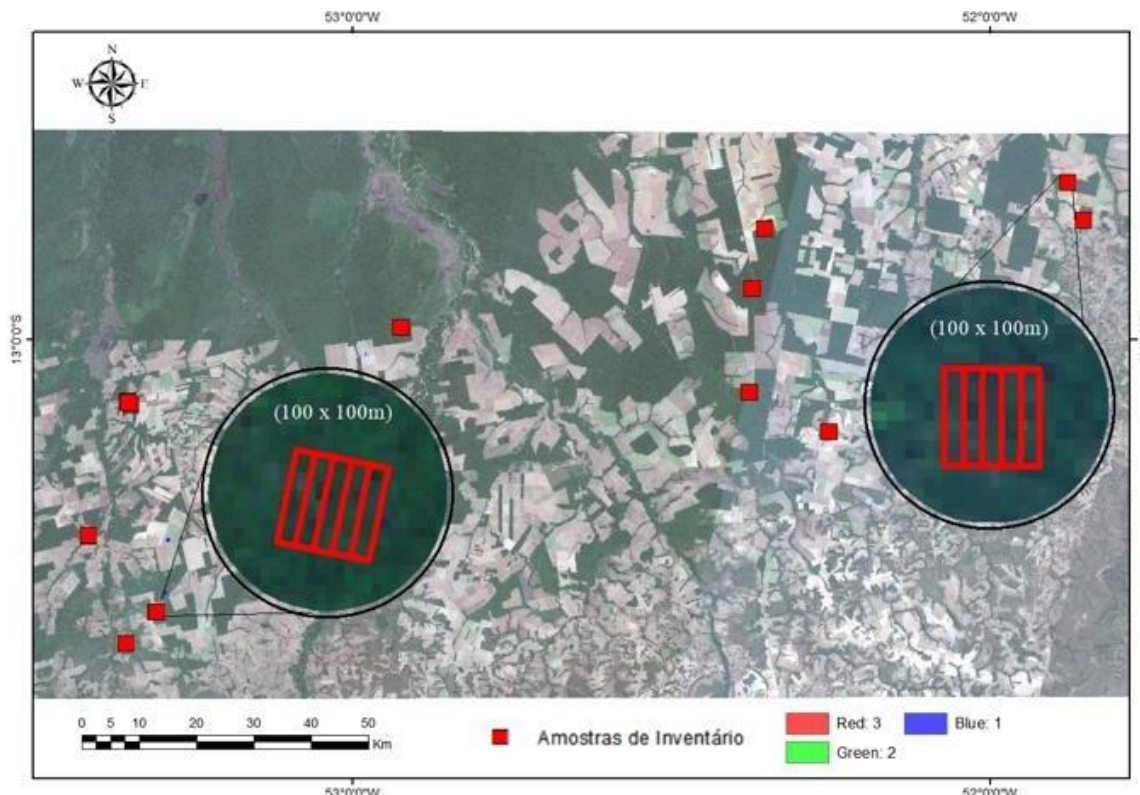
As informações obtidas sobre o uso e cobertura do solo na área de estudo apresentam relevância na elaboração de mapas de biomassa. Isso se deve ao fato de que a distribuição dos diferentes tipos de cobertura terrestre tem um impacto direto sobre a quantidade de biomassa presente na região. Por isso, é importante ter informações precisas sobre a distribuição dos diferentes tipos de cobertura do solo para desenvolver mapas de biomassa confiáveis e úteis para fins como a gestão ambiental e a tomada de decisões relacionadas ao uso da terra.

## **4.2 Base de dados**

### **4.2.1 Variáveis dendrométricas do inventário**

Os inventários foram realizados nos anos de 2014 (uma parcela), 2018 (três parcelas), 2020 (cinco parcelas) e 2021 (três parcelas) pelos colaboradores do Laboratório de Ecologia Florestal da Universidade do Estado de Mato Grosso, com o objetivo de monitorar a vegetação das parcelas permanentes dentro dos diferentes tipos de estratos, solos, zonas climáticas e grupos regionais. O processo de amostragem foi aleatório, em 12 unidades amostrais com dimensões de 100 x 100 m cada. Cada unidade amostral foi implantada com cinco transectos, totalizando 60 subamostras de 100 x 20 metros (Figura 7). A unidade GAU-06 apresentou dimensões diferenciadas, com área de 180 x 60 metros e transectos de 36 x 60 metros. Essa estratégia de amostragem foi adotada com o intuito de maximizar a representatividade da amostra e minimizar possíveis vieses que poderiam comprometer a validade dos resultados obtidos. Todas as etapas do processo de amostragem seguiram o protocolo detalhado em Phillips et al. (2021), a fim de garantir a confiabilidade dos dados coletados.





**Figura 7**-Distribuição das parcelas e seus transectos.

No interior de cada parcela foram coletadas informações detalhadas sobre a identificação das espécies e suas respectivas famílias, bem como dados de diâmetro e altura. A densidade básica da madeira foi estimada a partir de um extenso banco de dados disponível na plataforma ForestPlots.net, baseado em valores de mais de 2000 espécies de árvores neotropicais (BAKER et al., 2004; CHAVE et al., 2006; LOPEZ-GONZALEZ et al., 2006). Para a realização dessas avaliações, utilizamos o software Microsoft Excel 2016 para o cálculo da biomassa acima do solo em todas as parcelas da área de estudo para as estimativas, selecionamos os dados de DAP (diâmetro à altura do peito), H (altura total) e D (densidade básica da madeira de cada espécie), e organizamos com o auxílio da função de tabela dinâmica do software. É importante destacar que todas as informações coletadas foram analisadas e interpretadas à luz das teorias e métodos consagrados na literatura científica descritos nos manuais da RAINFOR. O delineamento da coleta de cada uma das variáveis em questão é apresentado a seguir, em conformidade com as diretrizes científicas estabelecidas pelos manuais.

#### **4.2.2 Biomassa florestal**

A fim de desenvolver métodos para avaliar a quantidade de biomassa existente acima do solo, é necessário obter estimativas dessa biomassa diretamente no local (in situ). Essas estimativas são usadas para calibrar e validar algoritmos que visam calcular a biomassa. Além disso, com base nos dados coletados em campo, é possível estimar outras

características das árvores, como a área basal e a quantidade total de biomassa. A partir dos dados de inventário florestal das parcelas, é possível fazer a previsão da biomassa acima do solo desta área de transição de biomas, levando em consideração a equação proposta por Chave et al. (2014) para as amostras localizadas no bioma Amazônia:

$$B = 0,0673 \times (Db \times Ht \times DAP^2)^{0,976}$$

Onde:

B = Biomassa cima do solo (kg);

Db = Densidade básica de cada espécie (g.cm<sup>3</sup>);

Ht = Altura total (m);

DAP = Diâmetro à 1,3m do solo (cm).

O estudo realizou a estimativa da biomassa acima do solo (BAS) em árvores com diâmetro à base da árvore (Db) igual ou superior a 5 cm, utilizando uma equação alométrica desenvolvida especificamente para o ambiente de Cerrado. A equação proposta por REZENDE et al. (2006), foi ajustada com base em dados coletados em campo e relaciona o Db com a biomassa acima do solo.

$$B = 0,4913 + 0,0291 * DAB^2 * Ht$$

Onde:

DAB = diâmetro à base da árvore;

Ht = altura da árvore.

Para cada subparcela foram estimados os valores de biomassa utilizando equações alométricas e todas as variáveis específicas da árvore, com o objetivo de normalizá-los e obter os resultados em Ton.ha<sup>-1</sup>.

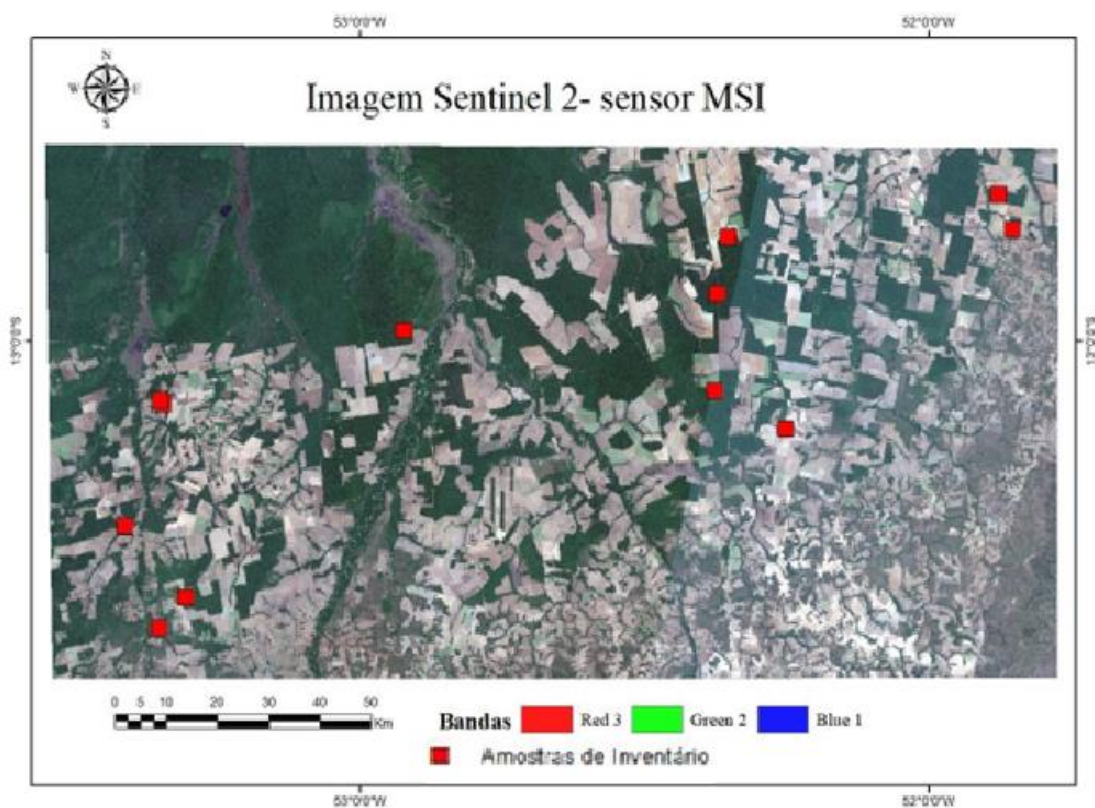
#### **4.3. Processamento das imagens Sentinel-2**

Utilizamos cenas obtidas pelo sensor MSI do satélite Sentinel-2. Esse sensor é capaz de capturar informações espectrais na faixa do vermelho, que é considerada uma das melhores bandas para a descrição da vegetação, devido à presença de clorofila nas plantas (CURRAN et al., 1990). As imagens foram coletadas durante o mês de agosto de 2019, correspondendo a um ano intermediário dos dados de inventário florestal que foram respectivamente coletados nos anos de 2014, 2018, 2020 e 2021.

A resolução espacial do satélite varia de 10m para as bandas do visível, 20 m para as do infravermelho e 60 m para as bandas de correção atmosférica (Figura 8). Em relação a

resolução espectral, o Sentinel-2 tem 13 bandas espectrais (variando de 442 nm até 2.202 nm) e um período de revisita de a cada cinco dias (ESA, 2023).

As imagens foram baixadas pelo Google *Earth Engine* (GEE), já com as devidas correções atmosféricas e geométricas para a área de estudo. A plataforma possibilita um armazenamento *online* disponível para seus usuários e, atualmente, sem nenhum custo para ser utilizada. Isso torna uma ferramenta essencial e muito poderosa para diversos projetos, pois funciona por meio de linguagem de programação, baseada no armazenamento em nuvem, ocasionando algumas mudanças significativas no mapeamento e monitoramento da vegetação (XIONG, 2017).



