



PREDIÇÃO VOLUMÉTRICA UTILIZANDO REDES NEURAS ARTIFICIAIS E
DADOS DE SENSORIAMENTO REMOTO EM FLORESTA NATIVA NA
AMAZÔNIA BRASILEIRA

FRANCIMAR CARVALHO GONÇALVES

DISSERTAÇÃO DE MESTRADO
DEPARTAMENTO DE ENGENHARIA FLORESTAL

FACULDADE DE TECNOLOGIA
UNIVERSIDADE DE BRASÍLIA

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

FRANCIMAR CARVALHO GONÇALVES

PREDIÇÃO VOLUMÉTRICA UTILIZANDO REDES NEURAIAS ARTIFICIAIS E
DADOS DE SENSORIAMENTO REMOTO EM FLORESTA NATIVA NA
AMAZÔNIA BRASILEIRA

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

ORIENTADOR: Dr. EDER PEREIRA MIGUEL

Brasília – DF, 23 fevereiro de 2021

**PREDIÇÃO VOLUMÉTRICA UTILIZANDO REDES NEURAS ARTIFICIAIS
E DADOS DE SENSORIAMENTO REMOTO EM FLORESTA NATIVA NA
AMAZÔNIA BRASILEIRA**

FRANCIMAR CARVALHO GONÇALVES

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. Eder Pereira Miguel

(Departamento de Engenharia Florestal, UnB); (Orientador)

Prof. Dr. Eraldo Aparecido Trondoli Matricardi

(Programa de Pós-Graduação em Ciências Florestais)

Prof. Dr. Fabiano Emmert

(Instituto Nacional de Pesquisas da Amazônia - INPA)

Brasília-DF, 23 de fevereiro de 2021.

FICHA CATALOGRÁFICA

GG635p Gonçalves, Francimar Carvalho
 PREDIÇÃO VOLUMÉTRICA UTILIZANDO REDES NEURAIAS ARTIFICIAIS
 E DADOS DE SENSORIAMENTO REMOTO EM FLORESTA NATIVA NA
 AMAZÔNIA BRASILEIRA / Francimar Carvalho Gonçalves;
 orientador Eder Pereira Miguel. -- Brasília, 2021.
 65 p.

 Dissertação (Mestrado - Mestrado em Ciências Florestais)
 - Universidade de Brasília, 2021.

 1. Amazônia. 2. Redes Neurais Artificiais. 3. Planos de
 Manejo. 4. Volume. 5. Modelagem. I. Miguel, Eder Pereira ,
 orient. II. Título.

REFERÊNCIA BIBLIOGRÁFICA

GONÇALVES, F.C. 2021. **Predição volumétrica utilizando redes neurais artificiais e dados de sensoriamento remoto em floresta nativa na Amazônia brasileira.** Dissertação de Mestrado em Ciências Florestais, Publicação Programa de Pós-graduação em Ciências Florestais Departamento de Engenharia Florestal, Universidade de Brasília, Brasília, DF. **64 p.**

CESSÃO DE DIREITOS

AUTOR: Francimar Carvalho Gonçalves

TÍTULO: Predição volumétrica utilizando redes neurais artificiais e dados de sensoriamento remoto em floresta nativa na Amazônia brasileira.

GRAU: Mestre ANO: 2021

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.

Francimar Carvalho Gonçalves
francimar.cgoncalves@gmail.com

Brasília-DF, 23 de fevereiro de 2021.

**Aos meus pais,
Francisco e Idelma. Dedico.**

AGRADECIMENTOS

Primeiramente à Deus, por tudo que já alcancei em minha vida. Aos meus pais, irmãos e namorada, por estarem sempre ao meu lado.

Ao professor Eder Pereira Miguel, por ser tão solícito, claro e objetivo, pelo companheirismo, pelo apoio, pelas cobranças e principalmente por ter me orientado, acreditado e confiado na minha pessoa.

Ao professor Eraldo Aparecido Trondoli Matricardi, pelo companheirismo, pelos conhecimentos transmitidos e toda a prestatividade.

Ao Engenheiro Florestal Mauro Lucio Trondoli Matricardi, por todo aporte, disponibilidade e ajuda, a fazenda agro industrial 4 ventos pela aprovação da pesquisa no local.

Aos colegas que dividiram momentos bons e ruins durante esse período.

A todos os professores e funcionários do Departamento de Engenharia Florestal e do Programa de Pós-Graduação da EFL e a todos aqueles que estiveram presentes nessa jornada, deixo aqui meus sinceros agradecimentos.

RESUMO

Amazônia brasileira envolve uma área de aproximadamente 5 milhões de quilômetros quadrados, nesta concentra-se a maior parte dos recursos florestais do planeta. Compreender sua conjuntura buscar formas para uma exploração sustentável é de suma importância no presente e futuro. Nesse sentido surgem os planos de manejo florestais sustentáveis (PMFS), porém a obtenção do volume nessas áreas muitas vezes é complexa e reservada a pequenas escalas. No presente estudo, objetivou-se correlacionar dados gerados dos índices de vegetação derivados de bandas espectrais do satélite Sentinel-2 e variáveis mensuradas em campo para prever a produção volumétrica de árvores dentro de um PMFS. Para tanto tomou-se o diâmetro mínimo de medição (DMM) 30 cm, e juntamente as árvores de interesse comercial de acordo com o diâmetro mínimo de corte (DMC) a partir de 50 cm. Foram treinadas 300 redes neurais, em que 70% dos dados foram utilizados para o ajuste e 30% para validação. Posteriormente, as cinco redes de melhor desempenho foram retidas e listadas em tabelas apresentando os valores de correlação (r) entre os dados observados e os dados estimados pelas redes. Para o ajuste os resultados foram superiores a 90% sendo que a melhor RNA teve um poder preditivo de 97% para as árvores do DMM e 98% para as árvores de interesse comercial de acordo com DMC, para a validação os resultados também são superiores a 90%, os erros médios das estimativas RMSE foram inferiores a 20% em todas as 5 melhores redes nos dois casos. Os resultados deste estudo indicam que a junção de variáveis de rotina na floresta e os índices de vegetação derivados de imagens obtidas pelo sensor MSI a bordo do satélite Sentinel-2, estimam com boa acurácia tanto o volume da floresta na Amazônia como também o volume explorado para árvores de interesse comercial.

Palavras chaves: Amazônia, redes neurais artificiais, planos de manejo, volume, modelagem

ABSTRACT

The Brazilian Amazon encompasses an area of approximately 5 million square kilometers, where most of the planet's forest resources are concentrated. Understanding your situation and seeking ways for sustainable exploration is of paramount importance in the present and the future. In this sense, sustainable forest management plans (PMFS) appear, but obtaining the volume in these areas is often complex and reserved for small scales. In the present study, the objective was to correlate data generated from vegetation indices derived from spectral bands from the Sentinel-2 satellite and variables measured in the field to predict the volumetric production of trees within a PMFS. For that, the minimum measurement diameter (DMM) was taken 30 cm, and together the trees of commercial interest according to the minimum cut diameter (DMC) from 50 cm. 300 neural networks were trained, in which 70% of the data were used for adjustment and 30% for validation. Subsequently, the five best performing networks were retained and listed in tables showing the correlation values (r) between the observed data and the data estimated by the networks. For the adjustment, the results were greater than 90% and the best RNA had a predictive power of 97 for the DMM trees and 98% for the trees of commercial interest according to DMC, for the validation the results are also greater than 90 %, the average errors of the RMSE estimates were less than 20% in all the 5 best networks in both cases. The results of this study indicate that the combination of routine variables in the forest and the vegetation indexes derived from images obtained by the MSI sensor on board the Sentinel-2 satellite, estimate with good accuracy both the volume of the forest in the Amazon as well as the volume explored for trees of commercial interest.

Keywords: Amazon, artificial neural networks, management plans, volume, modeling.

SUMÁRIO

1. INTRODUÇÃO	15
1.1 Apresentação e contextualização.....	15
2. OBJETIVOS	17
2.1 Objetivo geral	17
2.2 Objetivos específicos.....	17
3. REFERENCIAL TEÓRICO	18
3.1 Gestão das florestas públicas e privadas	18
3.1.1. Manejo florestal sustentável	19
3.1.2. Manejo florestal no Mato Grosso	20
3.2 Uso sensoriamento remoto no meio florestal	21
3.3 Missão sentinel-2.....	22
3.4 Redes Neurais Artificiais.....	24
4. MATERIAL E BASE DE DADOS	26
4.1 Área de estudo e caracterização.....	26
4.2 Características edafoclimáticas	28
4.3 Coletas de dados	28
4.3.1. Inventário Florestal.....	29
4.4 Análise de dados.....	34
4.4.1. Estimativa da área basal, volume e contagem de indivíduos por hectare.....	34
4.4.2. Índices de vegetação.....	34
4.4.3. Ajuste e treinamento das redes neurais artificiais.	35
5. RESULTADOS	38
5.1 Dados de volumetria.....	38
5.2 Modelagem.....	39
5.2.1. Seleção das variáveis independentes	39

5.2.2. Treinamento das redes neurais	41
5.3 Análise estatística	46
6. DISCUSSÃO	46
6.1 Análise geral dos dados	46
6.2 Modelagem.....	48
6.2.1. Seleção das variáveis independentes	48
6.2.1. Redes neurais.....	49
6.3 Análise estatística	50
7. CONCLUSÃO	51
REFERÊNCIAS BIBLIOGRÁFICAS	52

LISTA DE TABELAS

Tabela 1: Ficha técnica com as informações espaciais e espectrais. Erro! Indicador não definido.	
Tabela 2: Lista das espécies com o respectivo número de indivíduos, no município de Feliz Natal - MT, na Amazônia.	Erro! Indicador não definido.
Tabela 3: Variáveis dendrométricas estimadas do inventário florestal para o DMM, no município de Feliz Natal - MT, na Amazônia.	38
Tabela 4: Variáveis dendrométricas estimadas do inventário florestal para as árvores de interesse comercial a partir do DMC, no município de Feliz Natal - MT, na Amazônia.	38
Tabela 5: Finalidade das espécies comerciais de acordo com o DMC, no município de Feliz Natal - MT, na Amazônia.	39
Tabela 6: Média das variáveis independentes na floresta no município de Feliz Natal - MT, na Amazônia.	40
Tabela 7: Matriz de correlação entre as variáveis estudadas na floresta, no município de Feliz Natal - MT, na Amazônia.	40
Tabela 8: Matriz de correlação entre as variáveis estudadas para as árvores de comerciais, no município de Feliz Natal - MT, na Amazônia.	41
Tabela 9: Características e estatísticas de precisão das redes neurais artificiais selecionadas para predição do volume das árvores da floresta com $dap \geq 30cm$ no município de Feliz Natal - MT, na Amazônia.	41
Tabela 10: Características e estatísticas de precisão das redes neurais artificiais selecionadas para predição do volume das árvores comerciais, no município de Feliz Natal - MT, na Amazônia.	43

LISTA DE QUADRO

Quadro 1: Etapas da organização de um PMFS.....**Erro! Indicador não definido.**

LISTA DE FIGURAS

Figura 1: Esquema de um neurônio artificial em que: Definição do número de sinais de entrada (variáveis independentes); Definição das variáveis de saída (variáveis dependentes). (Castro et., al 2013). **Erro! Indicador não definido.**

Figura 2: Localização da área de estudo, em que UT: Unidade de Trabalho; UPA: Unidade de Produção Anual; APRMP: Área da Propriedade Rural por Matrícula ou Posse no município de Feliz Natal - MT, na Amazônia. **Erro! Indicador não definido.**

Figura 3: Placa do projeto (autex) com a chegada ao PMFS (A), Entrada da fazenda 4 ventos (B) no município de Feliz Natal - MT, na Amazônia. **Erro! Indicador não definido.**

Figura 4: Árvore remanescente identificada (A), toras sendo processadas na no pátio de estocagem da UPA (B) no município de Feliz Natal - MT, na Amazônia. **Erro! Indicador não definido.**

Figura 5: Mapa com as árvores presentes nas UT, corte = azul, proibidas de corte = preto, remanescentes = verde porta sementes = laranja, no município de Feliz Natal - MT, na Amazônia. 32

Figura 6: Mapa de densidade de Kernel com os valores de volume em $m^3 \cdot ha^{-1}$ variando de $25 m^3 ha^{-1}$ a $200 m^3 ha^{-1}$ no município de Feliz Natal - MT, na Amazônia.

