

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

**PREDIÇÃO DA BIOMASSA USANDO REDES NEURAIAS ARTIFICIAIS E  
SENSORIAMENTO REMOTO EM FLORESTAS NA AMAZÔNIA**

Adyne Cardoso da Costa

Orientador: Dr. José Roberto Rodrigues Pinto

Coorientador: Dr. Eraldo Aparecido Trondoli Matricardi

**Brasília**  
**Distrito Federal – Brasil**  
**Junho de 2022**

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

**ADYNE CARDOSO DA COSTA**

**PREDIÇÃO DA BIOMASSA USANDO REDES NEURAS ARTIFICIAIS E  
DADOS DE SENSORIAMENTO REMOTO EM FLORESTAS NA AMAZÔNIA**

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: JOSÉ ROBERTO RODRIGUES PINTO

COORIENTADOR: Dr. ERALDO APARECIDO TRONDOLI MATRICARDI

**DISSERTAÇÃO DE MESTRADO EM CIÊNCIAS FLORESTAIS**

**PUBLICAÇÃO: 06/2022**

**BRASÍLIA/ DF, 24 DE JUNHO DE 2022**

# PREDIÇÃO DA BIOMASSA USANDO REDES NEURAIIS ARTIFICIAIS E SENSORIAMENTO REMOTO EM FLORESTAS NA AMAZÔNIA

ADYNE CARDOSO DA COSTA

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. José Roberto Rodrigues Pinto  
(Departamento de Engenharia Florestal, UnB); (Orientador)

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

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

Prof. Dr. Ben Hur Marimon Júnior  
(Universidade Estadual de Mato Grosso - UNEMAT)

Brasília-DF, 24 de junho de 2022

## FICHA CATALOGRÁFICA

CC838p	Cardoso da Costa, Adyne Predição da biomassa usando redes neurais artificiais e sensoriamento remoto em florestas na Amazônia / Adyne Cardoso da Costa; orientador José Roberto Rodrigues Pinto ; co-orientador Eraldo Aparecido Trondoli Matricardi . -- Brasília, 2022. 66 p.
	Dissertação (Mestrado - Mestrado em Ciências Florestais) - Universidade de Brasília, 2022.
	1. Estoque de biomassa florestal. 2. Floresta Amazônica. 3. Índices de vegetação. 4. Redes neurais artificiais. 5. Sensoriamento Remoto. I. Roberto Rodrigues Pinto , José , orient. II. Aparecido Trondoli Matricardi , Eraldo , co orient. III. Título.

## REFERÊNCIA BIBLIOGRÁFICA

COSTA, A.C. 2022. **Predição da biomassa usando redes neurais artificiais e sensoriamento remoto em florestas na Amazônia.** Dissertação de Mestrado em Ciências Florestais, Publicação PPGEFL.DM-06/2022. Departamento de Engenharia Florestal, Universidade de Brasília, Brasília, DF, 66p.

## **CESSÃO DE DIREITOS**

AUTOR: Adyne Cardoso da Costa

**TÍTULO: Predição da biomassa usando redes neurais artificiais e sensoriamento remoto em florestas na Amazônia.**

GRAU: Mestre

ANO: 2022

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.

---

Adyne Cardoso da Costa  
adynecosta@gmail.com

Dedico este trabalho a Deus, que me deu a vida e criou os céus e a terra. Meu Senhor, meu escudo e minha fortaleza. Nada eu seria se não fosse o seu imenso amor.

À minha mãe, Sonia, e à minha irmã, Dayane, que estão sempre ao meu lado me apoiando e tornando a minha vida mais alegre, completa e digna.

Aos professores e orientadores de toda minha vida acadêmica, em especial ao professor Eraldo, por todo apoio, paciência e conhecimento compartilhado. Eu não teria chegado aqui se não fosse por vocês.

Ao meu namorado, Leonardo, por toda a paciência, amor e gentileza demonstrados sempre. Por ser um grande amigo, conselheiro e parceiro de vida.

Aos meus amigos, Gabrielle e Luan, por todas as palavras ditas nos momentos certos, pelas orações e pela presença de vocês na minha vida pessoal e acadêmica. Suas incessantes palavras me tranquilizaram e me deram força durante a realização deste trabalho.

A todos os pesquisadores que vivem para construir conhecimento, que se arriscam e desvendam mistérios infinitos do mundo acadêmico.

*“Se aqui eu cheguei é porque eu tive fé,  
bons líderes, bons aliados e determinação”.*

**(Brené Brown)**

## AGRADECIMENTOS

Agradeço a Deus, meu Senhor, por cuidar de mim durante toda a trajetória da minha vida até aqui, por cada experiência vivida e por cada vitória conquistada. Graças a Ele eu sou mais forte e mais feliz.

À minha mãe Sonia e irmã Dayane, que acompanharam e apoiaram toda a minha trajetória acadêmica, desde os tempos de escola.

Ao meu namorado Leonardo, pelo apoio, paciência e torcida. Obrigada por ser sempre tão compreensivo e por acreditar em mim até quando eu mesma não me achei capaz o suficiente.

Ao meu orientador José Roberto Rodrigues Pinto, pelos conhecimentos transmitidos por mostrar-se sempre disposto a auxiliar no que fosse necessário.

Ao meu coorientador Eraldo Aparecido Trondoli Matricardi, pela oportunidade de trabalhar com os dados do Projeto de Assentamento Extrativista Juruti Velho, pela orientação presente e cuidadosa e pela disposição constante em ajudar. Tenho certeza que ganhei um amigo para toda vida.

Ao professor Éder Pereira Miguel pelo apoio no desenvolvimento desse trabalho e pela disposição e paciência que demonstrou em ajudar. Sem a sua orientação não seria possível realizar um trabalho tão robusto e preciso.

À colega de faculdade, Gabrielle Xavier, que iniciou as pesquisas com os dados do inventário utilizados por mim neste trabalho. Aos Engenheiros Florestais Wilson Soares Abdala e Vilmar Ferreira pela condução dos trabalhos de Inventário Florestal no PAE Juruti Velho. Ao Engenheiro Florestal André Stella pelo apoio na interpretação e análise dos dados do inventário florestal. Sem o apoio destes profissionais, a presente pesquisa não teria sido realizada.

Aos meus amigos e amigas que me apoiaram e acreditaram em mim quando ingressei na pós-graduação. Obrigada pelas palavras de força e pelas orações.

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.



## RESUMO

As florestas tropicais estocam quantidade muito significativa de carbono orgânico em sua biomassa aérea e subterrânea. A mensuração da biomassa florestal é uma atividade laboriosa e demanda muito tempo e recursos financeiros para sua implementação. Portanto, tem sido crescente o interesse de muitos pesquisadores em desenvolver novas técnicas para quantificar a biomassa em ecossistemas naturais. No presente estudo, desenvolveu-se um modelo para a estimativa da biomassa florestal acima do solo (BFAS) em florestas tropicais a partir de dados de sensoriamento remoto e redes neurais artificiais ajustados e validados com base em dados de campo. Quatro índices de vegetação, derivados de imagens do Satélite Landsat-5 TM, foram testados e avaliados estatisticamente em suas correlações com a biomassa obtida do inventário florestal. Os resultados indicaram os índices de vegetação *Normalized Difference Vegetation Index* (NDVI) e *Aerosol Free Vegetation Index* (AFRI) como os melhores em desempenho na estimativa da BFAS. A partir daí foram treinadas 286 RNAs usando como dados de entrada o NDVI, o AFRI e a estratificação da área em duas fitofisionomias – Floresta Ombrófila Densa de Terras Baixas e Floresta Ombrófila Densa Sub-montana. A seleção da RNA mais adequada foi feita segundo os critérios da análise gráfica do erro residual e do coeficiente de correlação do modelo. Por fim, a validação da RNA selecionada foi feita a partir da análise dos resultados do teste *t* de Student e da diferença agregada entre os valores preditos pela rede neural e os valores observados para as parcelas de validação. Assim, este estudo indica que o uso de dados de sensoriamento remoto associados a redes neurais artificiais possibilita a estimativa com precisão da biomassa florestal acima do solo em florestas tropicais.

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

## ABSTRACT

The tropical forests stock a very significant amount of organic carbon as aboveground and soil biomass, which is an important research topic and a challenging for researchers in developing the techniques for quantifying biomass in natural ecosystems. Forest biomass measurement is a laborious activity that demands much time and financial resources. This study aimed to develop a model for estimating the aboveground biomass (AGB) in tropical forests using remotely sensed data and artificial neural networks. Nine vegetation indices retrieved from Landsat-5 TM sensor were tested and statistically evaluated based on their correlation with the biomass measured in field plots sampled by a forest inventory. Based on this study results, the Normalized Difference Vegetation Index (NDVI) and Aerosol Free Vegetation Index (AFRI) showed the best performance in estimating AGB. A total of 286 RNA were trained using as input layer the NDVI, AFRI, and the vegetation stratification classified into two Phytophysiognomies: lowland ombrophilous dense forest and sub-montane ombrophilous dense forest. The most appropriate RNA was selected based on graphical analysis of the residual errors and the correlation coefficient of the model. Ultimately, the validation of the selected RNA as based on the analysis of the Student's t-test results and on the aggregate difference between the predicted values by the artificial neural network and the observed values used for validation. This study results indicate that the use of remote sensing data and artificial neural networks combined can accurately estimate the forest above ground biomass in tropical forests.

**Keywords:** Biomass stock, Amazon rainforest, indexes of vegetation, neural artificial networks, remote sensing.

## SUMÁRIO

1.	INTRODUÇÃO .....	6
2.	OBJETIVOS.....	7
2.1.	Objetivo geral .....	7
2.2.	Objetivos específicos.....	8
3.	REFERENCIAL TEÓRICO .....	8
3.1.	Exploração de recursos florestais na Amazônia .....	8
3.2.	Biomassa florestal.....	9
3.3.	Uso do sensoriamento remoto na estimativa de biomassa florestal .....	10
3.4.	Redes neurais artificiais .....	13
4.	MATERIAL E MÉTODOS .....	15
4.1.	Área de estudo .....	15
4.1.1.	Localização.....	15
4.1.2.	Aspectos físicos.....	16
4.1.3.	Uso e cobertura do solo .....	17
4.2.	Base de dados .....	18
4.2.1.	Inventário florestal .....	18
4.2.2.	Estimativa do volume de árvores individuais .....	19
4.2.3.	Variáveis dendrométricas .....	20
4.3.	Biomassa florestal.....	21
4.4.	Análise das imagens de satélite .....	21
4.5.	Índices de vegetação.....	22
4.6.	Ajuste e treinamento das redes neurais artificiais .....	23
5.	RESULTADOS.....	25
5.1.	Inventário florestal .....	25
5.2.	Biomassa florestal .....	26
5.2.	Análise de correlação da biomassa e índices de vegetação.....	27
5.3.	Modelagem da biomassa .....	28
5.2.1.	Seleção das variáveis independentes.....	28
5.2.2.	Treinamento das redes neurais artificiais .....	28
5.4.	Análise estatística.....	32
5.5.	Distribuição espacial da biomassa.....	33
6.	DISCUSSÃO.....	34
6.1.	Biomassa florestal acima do solo .....	34
6.2.	Índices de vegetação.....	35
6.3.	Modelagem.....	36
6.3.1.	Seleção das variáveis independentes.....	36
6.3.2.	Treinamento das redes neurais .....	37
6.3.3.	Análise estatística.....	38
7.	CONCLUSÕES.....	39
8.	REFERÊNCIAS BIBLIOGRÁFICAS .....	40
9.	ANEXO.....	48

## LISTA DE TABELAS

<b>Tabela 1.</b> Uso e cobertura do solo em 2011, no Projeto de Assentamento Extrativista Juruti Velho, estado do Pará.....	18
<b>Tabela 2.</b> Divisão das amostras nas classes fitofisionômicas na área do Projeto de Assentamento Extrativista Juruti, estado do Pará. ....	19
<b>Tabela 3.</b> Distribuição das amostras nas classes fitofisionômicas na área Projeto de Assentamento Extrativista Juruti, estado do Pará. ....	19
<b>Tabela 4.</b> Índices de vegetação calculados para a Floresta Ombrófila do PAE Juruti Velho, no estado do Pará, Brasil.....	23
<b>Tabela 5.</b> Análise estatística do inventário florestal em 2010, na área do Projeto de Assentamento Agroextrativista Juruti Velho, estado do Pará.....	25
<b>Tabela 6.</b> Resultados estatísticos do inventário florestal realizado em 2010, na área do Projeto de Assentamento Agroextrativista Juruti Velho, estado do Pará.....	26
<b>Tabela 7.</b> Resultados do estoque médio e desvio padrão da biomassa total acima do solo e por tipo de fitofisionomia na área do Projeto de Assentamento Agroextrativista Juruti Velho, estado do Pará.....	27
<b>Tabela 8.</b> Características e análise de precisão das redes neurais artificiais treinadas.....	29

## LISTA DE FIGURAS

<b>Figura 1.</b> Estrutura da arquitetura de uma rede neural artificial com camada oculta. Fonte: Castro et al., 2017.....	14
<b>Figura 2.</b> Localização da área de estudo dentro do projeto de Assentamento Agroextrativista Juruti Velho (PAE Juruti Velho), no estado do Pará.....	15
<b>Figura 3.</b> Uso e cobertura do solo em 2011, na área do Projeto de Assentamento Agroextrativista (PAE) Juruti Velho (PAE Juruti Velho), no estado do Pará. ....	17
<b>Figura 4.</b> Cena do satélite Landsat 5 TM adquirida em 09/11/2009 para a área do Projeto de Assentamento Agroextrativista Juruti Velho (PAE Juruti), no estado do Pará.....	22
<b>Figura 5.</b> Índices de vegetação NDVI (A) e AFRI (B) derivados de imagem Landsat-5 TM, adquirida em 2009, para a área do Projeto de Assentamento Agroextrativista Juruti Velho (PAE Juruti Velho), estado do Pará. ....	28
<b>Figura 6.</b> Distribuição de resíduos (A), valores observados e estimados (B) e distribuição de classes de erro (C) da estimativa de biomassa florestal para a área do Projeto de Assentamento Agroextrativista Juruti Velho (PAE Juruti Velho), no estado do Pará. ....	30
<b>Figura 7.</b> Arquitetura da RNA selecionada para a predição da biomassa florestal por estrato em Floresta Ombrófila (4-13-1). ....	31
<b>Figura 8.</b> Distribuição espacial da biomassa florestal ( $\text{ton}\cdot\text{ha}^{-1}$ ) estimada para a área do Projeto de Assentamento Agroextrativista Juruti Velho (PAE Juruti Velho), no estado do Pará.....	32
<b>Figura 9.</b> Distribuição espacial da densidade de Kernel, com os valores de biomassa em $\text{ton}\cdot\text{ha}^{-1}$ , variando de 25 a 275 $\text{ton}\cdot\text{ha}^{-1}$ na área do Projeto de Assentamento Agroextrativista Juruti Velho (PAE Juruti Velho), no estado do Pará.....	33

## ANEXO

<b>Anexo 1.</b> Densida básica da madeira por espécie, gênero ou família, a depender do dado disponível no pacote BIOMASS do software R (2022).....	48
---	----

## 1. INTRODUÇÃO

Os ecossistemas florestais cobrem cerca de 30% da superfície terrestre e estocam em torno de 85% do carbono orgânico disponível no meio ambiente (BRIENEM, 2015). Devido à importância das florestas no ciclo do carbono global, tem sido crescente o interesse de muitos pesquisadores sobre o fluxo e o estoque de carbono nos ecossistemas naturais (RATUCHNE et al., 2016). As questões climáticas ligadas ao aumento da concentração de gases do efeito estufa, principalmente o dióxido de carbono (CO<sub>2</sub>), têm aumentado esse interesse devido ao papel fundamental que as florestas exercem na remoção do carbono atmosférico (FERREIRA et al., 2016).

Entende-se por biomassa todo o material de origem biológica, viva ou morta, animal ou vegetal (ELOY, 2013), ao passo que a biomassa florestal (BF) é conceituada especificamente como todo material vegetal da floresta ou apenas a fração arbórea da mesma (SANQUETTA et al., 2014; VIEIRA, 2013). A biomassa florestal acima do solo (BMAS) integra a área basal densidade e altura das árvores, sendo um importante indicador do estado dos fragmentos florestais (FERREIRA et al., 2016). A BF tem sido estudada com propósitos variados, dentre eles a ciclagem de nutrientes, a utilização energética, a avaliações do crescimento de espécies arbóreas, entre outros (SANQUETTA et al., 2014).

A BF pode ser estimada pelo método direto, de maneira destrutiva, ou indireto, através de equações que estimam a variável de interesse a partir de dados dendrométricos coletados em campo, como altura, diâmetro e densidade da madeira (RATUCHNE et al., 2016). Todavia, A mensuração da BF é um processo que demanda tempo e muitos recursos financeiros (SANTANA, 2018). Assim, a utilização de técnicas e métodos precisos, aliados a ferramentas que confirmam agilidade ao processo, é fundamental para o monitoramento da BF da floresta e seus serviços ambientais (CARNEIRO & CASTRO, 2014; FERREIRA et al., 2016). Estas técnicas são especialmente de grande utilidade na Amazônia, devido à sua imensa extensão territorial e importância no cenário climático global.

A utilização de métodos ou técnicas precisas para estimar os estoques de biomassa é fundamental também para auxiliar nos processos de gestão e conservação da vegetação nativa (SANTANA, 2018). Neste caso, o sensoriamento remoto (SR) pode contribuir para a quantificação da produção florestal quanto ao estoque de madeira e biomassa (ELOY, 2013). Os dados derivados de satélites representam uma técnica fácil e menos onerosa para a obtenção de dados de biomassa florestal, além do alto nível de confiança e acurácia oferecido na busca por essas informações (MIGUEL et al., 2015a).

Os índices de vegetação são os produtos de sensores remotos mais utilizados na estimativa da BF (DAGNACHEW et al., 2020). Entre os diferentes índices de vegetação usados, destacam-se o Índice de Vegetação da Diferença Normalizada (*Normalized Difference Vegetation Index* - NDVI) e o Índice de Realce da Vegetação (*Enhanced Vegetation Index* - EVI), em função das suas relações com as atividades fotossintéticas da vegetação (GARROUTTE et al., 2016).