**Figura 8-** Mosaico de cenas do satélite Sentinel-2, composição R3G2B1, adquirida em 22/08/2019, 19/08/2019, 09/08/2019 e 07/08/2019, das parcelas de monitoramento do Laboratório de Ecologia Vegetal da UNEMAT, no estado do Mato Grosso.

Para a obtenção dos índices de vegetação, empregamos um mosaico de imagens provenientes do sensor MSI a bordo do satélite Sentinel-2, referente ao período de agosto de 2019. Os resultados obtidos foram sintetizados e tabelados (Tabela 2).

**Tabela 2-** Cenas do satélite Sentinel-2 adquiridas através do Google Earth Engine (GEE) usadas para o processamento dos índices de vegetação.

<b>ID Sentinel-2A</b>	<b>Data</b>	<b>Sensor</b>
COPERNICUS/S2/20190807T135119_20190807T135119_ <b>T22LBL</b>	07/08/2019	MSI
COPERNICUS/S2/20190807T135119_20190807T135119_ <b>T22LCL</b>	07/08/2019	MSI
COPERNICUS/S2/20190809T134211_20190809T134214_ <b>T22LCL</b>	09/08/2019	MSI
COPERNICUS/S2/20190809T134211_20190809T134214_ <b>T22LDL</b>	09/08/2019	MSI
COPERNICUS/S2/20190819T134211_20190819T134408_ <b>T22LCL</b>	19/08/2019	MSI
COPERNICUS/S2/20190819T134211_20190819T134408_ <b>T22LDL</b>	19/08/2019	MSI
COPERNICUS/S2/20190822T135111_20190822T135223_ <b>T22LBL</b>	22/08/2019	MSI

Para elaborar os índices de vegetação, utilizamos as bandas espectrais que abrangem as faixas de comprimento de onda do espectro vermelho, verde, azul e infravermelho (Tabela 3). A partir dessas faixas, calculamos os índices de vegetação com base nas equações propostas pelos autores detalhados no referencial teórico deste trabalho. Esses índices foram estimados para avaliar a cobertura vegetal na área de estudo.

**Tabela 3-** Bandas do espectro visível que foram aplicadas na confecção dos índices de vegetação da área de estudo.

<b>Bandas Sentinel-2A</b>	<b>Central wavelength (µm)</b>	<b>Resolução (m)</b>
<b>2-</b> Blue	0.490	10
<b>3-</b> Green	0.560	10
<b>4-</b> Red	0.665	10
<b>5-</b> Vegetation Red Edge	0.705	20
<b>6-</b> Vegetation Red Edge	0.740	20
<b>7-</b> Vegetation Red Edge	0.783	20
<b>8-</b> NIR	0.842	10
<b>8A-</b> Vegetation Red Edge	0.865	20
<b>11-</b> SWIR	1.610	20
<b>12-</b> SWIR	2.190	20

#### **4.4 Modelagem das redes neurais artificiais (RNAs)**

A acurácia das estimativas de volume de madeira e biomassa na vegetação lenhosa em áreas de cerrado foi comprovada através de modelos de regressão e RNAs. Esses modelos são ajustados com base em dados gerados por sensoriamento remoto, incluindo índices de vegetação e área basal. Entre os dois métodos, as RNAs apresentam melhor precisão nas estimativas (MIGUEL et al., 2015).

Neste estudo, as redes neurais artificiais (RNAs) do tipo *Multilayer Perceptron*

(MLP) foram submetidas a um processo de ajuste e treinamento utilizando o software Statistica versão 12, com o objetivo de estimar a biomassa florestal nas unidades amostrais do LABEV-UNEMAT. Para o alcance dos resultados desejados, o software conta com uma ferramenta denominada *Intelligent Problem Solver* (IPS), que se encarrega de otimizar a arquitetura da rede, o número de camadas, neurônios e ciclos, de forma a garantir a máxima eficiência na obtenção dos resultados (STATSOFT, 2023). O processo de treinamento é realizado de forma supervisionada, através de um algoritmo de retropropagação de erro, fundamentado na regra de aprendizado por retroalimentação de erro (BORSATO et al., 2009).

A camada de entrada da rede neural foi composta por variáveis de natureza categórica enumerada. A variável categórica relacionava-se aos dois tipos de estratos presentes na área de estudo, Floresta Estacional Perenifolia e Cerrado típico, enquanto as variáveis numéricas consistiam nos índices de vegetação NDVI, EVI, GNDV, AFRI, MSAVI, NDRE, SAVI e MSAVIaf. A camada oculta foi formada por um número  $n$  de neurônios, enquanto a camada de saída foi composta por um único neurônio, responsável por estimar a biomassa acima do solo (BAS).

Para o treinamento das Redes Neurais Artificiais (RNAs), selecionamos 42 subamostras, representando 70% do total das 60 subamostras demarcadas em campo durante os inventários. As 18 subamostras restantes foram destinadas à validação dos resultados obtidos. As RNAs do tipo MLP consideram a média aritmética ponderada dessas entradas (SHIBLEE et al., 2010) e neste caso foi ativada por uma função exponencial.

Com o intuito de avaliar o desempenho dos modelos desenvolvidos por meio das RNAs, consideramos os parâmetros de coeficiente de correlação (R) e a raiz do erro quadrático médio (RMSE). Tais coeficientes já foram empregados em outras pesquisas com RNAs, a exemplo do estudo realizado por Fischer et al. (2020). O cálculo da raiz do erro quadrático médio (RMSE%) é obtido pela aplicação da equação a seguir:

$$RMSE (\%) = \frac{100}{\hat{Y}} \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad \text{Eq. 09.}$$

Onde:

$\hat{Y}$  = média dos valores observados;

$Y_i$  = valor observado;

$\hat{Y}_i$  = valor estimado para a RNA;

$n$  = número total de dados

Para validar o desempenho das melhores RNAs, realizamos análises estatísticas utilizando o teste  $t$  de Student. Para verificar se houve subestimação ou superestimação, calculamos a diferença agregada em percentual (DA%). As análises estatísticas foram conduzidas no software Microsoft Excel.

## **5. RESULTADOS**

### **5.1 Inventário da vegetação**

Com base em dados coletados em campo, realizamos uma análise estatística preliminar das parcelas da área de estudo, com o objetivo de compreender as variações nas características dendrométricas. A análise descritiva da tabela permite organizar, resumir e descrever as variáveis do inventário, facilitando a observação e comparação dessas características com dados de áreas semelhantes. Isso contribui para uma melhor compreensão e ampliação do conhecimento científico nesse campo.

Os resultados da Tabela 4, indicam diferenças significativas nas variáveis avaliadas, o que sugere uma variação substancial nas características dendrométricas das parcelas localizadas em áreas de Cerrado e Amazônia. Ao analisarmos os valores de biomassa acima do solo, é possível notar que as árvores da Floresta apresentam cerca de oito vezes maior quantidade de material vegetal acima do solo em média do que as do Cerrado (Tabela 4). Esse resultado pode estar relacionado a troncos mais largos (37% maiores na Floresta em relação ao Cerrado) e cerca de três vezes mais altos na Floresta. Embora haja essa diferença na biomassa acima do solo entre as formações vegetacionais, a densidade de madeira média foi praticamente a mesma nas duas formações na área de estudo.

**Tabela 4-** Variáveis dendrométricas calculadas a partir de inventário florestal para as áreas das parcelas LABEV-UNEMAT. DAP = diâmetro à altura do peito (cm), Ht = altura total (m), DM = densidade média da madeira (g.cm<sup>3</sup>), BAS = biomassa acima do solo (Ton.ha<sup>-1</sup>).

<b>Cerrado</b>					<b>Floresta</b>				
	<b>DAP</b>	<b>Ht</b>	<b>DM</b>	<b>BAS</b>		<b>DAP</b>	<b>Ht</b>	<b>DM</b>	<b>BAS</b>
<b>Mínimo</b>	13,26	6,13	0,61	14,35	<b>Mínimo</b>	16,55	10,97	0,59	66,56
<b>Máximo</b>	15,09	7,37	0,69	23,49	<b>Máximo</b>	21,70	17,08	0,75	331,38
<b>Média</b>	13,93	6,63	0,65	18,38	<b>Média</b>	19,08	13,81	0,66	146,86
<b>Variância</b>	0,32	0,18	0,00	10,97	<b>Variância</b>	1,47	1,82	0,00	2572,76
<b>Desvio</b>	0,57	0,42	0,03	3,31	<b>Desvio</b>	1,21	1,35	0,04	50,72
<b>CV%</b>	4,09	6,33	3,85	18,02	<b>CV%</b>	6,35	9,76	5,50	34,54



Os resultados das medições de biomassa nas amostras de Floresta apresentaram consistência, com um valor médio de 146,84 t ha<sup>-1</sup>, em conformidade com os achados do estudo realizado pela EMBRAPA (2021). Ao analisar um fragmento florestal localizado na borda sul da área estudada, observou-se uma variabilidade nos valores de biomassa, que variaram entre 155 e 195 t ha<sup>-1</sup> de matéria seca. Além disso, em um estudo de Sanqueta et al (2020) sobre o estoque de biomassa em pastagens cultivadas no norte de Rondônia, foi avaliado um valor de 18,90 ton ha<sup>-1</sup>, substancialmente inferior ao encontrado na floresta.

## 5.2. Análise de Correlação da Biomassa e Índices de vegetação (IV)

Para fins deste estudo, elaboramos um mosaico com as imagens corrigidas do Sentinel-2, adquiridas para o ano de 2019 para produzir os índices de vegetação na área de interesse (tabela 5).

**Tabela 5-** Média das variáveis independentes na área de estudo. AFRI = Aerosol Free Vegetation Index; EVI = Enhanced Vegetation Index; Gndvi = Green Normalized Difference Index; MSAVIaf = Modified Soil Adjusted Vegetation Index aerosol resistant; MSAVI = Modified Soil Adjusted Vegetation Index; NDVI = índice de vegetação da diferença normalizada; NDRE = índice de vegetação da diferença normalizada com a banda red edge; SAVI = Soil-Adjusted Vegetation Index.

Índices de Vegetação (IV)	Médias
AFRI	0,561
EVI	0,568
Gndvi	0,566
EVI2	0,388
MSAVIaf	0,319
MSAVI	0,541
NDRE	0,511
NDVI	0,695
SAVI	0,421

Para avaliar a normalidade dos dados de biomassa e índices de vegetação, aplicamos o teste de Shapiro-Wilk, que evidenciou a ausência de normalidade nas variáveis. Consequentemente, optamos pela utilização da matriz de correlação de Spearman, indicada para dados não-paramétricos, conforme a análise dessas variáveis.

Verificamos correlação positiva e significativa entre a biomassa acima do solo e os índices de vegetação, bem como entre os índices avaliados (Tabela 6).