Figura 7: Distribuição de resíduos em treinamento (A1) e validação (B1), valores observados e preditos em correlação $r = 0,97$ e probabilidade $\alpha = 0,05$ $p = 0,99$, e validação (B2) correlação $r = 0,94$ e distribuição de classes de erro em treinamento (A3) e validação (B3) da estimativa do volume das árvores com $dap \geq 30$ cm, no município de Feliz Natal - MT, na Amazônia. 42

Figura 8: Distribuição de resíduos em treinamento (A1) e validação (B1), valores observados e preditos em treinamento (A2), correlação $r = 0,98$ e probabilidade $\alpha = 0,05$ $p = 0,97$, e validação (B2) correlação $r = 0,95$ e distribuição de classes de erro em treinamento (A3) e validação (B3) da estimativa do volume das árvores com $DAP \geq 50$ no município de Feliz Natal - MT, na Amazônia. 44

Figura 9: Arquitetura da RNA selecionada para predição do volume da floresta na configuração (6-10-1) no município de Feliz Natal - MT, na Amazônia. 45

Figura 10: Arquitetura da RNA selecionada para predição do volume das espécies de valor comercial na configuração (6-10-1) no município de Feliz Natal - MT, na Amazônia. 46

1. INTRODUÇÃO

1.1 Apresentação e contextualização

A Amazônia brasileira envolve uma área de aproximadamente 5 milhões de quilômetros quadrados, representada em fitofisionomias de florestas de terra firme e florestas alagadas, na qual corresponde a 59% dentro do território brasileiro, é também a maior reserva contínua de floresta tropical úmida do mundo (IBGE, 2020). A floresta tropical amazônica oferece uma série de benefícios à sociedade, sendo de maior destaque a produção madeireira, que consiste no produto mais consumido e negociado no mundo. Neste ecossistema natural, embora haja imensa diversidade de espécies arbóreas, a maioria se apresenta de forma rara ou agregada (CONDIT et al., 2000; PLOTKIN et al., 2000) sendo que nem todas as espécies possuem características comerciais (CUNHA et al., 2016), tornando necessário, o levantamento de extensas áreas florestais para acolher a demanda cada vez maior de madeira (AKINDELE; LEMAY, 2006; CLEMENT; HIGUCHI, 2006).

Florestas tropicais contribuem de forma positiva no balanço entre os gases do efeito estufa pelo seu potencial de sequestro de carbono (PHILIPS; BRIENEN, 2017), além de contribuir com a economia local, regional e global, através do manejo florestal madeireiro e não madeireiro (VERÍSSIMO; PEREIRA, 2015). Entretanto, ainda existe a demanda por mais informações sobre o volume explorado em planos de manejo florestais sustentáveis (PMFS). Esses planos demandam de autorização para exploração florestal e os dados de volume retirado são obtidos através de inventários florestais conduzidos em campo, sendo na maioria dos casos escassos e de difícil acesso (CHULES et al., 2018).

Diversas atividades de manejo e conservação das florestas tropicais requerem estimativas seguras e precisas da produção (COLE; EWEL, 2006; CHÁIDEZ, 2009; ADEKUNLE et al., 2013; CYSNEIROS, 2016). A estimativa do volume florestal pode ser feita a partir de: (i) inventário florestal: calculado pelo fator de forma (HEINSDJIK; BASTOS 1963), e medições sobre diâmetro e altura, podendo fornecer informações confiáveis em escala local ou regional; (ii) equações de regressão: envolvem medições de parcelas amostrais e fornecem estimativas de volume em escala local, regional e global com base na cubagem rigorosa (LU, 2006); (iii) imagens de satélite: método mais recente e não tradicional, onde geralmente são combinações de medições remotas e as obtidas pelo inventário em campo, permitem estimativas em escala global

com maior facilidade (CORONA et al., 2011; HENTZ et al., 2014). Os métodos tradicionais envolvendo levantamento de campo são considerados os mais precisos, porém são processos demorados e caros. Em grandes extensões e em áreas inacessíveis, os levantamentos de campo se tornam ainda piores de serem implementados (FREITAS; MAGALHÃES, 2012).

A estimativa da produção florestal e da densidade de árvores em uma grande área usando dados de sensoriamento remoto tem uma significância considerável para o manejo sustentável dos recursos naturais, nas últimas décadas, técnicas de sensoriamento remoto vêm sendo utilizadas para estimar o volume do estoque de madeira em florestas com planos de manejo na Amazônia. Tais aplicações resultaram em melhorias consideráveis em termos de tempo, custos e escala (DA SILVA, et al 2014; SANTOS et al, 2017; SILVA et al., 2018). Por outro lado, as metodologias e precisão ainda consistem em um grande desafio técnico-científico (D'OLIVEIRA et al., 2014; SCHMINK ; WOOD, 2019).

Paralelamente, a utilização de redes neurais artificiais (RNAs) vem se mostrando uma ótima alternativa para os métodos de manejo e mensuração florestal. RNAs consistem em um agrupamento de unidades que contêm funções matemáticas, unidas por pesos. As redes têm a capacidade de aprender, através da mudança dos pesos sinápticos, e generalizar o aprendizado para outra base de dados. O esquema de redes neurais é composto por três etapas: pré- processamento, processamento e pós-processamento dos dados (GORGENS et al., 2009; SILVA et al., 2010; AKKOÇ, 2012; BRAGA et al., 2014; CARRIJO et al., 2020). Vários trabalhos vêm sendo desenvolvidos visando sua adaptação e parametrização para as mais diversas situações do meio como a estimativas do volume e biomassa de árvores (BINOTI et al., 2014; MIGUEL et al., 2015), crescimento e produção (CASTRO et al., 2013), taper (LEITE et al., 2011), resistência da madeira (MIGUEL et al., 2018), propriedades energéticas (CARRIJO, 2020) dentre outras aplicações.

O principal desafio é a integração de RNAs com dados de sensoriamento remoto. O uso associado de dados de satélites com inteligência artificial parece uma alternativa promissora para modelar variáveis dendrométricas em florestas nativas e plantadas. O uso dessas técnicas associadas a índices de vegetação apresenta potencial para reduzir os custos nas operações tradicionais de inventários florestais em campo e com a possibilidade ser aplicadas em áreas inacessíveis e de grandes extensões

(NELSON et al., 2009, MIGUEL et al., 2015, LI et al., 2020). Os índices de vegetação estão sendo utilizados amplamente como números da presença e das condições físicas das espécies vegetais, são baseados em razões ou transformações de valores espectrais e ou combinações lineares. Sua principal característica é a capacidade de realçar os atributos espectrais da vegetação, solo, água e outras superfícies (BANNARI et al., 1995, ALMEIDA et al., 2009; XUE; BAOFENG, 2017).

No presente estudo, buscou-se desenvolver e avaliar modelos para estimativas de volume de madeira usando dados de sensoriamento remoto, associados às redes neurais artificiais. Face ao exposto levantou-se a seguinte questão de pesquisa: Os índices de vegetação como variáveis preditoras associados a informações de inteligência artificial proporcionam estimativas precisas do volume em florestas nativas? E a seguinte hipótese: As estimativas da produção utilizando técnicas de inteligência artificial com índices de vegetação são compatíveis, logo não existe diferença significativa no volume calculado por inventários tradicionais.

2. OBJETIVOS

2.1 Objetivo geral

Avaliar a estimativa volumétrica utilizando redes neurais artificiais e índices de vegetação em floresta nativa na Amazônia brasileira.

2.2 Objetivos específicos

- Desenvolver modelos para estimar volume explorado em floresta tropical usando dados do satélite Sentinel-2 e redes neurais artificiais (RNA);
- Estimar volume das árvores de interesse comercial, usando dados de sensoriamento remoto e RNA.

3. REFERENCIAL TEÓRICO

3.1 Gestão das florestas públicas e privadas

A ideia de floresta pública parte da premissa de conservar e manter os estoques de recursos naturais para o desenvolvimento sustentável. Em 1911, foi estabelecida no estado do Acre a primeira reserva florestal do Brasil e, em 1946 no Ceará, a primeira Floresta Nacional, a FLONA do Araripe-Apodi (ICMBIO, 2016).

O desenvolvimento sustentável, segundo o Relatório de Brundtland da Comissão Mundial sobre Meio Ambiente e Desenvolvimento da Organização das Nações Unidas de 1987, é “aquele capaz de satisfazer a necessidade presente sem comprometer a capacidade das gerações futuras de satisfazer a sua própria necessidade” (BRUNDTLAND, 1987).

A Lei 11.284/2006 que dispõe sobre a gestão e concessão de florestas públicas para o manejo florestal foi o primeiro passo de consolidação da utilização das florestas públicas no Brasil. Nesta lei, as unidades de conservação de uso sustentável registradas no Cadastro Nacional de Florestas Públicas (CNFP) podem oferecer a empresas privadas o direito de concessão dessas florestas para uso e manejo de forma sustentável (BRASIL, 2006).

Das unidades de manejo florestal sob concessão, todas estão localizadas na região norte do Brasil mais precisamente no bioma amazônico, Floresta Nacional do Jamari, Floresta Nacional Saracá - Taquera, Floresta Nacional de Jacundá, Floresta Nacional Saracá - Taquera (Lote Sul), Floresta Nacional de Altamira, Floresta Nacional Caxiuanã, e Floresta Nacional de Crepori, com destaque para a Floresta Nacional do Jamari, que foi a primeira a ser formalmente concedida em 2007 (SFB, 2017).

As florestas privadas são consideradas aquelas que advêm de reserva legal (RL) das propriedades particulares e podem ser exploradas. Reserva Legal é definida segundo Código Florestal Brasileiro Lei 12.651/2012:

Área localizada no interior de uma propriedade ou posse rural, permitido o uso sustentável dos recursos naturais, desde que haja à conservação e reabilitação dos processos ecológicos, à conservação da biodiversidade e ao abrigo e proteção de fauna e flora nativas, com exceção a área de preservação permanente APP, (BRASIL, 2012).

Nessas áreas é permitido o manejo florestal sustentável para a produção de bens e serviços, desde que o plano de manejo seja aprovado pelo órgão governamental competente. O tamanho estimado das áreas de florestas protegidas em imóveis privados considerando todas APP, RL, RPPN (Reserva Particular do Patrimônio Natural), áreas de florestas naturais e plantadas e áreas com sistemas agroflorestais totaliza em 100 milhões de hectares (SFB, 2017).

Da produção de madeira na Amazônia legal os estados do Pará, Mato Grosso e Rondônia juntos somam 93% (SNIF, 2017). O Estado do Mato Grosso apresenta 53,6% de sua área ocupada pelo bioma amazônico, 39,6% de Cerrado e 6,8% de Pantanal segundo (IBGE, 2020). De acordo com o Centro das Indústrias Produtoras e Exportadoras de Madeira do Estado de Mato Grosso, o mesmo é destacado como o estado com a maior quantidade de PMFS (Plano de Manejo Florestal Sustentável) além de ser o único que não possui floresta nacional (CIPEM, 2018).

3.1.1. Manejo florestal sustentável

O manejo florestal sustentável pode ser acrescentado à madeira, sementes, fibras ou outros produtos florestais. No manejo da madeira, o corte é feito de forma seletiva, em áreas com intervenção da atividade humana, utilizando técnicas e conhecimento científico que minimizam os impactos no ecossistema e propiciam a regeneração da floresta (SFB, 2017).

O código florestal brasileiro, Lei 12.651/2012 definiu que as florestas da Amazônia só poderiam ser utilizadas através de planos de manejo.

Fica proibida a exploração sob forma empírica das florestas primitivas da bacia amazônica, que só poderão ser utilizadas em observância a planos técnicos de condução e manejo a serem estabelecidos por ato do Poder Público, a ser baixado dentro do prazo de um ano (BRASIL, 2012).

Em 1989, o IBAMA deliberou um extensivo protocolo de plano de manejo, que incluía particularização de técnicas de extração com intuito de mitigar os impactos na floresta, tratamentos silviculturais, estimativas do volume a ser explorado e procedimentos de monitoramento do desenvolvimento da floresta após a exploração (IMAZON, 2013). Além disso, foi estipulado um ciclo de corte mínimo de 30 anos

(BRASIL, 2009). O que de fato só veio ocorrer em 1994 sob forte pressão da Rio 92, sob decreto nº 1.282, que definiu que a exploração florestal sob a forma de manejo sustentável, seria feita com base nos princípios gerais e fundamentos técnicos (GARRIDO, 2002).