As redes neurais artificiais (RNAs) também têm sido amplamente utilizadas na predição de biomassa, volume, crescimento, produtividade, resistência e propriedades energéticas da madeira (CARRIJO et al., 2020; GONÇALVES et al., 2021; MIGUEL et al., 2018). As RNAs são sistemas de computação com nós interconectados que possuem a capacidade de aquisição e manutenção de conhecimento, para realizar uma tarefa, processo conhecido como aprendizagem de máquina (BINOTI, 2013; GONÇALVES et al., 2021). Associadas aos dados de sensoriamento remoto, as redes neurais artificiais apresentam grande potencial para a estimativa de variáveis dendrométricas de florestas tropicais. (BINOTI, 2013; SERPEN; GAO, 2014; VIEIRA et al., 2018)

No presente estudo, foi desenvolvido um modelo usando RNA, dados de SR e dados do inventário florestal realizado em campo para estimar a biomassa florestal acima do solo (BFAS) na região oeste da Amazônia brasileira, no estado do Pará. A modelagem BFAS desenvolvida nesta pesquisa é útil para avaliar os serviços ambientais gerados pelos ecossistemas florestais, como a captura e emissões de carbono em florestas tropicais. Esta tecnologia, que está na fronteira do conhecimento, representa um avanço metodológico no uso integrado de técnicas de sensoriamento remoto e redes neurais artificiais, com as devidas adequações, em qualquer região de florestas tropicais.

## **2. OBJETIVOS**

### **2.1. Objetivo geral**

Desenvolver modelo para predição da biomassa florestal acima do solo em florestas tropicais usando dados de sensoriamento remoto e redes neurais artificiais.

## **2.2. Objetivos específicos**

- Analisar a correlação entre índices de vegetação derivados de dados do satélite Landsat-5 TM e dados de biomassa acima do solo obtidos em campo a partir de inventário florestal;
- Testar modelos de redes neurais artificiais para a estimar da biomassa acima do solo a partir de dados de inventário florestal e de sensoriamento remoto;
- Avaliar a acurácia das estimativas da biomassa florestal acima do solo usando redes neurais artificiais e dados de satélite.

## **3. REFERENCIAL TEÓRICO**

### **3.1. Exploração de recursos florestais na Amazônia**

A Amazônia brasileira abrange uma área de aproximadamente 5 milhões de quilômetros quadrados, composta por fitofisionomias de florestas de terra firme e florestas alagadas, sendo a maior reserva contínua de floresta tropical úmida do mundo (IBGE, 2020). A área da floresta abrange seis países: Brasil, Peru, Bolívia, Equador, Colômbia Venezuela, com 60% de sua cobertura de terras localizada em território brasileiro (QUARESMA & JARDIM, 2015). Essa floresta desempenha papel imprescindível na manutenção de serviços ecológicos, tais como, garantia da qualidade do solo, dos estoques de água doce e proteção da biodiversidade. (GONÇALVES et al., 2021)

A Floresta Amazônica tem se configurado como uma das principais áreas produtoras de recursos florestais no mundo, com destaque para os estados do Pará, Amazonas e Mato Grosso (TAKEDA, 2015). A região é responsável por mais de 90% da produção florestal do país, fornecendo produtos madeireiros e não madeireiros fundamentais para as famílias florestais extrativistas, que contribuem para o desenvolvimento socioeconômico da região (OLIVEIRA et al., 2015).

O crescimento acelerado do setor florestal na Amazônia se deu por diversos motivos, entre eles: (1) a abertura de estradas pelo governo, entre a décadas de 60 e 70, o que possibilitou maior acesso à floresta; (2) uma demanda crescente por madeiras devido ao crescimento da economia do Brasil; (3) o esgotamento dos estoques de madeira nobre na região sul do país; (4) o baixo custo da madeira e sua abundância na Floresta Amazônica (TAKEDA, 2015). Além disso, a região apresenta grande extensão de rios navegáveis e relevo suavemente ondulado, o que facilita a exploração florestal nessa região norte do Brasil (FERREIRA et al., 2016).



No Pará, a exploração de recursos florestais tem sido crescente, levando o estado à posição de maior produtor de madeiras em tora no país (FIOCRUZ, 2022). A partir dos dados extraídos dos sistemas oficiais de controle florestal, estimou-se que o Pará produziu em 2019 aproximadamente 3 milhões de metros cúbicos de madeira em tora a partir da exploração regulada de florestas naturais, sendo que mais da metade desta produção foi gerada no oeste do estado (IMAFLOA, 2021). Outros produtos oriundos da floresta também tem destaque, com o carvão vegetal, cuja a exploração destina-se às indústrias produtoras de ferro (FILGUEIRAS & SANTANA, 2018). Diante disso, vale ressaltar que o desmatamento e a degradação florestal no estado do Pará cresce de maneira acelerada e está relacionado também à situação fundiária, à pecuária extensiva, à agricultura e à siderurgia (LEMOS & SILVA, 2011).

### **3.2. Biomassa florestal**

Biomassa é a matéria de origem biológica, viva ou morta, animal ou vegetal, que possua potencial para geração de energia ou combustíveis (ELOY, 2013). Quanto à biomassa florestal (BF), esta pode ser definida como toda a massa existente na floresta ou apenas fração arbórea (CARON et al., 2015). A BF relaciona a área basal, altura, densidade da madeira com produtividade e assim, em longo prazo, resulta do equilíbrio entre o crescimento da floresta (aumento da área basal) e a mortalidade (perda de madeira) (PAN et al., 2013; REJOU-MECHAIN, 2017). Dessa forma, estudos que possibilitem prever a magnitude da produtividade de biomassa são extremamente importantes para entender ecossistemas locais, assim como para prever componentes do balanço de carbono global. (BALZTER, 2001; MABUNDA et al., 2021)

Nos dias atuais, o consumo mundial de energia vem crescendo de maneira acelerada, aumentando a demanda principalmente de fontes não-renováveis. Isso acarreta em uma série de questionamentos em relação ao abastecimento energético e ao equilíbrio ambiental (CARON et al., 2015). Assim, na tentativa de minimizar essa problemática, muitos países buscam fontes alternativas de energia, principalmente o uso de fontes de energia renováveis, entre elas, a biomassa florestal (ELOY, 2013).

O aproveitamento da biomassa florestal como fonte de energia pode revelar-se uma oportunidade de valorização dos recursos florestais, pois contribui para a melhoria da gestão das explorações e intensificação do uso de energias renováveis (BRIENEM, 2015; REJOU-MECHAIN, 2017). Por ser capaz de fixar o carbono, a BF é vista como uma alternativa viável para mitigar o aumento da concentração de CO<sub>2</sub> na atmosfera e assim desacelerar o

efeito estufa tão presente no contexto atual de mudanças climáticas globais (SANQUETTA et al., 2014; CARNEIRO; CASTRO, 2014). Diante disso, a quantificação da BF nas formações florestais é fundamental para prever as emissões de carbono e avaliar os impactos do efeito das mudanças climáticas (BRIENEM, 2015).

A mensuração da biomassa florestal, em florestas plantadas ou naturais implica na quantificação de três reservatórios de carbono: biomassa acima do solo (troncos, tocos, galhos, copa, sementes e folhas), biomassa subterrânea (raízes) e serrapilheira (BIRDSEY, 2006). A biomassa total é a soma de todos esses compartimentos e, em âmbito florestal, caracteriza-se como o componente arbóreo e a fitomassa de todos os componentes vegetais da comunidade. (MELLO & GONÇALVES, 2008; WATZLAWICK et al., 2009).

A quantificação da biomassa nas florestas tropicais é realizada por métodos diretos ou indiretos. A medição direta da BF em campo é realizada a partir da coleta e pesagem de todas as partes das árvores, mudas, cipós, parte radicular e serrapilheira (RIBEIRO et al., 2009). O método direto é mais acurado para quantificar a BF, já que os resultados são os mais reais possíveis. Porém, caso ocorram erros no uso dos equipamentos de medição ou o local de coleta seja de difícil acesso, a precisão e o custo de aplicação das medições pode inviabilizar a escolha deste método (BUSTAMANTE et al., 2016).

O método indireto consiste em utilizar relações já determinadas entre a biomassa e outras variáveis da árvore, como diâmetro, altura total, área basal e densidade da madeira, resultando em modelos estatísticos (RIBEIRO et al., 2009). Este método está mais sujeito a erros nas estimativas de biomassa, desde a escala de árvore até a escala de paisagem devido à sistematização e extrapolação dos erros cometidos (FERRAZ et al., 2014). A área basal e a densidade da madeira são as variáveis de campo que mais se relacionam com a BF, entretanto, as equações resultantes dessa estimativa limitam a predição da BF ao local de coleta dos dados (BRIENEM, 2015; SANQUETTA, 2014). Assim, são necessários estudos que possibilitem a extrapolação da estimativa de BF com um bom nível de precisão para áreas maiores (GOODMAN, 2014; RIBEIRO et al., 2009).

### **3.3. Uso do sensoriamento remoto na estimativa de biomassa florestal**

O Sensoriamento Remoto (SR) é a área do conhecimento que trata da aquisição de dados de objeto ou cena por sensor que está distante dos alvos (JENSEN, 2009). Dessa forma, são gerados produtos a partir da detecção e medição quantitativa da interação entre a radiação eletromagnética com os alvos terrestres (HENTZ et al., 2014). A energia registrada pelos instrumentos sensoriados apresenta propriedades bio-físico-químicas fundamentais que

devem ser modeladas para a correta extração de informações qualitativas e quantitativas(MOURA, 2015).

O uso de dados oriundos de sensores remotos para a estimativa de biomassa tornou-se opção interessante, pois facilita a aplicação dos métodos de estimativa de biomassa, além de reduzir o tempo e o custo demandados com inventários florestais, permitindo também obter informações de áreas remotas de difícil acesso (LE MAIRE et al., 2011). A utilização de tecnologias provenientes do SR demonstra efetividade na análise da cobertura vegetal, possibilitando o monitoramento das mudanças no crescimento e do acúmulo de biomassa que ocorrem na dinâmica de um ecossistema florestal (HENTZ et al., 2014).

Por meio da aplicação de resultados de modelos matemáticos em equações elaboradas com valores digitais dos sensores remotos é possível quantificar as áreas e estimar indiretamente a BF (MATOS & KIRCHNER, 2008). Watzlawick (2009) e Baccini (2012) também afirmaram que o avanço no processamento das imagens de satélite influenciou na utilização crescente desses métodos para os estudos da biomassa e consequente caracterização dos ecossistemas florestais (WATZLAWICK, 2009; BACCINI, 2012).

O ajuste de valores espectrais permite obter índices de vegetação (IV's) que podem ser comparados com indicadores ecológicos da estrutura e dinâmicas das florestas (LI et al., 2019). Segundo Jensen (2009), os IV's são mensurações radiométricas adimensionais que indicam a abundância relativa e a atividade da vegetação verde, incluindo o índice de área foliar (IAF), a porcentagem de cobertura verde, o teor de clorofila, a biomassa verde e a radiação fotossinteticamente absorvida (RFAA). Esses índices são as variáveis obtidas a partir do SR mais utilizadas na estimativa da BF, pois a produção primária apresenta estreita relação com a radiação solar absorvida pela vegetação (SANTANA, 2018). Além disso, os IV's também são usados no monitoramento da vegetação, pois fornecem informações a respeito dos parâmetros de crescimento e desenvolvimento da vegetação (HENTZ, 2014; LE MAIRE, 2011; MOURA, 2015).

Os IV's são capazes também de identificar e diagnosticar a relação de área foliar, biomassa e taxa de solo exposto. Isso ocorre porque a clorofila nas células vegetais apresentam uma resposta específica à radiação na imagem espectral, o que diferencia a vegetação de outros elementos em uma imagem (MARCUSI, 2010; VIEIRA et al., 2018). Assim, esses algoritmos matemáticos fornecem informações relevantes que podem apoiar a elaboração de estimativas de biomassa de maneira mais rápida e com boa precisão (ALMEIDA et al., 2015; MARCUSI, 2010).

A maior parte dos índices baseiam-se no comportamento antagônico da vegetação nas regiões espectrais do vermelho e do infravermelho próximo (VINA & GITELSON, 2011). Uma vez que os IV's minimizam os efeitos que influenciam os valores de reflectância da vegetação, tais como iluminação da cena, declividade da superfície e geometria de aquisição (HENTZ, 2014; BACCINI, 2012; MOURA, 2015). Assim, quanto maior é a densidade da cobertura vegetal, menor é a reflectância no visível, já que os pigmentos fotossintetizantes estão mais presentes. (JENSEN, 2009; PONZONI et al., 2012)

Entre os índices de vegetação mais comuns, está o Índice de Vegetação da Diferença Normalizada (*Normalized Difference Vegetation Index* – NDVI), que é classificado como índices diferenciais de razão convencional (JENSEN, 2009; VILA NOVA, 2013). O valor do NDVI varia de acordo com a absorção da radiação na banda do vermelho pela clorofila e a reflexão da banda do Infravermelho pelas células das folhas vivas (BARATI & RAYEGANI, 2011). A razão desse índice reduz muitas formas de ruídos que são apresentados nas imagens, porém, mesmo sendo extremamente útil na estimativa de biomassa da vegetação, o NDVI apresenta problemas de saturação em áreas densamente vegetadas (HENTZ, 2014).

Na busca por melhores resultados, foi desenvolvido o Índice de Vegetação Ajustado para o Solo (*Soil Ajusted Vegetation Index* - SAVI), que considera a influência das características dos solos no cálculo dos índices de vegetação (MOURA, 2015). O Índice de Vegetação Melhorado (*Enhanced Vegetation Index* - EVI), foi desenvolvido para otimizar o sinal da vegetação, melhorando a sua detecção em regiões de maior densidade de biomassa (PONZONI, 2012). O EVI é um NDVI modificado, composto por um fator de ajuste para solos e dois coeficientes que atuam na correção da banda vermelha quanto ao espalhamento atmosférico por aerossóis (HENTZ, 2014). Outro índice desenvolvido foi o de Vegetação Livre de Aerossol AFRI (*Aerosol Free Vegetation Index* - AFRI), que surgiu como alternativa para diminuir a influência de efeitos atmosféricos que impedem a análise multitemporal da vegetação (KARNIELI et al., 2001). Esse índice tem sido utilizado para estimar a biomassa queimada em áreas com muita presença de fumaça e outros poluentes atmosféricos (MATRICARDI et al., 2010).

As séries de imagens obtidas de satélites Landsat são as mais utilizadas no sensoriamento remoto, em função da facilidade de obtenção dos dados e maior cobertura temporal e espacial (FOODY et al., 2001). O satélite Landsat-5 TM (*Thematic Mapper*) foi lançado em 1984 e gera imagens com resolução espacial de 30 metros, o que facilita a identificação e caracterização dos alvos na superfície terrestre (INPE, 2022). O sensor TM possui resolução


radiométrica de 8 bits e opera com 7 bandas nas regiões do visível, infravermelho próximo, médio e termal (EMBRAPA, 2022). Inúmeros trabalhos são feitos utilizando imagens Landsat para mapeamento e monitoramento da cobertura terrestre, inclusive para estimativa de biomassa (CUTLER et al., 2012; LI et al., 2020; MABUNDA et al., 2021).

### **3.4. Redes neurais artificiais**

Redes Neurais Artificiais (RNAs) são sistemas de computação com nós interconectados que funcionam como neurônios do cérebro humano (VALERI, 2022). As RNAs são compostas por uma série de neurônios artificiais interligados por conexões chamadas de pesos sinápticos que possuem a capacidade de aquisição e manutenção de conhecimento, isto é, aprendizagem, para realizar uma tarefa (BINOTI, 2013; GONÇALVES et al., 2021; PANDA et al., 2010). A aprendizagem de uma RNA altera os pesos sinápticos de acordo com a entrada de amostras de treinamento até o alcance da estabilidade da rede e entrega do resultado final (BUSTAMANTE et al., 2016). Após o treinamento da RNA, ela passa por um processo de validação, em que se verifica a acurácia dos dados estimados (BINOTI, 2013).

O neurônio é parte fundamental em uma RNA e é nele que ocorre o processamento dos valores de entrada até que se alcance o resultado de interesse, no caso a biomassa florestal. Ocorre a combinação e reprodução de informações com base nas conexões entre as entradas e a saída (GONÇALVES et al., 2021). Um peso (representado por uma sinapse) é atribuído para cada entrada e as RNAs fixam o conhecimento aprendido. (CARRIJO, 2020; MIGUEL et al., 2015)

A RNA pode ser dividida em três camadas (BRAGA, 2007; CUTLER et al., 2012): i) entrada, onde há o recebimento de dados; ii) oculta ou intermediária, onde o processamento dos dados ocorre; e iii) saída, onde ocorre a apresentação do resultado final da rede (Figura 1). A forma como as conexões estão organizadas entre os neurônios define a arquitetura da RNA (número de camadas) e sua topologia, ou seja, o número de ligações (SILVA, 2010).



**Figura 1.** Estrutura da arquitetura de uma rede neural artificial com camada oculta. Fonte: Castro et al., 2017.

As RNAs têm sido amplamente empregadas no ramo das Ciências Florestais, sendo amplamente utilizadas mundialmente em estudos com o emprego de variáveis dendrométricas, edáficas e climáticas (MARONEZE et al., 2014). Diamantopoulou (2005), Özçelik et al., (2010), e Silva (2009) avaliaram, por exemplo, a aplicação de RNA para estimação de volume de madeira. Já Binoti (2013) e Castro (2013) utilizaram RNA para modelar altura e crescimento em um povoamento de eucalipto. As RNA's foram utilizadas também para estimar erosão do solo, como foi visto nos trabalhos de Levine (1996) e Licznar (2003). O estudo realizado por Gonçalves (2016) mostrou a eficiência da utilização dos dados do satélite Landsat 5 TM, associado às RN's para classificação de dois tipos de Floresta Ombrófila Densa em Mamuru-Arapinus, no estado do Pará, quanto ao estoque de biomassa.