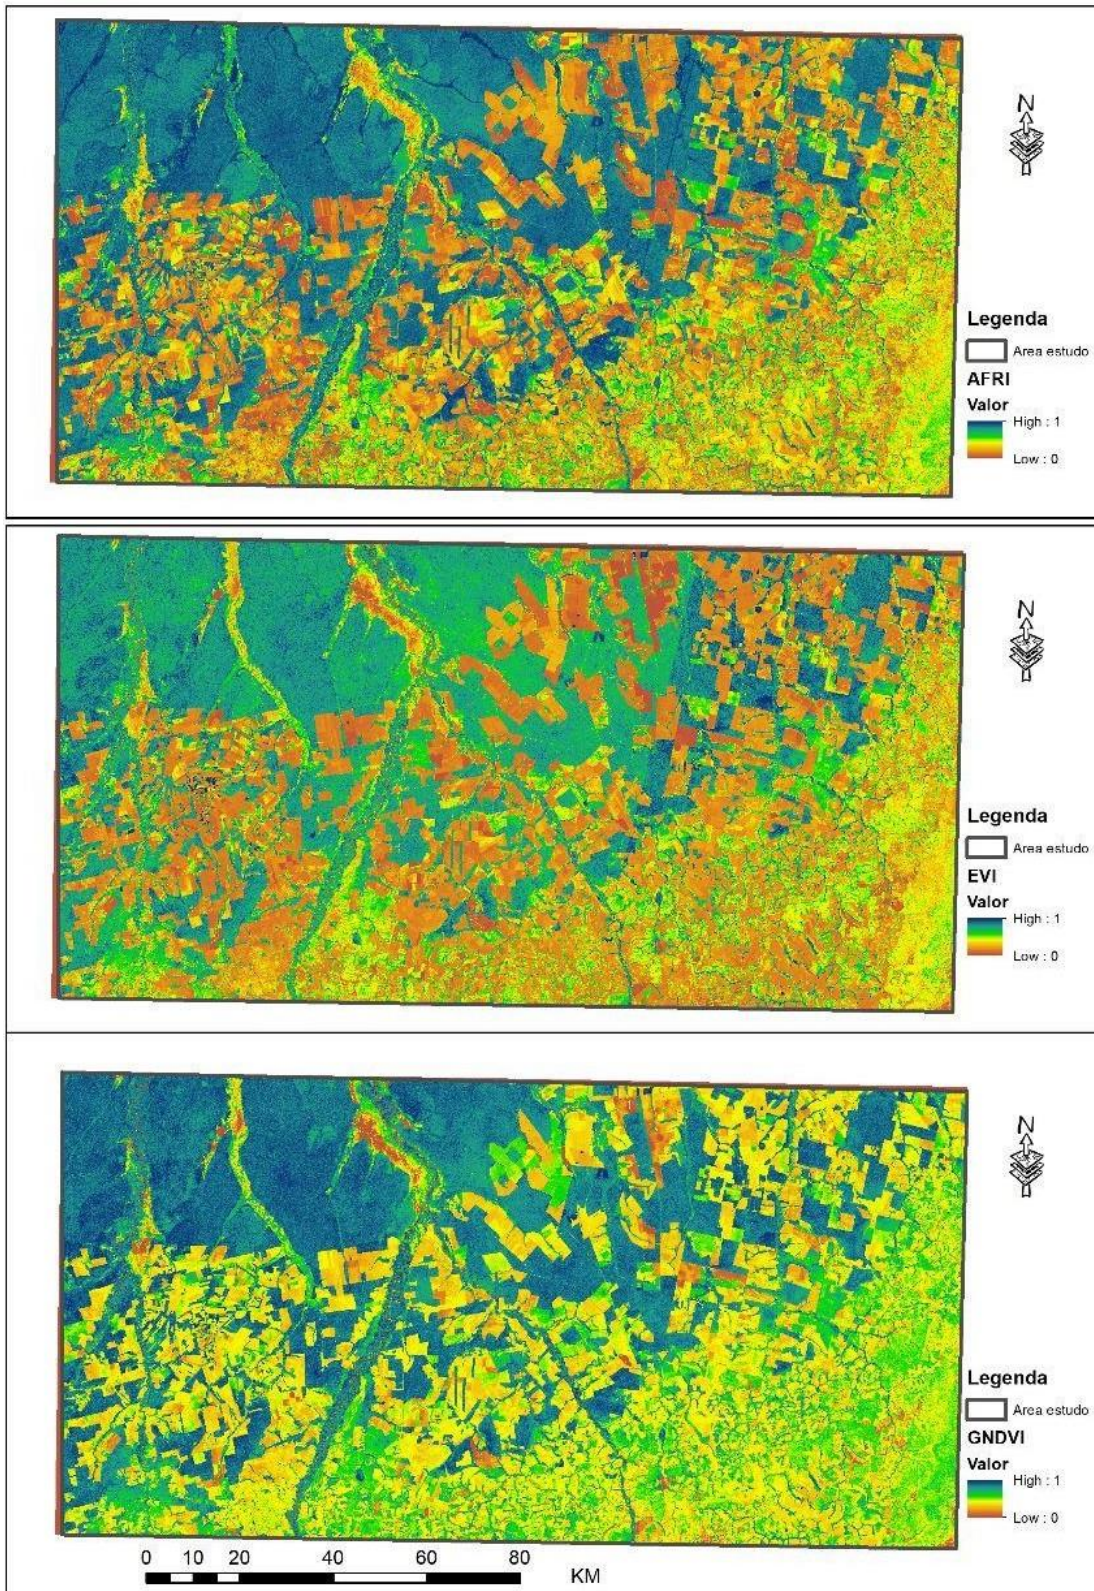
**Tabela 6-**A matriz de correlação de Spearman usada para analisar a relação entre a biomassa acima do solo e os índices de vegetação da área de estudo.

	<i>AFRI</i>	<i>EVI</i>	<i>EVI2</i>	<i>Gndvi</i>	<i>MSAVIaf</i>	<i>MSAVI</i>	<i>NDRE</i>	<i>NDVI</i>	<i>SAVI</i>	<i>Biomassa (ton/ha)</i>
<b>AFRI</b>	1									
<b>EVI</b>	0,881	1								
<b>EVI2</b>	0,887	0,969	1							
<b>Gndvi</b>	0,921	0,896	0,955	1						
<b>MSAVIaf</b>	0,945	0,964	0,984	0,959	1					
<b>MSAVI</b>	0,860	0,977	0,937	0,860	0,946	1				
<b>NDRE</b>	0,966	0,864	0,896	0,948	0,928	0,834	1			
<b>NDVI</b>	0,973	0,898	0,904	0,919	0,937	0,880	0,975	1		
<b>SAVI</b>	0,902	0,962	0,998	0,964	0,985	0,926	0,914	0,919	1	
<b>Biomassa (ton/ha)</b>	0,467	0,438	0,576	0,646	0,551	0,405	0,522	0,472	0,585	1

Legenda: \*Significante à 5%; \*\*Todos os índices são significantes à 1%. Em que: AFRI = Aerosol Free Vegetation Index; EVI = Enhanced Vegetation Index; Gndvi = Green Normalized Difference Index; MSAVIaf = Modified Soil Adjusted Vegetation Index aerosol resistant; MSAVI = Modified Soil Adjusted Vegetation Index; NDVI = índice de vegetação da diferença normalizada; NDRE = índice de vegetação da diferença normalizada com a banda red edge; SAVI = Soil-Adjusted Vegetation Index.

Realizamos uma análise de regressão *stepwise* em redes neurais artificiais (RNAs), como intuito de identificar os índices mais adequados para a estimativa da BAS na área de estudo. A partir desses testes, selecionamos os índices AFRI, EVI e GNDVI para serem incluídos na modelagem como variáveis independentes, levando em consideração os resultados mais promissores e o menor valor possível de "p" nos testes estatísticos das RNAs.

Verificamos que os índices de vegetação que apresentaram correlação significativa e que foram usados como variáveis independentes no processo de estimativa da BAS na área de estudo, por meio do uso de redes neurais artificiais, são compostos pelas bandas do infravermelho e estão associados a bandas específicas do espectro visível (Figura 9).



**Figura 9-** Índices de vegetação GNDV, EVI e AFRI derivados de imagem Sentinel-2, adquirida em 2019, para a área de estudo.

### **5.3. Modelagem da biomassa**

#### **5.3.1. Treinamento das redes**

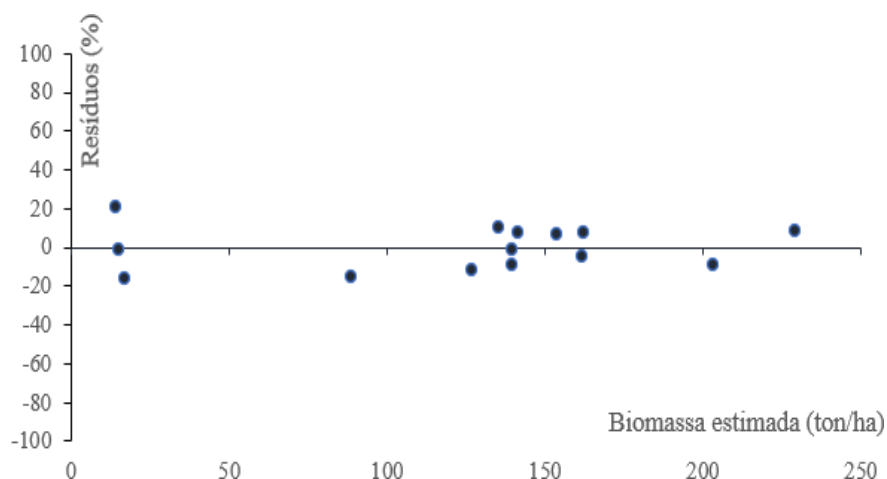
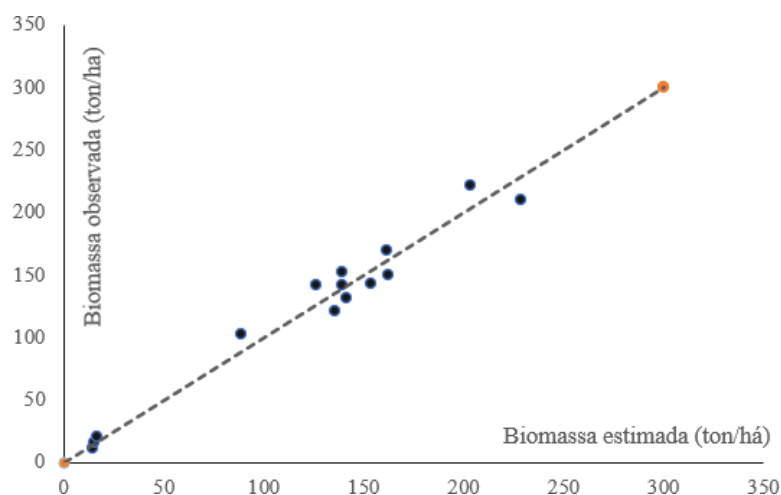
Considerando que as variáveis independentes AFRI, EVI e GNDVI foram utilizadas para treinar as redes neurais artificiais (RNAs), as cinco RNAs com melhor desempenho foram selecionadas com base em valores de coeficiente de correlação ( $r$ ) superiores a 0,90, e erros de estimativa inferiores a 14%, após o processo de validação. Uma análise minuciosa das estatísticas de ajuste e precisão revelou que a rede neural 1 apresentou a melhor capacidade preditiva para a biomassa acima do solo da vegetação, conforme evidenciado pelos valores de RMSE% (Tabela 7).

**Tabela 7-** Estatísticas de precisão das redes neurais artificiais selecionadas para predição da biomassa acima do solo para as parcelas LABEV-UNEMAT.

RNA	Arquitetura	Ativação		Ajuste	R	Validação	
		Oculto	Saída	RMSE%		RMSE%	R
1	MLP 3-14-1	Tang	Logistic	15,09	0,93	10,76	0,94
2	MLP 3-9-1	Exponential	Exponential	16,44	0,92	12,09	0,92
3	MLP 3-5-1	Exponential	Logistic	19,77	0,91	11,41	0,93
4	MLP 3-13-1	Tang	Exponential	18,53	0,92	11,62	0,93
5	MLP 3-7-1	Logistic	Identity	20,19	0,90	13,91	0,91

RNA = redes neurais artificiais; MLP = Multilayer perceptron (Perceptron multicamadas); RMSE = Root mean-SquareError (Raiz do erro quadrático médio); r = correlação entre os valores observados e estimados.

A análise dos resultados obtidos na rede neural artificial 1, indica que houve uma distribuição satisfatória dos resíduos (Figura 10A) e que a previsão da biomassa acima do solo (Figura 10B) foi precisa e consistente. Isso sugere que o modelo apresentou um bom ajuste, com uma minimização das diferenças entre os valores observados e previstos, sem qualquer viés significativo.