Em marcos ambientais, o manejo proporciona a floresta manter sua forma e função com a proximidade original. A conservação se dá à medida que se torna mínimo as perdas para floresta e como consequência, minimizar os danos às árvores comerciais, garantindo a sua forma, a floresta é capaz de cumprir com seus empregos: abrigar a biodiversidade, preservar a qualidade da água, proteger o solo contra a erosão e outras (SERRANO, 2019). O bom manejo também pode contribuir para que a floresta remanescente tenha menores chances de incêndios além de poder ser enriquecida com tratamentos silviculturais (MORAN, 2017).

Os planos de manejo florestal são ferramentas usadas com o objetivo de avaliar que as florestas sejam gerenciadas pelo provimento de bens e serviços em longo prazo, e são estabelecidos para fins diferentes ou múltiplos, como produção, conservação e prestação de serviços ambientais (MACDICKEN et al., 2015).

O Plano de Manejo deve ser elaborado em várias etapas, conforme apresentado no quadro a seguir:

Quadro 1: Etapas da organização de um PMFS.

Principais Passos para Elaboração do Plano de Manejo
1º- Organização do Planejamento;
2º- Reuniões técnicas (A)* da equipe de planejamento;
3º Atualização bibliográfica e análise das informações disponíveis;
4º- Interpretação das imagens orbitais e sub-orbitais;
5º- Visitas de campo;
6º-- Análise do manejo da unidade de conservação;
7º- Visitas de campo à unidade de conservação;
8º- Reuniões técnicas (B)* da equipe de planejamento;
9º- Realização de uma Oficina de Planejamento;
10º- Consolidação dos subsídios da Oficina de Planejamento;
11º- Elaboração do Plano de Manejo – versão 1;
12º- Reuniões técnicas (C)* da equipe de planejamento;
13º- Elaboração do Plano de Manejo – versão 2;
14º- Reuniões técnicas (D)* da equipe de planejamento;
5º- Elaboração do Plano de Manejo – versão 3;

Fonte: IBAMA, 1996

3.1.2. Manejo florestal no Mato Grosso

O setor de base florestal em Mato Grosso está empenhado em melhorar a sustentabilidade da atividade, em um estudo do centro das indústrias produtoras e exportadoras de madeira do estado de Mato Grosso 93% (262,5 mil hectares) das áreas exploradas legalmente no estado ocorreram a partir de Planos de Manejo Florestal Sustentável (PMFS). O estudo ainda diz que após analisar 697 autorizações de exploração florestal vigentes entre 2014 e 2016, foi constatado que 59% da área total de exploração madeireira mapeada foram feitas com autorização válida (CIPEM, 2018).

De acordo com o sistema nacional de informações florestais a região Amazônica por meio dos polos madeireiros alcançam 95% da produção de madeira. Amazônia Legal conta com 72 polos madeireiros, somente no estado do Mato Grosso são registrados 20 polos madeireiros cuja atividade empresarial já passa de meio século. A região norte do Mato Grosso é conhecida por ser uma região potencial para o polo madeireiro, as cidades de Sinop, Alta Floresta e Colniza reúnem 70% da produção de madeira no bioma amazônico no estado. Mostrando que, atividade do manejo florestal tem uma disposição positiva para dar garantias ao futuro dos polos madeireiros na Amazônia brasileira além de colocar as reservas legais em um nível de qualidade na produção de madeira, produtos e subprodutos florestais (SNIF, 2017).

A produção de base florestal em Mato Grosso é um setor importante, gerando cerca de noventa mil empregos diretos e indiretos e representando o quarto lugar na economia estadual. Além disso, o manejo florestal sustentável no estado presta importantes serviços ambientais, como o extrativismo sustentável de produtos não madeireiros mantendo a floresta de pé, que desenvolve outras cadeias socioeconômicas e o sequestro de carbono, que reduz o efeito estufa (CIPEM, 2018).

3.2 Uso sensoriamento remoto no meio florestal

Assim como acontece em diversas áreas científicas e do desenvolvimento humano, a ciência florestal tem sido muito beneficiada pelos avanços das geotecnologias, definidas como todas as tecnologias que estão relacionadas geoinformação. Essa área tem abrangência da aquisição, processamento, interpretação (ou análise) de dados ou informações espacialmente referenciadas, condicionadas pelos sistemas de informações geográficas, geoestatística, sensoriamento remoto, geodésia, cartografia, dentre outros (TAKIKAWA, 2020).

Tarefas que já foram complicadas e demandavam muito tempo, agora são realizadas com rápidos resultados e alta eficiência, como, estudo de ecologia da paisagem, demarcação de corredores ecológicos, manejo de bacias hidrográficas, risco de inundação, monitoramentos, risco de incêndios florestais e adequações ambientais, projetos de implementação e condução de maciços florestais, zoneamentos ambientais, planos de manejo de unidades de conservação, estimativas do estoque de volume e biomassa das florestas dentre outras (KERSKI, 2015; DA SILVA, 2017).

Vários autores do meio florestal criaram e ou usaram equações correlacionando métricas do volume associadas aos índices de vegetação (IV) em florestas tropicais com dados espectrais do sensor óptico TM do satélite Landsat (ZERBINE et al,1995; MACIEL, 2007; CELES et al, 2013; BARROS et al, 2015; MACEDO et al, 2018). Os sensores ópticos, que atuam nas bandas espectrais do visível e do infravermelho têm sido os mais empregados para o mapeamento de recursos terrestres e monitoramento da dinâmica de ocupação das terras, volume e biomassa e entre outras aplicações (OLIVEIRA, 2011). Os índices de vegetação usados nestas estimativas são baseados nas diferenças da relação inversa que existe entre as bandas do vermelho e do infravermelho próximo no comportamento espectral da vegetação viva, morta e do solo. Os índices de vegetação são modelos matemáticos desenvolvidos para avaliar a cobertura vegetal e diagnosticar: área foliar, biomassa, porcentagem de cobertura do solo, atividade fotossintética, produtividade, entre outros (BASTIAANSSEN, 1995).

Alem do Landsat existem outros satélites que são utilizados na área florestal dentre eles podemos citar: Google Earth Engine (EE) que apresenta o sistema de alerta ao desmatamento na amazônia (SAD EE), desenvolvido em colaboração com o google e realizada na plataforma com imagens de reflectância do sensor MODIS para gerar os alertas de desmatamento e degradação florestal, SPOT 5- HRG, IKONOS II, e o satélite Sentinel -2, objeto desse estudo, muito usado para classificação do uso e cobertura da terra dentre outros (IMAZON, 2016).

3.3 Missão sentinel-2

O satélite Sentinel-2 faz parte da missão da *European Space Agency* (ESA) desenvolvido no quadro do programa da União Europeia, foi lançado no dia 23 de junho de 2015 e atualmente está em operação e está fundamentado nas missões SPOT

(França) e nos satélites da missão Landsat (Estados Unidos) (DRUSCH et al., 2012; HAGOLLE et al., 2015; SEGL et al., 2015).

Possui uma câmera multiespectral mais avançada do seu tipo de satélites, de fato é a primeira missão óptica de observação da terra de sua classe, pelo fato de compreender três bandas no “*red edge*” resultando em melhores informações sobre a condição da vegetação (TAQUIA et al., 2015). O design óptico do telescópio MSI permite um campo de visão de 290 km (ESA, 2015). Os dados projetados são comumente usados nas áreas temáticas, tais como, monitoramento agroambiental, ordenamento do território, monitoramento florestal, monitoramento da água e da vegetação, monitoramento de recursos naturais, monitoramento do carbono terrestre, e monitoramento global de culturas (ESA, 2012).

As especificações técnicas do satélite referentes a resolução espacial, espectral e radiométrica estão representadas conforme (Tabela 1). A resolução radiométrica do instrumento MSI é de 12 bits e permite que a imagem seja apanhada num intervalo de 0 a 4095 valores de intensidade de luz (ESA, 2015).

Tabela 1: Ficha técnica com as informações espaciais e espectrais.

Resolução	Nº da Banda	Nome da Banda	Comprimento de Onda (nm)	Combinações de Bandas
10 m	B02	Blue (Azul)	490	Cor Verdadeira
	B03	Green (Verde)	560	RGB 04/03/02
	B04	Red (Vermelho)	665	Falsa Cor 1 e 2
	B08	NIR (Infravermelho Próximo)	842	RGB 08/04/03 e 04/08/03
20 m	B05	Red Edge 1	705	SWIR 1RGB 12/11/8A
	B06	Red Edge 2	740	
	B07	Red Edge 3	783	
	B08A	Red Edge 4	865	
	B11	SWIR 1	1610	
	B12	SWIR 2	2190	
60 m	B01	Aerossol	443	-
	B09	Water Vapor	940	
	B10	Cirrus	1375	

Segundo Pandit et al. (2018), os dados do satélite Sentinel-2 proporcionam boa acessibilidade e têm uma maior quantidade de bandas espectrais de alta resolução em

comparação a dados comerciais de resoluções moderadas, por exemplo, dados ASTER. Sugerindo que é viável para uso em pesquisas florestais, com destaque para grandes áreas e onde os recursos financeiros são uma restrição, pois os dados são de acesso grátis.

No setor florestal existem bons estudos que correlacionaram os dados de imagens sentinel-2 com características do estrato florestal. No Brasil Perez et al. (2018), utilizou três imagens do sensor msi do satélite sentinel-2 para investigar a possibilidade de estimar parâmetros biofísicos da vegetação medidos em campo com os dados de 5 índices de vegetação e as variáveis DAP, porcentagem de cobertura e número de indivíduos, além de também usar dados LiDAR (Light Detection and Ranging), os resultados mostraram que muitos dos parâmetros biofísicos tem relação com as imagens obtendo um R^2 ajustado de até 0,62.

Na Itália Puletti et al. (2018), utilizou três imagens de diferentes períodos fenológicos para mapear o tipo de floresta no ambiente mediterrâneo a partir de quatro índices de vegetação, usados para avaliar e discriminar categorias de floresta (coníferas, florestas de folhas largas e mistas) e os quatro tipos de florestas (florestas de faias; florestas mistas de abetos e abetos; florestas de castanheiros; florestas mistas de carvalhos). A melhor configuração rendeu uma precisão superior a 83% em todos os tipos de floresta considerados.

3.4 Redes Neurais Artificiais

A Inteligência derivada de sistemas computacionais visa buscar o desenvolvimento de sistemas que pensem e ou imitem as características de um comportamento humano através de técnicas inspiradas na natureza. Por definição as redes neurais artificiais RNA são sistemas computadorizados constituídos por unidades de processamento de dados, que são conectadas entre si, de uma maneira específica para desempenhar uma determinada tarefa (BINOTI et al., 2013).

A ideia é que uma RNA tenha capacidade de aprender e adotar decisões com base no aprimoramento e na aprendizagem, pegando informação por meio da experiência, de modo que quanto mais se erra mais perto vai chegando ao acerto pelo meio da aprendizagem memorizada (HAYKIN, 2001; BINOTI et al., 2015; DIAS et al., 2017).

As redes Neurais assim como o cérebro humano, são compostas por milhares de neurônios, pequenos módulos que simulam o funcionamento de um neurônio conforme Figura 1. Estes módulos devem funcionar de acordo com os elementos em que foram inspirados, recebendo e retransmitindo informações (HAYKIN, 1994).

A aprendizagem é um termo adotado pelos autores quando a rede passa pelo processo de treinamento sendo uma tarefa que pode ser vista como busca no espaço dos pesos das conexões, de maneira sistemática, para determinar o vetor de peso que leva para uma solução ótima (mínima ou máxima), onde se tem vários critérios estatísticos, a máxima verossimilhança, soma de quadrados do erro, entropia relativa dentre outros (HASSOUN, 1995; CASTRO et., al 2013).