A utilização de RNA para estimar a biomassa florestal tem apresentado resultados bem precisos quando combinada com técnicas de SR (CUTLER et al., 2012; FERRAZ et al., 2014; FOODY, 2003). Essas análises conjuntas são precisas quando comparadas com as medições em campo e equivalentes aos métodos estatísticos de regressão linear e não linear para os dados estudados por Foody et al. (2003) e Del Frate (2004). Além disso, os resultados obtidos a partir desta análise integrada de RNA e SR reduziram custos se comparados com a metodologia tradicional dos inventários florestais (ALMEIDA, 2009; FERRAZ et al., 2014). Porém, a RNA tem grande capacidade de predição quando estudada para uma área de estudo específica e diminui consideravelmente quando a relação é extrapolada para um local diferente daquele em que foi desenvolvida (CUTLER et al., 2012; GARROUTE, 2016; MABUNDA et al., 2021).

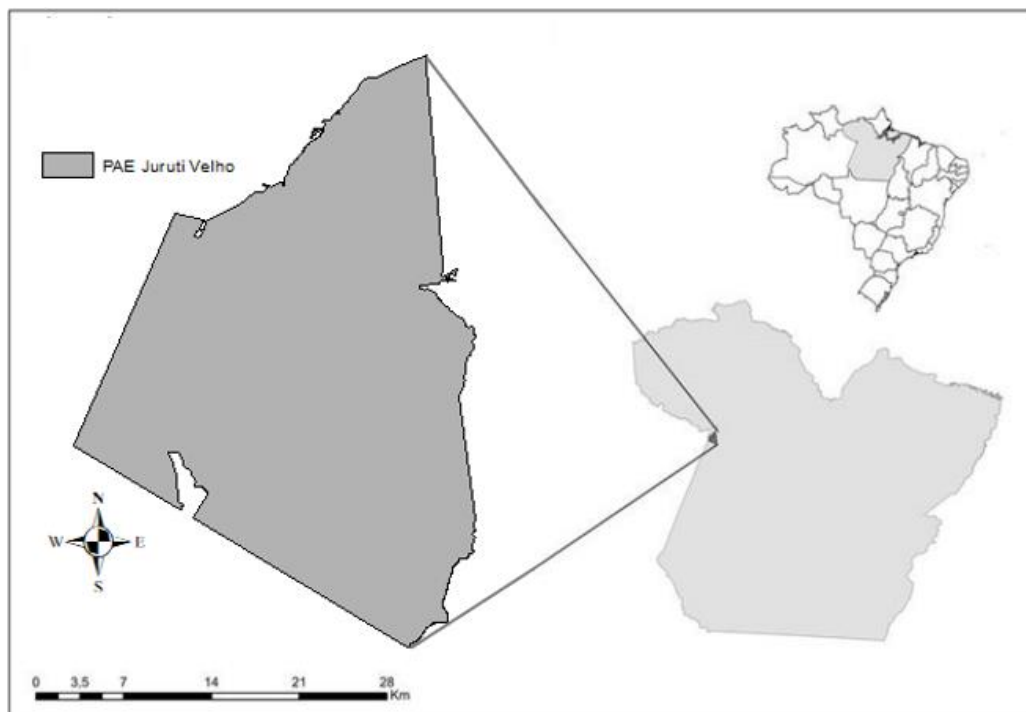
A utilização de RNAs associadas às técnicas de SR para estimativa de biomassa florestal em uma Floresta Ombrófila Densa, em Santa Catarina, mostrou ótimos resultados (Schoeninger, 2008). A estimativa de biomassa utilizando as mesmas técnicas também se mostrou promissora nos trabalhos de Almeida (2009) para a Floresta Amazônica. Diante disso, a utilização de RNAs e de imagens de satélite para estimativa de biomassa florestal vem crescendo consideravelmente (LI et al., 2020). Os resultados obtidos em estudos anteriores não diferiram estatisticamente dos valores estimados por modelos de regressão e ainda reduziram custos se comparados com a metodologia tradicional dos inventários florestais (ALMEIDA, 2009; FERRAZ et al., 2014).

## 4. MATERIAL E MÉTODOS

### 4.1. Área de estudo

#### 4.1.1. Localização

O estudo foi realizado na área do Projeto de Assentamento Extrativista (PAE) Juruti Velho, situado no oeste do estado do Pará, com área total de 109.551 hectares (Figura 2).



**Figura 2.** Localização da área de estudo dentro do projeto de Assentamento Agroextrativista Juruti Velho (PAE Juruti Velho), no estado do Pará.

O PAE Juruti Velho foi criado pela portaria INCRA/SR-30/Nº 18, de 10 de novembro de 2005, localizado a uma latitude de 02º09'08'' S e longitude 56º05'32'' W, no município de Juruti, no estado do Pará (IDESP,2011). Esse assentamento da Reforma Agrária foi criado com o objetivo de legitimar a posse de terra e realizar o ordenamento territorial das populações tradicionais do município de Juruti, que abriga 1.901 famílias em uma área de aproximadamente 96 mil hectares. (FERREIRA et al., 2016)

Em 2005, a empresa ALCOA (*Aluminium Company of America*), responsável pelo Projeto Mina de Bauxita de Juruti, instalou-se efetivamente no entorno do Lago Grande de Juruti Velho, onde vivem cerca de 50 comunidades (CARVALHO & DEMEDA, 2018). Diante dessa mobilização, os moradores da região criaram a Associação das Comunidades Reunidas de Juruti Velho (ACORJUVE), uma entidade representativa de seus interesses.

Os membros da ARCOJUVE protestaram contra o empreendimento minero-metalúrgico e conquistaram a titulação coletiva das terras exploradas, bem como o direito a um percentual sobre o lucro da lavra da bauxita (NAHUM & CASTRO, 2012). Essas mudanças agravaram os conflitos sob o ponto de vista fundiário e de recursos naturais, até então livremente apropriados pelos comunitários (VIEIRA, 2013). Segundo Nahum e Castro (2012), a chegada da ALCOA em Juruti constituiu um evento que alterou a dinâmica territorial, pois possibilitou novos usos de recursos no território, reorganizou a configuração espacial e gerou conflitos sociais.

#### **4.1.2. Aspectos físicos**

O relevo está associado à bacia sedimentar da Amazônica ocidental e é caracterizado por áreas de baixas colinas, tabuleiros aplainados, escarpas tabulares, terraços e várzeas (IDESP, 2011). Tais formações geomorfológicas estão inseridas na unidade Planalto Rebaixado do Amazonas (Médio Amazonas), onde a variação altimétrica é moderada e cotada em torno de 40 metros (THOMAS et al., 2015).

Os solos são representados pelas classes Latossolo Amarelo distrófico, com textura média e argilosa; Neossolo Quartzarênico e Podzólico Vermelho Amarelo textura média, além de áreas com solos Hidromórficos Gleizados (EMBRAPA, 2022). A hidrografia é representada principalmente pelo rio Amazonas e seus afluentes, entre eles o rio Juruti, e por vários igarapés da região (FIOCRUZ, 2022). Além disso, alguns lagos estão inseridos nas várzeas do Amazonas, como Salé e Grande Paranapitinga (IDESP, 2011).

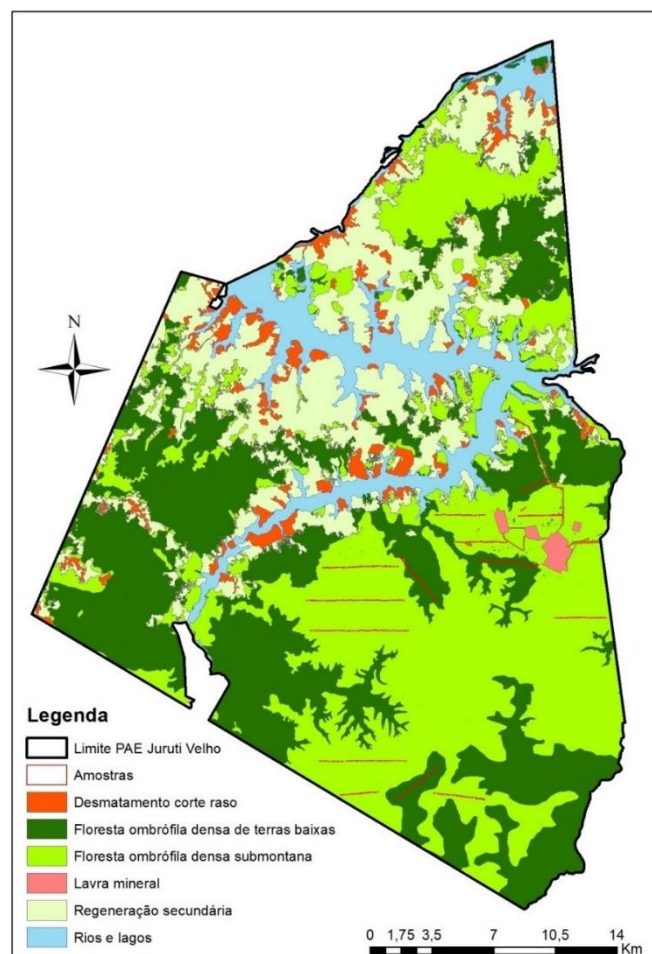


O clima na região é quente e úmido e apresenta temperatura média anual entre 25° e 28° C (IDESP, 2011). A umidade relativa apresenta valores acima de 80% em quase todos os meses do ano e a pluviosidade se aproxima de 2000 mm anuais (FERREIRA, et al., 2016).

#### 4.1.3. Uso e cobertura do solo

A vegetação é típica de Florestas Ombrófilas densas, bem características por sua cobertura vegetal, com predomínio de árvores de grande porte e emergentes (FERREIRA et al., 2016). A floresta é perene-folia e a composição florística é muito variada em espécies arbóreas e arbustivas (CARVALHO & DEMEDA, 2018).

A área de estudo foi classificada como Floresta Ombrófila Densa Sub-montana – FODS (Floresta de Platô) e Floresta Ombrófila Densa de Terras Baixas – FODTF (IBGE, 1991). A classificação da vegetação, bem como os diferentes usos da terra (desmatamento, regeneração, mineração e rios e lagos) área analisada, são apresentados na Figura 3 e os detalhes das áreas ocupadas por cada um deles em 2011 estão apresentados na Tabela 1.



**Figura 3.** Uso e cobertura do solo em 2011, na área do Projeto de Assentamento Agroextrativista (PAE) Juruti Velho (PAE Juruti Velho), no estado do Pará. Fonte: Relatório

Técnico de Geoprocessamento sobre Uso do Solo e Cobertura Florestal no PAE-JV (ECCOIDEIA, 2011a)

**Tabela 1.** Uso e cobertura do solo em 2011, no Projeto de Assentamento Extrativista Juruti Velho, estado do Pará.

<b>Uso e cobertura do solo</b>	<b>Área (ha)</b>
Desmatamento corte raso	3.585,7
Floresta Ombrófila Densa de Terras Baixas	29.919,9
Floresta Ombrófila Densa Sub-montana	35.592,9
Lavra mineral	416,4
Regeneração secundária	18.067,1
Rios e lagos	8.319,6
<b>Total</b>	<b>95.901,6</b>

Fonte: Relatório Técnico de Geoprocessamento sobre Uso do Solo e Cobertura Florestal no PAE-JV (ECCOIDEIA, 2011a).

#### **4.2. Base de dados**

Foram utilizados dados de campo obtidos a partir do inventário florestal realizado em 2010 pela empresa Florestal Planejamento, Paisagismo e Consultoria Ltda. O objetivo deste inventário florestal foi o de estimar o potencial florestal madeireiro e não madeireiro do PAE Juruti, além de dar suporte às estimativas de biomassa acima do solo na área do estudo.

##### **4.2.1. Inventário florestal**

Para o inventário florestal utilizou-se o método de amostragem estratificada proporcional. As amostras foram implantadas em 14 transectos, totalizando 250 amostras retangulares, com 1250 m<sup>2</sup> cada e 250 subparcelas de regeneração com 125 m<sup>2</sup> cada distribuídas nas duas classes fitofisionômicas: FODS e FOTF. As distribuições dos estratos amostrais e suas respectivas amostras são detalhadas em Tabela 2 e Tabela 3. A localização das amostras sobre os dois estratos pode ser vista na Figura 3.

Foram utilizados dados de 250 amostras principais do inventário florestal, incluindo as subparcelas de regeneração. O critério de inclusão de árvores considerou palmeiras e cipós dentro da área de interesse. O limite de erro máximo esperado foi de 10%, e o nível de confiança, 95%, conforme estabelecido pela Norma Técnica n. 01 de 2007 do Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA).

**Tabela 2.** Divisão das amostras nas classes fitofisionômicas na área do Projeto de Assentamento Extrativista Juruti, estado do Pará.

<b>Estrato amostral</b>	<b>Área (ha)</b>	<b>Nº de amostras mensuradas (12,5 m x 100 m)</b>
Floresta Ombrófila Densa Sub-montana	11.319,5	199
Floresta Ombrófila Densa de Terras Baixas	3.680,20	51
<b>TOTAL</b>	<b>14.999,70</b>	<b>250</b>

**Tabela 3.** Distribuição das amostras nas classes fitofisionômicas na área Projeto de Assentamento Extrativista Juruti, estado do Pará.

<b>Fitofisionomia</b>	<b>Nº do Transecto</b>	<b>Comprimento do Transecto (m)</b>	<b>Nº de Amostra no transecto</b>	<b>Nº das amostras no transecto</b>
<b>Floresta Ombrófila Densa de Terras Baixas</b>	1	5.000	25	1 a 25
	2	2.200	11	26 a 36
	3	3.000	15	37 a 51
<b>Subtotal</b>		<b>10.200</b>	<b>51</b>	
	4	3.200	16	52 a 67
	8	3.600	18	146 a 163
	10	3.600	18	179 a 196
<b>Floresta Ombrófila Densa Sub-montana</b>	14	1.800	9	242 a 250
	5	5.600	28	68 a 95
	6	5.600	28	96 a 123
	7	4.400	22	124 a 145
	9	3.000	15	164 a 178
	11	3.000	15	197 a 211
	12	3.000	15	212 a 226
	13	3.000	15	227 a 241
<b>Subtotal</b>		<b>39.800</b>	<b>199</b>	
<b>Total Geral</b>		<b>50.000,00</b>	<b>250</b>	

#### 4.2.2. Estimativa do volume de árvores individuais

Foram estimados o volume de 7060 árvores de 250 parcelas de 1250 m<sup>2</sup> com base no método indireto. Para isso, multiplicou-se a altura comercial pela área basal de cada

indivíduo arbóreo, resultando em um “volume cilíndrico” (ÖZÇELIK et al., 2010). Posteriormente, multiplicou-se o volume cilíndrico de cada árvore pelo fator de forma 0,7, conforme recomendado por Heinsdijk & Bastos (1963) para espécies da Amazônia. O fator de forma relaciona o volume cilíndrico com o volume real, corrigindo o resultado do volume do tronco, já que a o tronco das árvores na maioria das vezes não tem a forma de um cilindro perfeito (FERREIRA, 2016; HEINSDIJK & BASTOS, 1963). Para estimar o volume das árvores individuais, utilizou-se a seguinte expressão:

$$Va = \pi * \frac{DAP^2}{40000} * H * FF$$

Onde:

Va = Volume com casca por árvore (m<sup>3</sup>);

H = Altura comercial (m);

DAP = Diâmetro à altura do peito (1,3 m);

$\pi = 3,1416$ ;

FF = Fator de forma (adotado como 0,7).

#### 4.2.3. Variáveis dendrométricas

Para estimar o volume e o estoque de biomassa foram utilizadas quatro variáveis: DAP (diâmetro à altura do peito), G (área basal), H (altura total) e V (volume total). A organização dos dados foi feita utilizando tabela dinâmica, reunindo as variáveis dendrométricas por árvore. Para processamento desses dados, utilizou-se o software *Microsoft Excel 2016*.

##### 4.2.3.1. Diâmetro à altura do peito

O Diâmetro à altura do peito (DAP) foi obtido a partir das medições do inventário florestal realizado em campo e da seguinte equação:

$$DAP = \frac{CAP}{\pi}$$

Onde:

DAP = Diâmetro à altura do peito (cm);

CAP = Circunferência à altura do peito (cm);

$\pi = 3,1416$ .

##### 4.2.3.2. Área basal

A Área Basal foi calculada a partir das medições do inventário florestal realizado em campo e da seguinte equação:

$$AB = \pi * \frac{DAP^2}{40000}$$

Onde:

$AB$  = Área Basal (cm);

$DAP$  = Diâmetro à altura do peito (cm);

$\pi$  = 3,1416.

#### **4.2.3.3. Altura total**

A altura total foi medida, quando possível, com um telêmetro, que é um dispositivo de precisão destinado à medição de distâncias entre dois pontos em tempo real.

### **4.3. Biomassa florestal**

Para estimar a biomassa florestal foi utilizado os dados do inventário florestal e a equação proposta por Chave et al. (2014):

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

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)

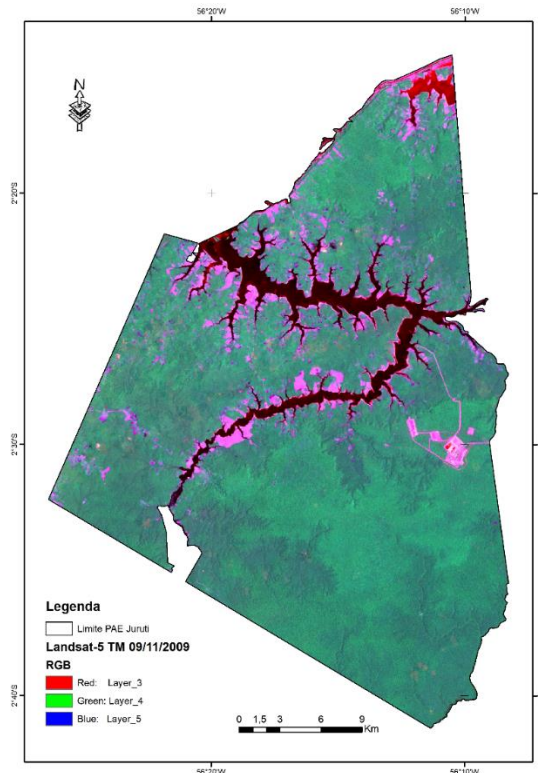
A densidade básica média da madeira foi obtida para as espécies dos indivíduos presentes no inventário florestal realizado em 2010. Utilizou-se a base de dados do pacote BIOMASS do *Software R* (REJOU-MECHAIN, 2017) a nível de espécie, gênero e família, a depender do nível do dado disponível no pacote (Tabela 8, em anexo).