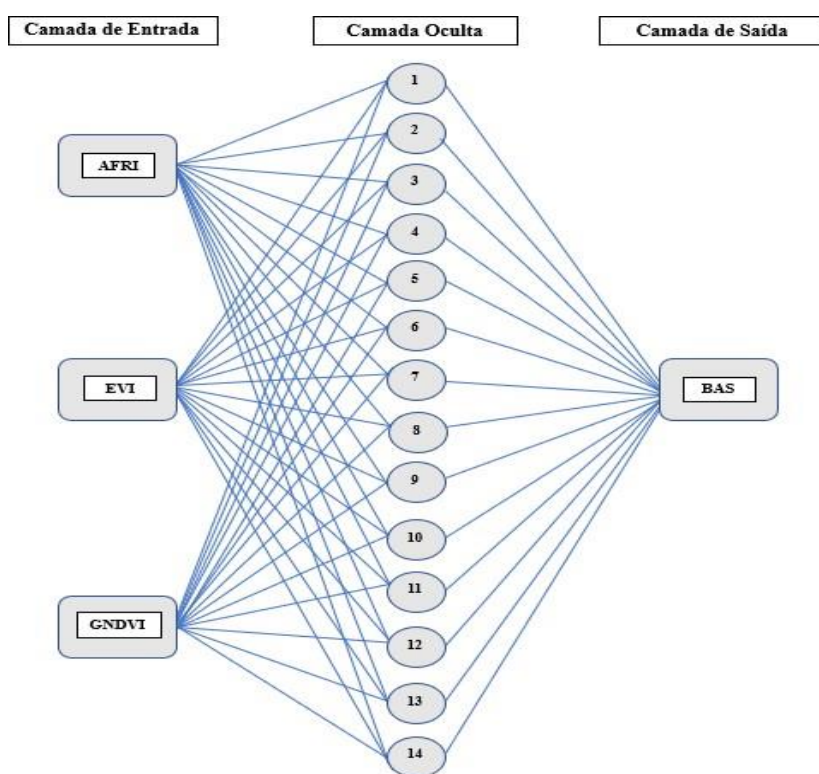


**Figura 10-** Valores observados e estimados (A) e distribuição de resíduos (B) para a RNA 1.



A precisão das estimativas da biomassa acima do solo é um indicador importante da eficácia do modelo utilizado. A obtenção de resultados precisos nessa área de transição de biomas, é crucial para a compreensão da vegetação e para o estabelecimento de políticas voltadas para a gestão sustentável dos recursos florestais.

A arquitetura da RNA 1 (Figura 11) foi estruturada em três camadas: a de entrada, composta por três neurônios que representam as variáveis predictoras (EVI, AFRI, GNDVI); uma camada oculta, que consiste em 14 neurônios, responsável pelo processamento dos dados, com ativação realizada por meio de uma função tangencial; e uma camada de saída, composta pela variável de interesse (BAS), com ativação realizada por meio de uma função logística.



**Figura 11-** Arquitetura da RNA 1, selecionada para a predição da biomassa acima do solo para a área de estudo.

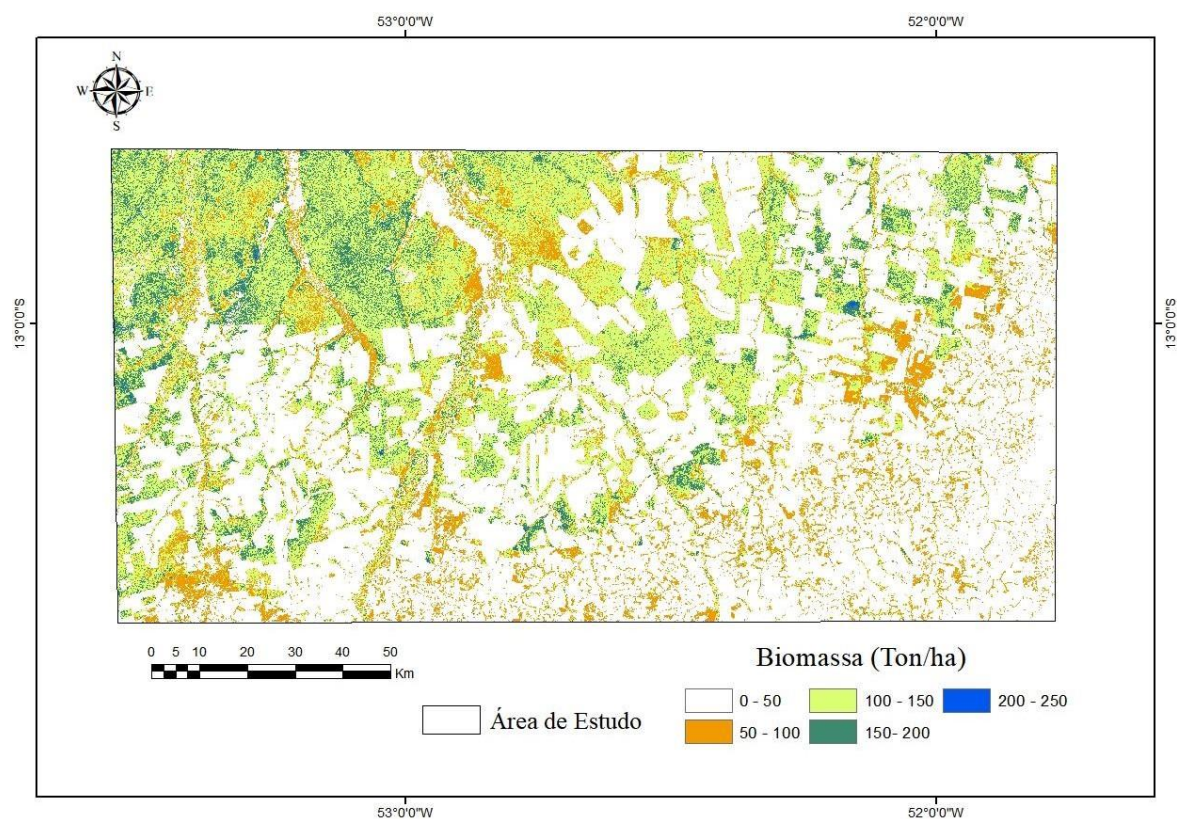
#### 5.4. Análise estatística

A aplicação do teste *t* de Student revelou que o valor *p* obtido para a rede neural selecionada foi maior que o nível de significância estabelecido ( $\alpha = 0,05$ ), especificamente  $p = 0,952$ . Isso quer dizer que não há dados estatísticos que sejam conclusivos para rejeitar a hipótese nula de que não existem diferenças entre os valores observados e os valores previstos pela rede neural para as parcelas de validação. Além disso, a análise da diferença agregada (DA) apontou uma leve tendência de superestimação dos valores previstos pela

rede neural, com um desvio de -0,1637%. No entanto, estes resultados são consistentes com as informações de precisão encontradas para a RNA durante o processo de treinamento, validando sua capacidade de realizar estimativas precisas para a BAS. Esse resultado sugere que as estimativas geradas pela RNA são precisas e confiáveis para a predição de Biomassa Aérea (BAS) em áreas de transição de biomas.

### 5.5. Análise da distribuição espacial da biomassa

Com base nos resultados obtidos a partir do treinamento das redes neurais, foi possível realizar uma expansão das estimativas de biomassa acima do solo (BAS) para toda a área coberta por vegetação nativa na região de interesse. Assim, a biomassa total da área de estudo, considerando o uso e cobertura do solo de vegetação nativa, foi estimada em 110.208.020 toneladas. Verificamos que a maior concentração de BAS ocorreu na faixa de 0 a 50 Ton.ha<sup>-1</sup>, seguida pela faixa de 100 a 150 Ton.ha<sup>-1</sup> (Figura 12).



**Figura 12-** Distribuição espacial da biomassa florestal estimada para a área de transição Amazônia-Cerrado. As áreas mais escuras indicam maior biomassa acima do solo, enquanto as áreas mais claras indicam menor biomassa.

## 6. DISCUSSÃO

### 6.1 Biomassa florestal

De modo geral, a Floresta apresenta maiores valores médios de biomassa acima do solo, DAP e altura, mas a variação em relação a essas medidas também é maior na Floresta. Essas diferenças podem estar relacionadas a diversos fatores, como as condições climáticas, geológicas e de solo, bem como às diferentes histórias de perturbação e uso da terra nas duas áreas (BUSTAMANTE et al., 2016).

Uma hipótese para explicar os valores mais baixos de biomassa acima do solo (BAS) na área de estudo é a forte influência das atividades antrópicas, especialmente a agricultura e a pecuária, que podem causar o efeito de borda do desmatamento e a degradação florestal nas áreas de vegetação nativa. Esses resultados evidenciam o impacto negativo dessas atividades na vegetação, ressaltando a necessidade de políticas públicas que promovam o uso sustentável do solo e a conservação dos ecossistemas naturais (SANTOS et. al, 2017).

É importante notar que, embora a soja seja uma cultura importante em termos econômicos, o seu cultivo pode ter impactos ambientais negativos, como o desmatamento de áreas naturais e a poluição do solo e da água com pesticidas e fertilizantes químicos. A categoria de pastagem ocupa quase 16% da área total, mostrando que a pecuária também é uma atividade importante na região. Novamente, é importante lembrar que a pecuária pode ter impactos ambientais significativos, incluindo a emissão de gases de efeito estufa e a degradação do solo e da água (SCREMIN; KEMERICH, 2010). As outras categorias, como a formação savânica, lavouras temporárias e campo alagado, ocupam áreas menores, mas ainda assim têm importância na composição da paisagem e na economia local.

Em geral, a distribuição de uso e cobertura da terra na área estudada mostra uma mistura de atividades agrícolas, pecuárias e florestais, refletindo a complexidade da paisagem e das atividades humanas em regiões rurais. No entanto, é importante considerar os possíveis impactos ambientais e sociais dessas atividades e buscar formas de conciliar o desenvolvimento econômico com a conservação dos recursos naturais e do meio ambiente (SILVA et. al, 2016).

O método de medição de biomassa através do sensoriamento remoto, tem vantagens em relação aos métodos tradicionais de medição em campo. Isso ocorre porque o sensoriamento remoto permite a obtenção de estimativas precisas da biomassa das florestas, em grandes áreas e em um menor período. Essa técnica também oferece a vantagem de possibilitar uma aplicação temporal, permitindo a monitorização da cobertura florestal em diferentes períodos



(SOENEN, 2010). Para interpretar os dados coletados de forma adequada e obter uma avaliação precisa das informações coletadas, é necessário compreender esses fatores em conjunto com as características da própria vegetação. Dessa forma, é possível entender adequadamente as características da vegetação em estudo e realizar uma estimativa precisa da biomassa (MIGUEL et al., 2015; KUMAR et al., 2015). Com o objetivo de aprimorar ainda mais as estimativas de biomassa florestal, o autor sugere a inclusão de um índice de altura da floresta, a fim de melhorar as estimativas em toda a faixa e reduzir os erros associados a altos valores de biomassa (SAATCHI, 2011).

## **6.2 Seleção das variáveis independentes - Índices de vegetação**

Os dados ópticos, obtidos a partir de sensores que detectam a reflectância na faixa do visível e do infravermelho, são afetados pelas características físicas das plantas, como a densidade, cobertura e pigmentação das folhas. Por outro lado, os dados de radar são mais sensíveis às propriedades elétricas e geométricas da vegetação, como a umidade e a estrutura tridimensional. Isso ocorre devido à diferença na natureza dos sinais emitidos pelos sensores ópticos e pelos radares (BISPO et al., 2020).

As bandas espectrais de borda vermelha, em conjunto com as faixas espectrais de cor vermelha e infravermelho próximo (NIR), foram identificadas como sendo sensíveis à variação na quantidade de biomassa durante as fases de crescimento vegetativo. Em contrapartida, as bandas espectrais de infravermelho de onda curta (SWIR) foram consideradas benéficas para incrementar a precisão na predição da biomassa principalmente em estágios de senescência (PORTER, 2014). Foi enfatizada através dos índices de vegetação a relevância do uso da banda do infravermelho de ondas curtas na compreensão das relações espectrais com a biomassa. Entretanto, é imprescindível salientar que essas relações manifestam variações sazonais em ambientes fenológicos diversos, ocasionadas pela menor influência das mudanças atmosféricas nas faixas de infravermelho de ondas curtas (ROY; RAVAN, 1996).