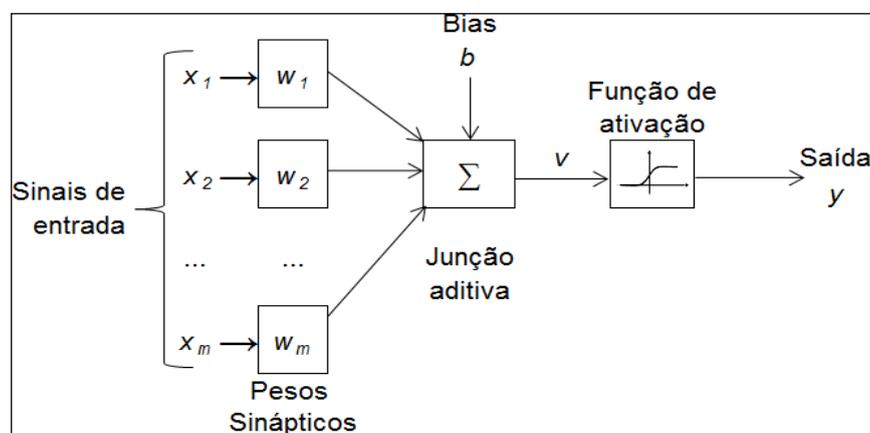


Figura 1: Esquema de um neurônio artificial em que: Definição do número de sinais de entrada (variáveis independentes); Definição das variáveis de saída (variáveis dependentes). (CASTRO et., al 2013).

O uso de redes neurais artificiais (RNAs) é diverso e abrangente em várias áreas da ciência e da indústria, desde a química e engenharia termal até o setor da saúde, as indústrias de transporte e aeroespaciais (ROSAS et al., 2013; ESFE et al., 2016; GITOOE et al., 2018; TOSUN, 2018).

Essa técnica vem se mostrando cada vez mais promissora nas ciências florestais devido a sua alta precisão na estimativa de inúmeras variáveis da floresta, e muitas vezes mais eficaz que os modelos de regressão tradicionais (FERRAZ et al., 2014; MIGUEL et al., 2015; VAHEDI, 2016; LIMA et al., 2017; ÖZÇELIK et al., 2017; VENDRUSCOLO et al., 2017; VIEIRA et al., 2018b).

No que diz respeito a trabalhos com RNAs, existem vários estudos de diferentes lugares e diferentes fitofisionomias que comprovam a sua eficiência como, por exemplo:

em povoamentos de *Eucalyptus sp*, Binoti et al. (2015), evidenciaram a capacidade das RNAs dar prognose volumétrica, com base nas variáveis numéricas, área basal, idade e volume pelas categorias de classes de solo, espaçamento, relevo e material genético. Em florestas tropicais no Brasil, Malásia e Tailândia Cutler et al. (2012), com uso de uma combinação de imagem textural e dados Landsat/TM, os autores testaram e comprovaram a eficiência das RNAs nas estimativas de volume e biomassa, Miguel et al. (2015), modelando através das RNAs o volume de madeira e biomassa do cerradão com dados do sensor LISS-III, a bordo do satélite ResourceSat1 usando índices de vegetação, na china Li et al. (2020), estimaram volume e biomassa acima do solo da floresta usando RNAs e imagens de satélites Landsat 8 e Sentinel-1A.

4. MATERIAL E BASE DE DADOS

4.1 Área de estudo e caracterização

O presente estudo foi realizado na região de Sinop, um dos polos de produção florestal do estado do Mato Grosso. A área situa - se na porção norte do estado, a 500 quilômetros da capital Cuiabá, onde estão presentes as sedes municipais de Itaúba, Marcelândia, Claudia, União do Sul, Santa Carmen e Feliz Natal.

A fazenda 4 Ventos (Antiga fazenda Nova Aliança) situada na Zona Rural do município de Feliz Natal com distância de 40 km aproximadamente pela Rodovia MT-225 até a sede da propriedade e posterior ao PMFS nas Coordenadas Geográficas 54° 26' 26,6" W e 12° 12' 01,1" S (Figura 2).

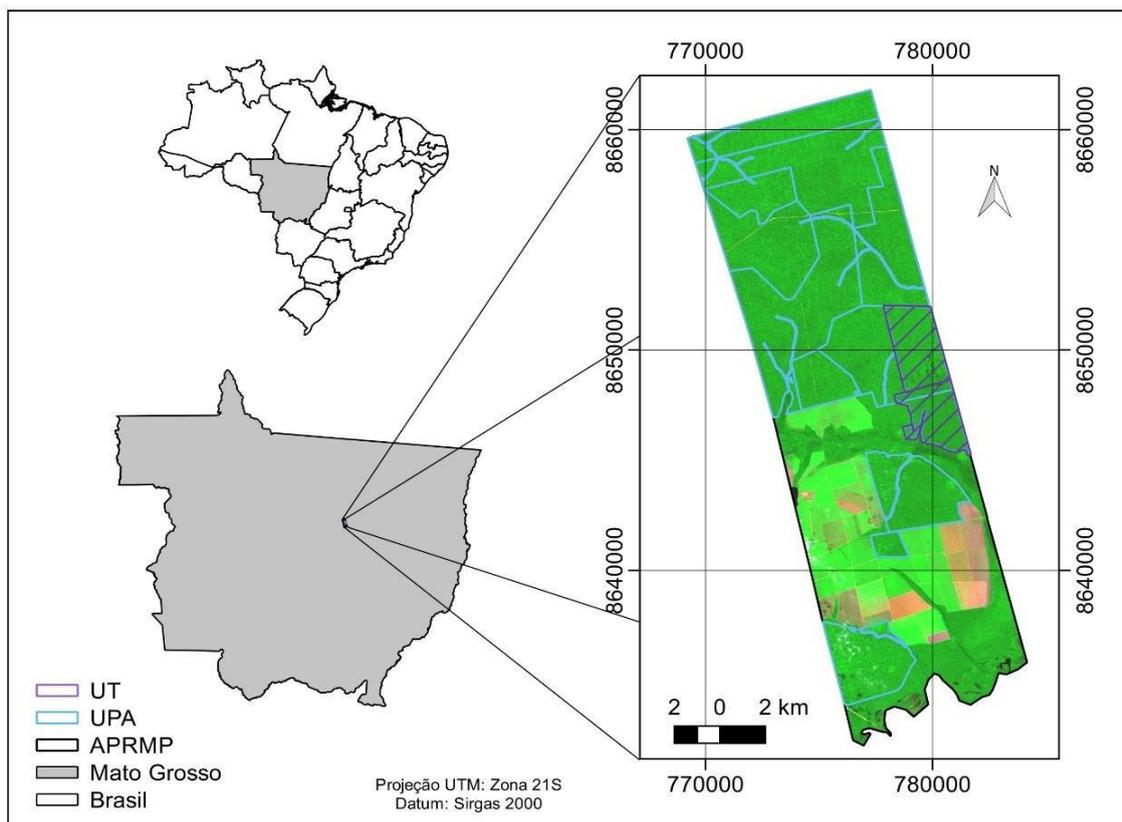


Figura 2: Localização da área de estudo, em que UT: Unidade de Trabalho; UPA: Unidade de Produção Anual; APRMP: Área da Propriedade Rural por Matrícula ou Posse no município de Feliz Natal - MT, na Amazônia.

A área faz parte de um projeto de manejo florestal sustentado aprovado no âmbito da Secretaria do Estado do Meio Ambiente do Mato Grosso (SEMA) através do PMFS de uma área de 1.351,2134 hectares (figura 3). A volumetria 36.797,9871 m³ autorizada para exploração advém de toras de madeira nativas, distribuídos em 12 espécies florestais produtoras de madeiras comercialmente aptas na região, no estado de Mato Grosso, no país e no exterior.

E



Figura 3: Placa do projeto (autex) com a chegada ao PMFS (A), Entrada da fazenda 4 ventos (B) no município de Feliz Natal - MT, na Amazônia.

4.2 Características edafoclimáticas

O território é compreendido pela floresta amazônica, abrangendo parte das bacias dos Rios Teles Pires e Xingu, está representada pelas sub-bacias dos Rios Manissauá-Miçu e Arroios. A maior parte da região está inserida na unidade geomorfológica do Planalto dos Parecis, incluído nas morfoestruturas das coberturas sedimentares da plataforma amazônica, com um relevo plano com formas dissecadas e topos tabulares com um solo predominante do tipo latossolo vermelho-amarelo (EMBRAPA, 2018). A Serra Formosa, orientada sul-norte, constitui o divisor entre as bacias do Teles Pires e do Xingu. O clima é classificado como tropical Aw, segundo a classificação de Köppen (ALVARES et al., 2014). A altitude em torno dos 384 metros, média anual da temperatura e precipitação são de 25,0°C e 1.818 mm, respectivamente.

4.3 Coletas de dados

Os dados de campo advêm de uma AMF que conta com duas Unidades de Trabalho (UT), e que estão sendo exploradas no contexto de um plano de operações anual (POA), divididos em finalidades de corte para a serraria e laminados. Foram tomadas as variáveis DAP e altura comercial de todas as árvores com o diâmetro mínimo de medição (DMM) a partir de 30 cm, todas as árvores mensuradas foram georreferenciadas, conforme plaquetas na figura 4 A.



Figura 4: Árvore remanescente identificada (A), toras sendo processadas na no pátio de estocagem da UPA (B) no município de Feliz Natal - MT, na Amazônia.

4.3.1. Inventário Florestal

O inventário foi do tipo 100%, todas as árvores foram mensuradas em 220 faixas de 50 metros de largura e comprimento variável, totalizando 24075 indivíduos média de 1,52m³/árvore representados por 39 espécies conforme (Tabela 2). Para o inventário foi calculado as métricas de número de árvores, área basal e volume conforme item 3.4.1.

Tabela 2: Lista das espécies com o respectivo número de indivíduos, no município de Feliz Natal - MT, na Amazônia.

Nome Científico/Autor	Nome popular	Família	N
<i>Anacardium giganteum</i> W. Hancock ex Engl.	Cajueiro, Cajuí, Caju de polpa	Anacardiaceae	13
<i>Apuleia leiocarpa</i> Vogel.	Garapeira, Garapa, Grapiá.	Fabaceae	86
<i>Apeiba tibourbou</i> Aubl.	Pente de macaco, pau jangada.	Malvácea	1
<i>Aspidosperma album</i> Vahl R.Benoist ex Pichon.	Peroba-dágua.	Apocynaceae	2
<i>Astronium gracile</i> Engl.	Aroeira, Muiracatiara, Guaritá	Anacardiaceae	20
<i>Bombax ceiba</i> L.	Paineira, Paineira-vermelha	Malvaceae	52
<i>Bowdichia virgilioides</i> Kunth.	Sucupira-preta.	Fabaceae	284

<i>Brosimum parinarioides</i> Ducke.	Leiteira, Amapá-amargo, Amaparana.	Moraceae	12
<i>Buchenavia tomentosa</i> Eichler.	Tarumarana, Mirindiba, Tarumã.	Combretaceae	264
<i>Byrsonima verbascifolia</i> L. Rich.	Murici, muricizeiro.	Malpighiaceae	1
<i>Calophyllum brasiliensis</i> Cambess.	Guanandi, Olandi, Galandim, Jacareúba	Clusiaceae	6
<i>Caryocar brasiliense</i> Cambess.	Pequi.	Caryocaraceae	1
<i>Chrysophyllum prieurii</i> A.DC.	Abiurana, abiurana-vermelha, abú- casca-fina	Sapotaceae	18
<i>Copaifera langsdorffii</i> Desf.	Copaíba, Pau-óleo	Caesalpinioideae	130
<i>Couma guianensis</i> Aubl.	Sorveira, Sorva da mata, Sorvão	Apocynaceae	5
<i>Dipteryx ferrea</i> Ducke.	João duro, Cumaru ferro	Fabaceae	1
<i>Dipteryx odorata</i> Aublet. Willd.	Champanhe, Cumarurana, Cumaru,	Fabaceae	2320
<i>Didymopanax morototoni</i> Aubl.	Mandiocão, Tobitoutou, Morototo,	Araliaceae	22
<i>Erisma uncinatum</i> Warm.	Cedrinho, Quarubarana	Vochysiaceae	3198
<i>Erythroxylum argentinum</i> O. E. Schulz.	Marmelada, Cocão	Erythroxylaceae	21
<i>Ferreirea spectabilis</i> Alemao.	Sucupira-amarela, Sucupira, S	Leguminosae	346
<i>Goupia glabra</i> Aubl.	Cupiúba,	Goupiaceae	18
<i>Hymenolobium excelsum</i> Ducke	Angelim, Angelim-Pedra, Angelim	Fabaceae	671
<i>Inga speciosa</i> Spruce ex Benth.	Ingá.	Mimosoideae	36
<i>Jacaranda copaia</i> Aubl.	Caroba, Pará-Pará	Bignoniaceae	150
<i>Lindackeria paraensis</i> Kuhlm.	Farinha-seca	Achariaceae	165
<i>Mezilaurus itauba</i> Meisn. Taub. ex Mez.	Itaúba, taúba-amarela	Lauraceae	5054
<i>Micropholis venulosa</i> Mart. Eichler. Pierre.	Catanudo	Sapotaceae	11