A biomassa florestal acima do solo (BFAS) de cada parcela foi obtida pela soma da biomassa dos indivíduos amostrados (SANQUETTA et al., 2014). Posteriormente, a BFAS foi transformada para unidade de tonelada (Ton) por hectare, conforme Chave et al. (2014).

### **4.4. Análise das imagens de satélite**

Para esta análise, foi utilizada uma cena do satélite Landsat-5 TM, adquirida em 9 de novembro de 2009, com resolução espacial de 30 metros, órbita/ponto 228/062. Esta cena foi obtida da coleção “LANDSAT/LT05/C01/T1\_TOA”, reflectância no topo da atmosfera, disponível na plataforma *Google Earth Engine* (GEE), recortada para a área de estudo e corrigida geométrica e radiometricamente, conforme recomendado por (FOODY et al.,

2001). A correção atmosférica representa um aprimoramento na qualidade da imagem, pois reduz os efeitos atmosféricos causados pela absorção de gases da atmosfera e pela consequente dispersão (ZHONG et al., 2016). A correção no Topo da Atmosfera considera três componentes: radiação não espalhada e refletida pela superfície; radiação espalhada na descendente e refletida pela superfície e a radiação atmosférica (MACHADO et al., 2017). A imagem foi selecionada com base na ausência de nuvens para a área de estudo e a data mais próxima possível da realização do inventário florestal em campo em 2010 (Figura 4).



**Figura 4.** Cena do satélite Landsat 5 TM adquirida em 09/11/2009 para a área do Projeto de Assentamento Agroextrativista Juruti Velho (PAE Juruti), no estado do Pará.

#### 4.5. Índices de vegetação

Foram utilizadas as bandas espectrais Landsat-5 TM, em reflectância no topo da atmosfera, para estimar os índices de vegetação. As imagens dos índices de vegetação foram obtidas da plataforma *Google Earth Engine* (GEE) para extração dos valores médios dos índices de vegetação para cada unidade amostral utilizando a ferramenta *Extract MultiValues to Point* do software ArcMap® 10.8 (Licença institucional da ESRI para a Universidade de Brasília).

Neste estudo, os índices de vegetação foram escolhidos com base nas propriedades estruturais, bioquímicas e biofísicas da vegetação, a fim de verificar quais apresentam melhor relação com a estimativa da quantidade de biomassa de florestas tropicais. Assim,

os índices de vegetação utilizados foram: o *Normalized Difference Vegetation Index* (o Índice de Vegetação da Diferença Normalizada - NDVI), o *Modified Soil Adjusted Vegetation Index* (Índice de Vegetação Modificado Ajustado por Solo - MSAVI), o *Enhanced Vegetation Index* (Índice de Vegetação Realçado - EVI) e o o *Aerosol Free Vegetation Index* (Índice de Vegetação Livre de Aerossol - AFRI). (Tabela 4)

**Tabela 4.** Índices de vegetação calculados para a Floresta Ombrófila do PAE Juruti Velho, no estado do Pará, Brasil.

Nome do índice	Sigla	Fórmula	Referência
Índice de Vegetação da Diferença Normalizada - <i>Normalized Difference Vegetation Index</i>	NDVI	$(\text{NIR} - \text{Vermelho}) / (\text{NIR} + \text{Vermelho})$	(ROUSE, 1973)
Índice de Realce da Vegetação - <i>Enhanced Vegetation Index</i>	EVI	$(G * (\text{NIR} - \text{Vermelho})) / (\text{NIR} + C1 * \text{Vermelho} - C2 * \text{Azul} + L)$	(HUETE, 1997)
Índice de Vegetação Modificado Ajustado por Solo - <i>Modified Soil Adjusted Vegetation Index</i>	MSAVI	$((\text{NIR} - \text{Vermelho}) / (\text{NIR} + \text{Vermelho} + L)) * (1+L)$	(BARNES, 2000)
Índice de Vegetação Livre de Aerossol - <i>Aerosol Free Vegetation Index</i>	AFRI	$\text{NIR} - 0,5 * \text{SWIR} / (\text{NIR} + 0,5 * \text{SWIR})$	(KARNIELI, 2001)

Onde L = 1,0; C1 = 6,0; C2 = 7,5; G = 2,5.

#### 4.6. Ajuste e treinamento das redes neurais artificiais

O ajuste e treinamento das redes neurais artificiais (RNAs) para estimar a BFAS foram realizados no software *Statistica* versão 12 (GONÇALVES et al., 2021; STATSOFT, 2022), buscando atingir a menor taxa de erro nas predições (MIGUEL et al., 2018). Foram treinadas RNAs de forma supervisionada, ou seja, indicando as variáveis de entrada e de saída, com arquitetura do tipo *Perceptron* de Múltiplas Camadas (MLP). Este tipo de RNA é comumente utilizado na solução de problemas não lineares, pois realiza uma comunicação bem intensa entre os neurônios (VIEIRA et al., 2018).

A camada de entrada, a qual recebe as variáveis preditoras, foi composta por quatro neurônios, sendo dois qualitativos (a-b) e dois quantitativos (c-d). Nessa etapa do estudo, os

três estratos de fitofisionomias foram agregados em apenas dois, conforme é apresentado a seguir:

- a. Tipo de floresta 1 - Ombrófila Densa de Terras Baixas
- b. Tipo de floresta 2 - Ombrófila Densa Sub-montana
- c. NDVI
- d. AFRI

O número de neurônios na camada oculta foi otimizado usando a ferramenta *Intelligent Problem Solver* (IPS), do software Statistica 12. Esta ferramenta otimiza a arquitetura das RNAs, e define o melhor número de neurônios na camada oculta e as melhores funções de ativação da camada de entrada para a camada oculta e da camada oculta para a camada de saída. Por fim a camada de saída foi composta por um único neurônio, a biomassa.

O algoritmo utilizado para treinamento das redes neurais foi o *Broyden-Fletcher-Goldfarb-Shanno* – BFGS (BROYDEN, 1970; FLETCHER, 1970; GOLDFARB, 1970; SHANNO, 1970), um algoritmo quase-Newton bastante utilizado e muito eficiente para resolução de problemas e otimização de predições (CARRIJO et al., 2020; CASTRO, 2017; GONÇALVES et al., 2021).

Para treinamento das RNAs foram selecionadas 170 (70%) do total de 225 amostras coletadas em campo durante o inventário florestal. As demais amostras foram utilizadas para validação da rede (BINOTI, 2013; MIGUEL et al., 2018). O número total de ciclos foi otimizado pelo próprio software, que visa minimizar os problemas de perda ou generalização da rede de acordo com o número sub ou superestimado de ciclos (GONÇALVES et al., 2021; MIGUEL et al., 2016).

Do total de 286 RNAs treinadas para estimativa da biomassa com o  $5 \geq \text{DAP} \geq 20$  cm, ou o  $\text{DAP} \geq 20$  cm, foram retidas as cinco melhores redes treinadas sequencialmente. A melhor RNA foi selecionada conforme os parâmetros de correlação de valores observados e estimados; distribuição gráfica de resíduos e raiz quadrada do erro quadrático médio (RMSE%), calculada conforme a equação abaixo (DRAPER, 1998):

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

Onde:

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

$Y_i$  = valor observado;

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



n = número total de dados

As amostras utilizadas para validação foram submetidas ao teste *t* de Student entre os valores reais e esperados, com probabilidade de 95% de certeza ( $p = 0,05$ ) e, posteriormente, uma diferença agregada em porcentagem (AD%), valor estatístico que indica sub ou superestimação (CARRIJO, 2020; GONÇALVES, 2021; MIGUEL, 2018). As análises estatísticas citadas acima foram realizadas por meio do software Microsoft Excel® 2016.

## 5. RESULTADOS

### 5.1. Inventário florestal

A partir dos dados estatísticos (Tabela 5 e

Tabela 6), estimou-se o erro padrão para a média de toda a população de 6,38%, com nível de significância de 95% de probabilidade.

**Tabela 5.** Análise estatística do inventário florestal em 2010, na área do Projeto de Assentamento Agroextrativista Juruti Velho, estado do Pará.

ANÁLISE ESTATÍSTICA	
Tipo de amostragem	Estratificado
Área do inventário florestal (ha)	14.999,70
Número de estratos na população	2
Número de unidades de amostragem em que a população está dividida	119.997,6
Número total de unidades de amostragem no estrato 1 (*)	66.321,6
Número total de unidades de amostragem no estrato 2 (**)	53676
Número de unidades de amostragem observadas na população	250
Número de unidades de amostragem observadas no estrato 1 (*)	138
Número de unidades de amostragem observadas no estrato 2 (**)	112
Proporção do estrato 1 (*) em relação à área total	0,553
Proporção do estrato 2 (**) em relação à área total	0,447
Limite Máximo de Erro	0,1000
População - POPULAÇÃO INFINITA	0,998
Valor de t (95% de probabilidade)	1,960

\* Floresta Ombrófila Densa Sub-montana \*\* Floresta Ombrófila Densa de Terras Baixas.

A área de estudo apresenta, em média, de 168,68 m<sup>3</sup> a 191,66 m<sup>3</sup> de madeira do tronco por hectare, com valores maiores encontrados no Estrato 1 (Figura 5).

**Tabela 6.** Resultados estatísticos do inventário florestal realizado em 2010, na área do Projeto de Assentamento Agroextrativista Juruti Velho, estado do Pará.

<b>Discriminação</b>	<b>Volume de madeira (m<sup>3</sup>)</b>
Média no Estrato 1 (*)	22,62
Média no Estrato 2 (**)	22,17
Média na população	22,52
Total na população	2.702.532,65
Variância da Média Aritmética do estrato 1 (*)	120,99
Variância da Média Aritmética do estrato 2 (**)	144,75
Desvio Padrão do estrato 1(*)	11,00
Desvio Padrão do estrato 2 (**)	11,74
Desvio Padrão da População	0,73
Erro padrão	1,44%
<b>INTERVALO DE CONFIANÇA (IC) - VOLUME</b>	
<b>Por unidade de amostra</b>	
21,09 a 23,96 m <sup>3</sup>	
<b>Por hectare</b>	
168,68 a 191,66 m <sup>3</sup>	
<b>Área do manejo</b>	
2.530.160,64 a 2.874.904,66 m <sup>3</sup>	
Valor de t	1,96
Intensidade ideal de amostragem	98,14
Expectativa de Erro (Erro amostral)	6,38

\* Floresta Ombrófila Densa Sub-montana \*\* Floresta Ombrófila Densa de Terras Baixas.

## **5.2. Biomassa florestal**

A biomassa da FOTB foi estimada em 212,86 ton. ha<sup>-1</sup> (Tabela 7), enquanto na FODS foi de 164,99 ton.ha<sup>-1</sup>. A média total de biomassa para a área de estudo foi 181,60 ton.ha<sup>-1</sup>.

**Tabela 7.** Resultados do estoque médio e desvio padrão da biomassa total acima do solo e por tipo de fitofisionomia na área do Projeto de Assentamento Agroextrativista Juruti Velho, estado do Pará.

<b>Biomassa total DAP <math>\geq</math> 5 cm (ton.ha<sup>-1</sup>)</b>		
<b>FOTB<sup>1</sup></b>	<b>FODS<sup>2</sup></b>	<b>(FOTB&amp;FODS)</b>
212,9 $\pm$ 72,6	165,0 $\pm$ 66,6	181,6 $\pm$ 71,4

<sup>1</sup>Floresta Ombrófila de Terras Baixas (FOTB); <sup>2</sup> Floresta Ombrófila Densa Sub-montana (FODS);  $\pm$  Desvio padrão.

## 5.2. Análise de correlação da biomassa e índices de vegetação

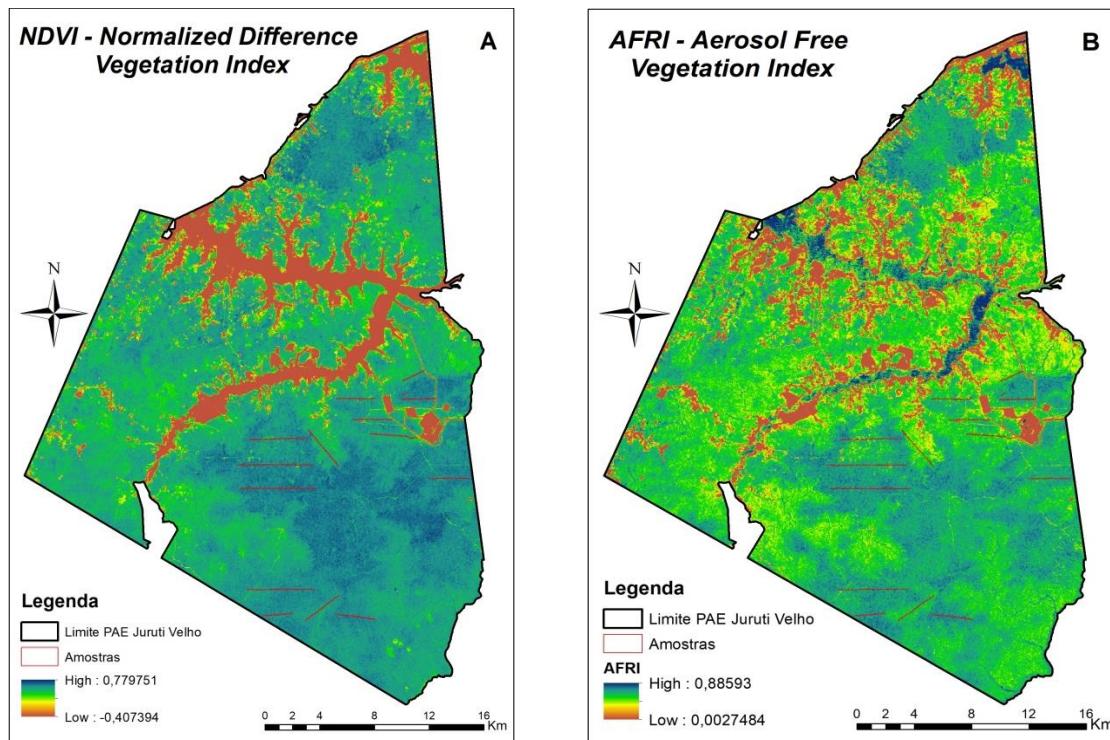
Os resultados da matriz de correlação indicaram que os índices NDVI e AFRI apresentaram correlação significativa ( $p > 95\%$ ) com o estoque de biomassa nas amostras do inventário florestal. Todos os índices de vegetação apresentaram correlações significativas ( $p > 99\%$ ) entre si (Tabela 7).

**Tabela 7.** Matriz de correlação entre os índices de vegetação e a biomassa florestal na área do Projeto de Assentamento Agroextrativista Juruti Velho, no Pará.

	<b>Biomassa</b>	<b>AFRI</b>	<b>NDVI</b>	<b>EVI</b>	<b>MSAVI</b>
Biomassa	1				
AFRI	0.458*	1			
NDVI	0.415*	0.788**	1		
EVI	0.334ns	0.808**	0.921**	1	
MSAVI	0.323ns	0.828**	0.948**	0.982**	1

Legenda: \*Significante à 5%; \*\*Significante à 1%. Em que: NDVI = Índice de Vegetação de Diferença Normalizada; AFRI = Índice de Vegetação Livre de Aerossol; EVI = Índice de Vegetação Realçado; MSAVI = Índice de Vegetação Modificado Ajustado por Solo.

Os índices de vegetação NDVI e AFRI apresentaram semelhanças na estimativa da biomassa acima do solo nas amostras do inventário florestal na área de estudo (Figura 5). Subsequentemente, estes dois índices foram utilizados como variáveis preditoras para biomassa no treinamento das redes neurais artificiais.



**Figura 5.** Índices de vegetação NDVI (A) e AFRI (B) derivados de imagem Landsat-5 TM, adquirida em 2009, para a área do Projeto de Assentamento Agroextrativista Juruti Velho (PAE Juruti Velho), estado do Pará.

### 5.3. Modelagem da biomassa

#### 5.2.1. Seleção das variáveis independentes

Para o desenvolvimento do modelo usando RNAs foram selecionados os dois índices de vegetação que apresentaram correlação estatística significativa com a biomassa acima do solo calculada com os dados do inventário florestal. Complementarmente, utilizou-se os dois estratos florestais (FODS e FODTF) como variáveis categóricas.

#### 5.2.2. Treinamento das redes neurais artificiais

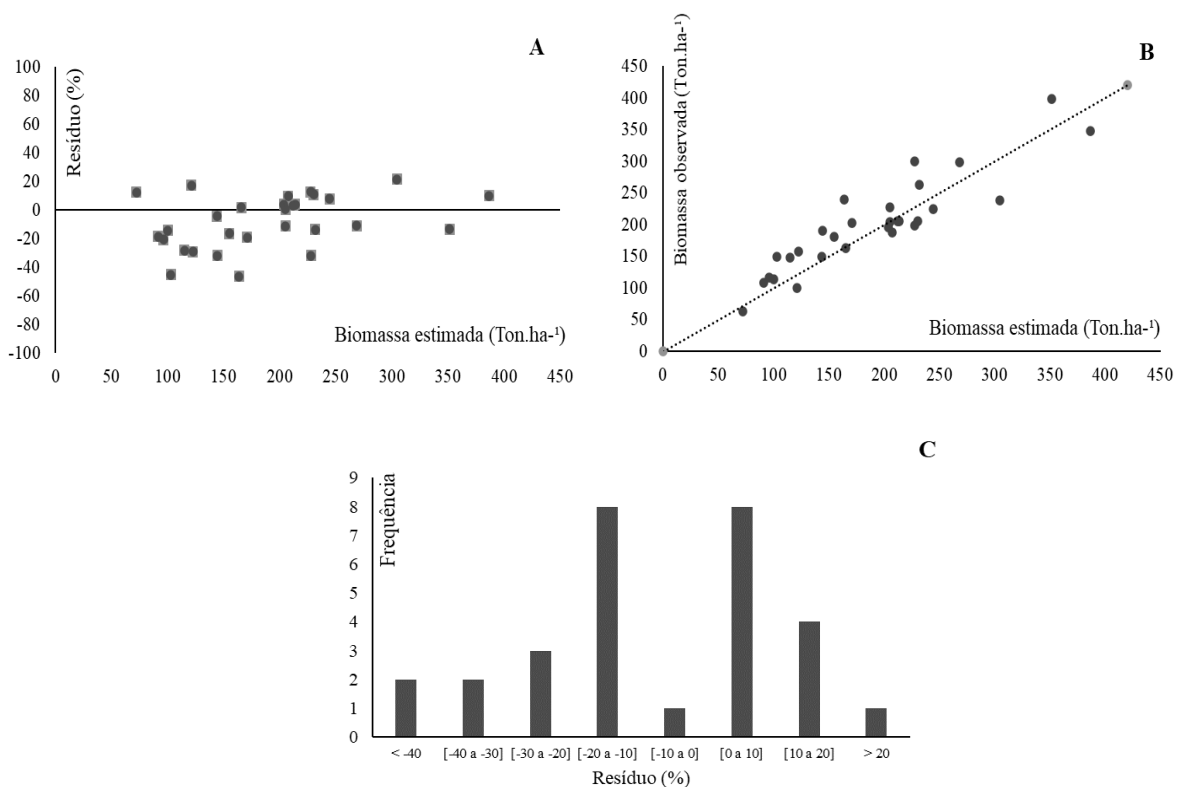
As cinco redes de melhor desempenho dentre as 286 RNAs treinadas apresentaram estatísticas de ajuste e precisão satisfatórias, com valores de coeficiente de correlação R próximos a 0,8 e erros de estimativa em torno de 20%. Porém, a rede neural 1 foi a RNA que demonstrou melhor capacidade preditiva, segundo valores de RMSE% e correlação. (Erro! Fonte de referência não encontrada.).