Neste estudo, descobrimos que os índices AFRI, EVI e GNDVI são os mais indicados em termos relação com o estoque de biomassa acima do solo. Esses índices já foram usados em outros estudos para medir a biomassa em florestas e, neste estudo em particular, foram aplicados em uma faixa na região de transição entre os biomas Cerrado e Amazônia. É importante ressaltar que os índices de vegetação usados como variáveis independentes usam diferentes faixas de luz do espectro eletromagnético em relação aos outros índices, o que

explica por que AFRI, EVI e GNDVI apresentaram as melhores correlações com a biomassa acima do solo na área estudada.

As correlações significativas observadas entre a Reflectância Verde (GREEN), pelo índice GNDVI, e a biomassa na área de estudo pode ser explicada pela variação do teor de clorofila e antocianinas nas folhas, os quais estão relacionados com o grau de desenvolvimento e maturidade da vegetação (MERZLYAK et al., 2008). Os índices vegetativos verdes (GVI) e de diferença normalizada verde (GNDVI), obtidos a partir de equações de reflectância, se correlacionam melhor com o teor de nitrogênio presente nas folhas da biomassa florestal em comparação com os índices vegetativos vermelhos (RVI) e de diferença normalizada vermelha (RNDVI), indicando uma maior sensibilidade na detecção das variações na vegetação (BRONSON, 2003). A combinação das bandas verde e infravermelho é crucial para a análise da biomassa acima do solo. Essas bandas atuam como descritores-chave neste índice, fornecendo informações confiáveis e precisas sobre a quantidade de biomassa em um determinado local (BARRACHINA, 2015).

A utilização da banda do espectro de ondas curtas do infravermelho próximo (SWIR) para calcular o índice AFRI tem se mostrado eficiente no monitoramento do conteúdo de água da vegetação e da biomassa seca, especialmente em áreas com baixa densidade vegetal. Esses resultados foram observados em áreas que passaram por processos de recuperação (HUANG, 2009). Além disso, neste estudo, verificou-se que o índice AFRI também apresentou uma correlação mais forte com a biomassa em áreas de transição entre biomas.

Os índices de vegetação, como NDVI e EVI, são comumente usados para monitorar a saúde da vegetação em diferentes regiões do mundo. No entanto, esses índices são influenciados por muitos fatores, incluindo a topografia do terreno. Nosso estudo constatou que o fator de ajuste do solo "L" teve um impacto maior no EVI em relação ao NDVI, tornando-o mais sensível às condições de topografia. Isso é especialmente importante em áreas acidentadas, onde o efeito topográfico pode ser significativo nos índices de vegetação que têm apenas um formato de razão de banda, como o NDVI (MATSUSHITA et al., 2007). A seleção de satélites para coleta de dados espectrais pode influenciar a precisão da estimativa de biomassa, no entanto, as imagens do satélite Sentinel-2 foram avaliadas como adequadas para a nossa análise. Bolas et al. (2021) relataram que a qualidade das imagens do sensor MSI/Sentinel-2, especificamente nas bandas com resolução de 10 m, reforça a utilidade deste satélite em pesquisas de avaliação da vegetação, comparando-se à qualidade de sensores aéreos com resolução de 0,13 m.

### 6.3 Treinamento das redes neurais

Os resultados indicam que as RNAs treinadas foram capazes de fornecer estatísticas de ajuste e precisão satisfatórias. Em particular, foram observados valores de coeficiente de correlação (R) superiores ou iguais a 0,9 e erros de estimativa de raiz quadrada média (RMSE) inferiores a 14%. A partir das cinco redes treinadas, foi selecionada a Rede 1, que apresentou um desempenho ainda melhor, com valores de  $R^2 = 0,94$  e  $RMSE\% = 10,76$ . Tais resultados sugerem que a Rede 1 é uma escolha promissora para a aplicação em questão. A estimativa de biomassa utilizando dados de sensoriamento remoto por satélite é uma abordagem viável para florestas naturais. Com base nos resultados obtidos no estudo de Güner et al. (2022), os modelos construídos para os componentes da biomassa total apresentaram valores de  $R^2 = 0,97$  e  $RMSE\% = 25,04$ . Os resultados obtidos a partir da simulação de dados de elevação de terreno (PCL) ao longo dos perfis do satélite ICESat-2 e Landsat, mostraram um potencial promissor para gerar um produto de estimativa da biomassa florestal com  $R^2 = 0,66$  (NARINE; POPESCU; MALAMBO, 2019). Esses resultados confirmam que os modelos criados nos estudos mencionados apresentam um bom desempenho para a estimativa da biomassa das árvores, com valores similares aos encontrados nesta pesquisa.

A determinação da capacidade preditiva da Rede Neural Artificial (RNA) escolhida pode ser estabelecida por meio da análise da relação entre os valores observados e preditos, o que permite avaliar a capacidade da rede neural selecionada em aderir aos dados reais. Além disso, a distribuição dos erros da RNA pode ser examinada para identificar possíveis padrões. Nesse sentido, observamos que a frequência de erros se concentrou majoritariamente nos intervalos de  $-1,5$  a  $-12\%$  e  $0$  a  $10\%$ . Verificamos também que a quantidade de erros que ultrapassaram o limite de  $\pm 16\%$  foi baixa. Os resultados também mostram que um tamanho de dados de treinamento de cerca de 60 subparcelas ou menos foi suficiente para garantir um bom ajuste do modelo funcional linear. Assim, a RNA em questão apresentou desempenho satisfatório na predição dos dados observados. Entretanto, é importante enfatizar que uma avaliação ampla e rigorosa deverá ser realizada para validar a eficácia da RNA em diferentes cenários.

A modelagem da biomassa arbórea consiste em minimizar os resíduos entre os valores medidos e preditos (ou seja, maximizar a eficiência do modelo) e, ao mesmo tempo, reduzir a diferença entre a biomassa total estimada e a soma da biomassa componente (ou seja, maximizar a compatibilidade do modelo). Essas medidas são utilizadas para avaliar a qualidade dos modelos de biomassa arbórea e podem ser aprimoradas por meio da aplicação

de técnicas estatísticas e de modelagem avançadas. Dessa forma, a modelagem da biomassa arbórea compatível é uma ferramenta importante para a gestão florestal sustentável e nas tomadas de decisões em relação à utilização dos recursos naturais (XU; LEI; ZHANG, 2022). Após a realização da modelagem utilizando RNA, a rede que apresentou os melhores resultados foi submetida ao teste *t* de Student para validação estatística. O resultado indicou a aceitação da hipótese nula de igualdade entre os valores observados e os preditos pela RNA. Diante desses resultados, conclui-se que as RNA's se apresentam como um método altamente eficaz e preciso para a estimativa de BAS em áreas de transição de biomas, utilizando índices de vegetação.

## 7. CONCLUSÕES

Os resultados deste estudo indicam uma boa correspondência entre a biomassa média estimada a partir dos dados do inventário florestal (125,44 ton.ha<sup>-1</sup>) e a biomassa média estimada pela modelagem utilizando redes neurais artificiais (123,493 ton.ha<sup>-1</sup>). Essa similaridade sugere que a utilização de índices de vegetação pode ser uma alternativa eficiente e precisa para a estimativa de biomassa florestal em grande escala. As maiores concentrações de biomassa na área de estudo foram observadas em áreas de floresta localizadas no bioma Amazônia, possivelmente devido às suas características fitofisionômicas, que promovem um maior acúmulo de biomassa em comparação com outras regiões.

Dentre os índices avaliados, EVI, AFRI e GNDVI apresentaram maior correlação com a biomassa florestal, sugerindo que esses índices podem ser utilizados como ferramentas promissoras para a estimativa dessa variável na região de estudo. A utilização desses índices em conjunto com outras técnicas, como o sensoriamento remoto e a modelagem por redes neurais artificiais, pode fornecer estimativas precisas de biomassa florestal e ser útil para a gestão e monitoramento ambiental da região.

Redes neurais artificiais (RNAs) são técnicas computacionais de aprendizado de máquina que têm sido utilizadas para a estimativa da biomassa florestal acima do solo (BAS) em diferentes regiões do mundo. No presente estudo, utilizamos RNAs do tipo *Multilayer Perceptron* (MLP) com funções de ativação tangencial e logística e o algoritmo de treino BFGS, em conjunto com índices de vegetação e diferentes fitofisionomias, para estimar a BAS por unidade de área. Além disso, apresentam uma vantagem em relação aos métodos convencionais de estimativa da BAS, pois permitem a obtenção de mapas de distribuição espacial da biomassa com alta resolução.

As RNAs associadas a dados de sensores remotos oferecem uma série de benefícios adicionais além da precisão na estimativa da biomassa florestal. Por exemplo, o uso dessas tecnologias pode acelerar o processo de coleta de dados, economizando tempo e recursos financeiros que seriam necessários para realizar inventários florestais tradicionais. Além disso, a capacidade em modelar relações complexas entre variáveis pode fornecer *insights* valiosos sobre as interações entre a vegetação e as condições ambientais. Essas informações podem ser usadas para orientar o manejo florestal sustentável e para ajudar a prever os impactos de mudanças ambientais futuras na biomassa florestal. Em resumo, os resultados sugerem que o uso de RNAs associadas a índices de vegetação e diferentes fitofisionomias é uma abordagem promissora para a estimativa da biomassa florestal.

Os resultados deste estudo são de grande importância para o monitoramento da biomassa florestal, inclusive para estimativas para o pagamento de serviços ambientais e para o desenvolvimento de políticas de conservação ambiental. Complementarmente, este estudo contribui para o avanço da compreensão dos processos ecológicos nas áreas de transição de biomas.

## 8. REFERÊNCIAS BIBLIOGRÁFICAS

- ABRAHAM, A. Artificial neural networks. **Handbook of measuring system design**, 2005.
- AHAMED, T. et. al. A Review of Remote Sensing Methods for Biomass Feedstock Production **Biomass and Bioenergy**, v. 35, n. 7, p. 2455-2469, 2011.
- ANDERSON, L.O. et al. Detecção de cicatrizes de áreas queimadas baseada no modelo linear de mistura espectral e imagens índice de vegetação utilizando dados multitemporais do sensor MODIS/TERRA no estado do Mato Grosso, Amazônia brasileira. **Acta Amazonica**, v. 35, n. 4, p. 445–456, 2005.
- AQUINO, C.M.S.; DIAS, A.A.; SANTOS, F.A. Análise temporal do NDVI da bacia hidrográfica do Rio Longá, Piauí. **Revista Formação**, v. 3, n. 23, p. 248-263, 2016.
- ARAÚJO, I. et al. Estrutura da vegetação de uma área minerada em restauração na transição Amazônia-Cerrado. **Ciências Agrárias: o avanço da ciência no Brasil**, v. 3, 2022.
- ASNER, G. P. et al. Ecosystem structure throughout the Brazilian Amazon from Landsat observations and automated spectral unmixing. **Earth Interactions**, v. 9, n. 7, 2005.
- BAKER, T.R.; PHILLIPS, O.L.; MALHI, Y.; ALMEIDA, S.; ARROYO, L.; DI FIORE, A.; ERWIN, T.; KILLEEN, T.J.; LAURANCE, S.G.; LAURANCE, W.F.; LEWIS, S.L.; LLOYD, J.; MONTEAGUDO, A.; NEILL, D.A.; PATIÑO, S.; PITMAN, N.C.A.; SILVA, J.N.M.; VÁSQUEZ MARTÍNEZ, R. Variation in wood density determines spatial patterns in Amazonian forest biomass. **Global Change Biology**, v. 10, p. 545–562, 2004.
- BALCH, J.K. et al. Size, species, and fire behavior predict tree and liana mortality from experimental burns in the Brazilian Amazon. **Forest Ecology and Management**, v. 261, p. 68- 77, 2011.
- BARNES, E.M. CLARKE, S. E. Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data. n. Proceedings of the 5th International Conference on Precision Agriculture, 2000.
- BARRACHINA, M. et al. Estimating above-ground biomass on mountain meadows and pastures through remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, v. 38, p. 184-192, 2015.
- BEDDOE, R. et al. Overcoming systemic roadblocks to sustainability: The evolutionary redesign of worldviews, institutions, and technologies. **Proceedings of the National Academy of Sciences**, v. 106, n. 8, p. 2483-2489, 2009. doi: 10.1073/pnas.0812570106.
- BERTIER, F; SILVA, R; NORA, G. Fire in the Woods, Danger for Real. Community Considerations About Using Fire in the Cerrado of Mato Grosso. **Rev. Rencima**, Edição Especial, v. 11, n.2, p. 144-157, 2020.