<i>Ocotea spixiana</i> Nees Mez.	Canelão	Lauraceae	2308
<i>Parkia pendula</i> Willd. Benth. ex Walp.	Angelim-saia, Visgueiro	Mimosoideae	83
<i>Qualea albiflora</i> Warm.	Cambará, Mandioqueira Lisa	Vochysiaceae	4068
<i>Sclerolobium aureum</i> Tul. Benth.	Carvoeiro-fedido, Carvoeiro	Fabaceae	39
<i>Trattinnickia burseraefolia</i> Mart. Willd.	Amescla, Breu-preto, Breu-Sucuruba	Burseraceae	3316
<i>Vochysia maxima</i> Ducke.	Rosinha, Quaruba-verdadeira,	Vochysiaceae.	409
<i>Xylopia frutescens</i> Aubl.	Pindaiba, Envira-preta	Annonaceae	1
Total			24075

As árvores mensuradas na AMF estão representadas em 4 categorias, corte, porta sementes, remanescentes e proibidas de corte (Figura 5). Para fins de conhecimento exclusivo do volume das espécies comerciais duas classes diamétricas foram separadas: árvores comerciais com diâmetro a altura do peito DAP \geq 50 cm, de acordo com diâmetro mínimo de corte (DMC), estabelecidos para os planos de manejo na Amazônia brasileira e a floresta como um todo, que compreende todas as árvores com DAP \geq 30 cm conforme descrito no item anterior o diâmetro mínimo de medição (DMM).

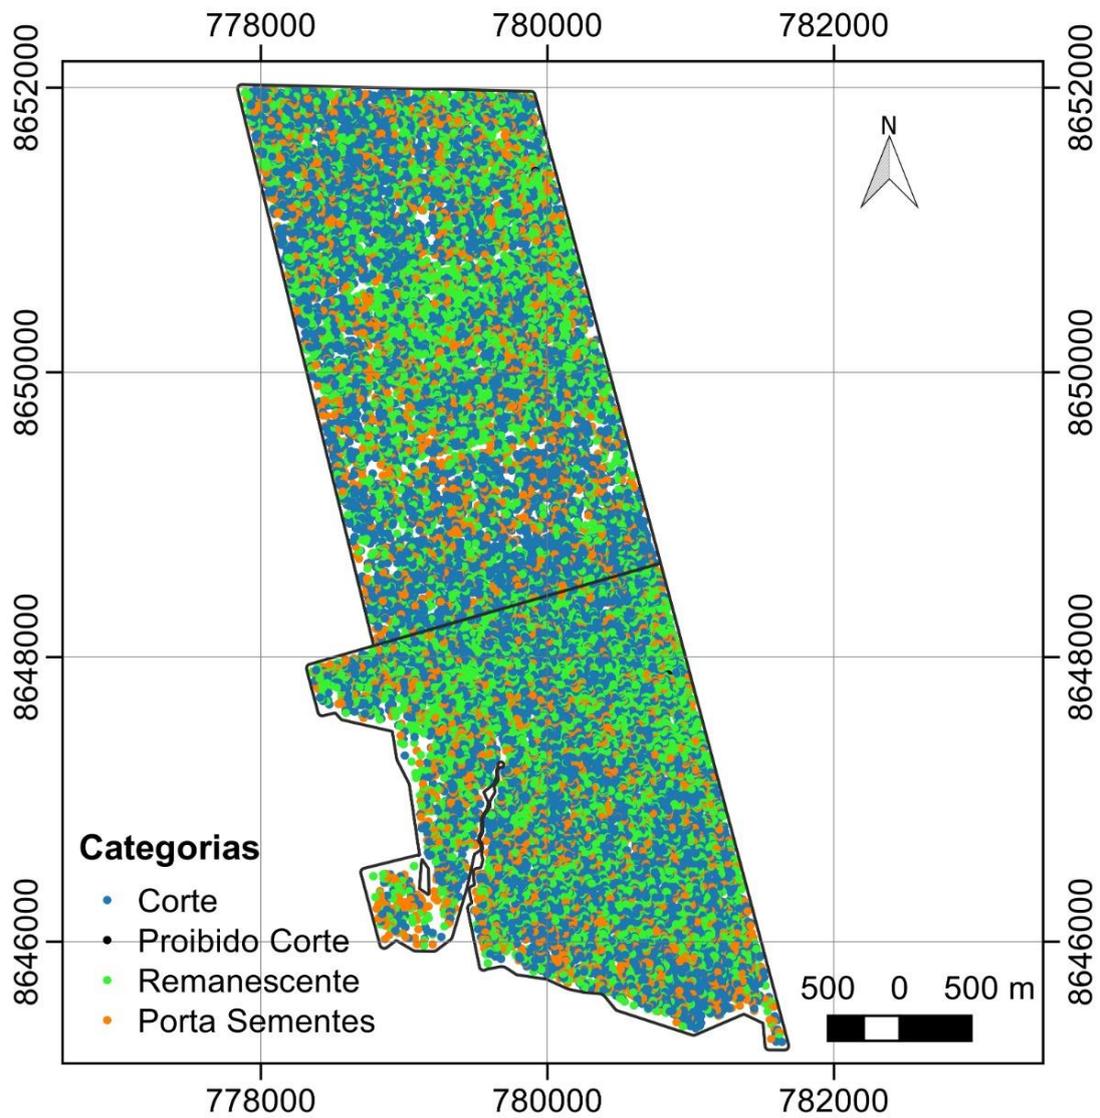


Figura 1: Mapa com as árvores presentes nas UT, corte = azul, proibidas de corte = preto, remanescentes = verde porta sementes = laranja, no município de Feliz Natal - MT, na Amazônia.

Posteriormente foi gerado um mapa de densidade de Kernel (Figura 2), para representar as regiões de maior volume na área. A densidade de Kernel, foi calculada com base no número de pontos de um local, ou seja, quanto maior for o número de pontos agrupados (cluster), a percepção da densidade será maior. Conforme figura 6.

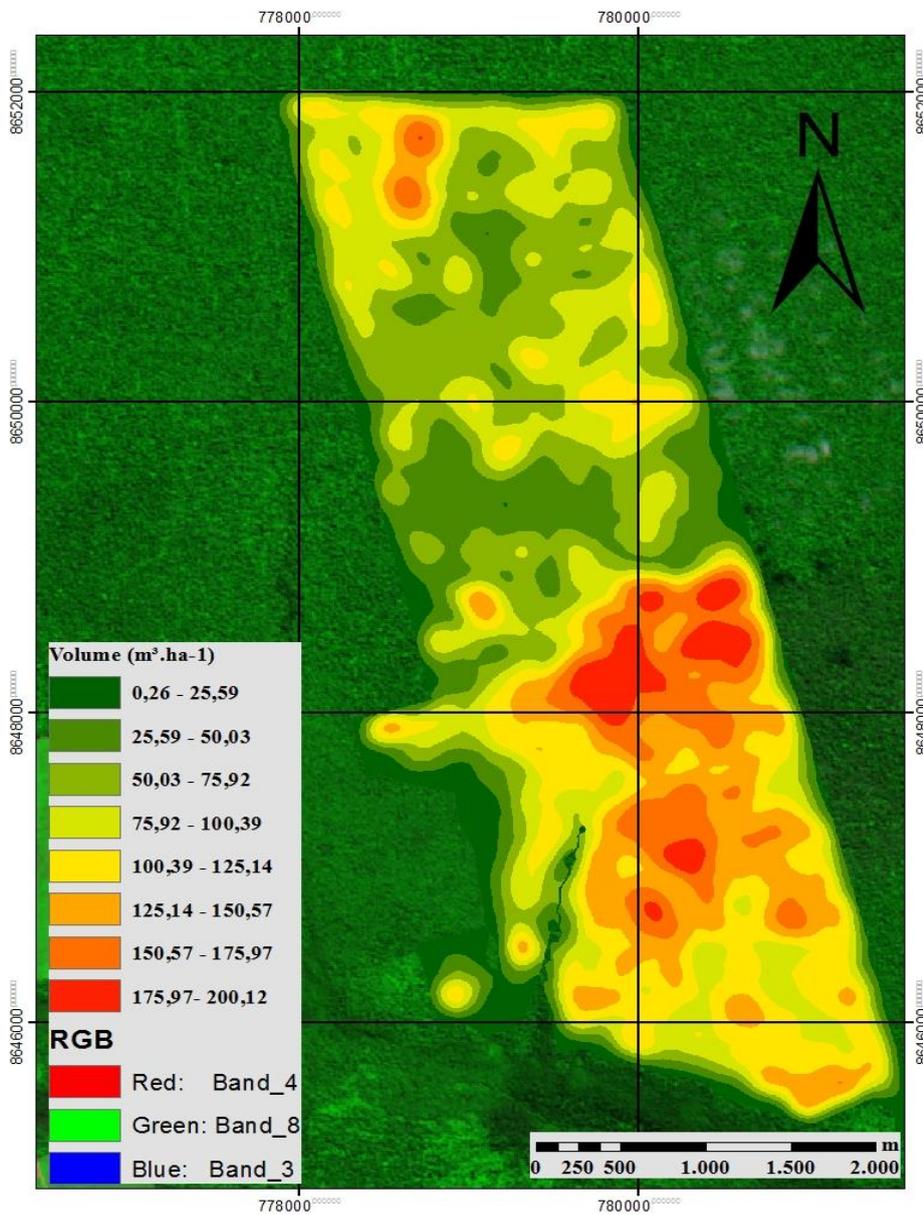


Figura 6: Mapa de densidade de Kernel com os valores de volume em m³. ha⁻¹ variando de 25 m³ ha⁻¹ a 200 m³ ha⁻¹ no município de Feliz Natal - MT, na Amazônia.

Para os dados originados do sensoriamento, foram gerados os seguintes produtos cartográficos: arquivos em formato *shapefile* da área de manejo florestal AMF, UT com um *buffer* de 30 metros e as faixas onde continham as árvores. Também foram utilizadas imagens

em formato GeoTIF do satélite sentinel-2, bandas 2, 3, 4, e 8, com resolução espacial de 10 metros, adquirida em 09 de maio de 2018. Foi utilizada a imagem corrigida de números digitais para reflectância do topo da atmosfera com intuito de minimizar efeitos do sensor e da atmosfera nos índices de vegetação.

4.4 Análise de dados

Os dados foram analisados com auxílio do *software* Microsoft Excel 2016 ® e *software* de Geoprocessamento ArcGis® versão 10.6.1. Datum sirgas 2000, zona utm 21 sul. Para o cálculo das métricas oriundas do volume em m³. ha⁻¹ foi necessário o auxílio do *software* ArcGis, para mensurar a área de cada faixa

4.4.1. Estimativa da área basal, volume e contagem de indivíduos por hectare.

As equações 1, 2, e 3 demonstram as fórmulas de número de árvores, área basal e volume.

$$N = \frac{ni*10000}{AF} \quad (1)$$

$$G = \frac{\pi*(DAP)^2}{40000} * HA^{-1} \quad (2)$$

.

$$V = \left(\frac{\pi*(DAP)^2}{40000} * ff * H \right) * HA^{-1} \quad (3)$$

Em que: N = Número de indivíduos por hectare; ni = Número de indivíduos na faixa; AF= área da faixa; G = área basal em m²; dap = diâmetro à altura do peito, em cm; v = volume em m³; hc = altura comercial; ff= fator de forma (HEINSDJIK; BASTOS 1963). As árvores presentes na área estão identificadas conforme (figura 5).

4.4.2. Índices de vegetação.