**Tabela 8.** Características e análise de precisão das redes neurais artificiais treinadas.

RNA	Arquitetura	Nº de Ciclos	Ativação Oculta	Ativação Saída	Ajuste		Validação	
					RMSE%	R	RMSE%	R
<b>1</b>	<b>MLP 4-13-1</b>	<b>286</b>	<b>Logística</b>	<b>Identidade</b>	<b>20,65</b>	<b>0,82</b>	<b>22,74</b>	<b>0,81</b>
2	MLP 4-10-1	198	Logística	Tangente	22,07	0,80	23,99	0,79
3	MLP 4-8-1	242	Identidade	Exponencial	21,11	0,82	23,62	0,81
4	MLP 4-18-1	310	Tangente	Identidade	22,06	0,80	24,34	0,80
5	MLP 4-19-1	225	Identidade	Identidade	21,33	0,81	24,79	0,79

**Legenda:** RNA = redes neurais artificiais; MLP = Multilayer perceptron (Perceptron multicamadas); RMSE = Root-Mean-Square Error (Raiz do erro quadrático médio); R = correlação entre os valores observados e estimados.

A RNA 1 apresentou padrão aceitável para distribuição de resíduos (A), com predições acuradas de biomassa florestal acima do solo (B). De acordo com o histograma de classes de erros, apresentou uma concentração maior de resíduos variando em  $\pm 20\%$ , evidenciando assim sua capacidade na predição da biomassa florestal acima do solo na área deste estudo (Figura 6).

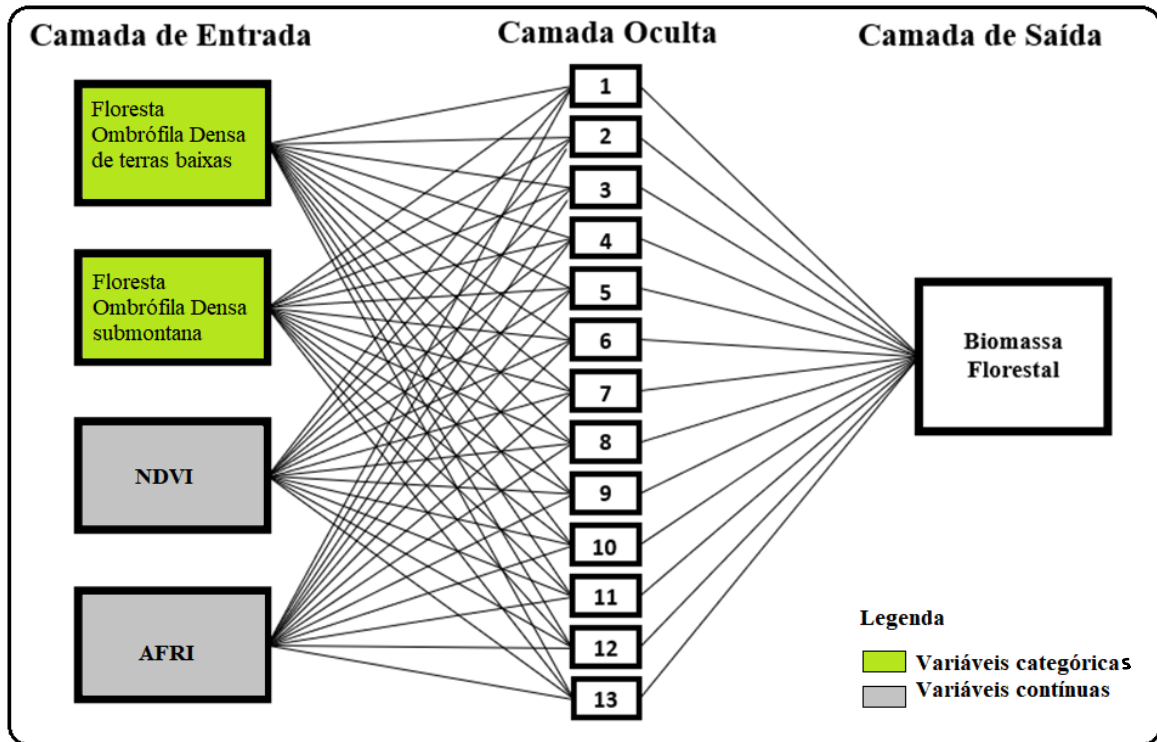


**Figura 6.** Distribuição de resíduos (A), valores observados e estimados (B) e distribuição de classes de erro (C) da estimativa de biomassa florestal para a área do Projeto de Assentamento Agroextrativista Juruti Velho (PAE Juruti Velho), no estado do Pará.

O comportamento do gráfico de dispersão dos resíduos da estimativa de biomassa florestal (Figura 6) apresentou distribuição adequada de erros, sem tendências visíveis, com pontos compactos e bem distribuídos ao longo da linha de regressão. Os erros máximos estão limitados à  $\pm 40\%$ , representando resultado satisfatório.

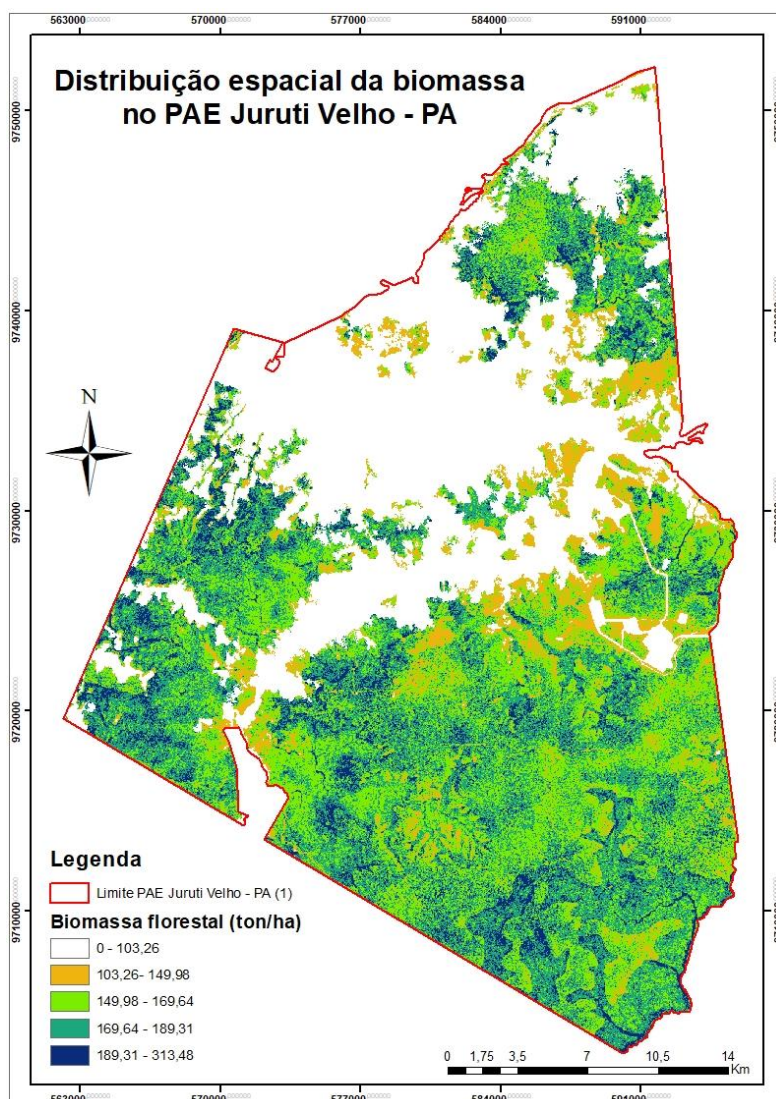
O poder preditivo da RNA escolhida é demonstrado pela relação entre valores observados e preditos, que apresenta a aderência da rede neural selecionada aos dados reais. Além disso, a frequência de erros concentrou-se em sua maior parte entre  $\pm 20\%$  (Figura 6), sendo registrados poucos erros superiores a  $\pm 20\%$ .

A RNA 1 apresentou em sua configuração 13 neurônios na camada oculta, ativada por uma função logística, enquanto a camada de saída é ativada por uma função identidade (Figura 7).



**Figura 7.** Arquitetura da RNA selecionada para a predição da biomassa florestal por estrato em Floresta Ombrófila (4-13-1).

No geral, a distribuição da biomassa acima do solo estimada com o modelo RNA 1 apresentou-se bastante homogênea, com algumas concentrações de maior quantidade nas áreas de FOTB. As variações de baixa quantidade de biomassa ocorrem em sua maioria nas áreas de influência das ações antrópicas (efeito de borda do desmatamento e florestas degradadas) (Figura 8).



**Figura 8.** Distribuição espacial da biomassa florestal ( $\text{ton}\cdot\text{ha}^{-1}$ ) estimada por rede neural aplicada a imagens do satélite Landsat-5 para a área do Projeto de Assentamento Agroextrativista Juruti Velho (PAE Juruti Velho), estado do Pará.

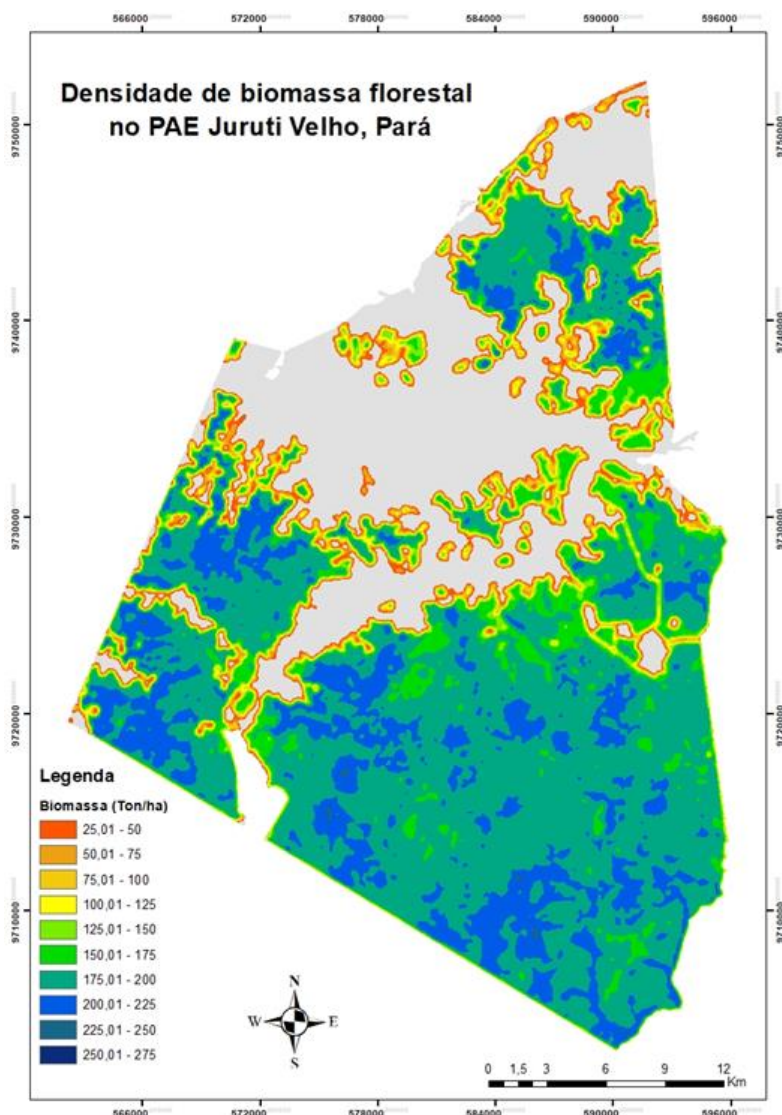
#### 5.4. Análise estatística

O resultado do teste  $t$  de *Student* mostrou que a RNA 1 não apresentou diferenças estatísticas significativas entre os valores preditos pela rede neural com os valores observados para as parcelas de validação ( $p = 0,78$ ), conseqüentemente, assume-se que as estimativas são precisas. Já a diferença agregada demonstrou leve viés de superestimação da rede ( $\text{DA}\% = -5,50$ ), validando os resultados de precisão encontrados para o treinamento da rede neural. Ou seja, a qualidade da predição não foi comprometida, pois o resultado da  $\text{DA}\%$  mostra que os valores estimados estão próximos dos valores reais de biomassa para a área de estudo.



## 5.5. Distribuição espacial da biomassa

A aplicação do filtro espacial de *Kernel Density* (Figura 9) sobre os dados de biomassa oriundos da modelagem produzida pela RNA 1 possibilitou a melhor observação da distribuição espacial das variações da biomassa na área de estudo. Registrou-se uma distribuição bastante homogênea de biomassa (175 a 200  $\text{ton}\cdot\text{ha}^{-1}$ ), com algumas concentrações ( $> 200 \text{ ton}\cdot\text{ha}^{-1}$ ) distribuídas na área de estudo. As menores concentrações de biomassa estão localizadas nas bordas dos fragmentos florestais e em áreas de fragmentos florestais menores, degradados por algum tipo de ação antrópica.



**Figura 9.** Distribuição espacial da densidade de Kernel, com os valores de biomassa ( $\text{ton}\cdot\text{ha}^{-1}$ ) variando de 25 a 275  $\text{ton}\cdot\text{ha}^{-1}$  na área do Projeto de Assentamento Agroextrativista Juruti Velho (PAE Juruti Velho), estado do Pará.

## 6. DISCUSSÃO

### 6.1. Biomassa florestal acima do solo

A média total de biomassa para a área de estudo ( $181,60 \text{ ton. ha}^{-1}$ ) é menor que a estimada por Matos (2008) para a Floresta Ombrófila na região central da Amazônia, de  $249,9 \pm 7,8 \text{ ton. ha}^{-1}$  e bem inferior à média obtida para a Floresta Ombrófila em Rondônia, estimada em  $339,1 \text{ ton. ha}^{-1}$  (Sampaio et al. 2003). A redução nos valores de biomassa encontrados pode ter ocorrido devido ao fato do modelo proposto por Chave et al. (2014) subestimar a biomassa em áreas onde as árvores são mais baixas, mas têm copas muito grandes.

Considerando que o inventário original da floresta foi realizado para fins de estimativa de volume de madeira, deve-se considerar o viés de amostragem no conjunto de dados de colheita florestal. Neste caso, como a colheita de árvores muito grandes é uma atividade trabalhosa, indivíduos com tronco bem formados podem ter sido priorizados (Goodman 2014), ao invés de árvores mais altas quebradas ou senescentes (CHAVE et al., 2014; GOODMAN, 2014). Assim, a biomassa florestal da área de estudo pode ter sido subestimada em locais em que os indivíduos considerados apresentavam alturas maiores.

Apesar dos valores estimados de biomassa serem menores que os encontrados em estudos em outras florestas ombrófilas, os resultados deste estudo são satisfatórios. Por exemplo, Clark & Kellner (2016), apontam que essa discrepância não deve necessariamente ser interpretada como uma falha do modelo, visto que o mesmo apresenta maior precisão do que modelos de regressão que não utilizam a densidade da madeira em suas equações. Os modelos que associam apenas o DAP e a altura das árvores podem superestimar a quantidade de biomassa em áreas com indivíduos arbóreos altos, finos e com baixa densidade específica da madeira (GOODMAN, 2014). Assim, a estimativa de biomassa utilizando o modelo proposto pode representar com melhor acurácia a área de estudo.

A maior quantidade de biomassa estimada na tipologia de Floresta Ombrófila Densa de Terras Baixas foi provavelmente devido à ausência de distúrbios florestais, como fogo ou extração seletiva de madeiras. Por outro lado, a diminuição na quantidade de biomassa na Floresta Ombrófila Densa Sub-montana pode estar relacionada ao fogo e aos impactos da extração ilegal de produtos madeireiros (HUETE, 1988; SAMPAIO et al., 2003). A região do PAE Juruti Velho é fortemente impactada pelas atividades de mineração, extração seletiva de madeiras, garimpos e siderurgia (FIOCRUZ, 2022), o que gera desmatamento e aumento das queimadas na região. A redução da biomassa florestal está diretamente

relacionada com a prática de queima e desmatamentos em florestas tropicais, especialmente na Amazônia, que provocam alterações físico-químicas e ecológicas nos ecossistemas (SAMPAIO et al., 2003).

## **6.2. Índices de vegetação**

Os quatro índices apresentaram boa correlação com o estoque de biomassa (NDVI, AFRI, EVI e MSAVI), os quais são comumente indicados para estimativa de biomassa em áreas de florestas densas, a depender dos satélites utilizados para extração dos dados espectrais (GARROUTTE et al., 2016; KARNIELI et al., 2001; MABUNDA et al., 2021; PANDA et al., 2010; ZHONG et al., 2016). Os melhores resultados obtidos pelo NDVI se devem ao fato deste índice apresentar alta correlação com a biomassa florestal quando proveniente de dados do satélite Landsat (FRANKLIN & HIERNAUX, 1991; MABUNDA ET AL., 2021). Os baixos valores de NDVI nos pontos amostrais estão relacionados com as áreas de menor cobertura vegetal ou áreas queimadas e com alta exploração de madeira (DAGNACHEW et al., 2020; MABUNDA et al., 2021; RISHMAWI, 2016). De maneira análoga, o NDVI apresenta valores maiores em regiões de maior conservação da vegetação, como observado nas áreas do estrato de Floresta Ombrófila de Densa de Terras Baixas nesse estudo (RISHMAWI, 2016; SYDOW et al., 2017; VILA NOVA, 2013). O resultado da alta correlação entre esse índice e a biomassa na área de estudo, em que duas fitofisionomias são estudadas e apresentam diferenças no nível de cobertura vegetal decorrente da ação antrópica, está em conformidade com os estudos disponíveis na literatura científica.