BISPO, P. C. et al. Woody aboveground biomass mapping of the Brazilian savanna with a multi-sensor and machine learning approach. **Remote Sensing**, v. 12, n. 17, p. 2685, 2020.

BOLLAS, N et al. Comparison of sentinel-2 and UAV multispectral data for use in precision agriculture: **An application from northern Greece**. *Drones*, v. 5, n. 2, p. 35, 2021.

BONINI, Isabelle. Transição Amazônia-Cerrado: Desmatamento e Colapso do Ciclo Hidrológico. 2019. 156 f. Tese (Doutorado em Ecologia e Conservação) - Universidade do Estado de Mato Grosso, Campus de Nova Xavantina, Nova Xavantina, MT, 2019.

BORATTO, I. M. P. **Aplicação dos índices de vegetação NDVI, SAVI e IAF na caracterização da cobertura vegetativa da região Norte de Minas Gerais**. 2013. 38 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Agrônômica) - Universidade Estadual de Montes Claros, Montes Claros, 2013.

BORSATO, D. et al. Aplicação de redes neurais artificiais na identificação de gasolinas adulteradas comercializadas na região de Londrina – Paraná. **Química Nova**, v. 32, n. 9, p. 2328-2332, 2009.

BRASIL. Governo Federal. Ministério da Ciência, Tecnologia e Inovações. Conselho Nacional de Desenvolvimento Científico e Tecnológico. **Programa de Pesquisas Ecológicas de Longa Duração**. Disponível em: <https://www.gov.br/cnpq/pt-br/aceso-a-informacao/acoes-e-programas/programas/peld>. Acessado em: 6 mai 2023.

BRASIL, L. S et al. Integridade ambiental e composição de espécies de libelinhas em riachos amazônicos na região do "arco do desmatamento", Mato Grosso, Brasil. **Acta Limnologica Brasiliensia**, v. 26, p. 278-287, 2014.

BRONSON, K. F et al. In-season nitrogen status sensing in irrigated cotton: II. Leaf nitrogen and biomass. **Soil Science Society of America Journal**, v. 67, n. 5, p. 1439-1448, 2003.

BULUT, S. Machine learning prediction of above-ground biomass in pure Calabrian pine (*Pinus brutia* Ten.) stands of the Mediterranean region, Türkiye. **Ecological Informatics**, v. 74, p. 101951, 2023.

BUSTAMANTE, M. C et al. Toward an integrated monitoring framework to assess the effects of tropical forest degradation and recovery on carbon stocks and biodiversity. **Global Change Biology**, v. 22, n. 1, p. 92-109, 2016.

CHAVE, J.; MULLER-LANDAU, H.C.; BAKER, T.R.; EASDALE, T.A.; TER STEEGE, H.; WEBB, C.O. Regional and phylogenetic variation of wood density across 2456 neotropical tree species. **Ecological Applications**, v. 16, p. 2356–2367, 2006.



CHAVE, J. et al. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global Change Biology**, v. 20, p. 3177-3190, 2014. Disponível em: <https://doi.org/10.1111/gcb.12629>. Acesso em: 09 mar. 2023.

COSTANZA, R. et al. The value of the world's ecosystem services and natural capital. **Nature**, v. 387, p. 253-260, 1997. Disponível em: <https://doi.org/10.1038/387253a0>. Acesso em: 08 mar. 2023.

CUNHA, M. V. Os periódicos em ciência da informação: uma análise bibliométrica. **Ciência e Informação**, v. 14, n. 1, p. 37-45, 1985.

CURRAN, P. J et al. Exploring the Relationship Between Reflectance Red Edge And ChlorophyllContent in Slash Pine. **Tree Physiol.**, v. 7, p. 33-48, 1990.

DORAN, J.W; PARKIN, T.B. Defining and assessing soil quality, in: Doran, J.W., Coleman, D.C., Bezdicek, D.F., Stewart, B.A., (Eds.).Defining soil quality for a sustainable environment. **Soil Science Society of America Journal**, p.3-21, 1994.  
DOI: <http://dx.doi.org/10.2136/sssaspepub35.c1>

EMBRAPA. Estoque de carbono e efeito estufa em floresta secundária de transição Amazônia-Cerrado. Sinop: EMBRAPA, 2021.  
Disponível em: <https://www.infoteca>. Acesso em: 11 jun. 2023.

EUROPEAN SPACE AGENCY (ESA). Sentinel online. Faltam dados aqui.... Disponível em: <<https://sentinel.esa.int/web/sentinel/missions>>. Acesso em: 28 jan. 2023.

FASSNACHT, F.E et. al. Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass, **Remote Sensing of Environment**, v. 154, p. 102-114, 2014.

FEARNSIDE, P. M. Brazil's Amazon forest and the global carbon problem. *Interciência*, v. 10, n. 4, p. 179-186, 1995.

FISCHER, D. R. et al. Previsão de Curto Prazo para Geração Fotovoltaica a partir de Dados Meteorológicos via RNA. In: **Congresso Brasileiro de Automática-CBA**. v. 2. n. 1, 2020.

FITZGERALD, G.; RODRIGUEZ, D.; O'LEARY, G. Measuring and predicting canopy nitrogen nutrition in wheat using a spectral index—The canopy chlorophyll content index (CCCI). **Field Crops Research**, v. 116, n. 3, p. 318–324, 2010.

FURTADO, M.I.V. **Redes neurais artificiais [recurso eletrônico]: uma abordagem para sala de aula**. – Ponta Grossa (PR): Atena Editora, 2019.

FLORENZANO, T. G. **Imagens de Satélite para Estudos Ambientais**. São Paulo, SP: Oficina de Textos, p.100, 2002.

FORESTPLOTS.NET; BLUNDO, C.; CARILLA, J.; GRAU, R.; MALIZIA, A.; MALIZIA, L.; OSINAGA-ACOSTA, O.; BIRD, M.; BRADFORD, M.; CATCHPOLE, D.; FORD, A.; GRAHAM, A.; HILBERT, D.; KEMP, J.; ...; TRAN, H.D. Taking the pulse of Earth's tropical forests using networks of highly distributed plots. **Biological Conservation**, v. 260, p. 108849, 2021. <https://doi.org/10.1016/j.biocon.2020.108849>

FORESTPLOTS.NET. **Sobre o ForestPlots**. Disponível em: <https://forestplots.net/pt/about-forest-plots>. Acesso em: 09 mar. 2023.

GARDNER, M.W; DORLING, S.R. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences, **Atmospheric Environment**, v. 32, n. 14–15, p. 2627-2636, 1998.

GITELSON, A. A et al. Use of a Green Channel in Remote Sensing of Global Vegetation from EOS-MODIS. **Remote Sens. Environ.**, v. 58, p. 289-298, 1996.

GITELSON, A. A.; MERZLYAK, M. N. Signature Analysis of Leaf Reflectance Spectra: Algorithm Development for Remote Sensing of Chlorophyll. **Journal of Plant Physiology**, v. 148, n. 3–4, p. 494–500, 1996.

GUIJAN, X et. al. Surface roughness prediction model of GH4169 superalloy abrasive belt grinding based on multilayer perceptron (MLP), **Procedia Manufacturing**, v. 4, p. 269–273, 2021.

GÜNER, Ş. T. et al. Employing artificial neural network for effective biomass prediction: an alternative approach. **Computers and Electronics in Agriculture**, v. 192, p. 106596, 2022.

HAYKIN, S. **Redes Neurais: Princípios e Prática [Neural Networks: principle and practice] (2nd edn)**. 2. ed. Porto Alegre, Brasil: Bookman, 2001.

HUANG, J. et al. Sub-pixel reflectance unmixing in estimating vegetation water content and dry biomass of corn and soybeans cropland using normalized difference water index(NDWI) from satellites. **International Journal of Remote Sensing**, v. 30, n. 8, p. 2075- 2104, 2009.

HUETE, A. R.; LIU, H. Q.; BATCHILY, K. A Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**, v. 44, n. 3, p. 165-178, 1994.

HUETE, A.; JUSTICE, C.; LIU, H. Development of vegetation and soil indices for MODIS-EOS. **Remote Sensing of Environment**, v. 49, n. 3, p. 224– 234, 1994.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295-309, 1988.

HUIMIAN, L et al. Prediction of Urban Forest Aboveground Carbon Using Machine Learning Based on Landsat 8 and Sentinel-2: A Case Study of Shanghai, China. **Remote Sensing**, v. 15, n. 1, p. 284, 2023.

IBGE, Instituto Brasileiro de Geografia e Estatística. Downloads - Geociências. Disponível em: <https://www.ibge.gov.br/geociencias/downloads-geociencias.html>. Acesso em: 13 abr. 2023.

ICMBIO, Instituto Chico Mendes de Conservação da Biodiversidade. Unidades de Conservação. Cerrado. Disponível em: <https://www.icmbio.gov.br/portal/unidadesdeconservacao/biomas-brasileiros/cerrado>. Acesso em: 18 mai. 2021.

INPE, Instituto Nacional de Pesquisas Espaciais. Coordenação Geral de Observação da Terra. PRODES – Incremento anual de área desmatada no Cerrado Brasileiro. Disponível em: <http://www.obt.inpe.br/cerrado>. Acesso em: 17 mai. 2021.

IVANAUSKAS, M. M. et al. Composição florística de trechos florestais na borda sul-amazônica. **Acta Amazônica**, v. 34, p. 399-413, 2004.

JACKSON, R; HUETE, A. Interpreting vegetation indices. **Preventive Veterinary Medicine**, v. 11, n. 3-4, p.185-200, 1991.

JENSEN, J. R. Introductory digital image processing: a remote sensing perspective. 2. ed. Upper Saddle River: Prentice-Hall, 1996.

KANG, Y. et al. Land cover and crop classification based on red edge indices features of GF-6 WFV time series data. **Remote Sensing**, v. 13, n. 22, p. 4522, 2021.

KARNIELI, A; YORAM, J. K; REMER, L. AFRI — Aerosol free vegetation index. **Remote Sensing of Environment**, v. 77, n. 1, p. 10–21, 2001.

KRALICEK et al, 2017. Simultaneous estimation of above-and below-ground biomass in tropical forests of Viet Nam. **For. Ecol. Manage.**, v. 390, p. 147-156, 2017.

KUMAR, L et al. Review of the use of remote sensing for biomass estimation to support renewable energy generation. **Journal of Applied Remote Sensing**, v. 9, n. 1, p. 097696-097696, 2015.

KUNG, S.Y. **Digital Neural Networks**. Prentice Hall, Englewood Cliffs, New Jersey 1993.

KUPLICH, M.T. et al. Time series of vegetation index for diferente vegetation types in Rio Grande do Sul. **Revista Brasileira Engenharia Agrícola Ambiental**, v.17, n.10, p.1116–1123, 2013.

LAL, R. Digging deeper: A holistic perspective of factors affecting soil organic carbon sequestration in agroecosystems. **Global Change Biology**, v. 24, n. 8, p. 3285-3301, 2018.