Foram gerados valores de cinco índices de vegetação: Índice de vegetação da diferença normalizada - NDVI (PEARSON e MILLER 1972), Índice de vegetação ajustado ao solo - SAVI (HUETE, 1988), Índice de vegetação ajustado ao solo modificado - MSAVI (QI et al., 1994), Índice de vegetação melhorado - EVI (HUETE et al., 1997), e Índice de vegetação melhorado 2 - EVI II (JIANG et al., 2008), e que estão representados nas seguintes expressões:

$$\text{NDVI} = \frac{\text{NIR}-\text{RED}}{\text{NIR}+\text{RED}} \quad (4)$$

$$\text{SAVI} = \frac{(\text{NIR}-\text{RED})}{(\text{NIR}+\text{RED}+\text{L})} * (1+\text{L}) \quad (5)$$

$$\text{MSAVI} = \frac{1}{2} * (2 * \text{NIR} + 1 - \sqrt{(2 * \text{NIR} + 1)^2 - 8 * (\text{NIR} - \text{RED})}) \quad (6)$$

$$\text{EVI} = 2,5 * \frac{(\text{NIR}-\text{RED})}{(\text{NIR}+6 * \text{RED}-7,5 * \text{BLUE}+1)} \quad (7)$$

$$\text{EVI II} = 2,5 * \frac{(\text{NIR}-\text{RED})}{(\text{NIR}+2,4 * \text{RED}+1)} \quad (8)$$

Em que:

NIR = reflectância na banda referente ao infravermelho próximo; RED = reflectância na banda referente ao vermelho; BLUE = reflectância na banda referente ao azul; L = fator de correção para o solo. O valor de L varia de 0 a 1, dependendo do grau de cobertura no solo, de acordo com autor o valor L = 0,25 é utilizado para vegetações densas e L = 1 para vegetações abertas, sendo o L = 0,50 um valor intermediário aos dois extremos. A constante é introduzida com o intuito de reduzir o brilho do solo e gerar isolinhas de vegetação que sejam mais livres do solo. Nesse trabalho foi adotado um valor de L= 0,50.

Os IVs foram submetidos a uma análise de correlação entre os cinco índices calculados e as variáveis dedrométricas.

4.4.3. Ajuste e treinamento das redes neurais artificiais.

Para o ajuste das redes neurais, foram selecionados aleatoriamente 70% dos dados, seguindo a distribuição diamétrica da floresta (DMM E DMC). A camada de entrada, a qual recebe as variáveis preditoras, foi composta por seis neurônios ($N \cdot ha^{-1}$, NDVI, SAVI, MSAVI, EVI e EVI 2). A camada de saída foi composta por um único neurônio, sendo o volume da floresta para árvores com o $dap \geq 30$ cm ou para o $dap \geq 50$ cm.

O número de neurônios nas camadas de entrada e saída foi determinado conforme os níveis das variáveis, sendo um neurônio para cada nível das variáveis. Entretanto, na camada oculta o número de neurônios e as funções de ativação das camadas oculta e de saída foi otimizado com auxílio da ferramenta *Intelligent Problem Solver* (IPS) do *software* Statistica versão 12 (STATSOFT INC, 2011), visando atingir a menor taxa de erro nas previsões (MIGUEL et.al., 2018).

O neurônio é o elemento fundamental da estrutura da RNA e é responsável pelo processamento dos dados e informações ao receber os valores de entrada número de árvores e índices de vegetação (N e IV) até que o resultado de interesse volume (V) seja alcançado. A funcionalidade dos neurônios das RNAs é estimada pela combinação e reprodução de informações com base nas conexões entre as n entradas possíveis x e a saída y . Para cada entrada é definido um peso w que representa as sinapses, e as RNAs armazenam o conhecimento aprendido (GORUNESCU; BELCIUG, 2016; CARRIJO et.al., 2020).

Foram treinadas 300 redes do tipo Perceptron de Múltiplas Camadas (MLP), de modo supervisionado, na qual 150 redes foram treinadas para estimativa do volume da floresta com o $DAP \geq 30$ cm, e as outras 150 para o volume das florestas com árvores de $DAP \geq 50$ cm. Esta categoria de RNA permite a resolução de problemas complexos, devido às suas características não-lineares e à presença de camadas ocultas em sua estrutura, com isso a rede adapte-se e processa com mais precisão informações de entradas (preditores) para saída ou resposta (HAYKIN, 2001; HEIDARI et al., 2016).

O algoritmo quase-Newton desenvolvido por Broyden-Fletcher-Goldfarb-Shanno (BFGS) foi utilizado para processar as redes neurais no IPS, que possui grande poder de resolução para problemas de otimização e previsões (GUERROUT et al., 2018). As funções de ativação sigmoideal, logística, exponencial, tangente, identidade e seno; e o algoritmo quasi-Newton de Broyden-Fletcher-Goldfarb-Shanno (BFGS) (GUERROUT et al., 2017), sendo este iniciado com pesos sinápticos gerados aleatoriamente (HEATON, 2011) e atualizados com base na função de erro.

Para finalizar o treinamento das redes, utilizou-se o número total de ciclos ou o erro quadrático médio, ambos otimizados pelo IPS, visando evitar problemas de perda de poder de generalização da rede causado pelo número exagerado de ciclos (overfitting) ou de desempenho inferior em razão do pequeno número de ciclos (underfitting) (SHIBLEE et al., 2010; CHEN et al., 2014; MELO; MIGUEL, 2016).

Do total das 150 Rnas's treinadas para estimativa do volume com o $dap \geq 30$ cm, ou o $Dap \geq 50$ cm, foram retidas as cinco melhores redes treinadas, sequencialmente, conforme os seguintes parâmetros: correlação entre os valores observados e estimados; distribuição gráfica dos resíduos; e raiz do erro quadrático médio (RMSE%), calculada conforme a equação 9, foi selecionada a melhor RNA.

$$RMSE(\%) = \frac{100}{\bar{Y}} \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (9)$$

Em que: \bar{Y} = é a média dos valores observados; Y_i = é o valor observado; \hat{Y}_i = é o valor estimado pela RNA; n = é o número total de dados.

Por fim, utilizando os 30% da base de dados não utilizadas no ajuste a RNA que apresentou os melhores resultados foi submetida ao processo de validação utilizando o teste "t" entre os valores reais e esperados, probabilidade ($p = 0,05$) e, posteriormente, uma diferença agregada em porcentagem (AD%), valor estatístico utilizado como indicador de sub ou superestimação (MIGUEL et al., 2015; VALE et al., 2017). Essas análises foram realizadas por meio do software Microsoft Excel 2016 ® (Microsoft Corp, Redmond, CA, EUA).

5. RESULTADOS

5.1 Dados de volumetria

A partir das variáveis dendrométricas foi gerado os primeiros resultados estatísticos da área, de acordo com a (tabela 3), referente a floresta (DAP \geq 30 cm).

Tabela 1: Variáveis dendrométricas estimadas do inventário florestal para o DMM, no município de Feliz Natal - MT, na Amazônia.

	N	Hc	DAP	G	Vcc	Vsc
Min	10,00	8,00	30,88	5,75	52,98	47,56
Max	80,00	19,00	141,33	15,76	233,57	210,21
Média	32,00	13,00	57,36	9,31	71,27	64,14
Variância	38,35	8,42	159,13	28,63	2754,24	2230,94
Desvio	6,19	2,90	12,61	5,35	52,48	47,23
CV%	19,17	22,32	21,96	67,02	73,64	73,64

Dados da floresta: N = árvores.ha¹, Hc = altura comercial, DAP = diâmetro altura do peito, G = área basal m².ha¹, Vcc = volume com casa em m³.ha¹, Vsc = volume sem casa em m³.ha¹.

Para as árvores de interesse comercial foi gerada a Tabela 4, com intuito de representar as métricas da mesma, de maneira exclusiva das demais espécies.

Tabela 2: Variáveis dendrométricas estimadas do inventário florestal para as árvores de interesse comercial a partir do DMC, no município de Feliz Natal - MT, na Amazônia.

	N	Hc	DAP	G	Vcc	Vsc
Min	10,00	8,00	50,29	2,90	25,50	23,04
Max	60,00	17,00	196,39	22,05	195,46	186,57
Média	18,00	12,00	63,82	7,52	56,33	46,45
Variância	19,73	5,65	119,69	19,37	1521,72	1024,72
Desvio	4,44	2,37	10,94	4,41	39,68	32,87
CV%	24,67	19,82	17,35	58,64	70,44	70,44

Dados das espécies comerciais N = árvores.ha¹, Hc = altura comercial, DAP = diâmetro altura do peito, G = área basal m².ha¹, Vcc = volume com casa em m³.ha¹, Vsc = volume sem casa em m³.ha¹.

Em seguida, além das estatísticas básicas do volume, a fim de separar as árvores com DMC e identificar somente as árvores comerciais, foi gerada a tabela 5, onde a mesma atribuiu informações dessas espécies, por finalidade e porcentagem do número das mesmas na

área, é notado que a maioria das árvores comerciais estão com mais de 50% do seu total destinados ao corte para serraria.

Tabela 3: Finalidade das espécies comerciais de acordo com o DMC, no município de Feliz Natal - MT, na Amazônia.

Espécie	(%)	Nº de árvores de corte (ha ⁻¹)			Volume de corte (m ³ ha ⁻¹)		
		Serraria	Laminado	Total	Serraria	Laminado	Total
Amescla	61	0	2	2	0	5,68	5,68
Angelim pedra	77	1	0	1	6,15	0	6,15
Cambara	68	1	0	1	5,14	0	5,14
Canelao	34	1	0	1	4,87	0	4,87
Cedrinho	88	4	0	4	11,31	0	11,31
Cedro rosinha	29	0	1	1	0	2,05	2,05
Champanhe	73	2	0	2	5,39	0	5,39
Farinha seca	35	0	1	1	0	3,08	3,08
Garapeira	18	1	0	1	2,53	0	2,53
Itauba	64	2	0	2	7,89	0	7,89
Sucupira amarela	67	1	0	1	3,94	0	3,94
Sucupira preta	17	1	0	1	3,51	0	3,51
Total		14	4	18	45,59	10,81	56,4

5.2 Modelagem

5.2.1. Seleção das variáveis independentes

Conforme apresentado na Tabela 6, estão presentes os dados das médias das variáveis independentes por hectares.

Tabela 4: Média das variáveis independentes na floresta no município de Feliz Natal - MT, na Amazônia.

N.ha ⁻¹	NDVI	SAVI	MSAVI	EVI	EVI II
18	0,680422	0,564732	0,508379	0,436575	0,426693

Legenda: N.ha⁻¹ = Média do número de árvores por hectare; NDVI = Índice de vegetação da diferença normalizada, SAVI = Índice de vegetação ajustado ao solo; MSAVI = Índice de vegetação ajustado ao solo modificado; VI = Índice de vegetação melhorado; EVI II = Índice de vegetação melhorado 2.

A matriz de correlação Tabela 7, apresentou valores moderados a fracos para todos os índices de vegetação, altura, DAP e apresentou alta correlação do número de árvores com o volume $r = 0,96$. Os valores de correlação entre os cinco índices de vegetação e o volume são muito próximos, valores de correlação variando entre 0,36 a 0,42, e por essa baixa diferença todos os cinco índices foram usados como variáveis preditoras no treinamento das redes para indivíduos da floresta.

Tabela 5: Matriz de correlação entre as variáveis estudadas na floresta, no município de Feliz Natal - MT, na Amazônia.

	V _{CC}	N	MSAVI	NDVI	SAVI	EVI	EVI2	DAP	Hc
V _{CC}	1.00								
N	0,96**	1							
MSAVI	0,38*	0,12ns	1						
NDVI	0,40*	0,18ns	0,96**	1					
SAVI	0,36*	0,26ns	0,98**	0,99**	1				
EVI	0,38*	0,28ns	0,94**	0,97**	0,99**	1			
EVI2	0,42*	0,14ns	0,91**	0,98**	0,98**	0,99**	1		
DAP	0,75**	-0,15ns	0,15ns	0,18**	0,16ns	0,16ns	0,16ns	1	
Hc	0,42*	0,18ns	0,16ns	0,05**	0,03ns	0,06ns	0,03ns	0,52**	1

Legenda: *significante à 5%; **Significante à 1%. Em que: V_{CC} = volume com casca área; N = número de árvores; NDVI = Índice de vegetação da diferença normalizada, SAVI = Índice de vegetação ajustado ao solo; MSAVI = Índice de vegetação ajustado ao solo modificado; VI = Índice de vegetação melhorado; EVI II = Índice de vegetação melhorado 2; DAP = diâmetro altura do peito Hc = altura comercial.