O índice AFRI, criado por Karnieli et al. (2001), como alternativa para diminuir a influência de efeitos atmosféricos que impedem a análise multitemporal da vegetação, apresentou alta correlação com a biomassa florestal. Devido a sua alta resposta em área com fumaça (MATRICARDI, et al., 2010), esse índice tem sido utilizado para estimar biomassa em áreas com alta presença de fogo, como é o caso da fitofisionomia Floresta Ombrófila Densa Sub-montana na PAE Juruti Velho. Karnieli et al. (2001) apontou o índice AFRI como substituto promissor ao NDVI em áreas com alta presença de fumaça ou outros poluentes, devido à sua maior capacidade de penetração atmosférica nessas condições. Assim, tanto o NDVI como o AFRI atuam de forma complementar na estimação de biomassa em áreas com variabilidade de presença de fogo (KARNIELI et al., 2001; ZHONG et al., 2016).

A menor correlação com a biomassa florestal dos índices EVI e MSAVI neste estudo foi provavelmente devido à grande variação que os mesmos sofrem em relação à estrutura do relevo. Apesar de serem apontados como adequados preditores de biomassa em áreas de

floresta tropical (FERRAZ et al., 2014; GARROUTE, 2016; MABUNDA et al., 2021; SANTANA, 2018), o EVI e o MSAVI possuem certa limitação para estimação de biomassa em florestas muito densas que apresentam grandes variações topográficas, por serem muito sensíveis a essa variável. Quando comparados ao NDVI, o EVI e o MSAVI, apresentam maior vulnerabilidade à variação do relevo (EPIPHANIO, 1997; FERRAZ et al., 2014), já que o NDVI é capaz de minimizar os efeitos topográficos ao produzir uma escala linear de medidas (ALMEIDA et al., 2015). Tal característica pode ter sido fundamental para aumentar a correlação do NDVI com a biomassa florestal na área de estudo, uma vez que as fitofisionomias se encontram em diferentes porções topográficas.

### **6.3. Modelagem**

#### **6.3.1. Seleção das variáveis independentes**

As moderadas correlações entre os índices de vegetação e a biomassa florestal, porém significativas, indicam que os dados de sensores remotos podem ser considerados para estimativa dessa variável. Resultados semelhantes foram encontrados em diversos estudos envolvendo índices de vegetação associados a diferentes variáveis da comunidade florestal, como volume de madeira e circunferência do tronco (GONÇALVES et al., 2021; MACHADO et al., 2017; MIGUEL et al., 2015b; MIRELES, 2017; PANDA; AMES; PANIGRAHI, 2010; PHUA, 2017; ZHU, 2015). O padrão moderado de correlação entre os índices de vegetação e a biomassa florestal está associado ao fato de que normalmente os IV's sofrem interferências das condições da atmosfera, do solo, de fontes de radiação e de aspectos relacionados à própria estrutura da vegetação, tais como arquitetura e irregularidades do dossel (GONÇALVES, 2021; JENSEN, 2009; MIGUEL et al., 2015). Assim, mesmo com a influência de alguns aspectos do ambiente e da estrutura arbórea, os índices de vegetação possuem relação satisfatória com a estimativa da biomassa florestal.

O fato dos valores de correlação encontrados entre os índices de vegetação e a biomassa serem significativos e positivos, pode ser explicado pela correlação positiva que os índices têm com o crescimento radial do fuste e área foliar (BUSTAMANTE et al., 2016; GONÇALVES et al., 2021; VICENTE-SERRANO, 2016). Esses parâmetros têm relação direta com o volume da madeira, a captura de carbono e, conseqüentemente, com a biomassa florestal (GONÇALVES et al., 2021; VICENTE-SERRANO, 2016). Além disso, os índices de vegetação têm a capacidade de normalizar e modelar efeitos externos, como sombra, influências do solo e da atmosfera (HAMADA, 2015; JENSEN, 2009; PONZONI, 2012). Assim, o uso de índices de vegetação para modelagem de BF reduz as interferências externas

à vegetação estudada, tornando-os mais sensíveis e correlacionados a BF do que a utilização exclusiva de faixas espectrais, por exemplo (VIEIRA, 2013).

A seleção da variável categórica do tipo de fitofisionomia trouxe mais precisão aos resultados encontrados nesse estudo. As variáveis independentes dentro dos modelos devem ser capazes de estimar a variável de interesse (JENSEN, 2009), como é o caso da biomassa florestal nesse estudo. A distribuição da biomassa florestal varia conforme a composição e estrutura da fitofisionomia em ordem decrescente das formações florestais para as herbáceo-arbustivas (ROQUETTE, 2018). Diante disso selecionou-se essa variável qualitativa para compor o modelo para estimativa de biomassa buscando analisar a BF na Floresta Ombrófila Densa de Terras Baixas e Floresta Ombrófila Densa Sub-montana. Ferraz et al. (2014), ao estimar a biomassa de uma Floresta Estacional em Minas Gerais utilizando redes neurais artificiais e dados do satélite Landsat-5 TM ressaltou que a adição da variável categórica “Fitofisionomia” conferiu maior precisão ao modelo. Semelhantemente, a inclusão dessa variável no treinamento das RNAs tornou os resultados encontrados mais concisos com a realidade da floresta tropical neste estudo.

A maior correlação entre os índices NDVI e AFRI e a biomassa florestal está relacionada à ação complementar e à sensibilidade destes dois índices em áreas de florestas densas (KARNIELI et al., 2001), com diferentes graus de cobertura vegetal e efeitos do solo.

### **6.3.2. Treinamento das redes neurais**

Dentre as 5 redes treinadas, a Rede 1 é a que apresenta os melhores resultados. Diante da alta complexidade das variáveis estudadas e da grande variabilidade encontrada em florestas nativas, é aceitável um limite de erro em torno de 20%, o que torna concisos os resultados encontrados (GONÇALVES et al., 2021; SYDOW et al., 2017). A aplicação das RNAs no meio florestal tem sido demonstrada em diversos trabalhos, com alto poder de predição se comparadas aos modelos de regressão clássicos para estimativas das variáveis de interesse da floresta (CARRIJO et al., 2020; ; GONÇALVES et al., 2021; MIGUEL et al., 2015b; MIRELLA et al., 2017; VIEIRA et al., 2018). Além disso, a associação de RNAs com dados de sensoriamento remoto confere maior precisão aos estudos da floresta, pois permitem assimilar a grande complexidade e variedade da vegetação, aspectos ambientais e climáticos (CARRIJO et al., 2020; MIGUEL et al., 2018). Diante disso, apesar das RNAs exigirem maior complexidade e capacidade computacional para seu treinamento, seu uso é recomendado em função de sua maior precisão para modelar relações complexas entre as variáveis (HAYKIN, 2001; MIGUEL et al., 2015b).

De modo geral, a distribuição de biomassa florestal mostrou-se homogênea, com maior variação nas bordas e em algumas manchas da área de estudo. O fato dos maiores valores de densidade de biomassa terem sido encontrados em áreas de floresta com menor grau de degradação por extração seletiva de madeiras e fogo, indica que o uso de mapas de densidade de Kernel pode auxiliar no monitoramento da biomassa florestal. Esta condição possibilita o direcionamento da exploração das áreas florestais, bem como a otimização e alocação dos locais com maior estocagem de carbono (GONÇALVES et al., 2021; RATUCHNE et al., 2016; SANQUETTA & BEHLING; CORTE, 2014).

Os resultados aqui apresentados corroboram com as pesquisas de diversos autores que relacionaram dados de sensoriamento remoto com treinamento de redes neurais artificiais para estimar variáveis em florestas tropicais (CARRIJO ET AL., 2020; FERRAZ, 2014; FOODY ET AL., 2001; GONÇALVES ET AL., 2021; INGRAM, 2005; MIGUEL ET AL., 2015; LI ET AL. 2019 E RIOS ET AL., 2008).

### **6.3.3. Análise estatística**

A RNA selecionada indica que o modelo é acurado, ou seja, os valores estimados estão próximos aos valores reais de biomassa. Conforme mencionado por Serpen e Gao, (2014), isso ocorre porque as RNAs tem grande capacidade de aprender e extrair padrões de um conjunto de dados, generalizá-los e aplicá-los sem perder a acurácia (SERPEN & GAO, 2014). Assim, a partir da seleção das variáveis independentes, a RNA pôde identificar padrões das relações complexas entre os índices de vegetação e as fitofisionomias e estimar satisfatoriamente a biomassa florestal da área de estudo.

A eficácia da RNA selecionada também foi confirmada pela diferença agregada (DA%), a qual apresentou um valor percentual pequeno (5,50%) de subestimação na estimativa da biomassa florestal. As redes foram treinadas e validadas para duas fitofisionomias do bioma amazônico que refletem variações ecotípicas de faixas altimétricas resultantes de ambientes também distintos (Floresta Ombrófila Densa de Terras Baixas e Floresta Ombrófila Densa Sub-montana). Dessa forma, levou-se em consideração a variabilidade de espécies, estrutura, arquitetura da copa e formato do dossel, o que confere ainda maior solidez nas estimativas de biomassa deste estudo.

## 7. CONCLUSÕES

Os resultados deste estudo impactam de forma positiva a tecnologia de estimativa remota de biomassa, representando uma importante ferramenta de gestão e direcionamento estratégico de áreas com diferentes quantidades de biomassa. Os índices NDVI e AFRI, calculados a partir de dados do satélite Landsat 5-TM, mostraram-se promissores para estimativa da variável em áreas de Floresta Ombrófila Densa e revelam como os estoques de carbono pode ser variáveis em áreas de florestas na Amazônia.

O modelo de rede neural artificial do tipo *Multilayer Perceptron* que utiliza funções de ativação logística e identidade e o algoritmo de treino BFGS, associado com índices de vegetação e diferentes fitofisionomias, revelou alta acurácia e eficiência na estimativa remota da biomassa florestal acima do solo em área de floresta tropical. Estas técnicas associadas estão na fronteira do conhecimento e da tecnologia, otimizando o tempo, reduzindo os custos e contribuindo positivamente para a gestão e o manejo sustentável de florestas até mesmo de difícil acesso.

## 8. REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, A. C. **Estimation of aboveground forest biomass in amazonia with neural networks and remote sensing**. IEEE Latin America Transactions. **Anais...**2009.

ALMEIDA, A. Q. et al. Índice de área foliar de eucalyptus estimado por índices de vegetação utilizando imagens TM - landsat 5. **Floresta e Ambiente**, v. 22, n. 3, p. 368–376, 2015.

BACCINI, A; GOETZ, S. J.; WALKER, W. S.; LAPORTE, N. T. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. **Nature Climate Change**, v. 2, n. 1, p. 1–4, 2012.

BALZTER, H. Forest mapping and monitoring with interferometric synthetic aperture radar (InSAR). **Progress in Physical Geography**, v. 25, n. 2, p. 159–177, 2001.

BARATI, S.; RAYEGANI, B. Comparison the accuracies of different spectral indices for estimation of vegetation cover fraction in sparse vegetated areas. **The Egyptian Journal of Remote Sensing and Space Sciences**, v. 14, n. 1, p. 49–56, 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.

BINOTI, M. L. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Arvore**, v. 37, n. 4, p. 639–645, 2013.

BIRDSEY, R. Carbon Accounting Rules and Guidt. **Forestry**, 2006.

BRAGA, A. P. **Redes neurais artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro: LTC, 2007.

BRIENEM, R. J. W. ET AL. Long-term decline of the Amazon carbon sink. **Nature**, v. 519, n. 7543, p. 340–353, 2015.

BROYDEN, G. The convergence of a class of double-rank minimization algorithms 1. General considerations. **IMA Journal of Applied Mathematics**, v. 6, n. 1, p. 76–90, 1970.

BUSTAMANTE, M. 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.

CARNEIRO, A. C.; CASTRO, A. F. N. Potencial energético da madeira Eucalyptus sp . em função da idade e de diferentes materiais genéticos. **Revista Árvore**, v. 38, n. 2, p. 375–381, 2014.

CARON, B. O. et al. Quantificação da Biomassa florestal em plantios de curta rotação com diferentes espaçamentos. **Comunicata Scientiae**, v. 6, n. 1, p. 1–7, 2015.

CARRIJO, J. V. N. et al. Morphometric indexes and dendrometric measures for classification of forest sites of Eucalyptus urophylla stands. **Australian Journal of Crop Science**, v. 11, n. 9, p. 1146–1153, 2017.



- CARRIJO, J. V. N. et al. Artificial intelligence associated with satellite data in predicting energy potential in the Brazilian savanna woodland area. **IForest**, v. 13, n. 1, p. 48–55, 2020.
- CARVALHO, L.; DEMEDA, K. Os royalties da mineração e o sistema da dádiva em Juruti Velho - Juruti, Pará. **Espacios**, v. 18 (Nº35), n. January, p. 6–8, 2018.
- CASTRO, G. Modelo de rede neural bioinspirada para o controle do trânsito urbano. p. 33–42, 2017.
- CASTRO, V. O. R. Individual growth model for Eucalyptus Stands in Brazil using artificial neural network. **ISRN Forestry**, v. 2013, p. 1–12, 15 abr. 2013.
- CHAVE, J. et al. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global Change Biology**, v. 20, n. 10, p. 3177–3190, 2014.
- CLARK, D.; KELLNER, J. Tropical forest biomass estimation and the fallacy of misplaced concreteness. **Journal of Vegetation Science**, v. 4, n. 2, p. 33–44, 2016.
- COOPERATIVA DE SERVIÇOS E IDÉIAS AMBIENTAIS - ECOOIDEIA. Relatório Técnico de Geoprocessamento sobre Uso do Solo e Cobertura Florestal no PAE-JV. p. 54p, 2011.
- CUNHA, E. Quantificação de biomassa em floresta estacional semidecidual por meio de redes neurais artificiais. n. Dissertação de Mestrado-Ciências Florestais. Diamantina, MG, p. 76, 2015.
- CUTLER, M. E. J. et al. Estimating tropical forest biomass with a combination of SAR image texture and Landsat TM data: An assessment of predictions between regions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 70, p. 66–77, 2012.
- DAGNACHEW, M. et al. Effects of Climate Variability on Normalized Difference Vegetation Index (NDVI) in the Gojeb River Catchment, Omo-Gibe Basin, Ethiopia. **Advances in Meteorology**, v. 2020, 2020.
- DEL FRATE, F. . S. D. On Neural Networks Algorithms for Retrieving Forest Biomass from SAR Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n. 1, p. 24–34, 2004.
- DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and electronics in agriculture**, v. 10, p. 235–244, 2005.
- DRAPER, N. Applied regression analysis. v. 3, n. 7, p. 716, 1998.
- ELOY, E. Quantificação e caracterização da biomassa florestal em plantios de curta rotação. v. 4, n. 21, p. 31–33, 2013.
- EMBRAPA. **Landsat**. Disponível em: <<https://www.embrapa.br/satelites-de-monitoramento/missoes/landsat>>. Acesso em: 25 abr. 2022.
- EPIPHANIO, J. Índices de vegetação no sensoriamento remoto. v. 7, n. 3, p. 1–10, 1997.
- FERRAZ, A. S. et al. Estimativa do estoque de biomassa em um fragmento florestal usando

- imagens orbitais. **Floresta e Ambiente**, v. 21, n. 3, p. 286–296, 2014.
- FERREIRA, E. C. Uso de Produtos Florestais Não Madeireiros em Projeto de Assentamento Agroextrativista na Amazônia. **Espacios**, v. 37 (Nº 38), n. January, p. 19, 2016.
- FILGUEIRAS, G. C.; SANTANA, A. C. Análise da economia florestal no estado do Pará - Uma aplicação da matriz de contabilidade social. v. 14 (Nº30), n. Teoria e Evidência Econômica, p. 37–62, 2008.
- FIOCRUZ. **Mineração versus comunidades tradicionais extrativistas no extremo oeste do Pará: deterioração de igarapés, lagos e corte de matas e castanheiras**. Disponível em: <<http://mapadeconflitos.ensp.fiocruz.br/conflito/mineracao-versus-comunidades-tradicionais-extrativistas-no-extremo-oeste-do-para-deterioracao-de-igarapes-lagos-e-corte-de-matas-e-castanheiras/>>. Acesso em: 1 jun. 2022.
- FLETCHER, R. A new approach to variable metric algorithms. **The Computer Journal**, v. 13, n. 3, p. 317–322, 1970.
- FOODY, G. M. et al. Mapping the biomass of Bornean tropical rain forest from remotely sensed data. **Global Ecology and Biogeography**, v. 10, n. 4, p. 379–387, 2001.
- FOODY, G. M. Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. **Remote Sensing of Environment**, v. 85, p. 463–474, 2003.
- FRANKLIN, J.; HIERNAUX, P. H. Y. Estimating foliage and woody biomass in Sahelian and Sudanian woodlands using a remote sensing model. **International Journal of Remote Sensing**, v. 12, p. 1387–1404, 1991.
- GARROUTE, E. Using NDVI and EVI to Map Spatiotemporal Variation in the Biomass and Quality of Forage for Migratory Elk in the Greater Yellowstone Ecosystem. **Remote Sensing**, v. 8, n. 404, p. 3–8, 2016.
- GARROUTTE, E. L.; HANSEN, A. J.; LAWRENCE, R. L. Using NDVI and EVI to Map Spatiotemporal Variation in the Biomass and Quality of Forage for Migratory Elk in the Greater Yellowstone Ecosystem. **Remote Sensing**, v. 8, n. 404, p. 3–8, 2016.
- GOLDFARB, D. family of variable-metric methods derived by variational means. **Mathematics of Computation**, v. 24, n. 109, p. 23–32, 1970.
- GONÇALVES, F. C. et al. Artificial intelligence associated with Sentinel-2 data in predicting commercial volume in Brazilian Amazon Forest. **Journal of Applied Remote Sensing**, v. 15, n. 04, p. 1–19, 2021.
- GONÇALVES, F. C. Predição volumétrica utilizando redes neurais artificiais e dados de sensoriamento remoto em floresta nativa na Amazônia brasileira. n. Dissertação de Mestrado-Ciências Florestais. Universidade de Brasília (UnB), Brasília, DF., p. 65, 2021.
- GONÇALVES, W. Classificação supervisionada de área irrigada utilizando índices espectrais de imagens Landsat-8 com Google Earth Engine. **Irriga**, v. 8546, p. 160–169, 2016.