LAZZARETTI, P. et al. Produção de cultivares de almeirão sob diferentes telados e campo aberto em clima tropical. **Revista Ibero-Americana de Ciências Ambientais**, v. 12, n. 12, p. 45-52, 2021.

LEIVAS, J. F. et al. Standard Vegetation Index Assessment in the Indicative Monitoring of Droughts for Soybean Crops in the Southern Region of Brazil. **Rev. Brasileira de Cartografia**, n. 66/5, p. 1145-1155, 2014.

LEWIS, K. et al. Identifying hotspots for ecosystem restoration across heterogeneous tropical savannah-dominated regions. **Philosophical Transactions of the Royal Society B**, v. 378, n. 1867, p. 20210075, 2023.

LIANG, M. et al. Quantifying aboveground biomass dynamics from charcoal degradation in Mozambique using GEDI Lidar and Landsat. **Remote Sensing of Environment**, v. 284, p. 113367, 2023.

LIMA, G.C. et al. Avaliação da cobertura vegetal pelo índice de vegetação por diferença normalizada (IVDN). **Rev Ambiente & Água - An Interdisciplinary Journal of Applied Science**: v. 8, n.2, 2013.

LIMA, S K. R et al. The *Platonia insignis* Mart. as the Promising Brazilian ‘Amazon Gold’: The State-of-the-Art and Prospects. **Rev. Agriculture**, v. 12, n. 11, p. 1827, 2022.

LOPEZ-GONZALEZ, G.; BAKER, T.R.; LEWIS, S.L.; PEACOCK, J.; PHILLIPS, O.L. **Functional Trait Database**. ForestPlots, Date of extraction: 10th Dec 2022, 2006.

LOPEZ-GONZALEZ, G.; LEWIS, S.L.; BURKITT, M.; PHILLIPS, O.L. ForestPlots.net: a web application and research tool to manage and analyse tropical forest plot data. **Journal of Vegetation Science**, v. 22, p. 610–613, 2011.

LOURENÇO, R. W.; LANDIM P. M. B. Estudo da variabilidade do “índice de vegetação por diferença normalizada/NDVI” utilizando krigagem indicativa. In: **HALO Environment**, v. 4, n.1, p.38-55, 2004.

MAGALHAES, T. G. D. **O uso da biomassa na gestão do risco de incêndio florestal no concelho de Fafe**. Dissertação de Mestrado. Universidade do Porto, Porto, Portugal, 2006.

MATSUSHITA, B. et al. Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: a case study in high-density cypress forest. **Sensors**, v. 7, n. 11, p. 2636-2651, 2007.

MAPBIOMAS. **Desmatamento em 2021 aumentou 20%, com crescimento em todos os biomas**. Disponível em: <https://mapbiomas.org/desmatamento-em-2021-aumentou-20-com-crescimento-em-todos-os-biomas-1>. Acesso em: 08 março 2023.

MAPBIOMAS. **Visão geral da metodologia**. Disponível em: <https://mapbiomas.org/visao-geral-da-metodologia>. Acesso em: 13 de abril de 2023.

MARIMON, B.S. et al. Observations on the vegetation of northeastern Mato Grosso, Brazil. IV. An analysis of the Cerrado-Amazonian forest ecotone. **Edinburgh Journal of Botany**, v. 63, n. 2-3, p. 323-341, 2006.

MARIMON, B.S.; MARIMON-JUNIOR, B.H.; FELDPAUSCH, T.R.; OLIVEIRA-SANTOS, C.; MEWS, H.A.; LOPEZ-GONZALEZ, G.; FRANCAZAK, D.D.; OLIVEIRA, E.A.; MARACAHIPES, L.; MIGUEL, A.; LENZA, E.; PHILLIPS, O.L. Disequilibrium and hyperdynamic tree turnover at the forest-savanna transition zone in southern Amazonia. **Plant Ecology & Diversity**, v. 7, n. 1-2, p. 281-292, 2014.

MARQUES, E.Q.; MARIMON-JUNIOR, B.H.; MARIMON, B.S.; MATRICARDI, E.A.T.; MEWS, H.A.; COLLI, G.R. Redefining the Cerrado–Amazonia transition: implications for conservation. **Biodiversity and Conservation**, v. 29, p. 1501–1517, 2020.

MATRICARDI, E. A. T et al. Assessment of tropical forest degradation by selective logging and fire using Landsat imagery. **Remote Sensing of Environment**, v. 114, n. 5, p. 1117-1129, 2010.

McCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.

MERZLYAK, M. N et al. Absorção de luz por antocianinas em folhas juvenis, estressadas e senescentes. **Journal of Experimental Botany**, v. 59, n. 14, p. 3903–3911, 2008.

MIGUEL, E. P. et al. Artificial neural networks for modeling wood volume and aboveground biomass of tall Cerrado using satellite data. **Pesquisa Agropecuária Brasileira**, v. 50, p. 829-839, 2015.

MORANDI, P.S.; MARIMON, B.S.; EISENLOHR, P.V.; MARIMON-JUNIOR, B.H.; OLIVEIRA-SANTOS, C.; FELDPAUSCH, T.R.; OLIVEIRA, E.A.; REIS, S.M.; LLOYD, J.; PHILLIPS, O.L. Patterns of tree species composition at watershed-scale in the Amazon ‘arc of deforestation’: Implications for conservation. **Environmental Conservation**, v. 43, n. 4, p. 317–326, 2016

MOREIRA, M. A. Fundamentos do sensoriamento remoto e metodologias de aplicação, 2. ed., Viçosa: UFV, 307 p., 2003.

NAIK, P.; DALPONTE, M.; BRUZZONE, L. Prediction of forest aboveground biomass using multitemporal multispectral remote sensing data. **Remote Sensing**, v. 13, n. 7, p. 1282, 2021.

NARINE, L. L.; POPESCU, S. C.; MALAMBO, L. Synergy of ICESat-2 and Landsat for mapping forest aboveground biomass with deep learning. **Remote Sensing**, v. 11, n. 12, p. 1503, 2019.

NASCIMENTO, J. et al. Balanço de Carbono, Aquecimento Global e Recuperação Áreas Degradadas. **Revista Verde**. v. 6, n. 2, p. 14, 2011.

NAVARRO, G et al. Evaluation of forest fire on Madeira Island using Sentinel-2A MSI imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 58, p. 97-106, 2017.

NIED, A. **Treinamento de redes neurais artificiais baseado em sistemas de estrutura variável com taxa de aprendizado adaptativa**. 2007. Belo Horizonte, MG. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais.

NUNES, E. E et al. Study of energy alternatives based on renewable generation sources for the electrification of isolated systems in the Amazon. **Brazilian Journal of Development**, v. 08, p. 56323-56329, 2022.

NOGUEIRA, D.S., MARIMON, B.S., MARIMON-JUNIOR, B.H., OLIVEIRA, E.A., MORANDI, P., REIS, S.M., ELIAS, F., NEVES, E.C., FELDPAUSCH, T.R., LLOYD, J., PHILLIPS, O.L. Impacts of Fire on Forest Biomass Dynamics at the Southern Amazon Edge. **Environmental Conservation** v. 46, p. 285–292, 2019.

NOVO, E. et al. Advanced remote sensing techniques for global changes and Amazon ecosystem functioning studies. **Revista Acta Amazônica**, v. 35, n. 2, p. 259 – 272, 2005.

PEEL, M. C et al. Updated world map of the Köppen-Geiger climate classification. *Hydrology and Earth System Sciences*, 11, 1633-1644. Acesso em: <http://dx.doi.org/10.5194/hess-11-1633-2007>.

PHILLIPS, O.; BAKER, T.; FELDPAUSCH, T.R.; BRIENEN, R. **RAINFOR Field Manual for plot establishment and remeasurement**. 2021. Disponível em: [https://forestplots.net/upload/ManualsEnglish/RAINFOR\\_field\\_manual\\_EN.pdf](https://forestplots.net/upload/ManualsEnglish/RAINFOR_field_manual_EN.pdf).

PIETRZYKOWSK, M et al., 2021. Carbon sink potential and allocation in above- and below-ground biomass in willow coppice. **J. For. Res.**, v. 32, p. 349-354, 2021.

PITTA, F. T.; VEGA, G. C. **Impactos da expansão do agronegócio no Matopiba: comunidades e meio ambiente**. 1. ed. Rio de Janeiro, RJ: Mórula, 2017.

- PORTER, Tucker F. et al. Estimating biomass on CRP pastureland: A comparison of remote sensing techniques. **Biomass and Bioenergy**, v. 66, p. 268-274, 2014.
- QI, J et al. A modified soil adjusted vegetation index. **Remote Sensing of Environment**, v. 48, n. 2, p. 119-126, 1994.
- RAINFOR. **Rede Amazônica de Inventários Florestais**. Disponível em: <<https://rainfor.org/pt/>> Acesso em: 29 jan. 2023.
- RATTER, J.A.; RICHARDS, P.W.; ARGENT, G.; GIFFORD, D.R. Observations on the vegetation of northeastern Mato Grosso: I. The woody vegetation types of the Xavantina-Cachimbo Expedition area. **Philosophical Transactions of the Royal Society of London. Series B, Biological Sciences**, v. 266, n. 880, p. 449-492, 1973.
- REIS, L. P et al. Modeling of tree recruitment by artificial neural networks after wood harvesting in a forest in eastern Amazon rain forest. **Ciência Florestal**, v. 29, p. 583-594, 2019.
- REIS, S.M., MARIMON, B.S., ESQUIVEL-MUELBERT, A., MARIMON JR, B.H., MORANDI, P.S., ELIAS, F., DE OLIVEIRA, E.A., GALBRAITH, D., FELDPAUSCH, T.R., MENOR, I.O., MALHI, Y., PHILLIPS, O.L., 2022. Climate and crown damage drive tree mortality in southern Amazonian edge forests. **Journal of Ecology**, v. 110, n. 4, p. 876–888.
- REZENDE, A. et al. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado sensu stricto em Brasília, DF. **Scientia Forestalis**, p. 65–76, 2006.
- RIBEIRO, J.F; WALTER, B.M.T. **Diversidade, fitofisionomias e o papel do fogo no bioma Cerrado**, IBAMA, 2010.
- RODRIGUES, H.O. et al. Dinamica EGO, uma plataforma para modelagem de sistemas ambientais. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, Brasil, INPE, p. 3089-3096, abril 2007.
- ROUSE, J. W. et al. Monitoring the vernal advancement and retrogradation (greenwave effect of natural vegetation). **Remote Sensing Center**, 1974.
- ROY, P. S.; RAVAN, S. Biomass estimation using satellite remote sensing data—an investigation on possible approaches for natural forest. **J. Biosci.**, v. 21, n. 4, p. 535-561, 1996.
- SAATCHI, S. et al. Impact of spatial variability of tropical forest structure on radar estimation of aboveground biomass. **Remote Sensing of Environment**, v. 115, n. 11, p.

2836-2849, 2011.

SANQUETTA, C. R et al. Estoque de biomassa e carbono em pastagens cultivadas no norte de Rondônia. **Biofix Scientific Journal**, v. 5, n. 1, p. 102-107, 2020.



SANTOS, T. et al. Os impactos do desmatamento e queimadas de origem antrópica sobre o clima da Amazônia brasileira: um estudo de revisão. **Revista Geográfica Acadêmica**, v. 11, n. 2, p. 157-181, dez. 2017.

SCREMIN, A. P; KEMERICH, P. D. C. Impactos ambientais em propriedade rural de atividade mista. *Disc. Scientia. Série: Ciências Naturais e Tecnológicas*, Santa Maria, v. 11, n. 1, p. 126-148, 2010.

SHIBLEE, Md. et al. Learning of geometric mean neuron model using resilient propagation algorithm. **Expert Systems with Applications**, v. 37, n. 12, p. 7449-7455, 2010.