A matriz de correlação tabela 8, apresentou valores moderados a fracos para todos os índices de vegetação, altura, DAP e apresentou alta correlação do número de árvores com o volume $r = 0,90$. Os valores de correlação entre os cinco índices de vegetação e o volume são muito próximos, valores de correlação variando entre $r > 0,39$ e $r < 0,43$, por essa baixa diferença todos os cinco índices foram usados como variáveis preditoras no treinamento das redes para indivíduos comerciais.

Tabela 6: Matriz de correlação entre as variáveis estudadas para as árvores de comerciais, no município de Feliz Natal - MT, na Amazônia.

	V _{CC}	N	MSAVI	NDVI	SAVI	EVI	EVI2	DAP	Hc
V _{CC}	1,00								
N	0,90**	1							
MSAVI	0,41*	0,17ns	1						
NDVI	0,42*	0,28ns	0,98**	1					
SAVI	0,40*	0,30ns	0,98**	0,99**	1				
EVI	0,39*	0,31ns	0,96**	0,99**	0,99**	1			
EVI2	0,43*	0,24ns	0,94**	0,97**	0,98**	0,99**	1		
DAP	0,67**	0,10ns	0,17ns	0,15**	0,16ns	0,17ns	0,16ns	1	
Hc	0,32ns	0,15ns	0,10ns	0,06**	0,03ns	0,05ns	0,03ns	0,52**	1

Legenda: *significante à 5%; **Significante à 1%. Em que: V_{CC} = volume com casca área ; N = número de árvores; NDVI = Índice de vegetação da diferença normalizada, SAVI = Índice de vegetação ajustado ao solo; MSAVI = Índice de vegetação ajustado ao solo modificado; VI = Índice de vegetação melhorado; EVI II = Índice de vegetação melhorado 2; DAP = diâmetro altura do peito Hc = altura comercial.

5.2.2. Treinamento das redes neurais

Para a floresta, as cinco redes de melhor desempenho inicial dentre as 150 RNAs treinadas apresentaram estatísticas de ajuste e precisão satisfatórios, com valores de coeficiente de correlação (r) superiores a 0,95 e erros de estimativa abaixo de 15%. Entretanto, a rede neural 4 foi a RNA que demonstrou melhor capacidade preditiva, segundo valores de RMSE% e correlação (Tabela 9).

Tabela 7: Características e estatísticas de precisão das redes neurais artificiais selecionadas para predição do volume das árvores da floresta com dap \geq 30cm no município de Feliz Natal - MT, na Amazônia.

RNA	Arquitetura	Nº de ciclos	Função de ativação		Ajuste		Validação	
			Camada oculta	Camada de saída	RMSE (%)	r	RMSE (%)	r
1	6-09-1	560	Logística	Tangencial	12,25	0,96	15,75	0,93
2	6-09-1	735	Logística	Tangencial	12,75	0,96	14,75	0,91
3	6-12-1	2300	Logística	Exponencial	13,75	0,95	16,30	0,91
4	6-10-1	860	Logística	Exponencial	11,50	0,97	13,48	0,94
5	6-11-1	900	Logística	Identidade	13,90	0,95	16,58	0,92

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.

Após análise do desempenho das cinco redes, a rede quatro foi escolhida, por apresentar um padrão aceitável para distribuição de resíduos (Figura 7. A1 para o treinamento e B1 para validação), acurácia nas predições de volume em m^3 (Figura 7. A2 para o treinamento e B2 para a validação). O histograma referente a classes de erros apresentou uma concentração maior de resíduos nas classes centrais do gráfico, evidenciando a baixa de grandes níveis de sub ou superestimativa (Figura 7. A3 para o treinamento e B3 para validação).

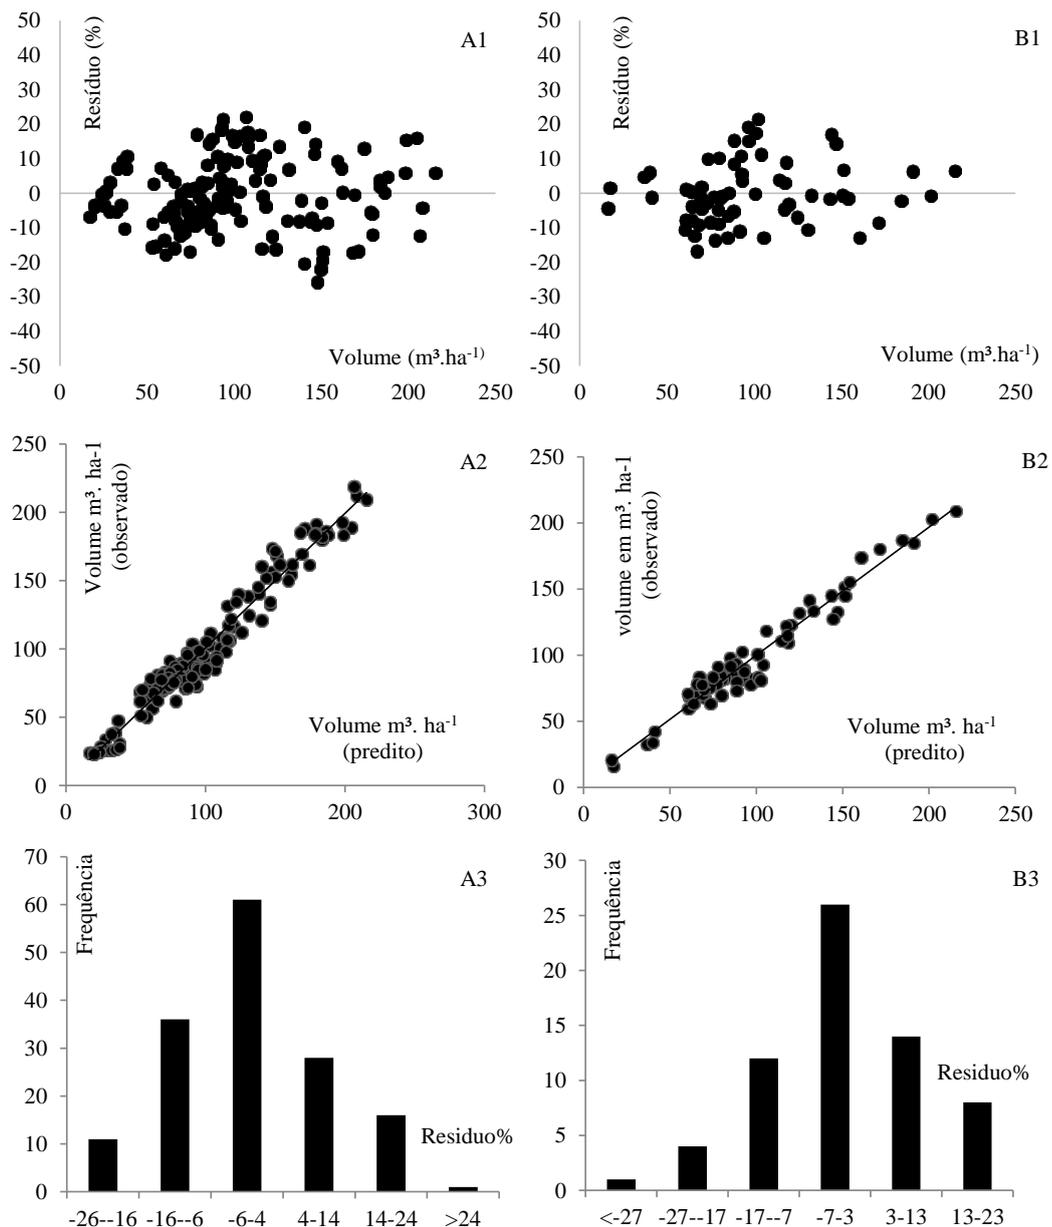


Figura 7: Distribuição de resíduos em treinamento (A1) e validação (B1), valores observados e preditos em correlação $r = 0,97$ e probabilidade $\alpha = 0,05$ $p = 0,99$, e validação (B2) correlação $r = 0,94$ e distribuição de classes de erro em treinamento (A3) e validação (B3) da estimativa do volume das árvores com $dap \geq 30$ cm, no município de Feliz Natal - MT, na Amazônia.

As estatísticas de ajuste e precisão das redes para os indivíduos comerciais, também apresentaram estatísticas de ajuste e precisão satisfatórias, com valores de coeficiente de correlação superiores a 0,95 e erros de estimativa abaixo de 15%. Todavia, de acordo com a Tabela 10, a rede neural 1 foi a RNA que demonstrou melhor capacidade preditiva, segundo valores de RMSE% e correlação.

Tabela 8: Características e estatísticas de precisão das redes neurais artificiais selecionadas para predição do volume das árvores comerciais, no município de Feliz Natal - MT, na Amazônia.

RNA	Arquitetura	Nº de ciclos	Função de ativação		Ajuste		Validação	
			Camada oculta	Camada de saída	RMSE (%)	r	RMSE (%)	r
1	6-10-1	760	Tangencial	Exponencial	9,23	0,98	11,18	0,95
2	6-09-1	1930	Logística	Logística	10,75	0,96	12,98	0,93
3	6-10-1	890	Logística	Tangencial	9,95	0,97	11,72	0,95
4	6-11-1	960	Logística	Tangencial	10,15	0,97	12,05	0,94
5	6-09-1	570	Exponencial	Identidade	10,43	0,96	12,32	0,93

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

Os gráficos da distribuição de resíduos (Figura 8. A1 para o treinamento e B1 para validação), acurácia nas predições de volume em m³ (Figura 8. A2 para o treinamento e B2 para a validação) apresentam características semelhantes aos gráficos da figura 7. O histograma referente a classes de erros, também apresentou uma concentração maior de resíduos nas classes centrais do gráfico, que evidencia a baixa de grandes níveis de sub ou superestimativa, (Figura 8. A3 para o treinamento e B3 para validação).