GOODMAN, R. C. The importance of crown dimensions to improve tropical tree biomass estimates. **Ecological Applications**, v. 14, n. 5, p. 33–43, 2014.

HAMADA, E. Aplicação de índices espectrais na avaliação do aumento da concentração de dióxido de carbono. n. Simpósio Brasileiro de Sensoriamento Remoto-SBSR, p. 2759–2766, 2015.

HAYKIN, S. Redes Neurais: Princípios e prática. v. 1, n. 12, p. 900, 2001.

HEINSDIJK, D.; BASTOS, A. M. Inventários florestais na Amazônia. **Ecological Modelling**, v. 1, n. 27, p. 153–167, 1963.

HENTZ, A.M.K; RUZA, M.S.; CORTE, A.P.D.; SANQUETTA, C. R. Técnicas de Sensoriamento Remoto para estimativa de biomassa em ambientes florestais. **Enciclopédia Biosfera**, v. 10, n.18, p. 2810–2823, 2014.

HUETE, A. DIDAN, K. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, n. 3, p. 440–451, 1997.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–307, 1988.

IBGE. Classificação da Vegetação Brasileira, Adaptada a um Sistema Universal. p. 62–64, 1991.

IBGE. **Brasil em síntese**. Disponível em: <<https://brasilemsintese.ibge.gov.br/territorio.html>>. Acesso em: 5 jun. 2022.

IDESP. **Estatística Municipal: Aspectos Físicos Territoriais de Juruti**. Disponível em: <<http://idesp.edunet.sp.gov.br/>>. Acesso em: 20 ago. 2021.

IMAFLORA. **A EVOLUÇÃO DA ATIVIDADE MADEIREIRA NO ESTADO DO PARÁ: SITUAÇÃO ATUAL E PERSPECTIVAS PARA O SETOR FLORESTAL NO SÉCULO XX**. Disponível em: <[https://www.imaflora.org/public/media/biblioteca/boletim\\_timberflow\\_3\\_marco\\_2021\\_fi nal\\_1.pdf](https://www.imaflora.org/public/media/biblioteca/boletim_timberflow_3_marco_2021_fi nal_1.pdf)>. Acesso em: 5 jun. 2022.

INGRAM, J. C. Mapping tropical forest structure in southeastern Madagascar using remote sensing and artificial neural networks. **Remote Sensing of Environment**, v. 94, n. 4, p. 491–507, 2005.

INPE. **Landsat**. Disponível em: <<http://www.dgi.inpe.br/documentacao/satelites/landsat>>. Acesso em: 24 abr. 2022.

JENSEN, J. R. Sensoriamento Remoto do Ambiente: Uma perspectiva em recursos terrestres. **Catena**, p. 153, 2009.

KARNIELI, A. .; YORAM, J. K. .; REMER, L. AFRI — Aerosol free vegetation index. **Remote Sensing of Environment**, v. 4257, n. May 2018, p. 10–21, 2001.

LE MAIRE, G.; MARDESEN, C.; NOUVELLON, Y; GRINAND, C. HAKAMADA, R.; STAPE, J.L.; LACLAU, J. P. NDVI time-series allow the monitoring of Eucalyptus

- plantation biomass. **Remote Sensing of Environment**, v. 115, n.10, p. 2613–2625, 2011.
- LEMOS, L.; SILVA, J. Desmatamento na Amazônia Legal: Evolução, Causas, Monitoramento e Possibilidades de Mitigação Através do Fundo Amazônia. **Floresta e Ambiente**, v. 18, n. 1, p. 98–108, 2011.
- LEVINE, E. R. Classifying soil structure using neural networks. **Ecological Modelling**, v. 92, p. 101–108, 1996.
- LI, C.; MINGYANG, L.; LIU, J. Comparative Analysis of Seasonal Landsat 8 Images for Forest Aboveground Biomass Estimation in a Subtropical Forest. **Forests**, v. 11, n. 45, p. 1–17, 2019.
- LI, Y. et al. Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms. **Scientific Reports**, v. 10, n. 1, p. 1–12, 2020.
- LICZNAR, P. Artificial neural networks of soil erosion and runoff prediction at the plot scale. **Catena**, v. 51, p. 89–114, 2003.
- MABUNDA, I. R. et al. Estimation of forest biomass for energy purposes using vegetation and field data indices, District of Mabalane - Mozambique. **Revista Brasileira de Cartografia**, v. 73, n. 1, p. 313–328, 2021.
- MACHADO, I. E. S. et al. Modelos para estimativa de variáveis florestais com a utilização de imagens multiespectrais. **Pesquisa Florestal Brasileira**, v. 37, n. 90, p. 171, 2017.
- MARCUSSI, A. B. Utilização de índices de vegetação para os sistemas de informação geográfica. **Caminhos de Geografia**, p. 41–53, 2010.
- MARONEZE, M. M. et al. A tecnologia de remoção de fósforo: Gerenciamento do elemento em resíduos industriais. **Revista Ambiente e Agua**, v. 9, n. 3, p. 445–458, 2014.
- MATOS, F.D.A.; KIRCHNER, F. F. Estimativa de biomassa da Floresta Ombrófila Densa de Terra Firme na Amazônia Central com o satélite IKRONOS II. **Floresta**, v. 38, n.1, n. 1993, p. 157–171, 2008.
- MATRICARDI, E. A. T.; SKOLE, D. L. ; PEDLOWSKI, M. A. Assessment of tropical forest degradation by selective logging and fire using Landsat imagery. **Remote Sensing of Environment**, v. 114, p. 1117–1129, 2010.
- MELLO, S. L. D. M.; GONÇALVES, J. L. D. M. Equations to estimate shoot and root system biomass in Eucalyptus grandis stands at sites with different productivities. **Revista Arvore**, v. 32, n. 1, p. 101–111, 2008.
- MIGUEL, E. P. et al. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerrado com dados de satélite. **Pesquisa Agropecuaria Brasileira**, v. 50, n. 9, p. 829–839, 2015a.
- MIGUEL, E. P. et al. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerrado com dados de satélite. **Pesquisa Agropecuaria Brasileira**, v. 50, n. 9, p. 829–839, 2015b.

- MIGUEL, E. P. et al. Caracterização florístico-estrutural e grupo sucessional de espécies arbóreas no bioma cerrado do estado de Tocantins, Brasil. **Revista Caatinga**, v. 29, n. 2, p. 393–404, 1 abr. 2016.
- MIGUEL, E. P. et al. Using artificial neural networks in estimating wood resistance. **Maderas: Ciencia y Tecnologia**, v. 20, n. 4, p. 531–542, 1 out. 2018.
- MIRANDA, J. F. N. Modelos de regressão e de redes neurais artificiais na quantificação de carbono e biomassa lenhosa em floresta estacional decidual no Brasil Central. n. Dissertação (Mestrado em Ciências Florestais)-Universidade de Brasília, Brasília-DF, p. 54–63, 2015.
- MIRELES, M. A. Landsat ETM + imaging for the estimation of the forest density in the southern region of the State of Mexico. **Revista Mexicana de Ciencias Forestales**, v. 8, n. 41, p. 30–55, 2017.
- MIRELLA, B. DE O. L. et al. Artificial neural networks in whole-stand level modeling of Eucalyptus plants. **African Journal of Agricultural Research**, v. 12, n. 7, p. 524–534, 2017.
- MOURA, D. C. Mapeamento e análise espectro-temporal das Unidades de Conservação de Proteção Integral da Administração Federal no Bioma Caatinga. **Sensoriamento Remoto e Ambiente**, n. 81, p. 12–16, 2015.
- NAHUM, J.S.; CASTRO, I. A. Um capítulo da questão agrária na Amazônia: mineração e campesinato no município de Juruti (PA). v. 2, n. 6, p. 2–7, 2012.
- OLIVEIRA, M.; NETO, J.; QUEIROZ, J. Açaizeiro: Cultivo E Manejo Para Produção De Frutos. **Embrapa Amazônia Oriental**, v. 2, n. 1, p. 22, 2015.
- ÖZÇELİK, R. et al. Estimating tree bole volume using artificial neural network models for four species in Turkey. **Journal of Environmental Management**, v. 91, n. 3, p. 742–753, jan. 2010.
- PAN, Y. et al. The Structure, Distribution, and Biomass of the World's Forests. **Annual Review of Ecology, Evolution, and Systematics**, v. 44, n. 1, p. 593–622, nov. 2013.
- PANDA, S. S.; AMES, D. P.; PANIGRAHI, S. Application of vegetation indices for agricultural crop yield prediction using neural network techniques. **Remote Sensing**, v. 2, n. 3, p. 673–696, 2010.
- PHUA, M.-H. Synergistic use of Landsat 8 OLI image and airborne LiDAR data for above-ground biomass estimation in tropical lowland rainforests. **Forest Ecology and Management**, v. 406, p. 163–171, 2017.
- PONZONI, F. J. . **Sensoriamento Remoto da Vegetação**. 2ª edição ed. São José dos Campos, SP: [s.n.].
- QUARESMA, A. C.; JARDIM, M. A. G. O Manejo do Açaizeiro, Euterpe oleracea Mart., Influencia a Diversidade de Bromélias Epífitas em Floresta de Várzea. **Biota Amazônia**, v. 3, n. 2, p. 94–100, 2015.
- RAMOS, N. O. Estimativa e modelagem da biomassa florestal acima do solo a partir do uso

do sensoriamento remoto: 20 anos de monitoramento da vegetação. n. Dissertação (Mestrado em Ciências Florestais), Universidade de Brasília-UnB, Brasília, DF, 2020.

RATUCHNE, L. C. et al. Estado da Arte na Quantificação de Biomassa em Raízes de Formações Florestais. **Floresta e Ambiente**, v. 23, n. 3, p. 450–462, 2016.

REJOU-MECHAIN, M. Biomass : an R package for estimating above-ground biomass and its uncertainty in tropical forests. p. 1163–1167, 2017.

RIBEIRO, S. C. et al. Quantificação de biomassa e estimativa de estoque de carbono em uma floresta madura no município de Viçosa, Minas Gerais. **Revista Árvore**, v. 33, n. 5, p. 917–926, 2009.

RIOS, E. et al. Territórios da Cidadania. n. Ministério do Desenvolvimento Agrário-Circular Técnica, p. 1–19, 2008.

RISHMAWI, K. Vegetation responses to climate variability in the northern arid to sub-humid zones of sub-Saharan Africa. **Remote Sensing**, v. 8, n. 11, 2016.

ROQUETTE, J. G. Distribuição da biomassa no cerrado e a sua importância na armazenagem do carbono. **Ciência Florestal**, v. 7, n. 5, p. 1–2, 2018.

ROUSE, J. W. Monitoring vegetation systems in the great plains with ERTS. v. 1, p. 309–317, 1973.

SAMPAIO, F. A. R. et al. Balanço de nutrientes e da fitomassa em um Argissolo Amarelo sob floresta tropical amazônica após a queima e cultivo com arroz. **Revista Brasileira de Ciência do Solo**, v. 27, n. 6, p. 1161–1170, 2003.

SANQUETTA, C. R.; BEHLING, A.; CORTE, A. P. D. Estoques de biomassa e carbono em povoamentos de acácia negra em diferentes idades no Rio Grande do Sul. **Scientia Florestalis**, v. 42, n. 103, p. 361–370, 2014.

SANTANA, S. H. C. Identificação dos índices de vegetação com melhores respostas espectrais para a Mata Atlântica na cidade de São Paulo-SP. **Journal of Environmental Analysis and Progress**, v. 02, n. 25, p. 200–209, 2018.

SCHOENINGER, E. R. Uso de redes neurais artificiais para mapeamento de biomassa e carbono orgânico no componente arbóreo de uma floresta ombrófila densa. **Ambiência.**, v. 4, n. 2, p. 179–195, 2008.

SERPEN, G.; GAO, Z. Complexity analysis of multilayer perceptron neural network embedded into a wireless sensor network. **Procedia Computer Science**, v. 36, n. C, p. 192–197, 2014.

SHANNO, D. Conditioning of quasi-Newton methods for function minimization. **Mathematics of Computation**, v. 24, n. 111, p. 647, 1970.

SILVA, I. N. **Redes Neurais Artificiais para engenharia e ciências aplicadas: curso prático**. São Paulo: [s.n.].

SILVA, L. M. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais

para estimar volume de árvores de eucalipto. v. 33, n. 6, p. 1133–1139, 2009.

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: 27 abr. 2022.

SYDOW, J. D. et al. Comparação De Métodos E Processos De Amostragem Para Inventário Em Floresta Ombrófila Mista. **BIOFIX Scientific Journal**, v. 2, n. 1, p. 60, 2017.

TAKEDA, W. M. Análise da exploração florestal de espécies nativas na Amazônia Ocidental. p. 120p, 2015.

THOMAS, S.; ALMEIDA, O.; PINHEIRO, E. Projeto de Assentamento Agroextrativista no ordenamento territorial e na gestão dos recursos naturais de várzea Amazônica. **Cadernos de Agroecologia**, v. 10 (Nº 3), 2015.

VALERI, S. A.I. Glossary. v. 2, n. 4, p. 72–83, 2022.

VICENTE-SERRANO, S. M. Diverse relationships between forest growth and the Normalized Difference Vegetation Index at a global scale. **Remote Sensing of Environment**, v. 187, p. 14–29, 2016.

VIEIRA, G. C. et al. Prognoses of diameter and height of trees of eucalyptus using artificial intelligence. **Science of the Total Environment**, v. 619–620, p. 1473–1481, 2018.

VIEIRA, S. A. Estimation of biomass and carbon stocks: the case of the Atlantic Forest. **Biota Neotropica**, v. 8 (Nº2), p. 21–26, 2013.

VILA NOVA, F. V. P. Application Of Normalized Difference Vegetation Index In Monitoring Of The Mangrove: The Southern Coast Of Pernambuco-Brazil. **Revista Geografares**, v. 15, n. 15, p. 36–6736, 2013.

VINA, A.; GITELSON, A. A. Remote Sensing of Environment Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. **Remote Sensing of Environment**, v. 115, n. 12, p. 3468–3478, 2011.

WATZLAWICK, L.F.; KIRCHNER, F.F.; SANQUETTA, C. R. Estimativa de biomassa e carbono em floresta com araucária utilizando imagens do satélite IKONOS II. **Ciência Florestal**, v. 19, n.2, p. 169–181, 2009.

ZHONG, G. et al. A modified aerosol free vegetation index algorithm for aerosol optical depth retrieval using GOSAT TANSO-CAI data. **Remote Sensing**, v. 8, n. 12, 2016.

ZHU, X. Improving forest aboveground biomass estimation using seasonal Landsat NDVI time-series. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 222–231, 2015.

## 9. ANEXO

**Anexo 1.** Densidade básica da madeira por espécie, gênero ou família, a depender do dado disponível no pacote BIOMASS do software R (2022).

<b>Nome científico</b>	<b>Nome popular</b>	<b>Nível</b>	<b>Densidade (g.cm<sup>3</sup>)</b>
<i>Abarema jupumba</i> (Willd.) Britton & Killip	Saboeiro	Espécie	0,59
<i>Agonandra brasiliensis</i> Miers	Pau Marfim / Marfim	Espécie	0,82
<i>Anacardium sp.</i>	Cajueiro	Gênero	0,45
<i>Anaxagorea phaeocarpa</i> Mart.	Envira Vermelha	Gênero	0,53
<i>Apeiba albiflora</i> Ducke	Pente de Macaco	Espécie	0,25
<i>Apuleia molaris</i> Spruce ex Benth.	Garapa	Espécie	0,75
<i>Aspidosperma album</i> (Vahl) R.Benoist ex Pichon	Araracanga	Espécie	0,77
<i>Aspidosperma rigidum</i> Rusby	Carapanaúba	Espécie	0,46
<i>Astronium lecointei</i> Ducke	Muiracatiara	Espécie	0,79
<i>Bagassa guianensis</i> Aubl.	Tatajuba	Espécie	0,71
<i>Balizia pedicellaris</i> (DC.) Barneby & J.W.Grimes	Fava Mapuchiqui	Espécie	0,50
<i>Bertholletia excelsa</i>	Castanheira	Espécie	0,64
<i>Bixa arborea</i> Huber	Urucum Bravo	Espécie	0,37
<i>Bixa orellana</i> L.	Urucum	Espécie	0,36
<i>Bombacopsis macrocalix</i>	Mamorana da Mata	Espécie	0,56
<i>Bowdichia nitida</i>	Sucupira Amarela	Espécie	0,80
<i>Brosimum acutifolium</i> Huber	Muirapiranga	Espécie	0,64



<i>Brosimum lactescens</i> (S.Moore) C.C.Berg	Janitá	Espécie	0,66
<i>Brosimum potabile</i> Ducke	Amapá Doce	Espécie	0,54
<i>Brosimum sp.</i>	Mururé	Espécie	0,68
<i>Buchenavia amazonica</i> Alwan & Stace	Cuiarana Folha Grande	Gênero	0,75
<i>Byrsonima crispa</i> A. Juss.	Murici	Espécie	0,58
<i>Carapa guianensis</i> Aubl	Andiroba	Espécie	0,53
<i>Caryocar glabrum</i> (Aubl.) Pers.	Piquiarana	Espécie	0,65
<i>Caryocar microcarpum</i> Ducke	Pequiá	Espécie	0,67
<i>Casearia aculeata</i> Jacq.	Passarinheira	Espécie	0,66
<i>Cassia leiandra</i> Benth.	Canafístula	Gênero	0,74
<i>Cassia spruceana</i> Benth.	Acácia Amarela	Gênero	0,74
<i>Cecropia obtusa</i> Trécul	Embaúba Branca	Espécie	0,31
<i>Cecropia palmata</i> Willd.	Embaúba vermelha	Gênero	0,34
<i>Cecropia sciadophylla</i> Mart.	Embaúba Torém	Espécie	0,39
<i>Cecropia sp.</i>	Embaubarana	Gênero	0,34
<i>Cecropia sp.</i>	Embaúba	Gênero	0,34
<i>Cedrela odorata</i> L.	Cedro Rosa	Espécie	0,45
<i>Ceiba pentandra</i> (L.) Gaertn.	Sumaúma	Espécie	0,31
<i>Chaunochiton sp.</i>	Lacrão	Gênero	0,65
<i>Chimarrhis turbinata</i> DC.	Pau de Remo	Espécie	0,72
<i>Chrysophyllum manaosense</i> (Aubr.)	Guajará Bolacha	Gênero	0,67
<i>Clavija sp.</i>	Clavija	Família	0,64