SILVA, F et al. Sensoriamento Remoto para Detecção de Queimadas no Cerrado Maranhense: Uma Aplicação no Parque Estadual do Mirador. **Rev. Geogr. Acadêmica**, v.13, n. 2, p. 90-105, 2019.

SILVA, F. L. et al. Dimensões do Uso e Cobertura da Terra nas Mesorregiões do Estado do Pará. **Espacios**, Vol. 37 (Nº 05), p. 5, 2016.

SIQUEIRA, J. G et al. Strategic planning to mitigate mining impacts on protected areas in the Brazilian Amazon. **Rev. Nature Sustainability**, v. 5, n. 10, p. 853-860, 2022.

SNIF - Sistema Nacional de Informações Florestais. Tipologias Florestais. Disponível em: <https://snif.florestal.gov.br/pt-br/conhecendo-sobre-florestas/168-tipologias-florestais#:~:text=%C3%81reas%20de%20tens%C3%A3o%20ecol%C3%B3gica,se%20interpenetram%2C%20formando%20comunidades%20indiferenciadas>. Acesso em: 11 jun. 2023.

SOENEN, S. A. et al. Estimating aboveground forest biomass from canopy reflectance model inversion in mountainous terrain. **Remote Sensing of Environment**, v. 114, n. 7, p. 1325-1337, 2010.

STATSOFT. **Comparativo de versões do software Statistica**. Disponível em: [http://www.statsoft.com.br/ftp/COMP\\_VERS\\_STATISTICA.pdf](http://www.statsoft.com.br/ftp/COMP_VERS_STATISTICA.pdf). Acesso em: 20 mar. 2023.

VOSS, Andreas et al. Cognitive processes in associative and categorical priming: a diffusion model analysis. **Journal of Experimental Psychology: General**, v. 142, n. 2, p. 536, 2013.

WWF, WWF-World Wide Fund For Nature. Disponível em: [https://www.wwf.org.br/informacoes/noticias\\_meio\\_ambiente\\_e\\_natureza/76383/Amazonia-e-Cerrado-somam-967-do-desmatamento-no-pais#:~:text=A%20velocidade%20m%C3%A9dia%20de%20desmatamento,3%20hectares%20destru%C3%ADdos%20por%20dia.>](https://www.wwf.org.br/informacoes/noticias_meio_ambiente_e_natureza/76383/Amazonia-e-Cerrado-somam-967-do-desmatamento-no-pais#:~:text=A%20velocidade%20m%C3%A9dia%20de%20desmatamento,3%20hectares%20destru%C3%ADdos%20por%20dia.>). Acesso em: 15 abril de 2021.

XU, Q.; LEI, X.; ZHANG, H. A novel method for approaching the compatibility of tree biomass estimation by multi-task neural networks. **Forest Ecology and Management**, v. 508, p. 120011, 2022.

YAN, E. et al. Phenology-based classification of vegetation cover types in Northeast China using MODIS NDVI and EVI time series. **Rev. International Journal of Remote Sensing**. v. 36, n. 2, p. 489-512, 2015.

ZHANG, Y. et al. A new strategy for improving the accuracy of forest aboveground biomass estimates in an alpine region based on multi-source remote sensing. **GIScience & Remote Sensing**, v. 60, n. 1, p. 2163574, 2023.

ZHAO, K et al. Lidar remote sensing of forest biomass: A scale-invariant estimation approach using airborne lasers. **Remote Sensing of Environment**, v. 113, n. 1, p. 182-196, 2009.

## 9. ANEXO

**Anexo I.** Valores de Biomassa estimados por inventario florestal da RAINFOR e índices de vegetação usados como variáveis preditoras.

<b>Amostras_RAINFOR</b>	<b>Biomassa (ton/há)</b>	<b>AFRI</b>	<b>EVI</b>	<b>Gndvi</b>	<b>EVI2</b>	<b>MSAVIaf</b>	<b>MSAVI</b>	<b>NDRE</b>	<b>NDVI</b>	<b>SAVI</b>
<b>FLO-01-1</b>	188,945	0,617	0,665	0,598	0,451	0,391	0,690	0,557	0,740	0,478
<b>FLO-01-2</b>	161,807	0,610	0,656	0,593	0,444	0,382	0,667	0,548	0,735	0,472
<b>FLO-01-3</b>	112,828	0,612	0,672	0,603	0,455	0,389	0,707	0,568	0,743	0,481
<b>FLO-01-4</b>	144,047	0,615	0,671	0,604	0,455	0,393	0,691	0,570	0,737	0,481
<b>FLO-01-5</b>	106,721	0,611	0,656	0,596	0,444	0,382	0,665	0,561	0,735	0,471
<b>FLO-02-1</b>	144,238	0,582	0,637	0,588	0,426	0,347	0,623	0,549	0,730	0,457
<b>FLO-02-2</b>	107,569	0,594	0,651	0,595	0,434	0,360	0,656	0,558	0,740	0,464
<b>FLO-02-3</b>	99,950	0,596	0,650	0,594	0,434	0,360	0,657	0,553	0,741	0,464
<b>FLO-02-4</b>	140,764	0,602	0,652	0,595	0,437	0,367	0,676	0,553	0,745	0,467
<b>FLO-02-5</b>	98,352	0,599	0,659	0,592	0,440	0,367	0,677	0,558	0,744	0,470
<b>FSJ-01-1</b>	17,871	0,484	0,497	0,503	0,334	0,254	0,381	0,409	0,616	0,369
<b>FSJ-01-2</b>	14,353	0,404	0,427	0,469	0,255	0,175	0,318	0,329	0,535	0,289
<b>FSJ-01-3</b>	15,776	0,399	0,410	0,461	0,243	0,167	0,297	0,315	0,524	0,278
<b>FSJ-01-4</b>	15,526	0,395	0,411	0,461	0,242	0,162	0,299	0,315	0,531	0,278
<b>FSJ-01-5</b>	15,296	0,408	0,421	0,463	0,250	0,175	0,312	0,328	0,532	0,284
<b>GAU-02-1</b>	157,857	0,627	0,639	0,602	0,441	0,389	0,691	0,547	0,747	0,470
<b>GAU-02-2</b>	157,958	0,636	0,656	0,610	0,453	0,406	0,725	0,559	0,752	0,481
<b>GAU-02-3</b>	153,810	0,643	0,674	0,618	0,466	0,417	0,792	0,565	0,764	0,491
<b>GAU-02-4</b>	150,448	0,652	0,700	0,623	0,483	0,437	0,865	0,569	0,771	0,506
<b>GAU-02-5</b>	135,506	0,632	0,651	0,607	0,451	0,399	0,734	0,553	0,753	0,478
<b>GAU-03-1</b>	17,159	0,451	0,451	0,492	0,310	0,223	0,345	0,405	0,603	0,347
<b>GAU-03-2</b>	22,434	0,457	0,454	0,496	0,313	0,228	0,350	0,411	0,606	0,350
<b>GAU-03-3</b>	23,491	0,457	0,456	0,495	0,315	0,229	0,352	0,407	0,604	0,351
<b>GAU-03-4</b>	21,531	0,453	0,447	0,489	0,309	0,224	0,342	0,397	0,599	0,345
<b>GAU-03-5</b>	20,331	0,452	0,443	0,485	0,306	0,223	0,337	0,391	0,595	0,342
<b>GAU-04-1</b>	152,090	0,541	0,501	0,535	0,346	0,286	0,423	0,470	0,654	0,382

<b>GAU-04-2</b>	229,094	0,680	0,656	0,651	0,483	0,431	0,601	0,598	0,782	0,516
<b>GAU-04-3</b>	200,626	0,554	0,518	0,536	0,355	0,296	0,444	0,472	0,668	0,392
<b>GAU-04-4</b>	203,476	0,571	0,562	0,555	0,389	0,331	0,520	0,502	0,679	0,421
<b>GAU-04-5</b>	218,289	0,663	0,658	0,663	0,484	0,415	0,622	0,611	0,748	0,518
<b>GAU-05-1</b>	109,253	0,520	0,457	0,517	0,314	0,247	0,374	0,477	0,657	0,354
<b>GAU-05-2</b>	126,693	0,543	0,512	0,546	0,353	0,281	0,451	0,482	0,688	0,391
<b>GAU-05-3</b>	174,297	0,540	0,508	0,545	0,351	0,276	0,450	0,486	0,693	0,389
<b>GAU-05-4</b>	154,383	0,552	0,532	0,549	0,367	0,294	0,484	0,489	0,697	0,404
<b>GAU-05-5</b>	162,409	0,547	0,543	0,553	0,376	0,298	0,508	0,490	0,699	0,412
<b>GAU-06-1</b>	206,367	0,562	0,567	0,577	0,391	0,317	0,554	0,528	0,709	0,425
<b>GAU-06-2</b>	249,405	0,661	0,661	0,665	0,487	0,417	0,631	0,621	0,745	0,520
<b>GAU-06-3</b>	256,727	0,613	0,611	0,648	0,450	0,367	0,552	0,594	0,778	0,487
<b>GAU-06-4</b>	145,665	0,303	0,392	0,460	0,275	0,149	0,282	0,303	0,522	0,309
<b>GAU-06-5</b>	331,378	0,384	0,457	0,555	0,366	0,257	0,371	0,400	0,544	0,393
<b>GAU-07-1</b>	79,984	0,592	0,627	0,599	0,435	0,362	0,655	0,561	0,735	0,464
<b>GAU-07-2</b>	77,892	0,569	0,578	0,578	0,400	0,325	0,555	0,538	0,714	0,433
<b>GAU-07-3</b>	88,844	0,571	0,567	0,580	0,392	0,322	0,534	0,543	0,708	0,426
<b>GAU-07-4</b>	75,765	0,576	0,575	0,585	0,398	0,328	0,562	0,548	0,716	0,431
<b>GAU-07-5</b>	105,529	0,589	0,595	0,596	0,413	0,345	0,600	0,569	0,726	0,445
<b>TAN-02-1</b>	135,540	0,612	0,680	0,591	0,451	0,382	0,725	0,559	0,755	0,479
<b>TAN-02-2</b>	150,668	0,606	0,662	0,587	0,440	0,371	0,690	0,556	0,748	0,469
<b>TAN-02-3</b>	139,470	0,585	0,629	0,575	0,416	0,342	0,615	0,542	0,735	0,448
<b>TAN-02-4</b>	66,561	0,584	0,635	0,576	0,420	0,345	0,622	0,543	0,733	0,452
<b>TAN-02-5</b>	139,417	0,590	0,647	0,580	0,428	0,353	0,649	0,553	0,738	0,459
<b>TAN-03-1</b>	139,313	0,607	0,558	0,584	0,383	0,332	0,541	0,565	0,731	0,420
<b>TAN-03-2</b>	167,192	0,602	0,547	0,576	0,376	0,326	0,521	0,559	0,723	0,414
<b>TAN-03-3</b>	145,834	0,595	0,549	0,576	0,376	0,320	0,518	0,551	0,723	0,414
<b>TAN-03-4</b>	137,937	0,606	0,564	0,588	0,389	0,336	0,554	0,565	0,732	0,426
<b>TAN-03-5</b>	127,052	0,607	0,569	0,584	0,391	0,339	0,561	0,556	0,732	0,427
<b>TAN-04-1</b>	139,609	0,594	0,527	0,567	0,362	0,310	0,485	0,556	0,716	0,401

<b>TAN-04-2</b>	141,376	0,586	0,519	0,568	0,356	0,299	0,474	0,549	0,715	0,395
<b>TAN-04-3</b>	106,829	0,583	0,519	0,567	0,358	0,302	0,474	0,550	0,708	0,396
<b>TAN-04-4</b>	111,513	0,590	0,545	0,579	0,375	0,317	0,513	0,555	0,720	0,413
<b>TAN-04-5</b>	85,656	0,570	0,520	0,560	0,358	0,294	0,474	0,538	0,707	0,396

---