<i>Coccoloba sp.</i>	Cocoloba	Gênero	0,69
<i>Cochlospermum orinoccense</i> (H.B.K.) Steud.	Piriquiteira	Espécie	0,22
<i>Copaifera bijuga</i> Hayne	Copaíba	Gênero	0,61
<i>Cordia alliodora</i> Chamier	Freijó Branco	Espécie	0,52
<i>Cordia goeldiana</i> Huber	Freijó	Espécie	0,50
<i>Couepia bracteosa</i> Benth.	Marirana / Mari Mari	Espécie	0,77
<i>Couepia sp.</i>	Coco Pau	Gênero	0,80
<i>Couma guianensis</i> Aubl.	Sorva	Espécie	0,47
<i>Couratari guianensis</i>	Tauari	Espécie	0,51
<i>Couratari oblongifolia</i> Ducke & Knuth	Tauari Rosa	Espécie	0,51
<i>Croton matourensis</i> Aubl.	Maravuvuia	Espécie	0,39
<i>Croton sp.</i>	Pau de Índio	Gênero	0,51
<i>Croton sp.</i>	Croton	Gênero	0,51
<i>Cupania cinerea</i> Poepp.,	Pau de Espeto	Espécie	0,50
<i>Dialium guianense</i> (Aubl.) Sandwith.	Jutaí Pororoca	Espécie	0,90
<i>Dinizia excelsa</i>	Angelim Vermelho	Espécie	0,91
<i>Dipteryx odorata</i>	Cumarú	Espécie	0,92
<i>Duguetia cadaverica</i> Huber	Envira Amarela	Gênero	0,73
<i>Duguetia riparia</i> Huber	Envira Ata	Gênero	0,73
<i>Dyospirus vestita</i>	Caqui	Gênero	0,68
<i>Ecclinusa abbreviata</i> Ducke	Serigarana	Gênero	0,73
<i>Emmotum nitens</i> (Benth.) Miers.	Marachimbé	Espécie	0,93
<i>Endopleura uc hi</i> (Huber)	Uxi	Gênero	0,79

Cuatrec.			
<i>Enterolobium amazonicum</i> Mart.	Jucá	Gênero	0,51
<i>Enterolobium maximum</i> Duck	Tamboril	Espécie	0,41
<i>Enterolobium schomburgkii</i> (Benth.) Benth.	Fava Orelha	Espécie	0,70
<i>Enterolobium sp.</i>	Fava Branca	Gênero	0,51
<i>Erisma calcaratum</i> (Link) Warm.	Cafearana	Espécie	0,68
<i>Erisma uncinatum</i> Ducke	Quarubarana	Espécie	0,52
<i>Erythrina fusca</i> Lour.	Mulungu	Espécie	0,30
<i>Eschweilera alba</i> Knuth.	Matá Matá	Gênero	0,83
<i>Eschweilera blanchetiana</i> (Berg.) Miers	Mata Mata Preto	Gênero	0,83
<i>Eschweilera coriacea</i> Mart. ex Berg.	Mata Mata Branco	Espécie	0,85
<i>Eschweilera sp.</i>	Mata Matá Vermelho	Gênero	0,83
<i>Euplassa pinnata</i> (Lam.) Jonston	Louro Faia	Espécie	0,52
<i>Fagara sp.</i>	Tamanqueira	Família	0,71
<i>Ficus grandiflora</i> Corner	Gameleira	Gênero	0,41
<i>Ficus maximum</i> (P.) Miller	Caxinguba	Espécie	0,36
<i>Franchetella gougripii</i> (Eyma) Aubrév.	Abiurana	Família	0,71
<i>Geissospermum sericeum</i> (Benth.) Hook.	Quinarana	Espécie	0,78
<i>Genipa americana</i> L.	Jenipapo	Espécie	0,63
<i>Glycydendron amazonicum</i> Ducke	Mirindiba	Espécie	0,68
<i>Goupia glabra</i> (Gmel.)	Cupiúba	Espécie	0,73

Aublet			
<i>Guarea kunthiana</i> A. Juss.	Andirobarana	Espécie	0,62
<i>Guatteria poeppigiana</i> Mart.	Envira Preta	Gênero	0,58
<i>Guatteria sp.</i>	Envira Branca	Gênero	0,58
<i>Gustavia augusta</i> L.	Jeniparana	Espécie	0,65
<i>Henriquezia sp.</i>	Roxinho	Gênero	0,73
<i>Hevea brasiliensis</i> Müll.Arg.	Seringueira	Espécie	0,47
<i>Himatanthus sucuuba</i> (Spruce ex Muell. Arg.) Woodson	Sucuúba	Espécie	0,46
<i>Holopyxidium jarana</i> Ducke	Jarana	Família	0,64
<i>Hymenaea courbaril</i> L.	Jatobá	Espécie	0,79
<i>Hymenolobium petraeum</i> Ducke	Angelim Pedra	Espécie	0,71
<i>Inga acrocephala</i> Steud.	Ingá de Porco	Espécie	0,51
<i>Inga alba</i> (Sandw.) Willd.	Ingá Branco	Espécie	0,59
<i>Inga brachystachya</i> Ducke	Ingá Chichica	Gênero	0,58
<i>Inga grandis</i> T.D. Penn.,	Ingá Grande	Gênero	0,58
<i>Inga heterophylla</i> Willd.	Ingá Vermelho	Espécie	0,56
<i>Inga rubiginosa</i> (Rich.) DC.	Ingá Peludo	Espécie	0,66
<i>Inga sp.1</i>	Ingá	Gênero	0,58
<i>Inga sp.2</i>	Ingá Ferro	Gênero	0,58
<i>Jacaranda copaia</i> (Aubl.) D.Don	Pará Pará	Espécie	0,35
<i>Jacaratia spinosa</i> (Aubl.) A.DC.	Mamuí	Gênero	0,27

<i>Joannesia princeps</i> Vell.	Capares / Boleira	Espécie	0,51
<i>Lacmellea aculeata</i> (Ducke) Monach.	Pau de Colher	Gênero	0,51
<i>Laetia procera</i> (Poepp et Engl.) Eichl.	Pau jacaré	Espécie	0,65
<i>Lecythis idatimon</i> Aubl.	Ripeiro	Espécie	0,80
<i>Lecythis usitata</i> Miers.	Sapucaia	Espécie	0,90
<i>Licania apetala</i> (E. Mey) F ritsch	Casca Seca	Espécie	0,76
<i>Licania bracteata</i> Prance	Cariperana	Gênero	0,82
<i>Licania heteromorpha</i> Benth.	Macucu	Espécie	0,82
<i>Licaria brasiliensis</i> (Nees) Kosterm	Louro Capitu	Gênero	0,79
<i>Licaria rigida</i> Kosterm.	Louro Amarelo	Espécie	0,79
<i>Lindackeria latifolia</i> Benth.	Farinha Seca	Gênero	0,56
<i>Lueheopsis duckeana</i> Burret	Açoita Cavalo	Espécie	0,62
<i>Mabea sp.</i>	Taquari	Gênero	0,61
<i>Macrolobium microcalyx</i>	Faveira	Gênero	0,62
<i>Macrolobium bifolium</i> Pers.	Ipê de Várzea	Espécie	0,67
<i>Manilkara amazonica</i> (Huber) A. Chev.	Maparajuba	Gênero	0,89
<i>Manilkara huberi</i> (Ducke) Chevalier	Maçaranduba	Espécie	0,92
<i>Maquira guianensis</i> Aubl.	Muiratinga	Espécie	0,77
<i>Martiodendron elatum</i> (Ducke) Gleason	Tamarindo	Gênero	0,85
<i>Metrodorea flavida</i> K.Krause	Laranjinha	Gênero	1,05
<i>Mezilaurus duckey</i>	Itaubarana	Espécie	0,67

<i>Mezilaurus itauba</i>	Itaúba	Espécie	0,74
<i>Miconia sp.</i>	Tinteiro da Folha Miúda	Gênero	0,63
<i>Miconia surinamensis</i> Gleason	Tinteiro	Gênero	0,63
<i>Minuartia guianensis</i> Aubl.	Acariquara	Espécie	0,79
<i>Mouriria brachyanthera</i> Ducke	Mirauba / Muríria	Gênero	0,84
<i>Myrcia atramentifera</i> Barb.Rodr.	Cumatê	Gênero	0,82
<i>Myrcia lanceolata</i> Cambess.	Murta	Gênero	0,82
<i>Myrcia sp.</i>	Goiabeira	Gênero	0,82
<i>Nectandra mollis</i> (Ness) Rohwer	Louro Preto	Espécie	0,74
<i>Neea macrophylla</i> Popp. & Endl.	João Mole	Gênero	0,64
<i>Nemaluma anomala</i> (Pires) Pires	Rosadinho	Família	0,71
<i>Neoxythece sp.</i>	Guajará	Família	0,71
<i>Ocotea abbreviata</i> Schwacke & Mrez	Louro Branco	Gênero	0,54
<i>Ocotea costulata</i> (Nees) Mez.	Louro Rosa	Espécie	0,49
<i>Ocotea myriantha</i> Mez.	Louro Abacate	Espécie	0,61
<i>Ocotea pretiosa</i> Benth. & Hook.f.	Canela Preciosa	Espécie	0,77
<i>Ocotea rubra</i> Mez.	Louro Vermelho	Gênero	0,54
<i>Ocotea sp.</i>	Louro	Gênero	0,54
<i>Ormosia paraensis</i> Ducke	Tento Amarelo	Espécie	0,66
<i>Osteophloeum sp.</i>	Ucuubão	Gênero	0,47

<i>Palicourea anisoloba</i> (Müll.Arg.) Boom & M.T.Campos	Erva de Rato	Gênero	0,55
<i>Parkia gigantocarpa</i> Ducke	Fava Atanã	Espécie	0,26
<i>Parkia multijuga</i> Benth.	Tucupi de Arara	Espécie	0,40
<i>Parkia oppositifolia</i> Spruce ex Benth.	Fava Vicki	Gênero	0,46
<i>Parkia paraensis</i> Ducke	Fava Arara Tucupi	Espécie	0,42
<i>Parkia pendula</i> (Willd.) Benth. Ex Walp.	Fava Bolota	Espécie	0,52
<i>Parkia ulei</i> (Harms) Kuhlman	Mapuxiqui	Espécie	0,38
<i>Perebea</i> sp.	Moracea	Gênero	0,50
<i>Phyllanthus nobilis</i> (L.f.) Müll.Arg.	Figueirinha	Gênero	0,61
<i>Piptadenia piteroclada</i> Benth.	Paricarana	Gênero	0,80
<i>Piptadenia suaveolens</i> Miq.	Timborana	Gênero	0,80
<i>Pithecellobium cauliflorum</i> (Willd.) Mart. Ex Benth.	Ingarana	Gênero	0,50
<i>Pithecellobium racemosum</i> Ducke	Angelim Rajado	Gênero	0,50
<i>Pithecellobium</i> sp.	Fava	Gênero	0,50
<i>Platymiscium duckei</i> Huber	Macacaúba	Gênero	0,81
<i>Poecilanthe effusa</i> (Huber) Ducke	Gema de Ovo	Gênero	0,81
<i>Pogonophora schomburgkiana</i> Miers et Benth.	Aracapuri	Espécie	0,83
<i>Posoqueria latifolia</i> Roem. & Schult.	Papa Terra	Espécie	0,57
<i>Pourouma guianensis</i> Aubl.	Embaubão	Espécie	0,38

<i>Pouteria anibifolia</i> (H.S. Smith) Baehni	Abiu Vermelho	Espécie	0,66
<i>Pouteria bilocularis</i> (H. Winkler) Baehni	Abiu Goiabão/Casca Grossa	Espécie	0,71
<i>Pouteria caimito</i> (Ruiz & Pav.) Radlk.	Abiu Seco	Espécie	0,81
<i>Pouteria guianensis</i> Aublet	Abiu Cutiti	Espécie	0,93
<i>Pouteria laurifolia</i> (Radik) Gomes	Abiu Casca Seca	Gênero	0,69
<i>Pouteria sp.</i>	Abiu	Gênero	0,69
<i>Protium altsonii</i> Sandw.	Breu Preto	Espécie	0,68
<i>Protium pallidum</i> Cuart.	Breu Branco	Gênero	0,57
<i>Protium sp.1</i>	Protum	Espécie	0,55
<i>Protium sp.2</i>	Breu	Gênero	0,57
<i>Protium subserratum</i> (Engler) Engler	Breu Vermelho	Espécie	0,55
<i>Pterocarpus rohrii</i> Vahl	Mututi	Espécie	0,46
<i>Qualea paraensis</i> Ducke	Mandioqueira	Espécie	0,69
<i>Quararibea ochrocalyx</i> (K.Schum.) Vischer	Inajarana	Gênero	0,49
<i>Raulwolphia paraensis</i> Ducke	Rarrúfia	dataset	0,58
<i>Rheedia macrophylla</i> (Mart.) Planch. & Triana	Bacuri Pari	Família	0,67
<i>Rinorea flavescens</i> (Aubl.) Kuntze	Canela de Jacamim	Espécie	0,63
<i>Rinorea guianensis</i> Aubl.	Acariquarana	Espécie	0,78
<i>Rollinia insignis</i> R.E.Fr.	Envira Biribá	Espécie	0,43
<i>Saccoglotis paraensis</i> Benth.	Uxirana	dataset	0,58
<i>Sagotia racemosa</i> (Baill.)	Arataciu	Espécie	0,58



Müll.Arg.			
<i>Sapindus saponaria</i> L.	Sabonete	Espécie	0,71
<i>Sapium aucuparium</i> Jacq.	Burra leiteira	Espécie	0,45
<i>Schefflera morototoni</i> (Aubl.) Decne. & Planch.	Morototó	Espécie	0,46
<i>Schizolobium amazonicum</i> (Huber) Ducke	Paricá	Espécie	0,58
<i>Sclerolobium chrysophyllum</i> Poepp. & Endl.	Taxi Vermelho	Espécie	0,62
<i>Sclerolobium sp.1</i>	Tachirana	Espécie	0,44
<i>Sclerolobium sp.2</i>	Tachi	Gênero	0,56
<i>Simaba cedron</i> Planch.	Pau Para Tudo	Espécie	0,47
<i>Simarouba amara</i> Aubl.	Marupá	Espécie	0,38
<i>Sloanea grandiflora</i> J. E. Smith	Urucurana	Espécie	0,81
<i>Sterculia pruriens</i> K. Sc hum.	Xixá	Espécie	0,49
<i>Stryphnodendron barbatiman</i> Mart.	Barbatimão	Gênero	0,64
<i>Swartzia panacoco</i> Cowan	Gombeira	Espécie	0,92
<i>Swartzia racemosa</i> Benth.	Pitaíca	Gênero	0,85
<i>Symphonia globulifera</i> L - f.	Anani	Espécie	0,60
<i>Tabebuia angustata</i> Britten	Ipê Roxo	Gênero	0,76
<i>Tabebuia serratifolia</i>	Ipê Amarelo	Espécie	0,92
<i>Tachigalia alba</i> Ducke	Tachi Branco	Gênero	0,58
<i>Tachigalia myrmecophila</i> Ducke	Taxi Preto	dataset	0,58
<i>Talisia praealta</i>	Mucuracá da Mata	Gênero	0,83

<i>Tapirira guianensis</i> Aubl.	Tatapirica	Espécie	0,46
<i>Tapura singularis</i> Ducke	Pau de Bicho	Gênero	0,64
<i>Tapura sp.</i>	Atapura	Gênero	0,64
<i>Terminalia amazonica</i> (J.F.Gmel) Exell.	Cuiarana	Espécie	0,67
<i>Tetragastris altissima</i> (Aubl.) Sandw.	Breu Mescla	Espécie	0,71
<i>Tetragastris sp.</i>	Amesclão	Gênero	0,70
<i>Theobroma subincanum</i> Mart.	Cupui	Espécie	0,47
<i>Theobroma sylvestris</i> Mart.	Cacau	Espécie	0,67
<i>Thyrsodium paraensis</i> Huber	Breu de Leite	Gênero	0,65
<i>Tovomita brevistaminea</i> Engl.	Manguirana	Gênero	0,70
<i>Trattinnickia rhoifolia</i> Willd.	Breu Sucuruba	Espécie	0,45
<i>Trichilia acariaeantha</i> H arms.	Cachuá	Gênero	0,64
<i>Vatairea paraensis</i> Ducke	Fava Bolacha	Espécie	0,71
<i>Virola albidiflora</i> Ducke	Ucuubarana	Espécie	0,45
<i>Virola michelii</i> Heckel	Virola	Espécie	0,47
<i>Virola sp.</i>	Ucuuba Preta	Gênero	0,48
<i>Vismia guianensis</i> Pers.	Lacre	Espécie	0,48
<i>Vitex cymosa</i> Bertero ex Spreng.	Tarumã	Espécie	0,56
<i>Vochysia biloba</i> Ducke	Quaruba Rosa / Roxa	Gênero	0,49
<i>Vochysia guianensis</i> (Aubl.) Poir.	Quaruba Tinga	Espécie	0,51
<i>Vochysia sp.</i>	Quaruba	Espécie	0,46

<i>Xylopiya amazonica</i> R.E. Fries	Envira Bobó	Espécie	0,79
<i>Xylopiya nitida</i> Dunal	Envira Cana	Espécie	0,55
<i>Xylopiya sp.</i>	Envira	Espécie	0,50
<i>Zollernia paraensis</i> Huber	Coração de Negro	Espécie	0,99