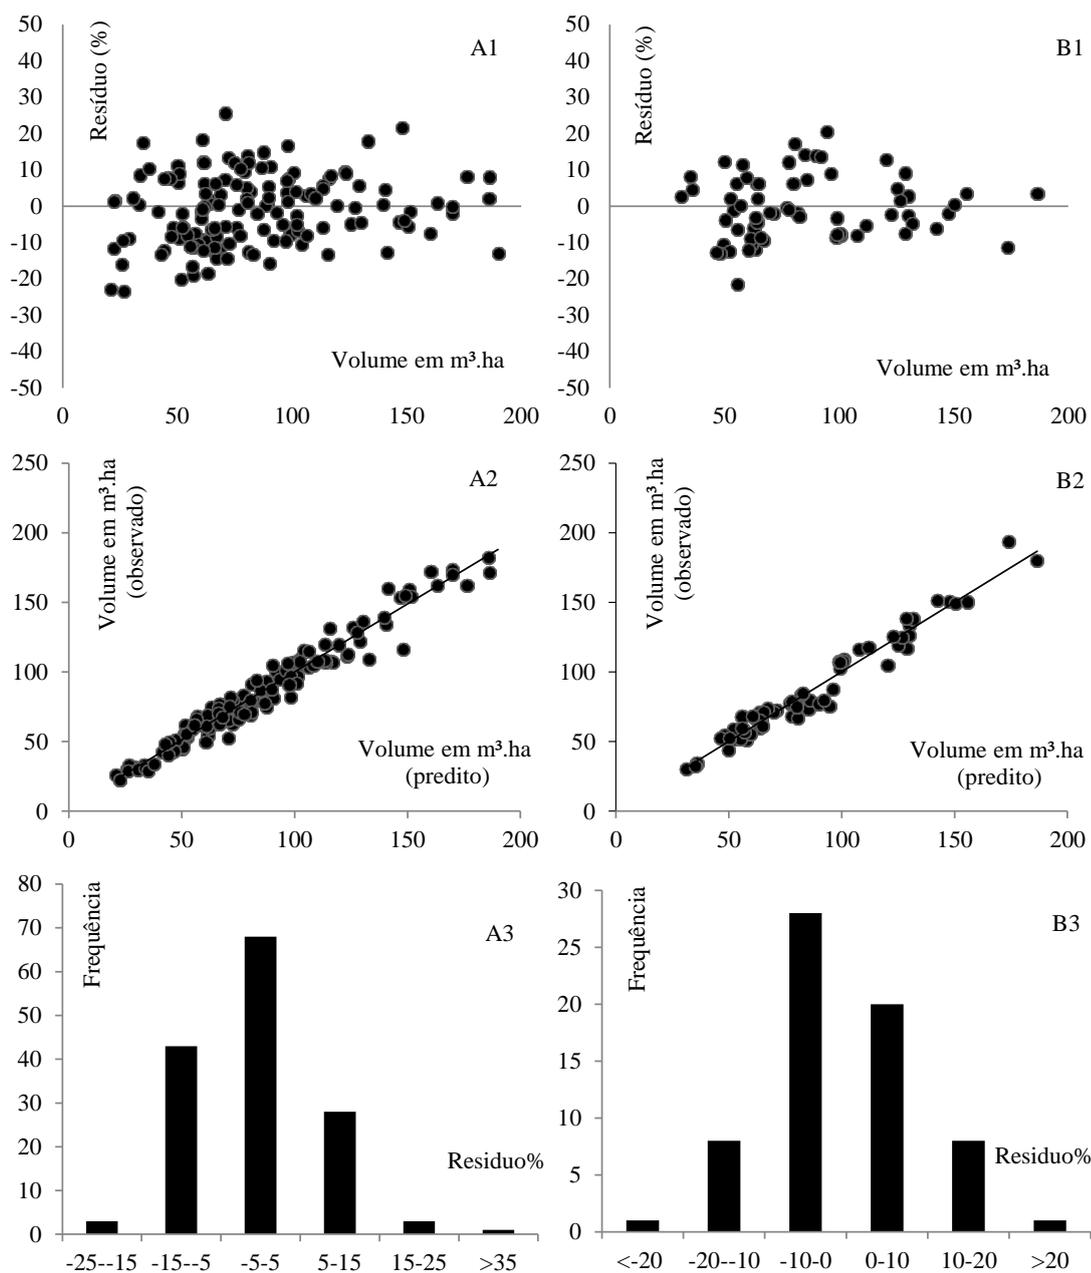


Figura 8: Distribuição de resíduos em treinamento (A1) e validação (B1), valores observados e preditos em treinamento (A2), correlação $r = 0,98$ e probabilidade $\alpha = 0,05$ $p = 0,97$, e validação (B2) correlação $r = 0,95$ e distribuição de classes de erro em treinamento (A3) e validação (B3) da estimativa do volume das árvores com $DAP \geq 50$ no município de Feliz Natal - MT, na Amazônia.

A arquitetura da rede foi composta por três camadas, sendo elas: entrada, determinada pelas variáveis predictoras (IVs e $N. ha^{-1}$), camada oculta, a qual é responsável pelo processamento dos dados e camada de saída, vinculada com a variável de interesse (volume). A arquitetura final da RNA selecionada foi 6-10-1, seis neurônios preditores na camada de entrada, 10 neurônios na camada oculta, ativada por uma função tangencial, enquanto que a

camada de saída com um único neurônio (volume em $\text{m}^3.\text{ha}^{-1}$) ativada por uma função exponencial conforme esquema da Figura 9.

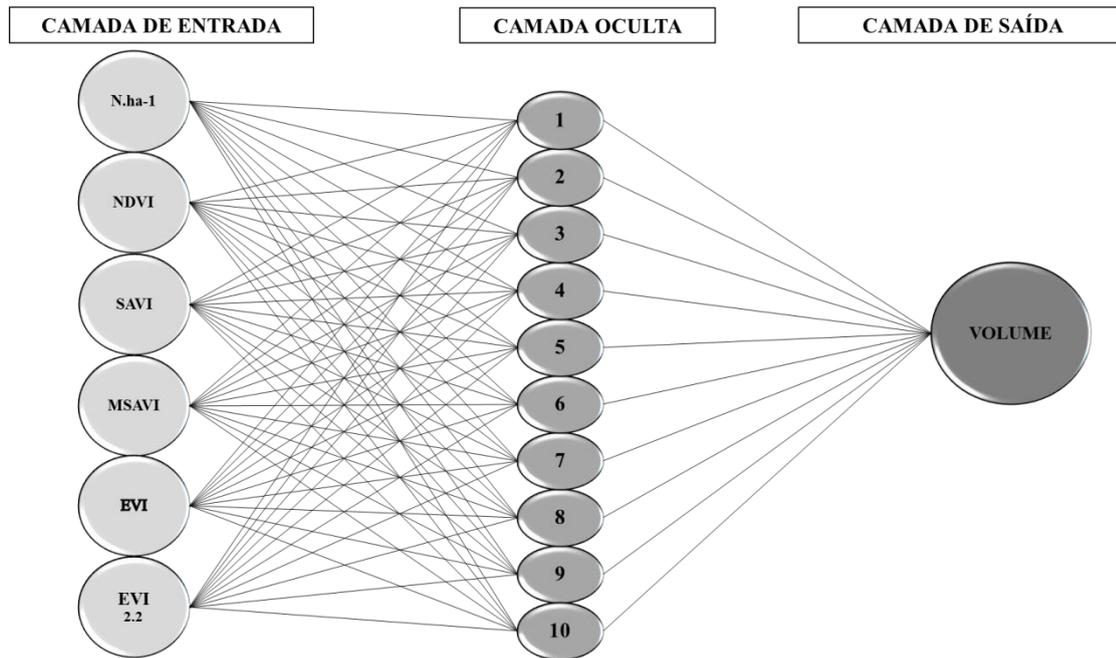


Figura 9: Arquitetura da RNA selecionada para predição do volume da floresta na configuração (6-10-1) no município de Feliz Natal - MT, na Amazônia

Para os indivíduos de interesse comercial ($\text{DAP} \geq 50$) a rede também apresenta em sua configuração seis neurônios preditores na camada de entrada 10 neurônios na camada oculta, ativada por uma função tangencial, enquanto a camada de saída é ativada por uma função exponencial (Figura 10).

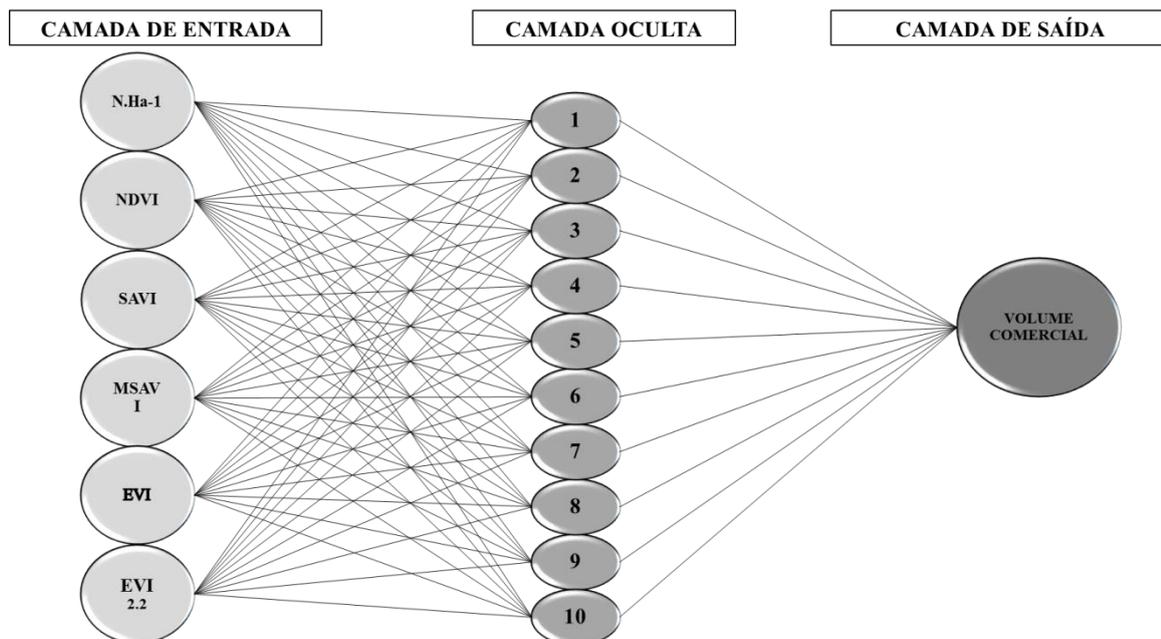


Figura 10: Arquitetura da RNA selecionada para predição do volume das espécies de valor comercial na configuração (6-10-1) no município de Feliz Natal - MT, na Amazônia.

5.3 Análise estatística

O resultado do teste *t* de *Student* mostrou que as RNAs selecionadas apresentaram valor de *p* maior que $\alpha = 0,05$ ($p = 0,99$), para floresta e ($p = 0,97$) para árvores comerciais, logo não existem diferenças estatísticas significativas entre os valores preditos pelas redes neurais com os valores observados nas faixas de validação. Já a diferença agregada demonstrou leve viés de subestimação da RNA para floresta (DA% = -0,19%), e leve viés de superestimação da RNA para as árvores comerciais (DA% = 0,71%), corroborando os resultados de precisão encontrados para o treinamento das RNAs.

6. DISCUSSÃO

6.1 Análise geral dos dados

Foi feita uma análise geral das variáveis oriundas do inventário florestal valores de média, mínimo e máximos de volume, área basal, DAP, altura e contagem de indivíduos.

Com base nesta análise, observou-se pela comparação de CV 73% para a floresta e CV 70,44% para as espécies comerciais, uma variabilidade esperada dentro dos valores normais de uma área de floresta tropical, onde existe uma relação inversamente proporcional da variabilidade dos valores do coeficiente de variação em função do tamanho das unidades amostrais (faixas), também descrito por (QUEIROZ et al., 2011).

As variações individuais de volume da floresta, $71\text{m}^3 \cdot \text{ha}^{-1}$ e árvores comerciais, $56 \text{m}^3 \cdot \text{ha}^{-1}$, estão dentro da média observada por (ROLIM et al. 2006; COLPINI et al. 2009; THAINES et al. 2010). Entre os valores encontrados para a floresta existem estudos que corroboram envolvendo inventários florestais com indivíduos de diferentes diâmetros na Amazônia brasileira (SILVA et al., 1985, COSTA et al., 1999, MACIEL et al., 2009; BARRETO et al. 2014; CYSNEIROS, 2016), onde o volume apresentou valores entre 69 e $153 \text{m}^3 \cdot \text{ha}^{-1}$, para indivíduos com DAP > 20 cm.

O volume comercial, seguindo o comportamento de estudos em florestas tropicais comparando equações de regressão e fatores de forma evidenciou resultados levemente inferiores, porem dentro das estimativas encontradas por (COLPINI et al., 2009; THAINES et

al., 2010; CONDÉ; TONINI, 2013; TONINI; BORGES, 2015; BIAZATTI, 2020). As diferenças podem estar relacionadas ao emprego de diferentes alturas e diâmetros no cálculo do volume, nas irregularidades no fuste que variam com a espécie, e/ou pelo diâmetro mínimo de amostragem, mas principalmente pela dificuldade da obtenção da altura total no inventário, sendo substituída pela altura comercial. Embora as medições de altura total sejam frequentemente demoradas e às vezes difíceis de alcançar em altas florestas tropicais, modelos incluindo diâmetro e altura total, apresentam melhores resultados nas estimativas do volume (CHAVE et al. 2005; SULLIVAN et al. 2018).

A maioria das árvores comerciais são destinadas a serraria em toras, espécies como amescla e farinha seca são as mais utilizadas para laminação, fato esse também observado por Angelo, H. et al. (2004) em uma análise econômica da indústria de madeiras tropicais no pólo de Sinop.

Das variáveis preditoras oriundas do volume da madeira, contagem do número de árvores por hectare foi a escolhida como variável na camada de entrada juntamente com os índices de vegetação para o treinamento das redes, pois além da maior correlação com o volume apresenta algumas vantagens no campo, como por exemplo, a facilidade e a praticidade de obtê-la, economizando tempo, e por consequência recursos financeiros, outra vantagem se dá pela melhor capacidade de obter essa informação utilizando a telemetria a laser LIDAR (SILVA et al., 2018).

O mapa de distribuição de Kernel (Figura 6) para os dados de volume oriundos do inventário florestal apresentou alta densidade de indivíduos, dessa forma chegando a áreas com o volume máximo $\leq 200 \text{ m}^3 \cdot \text{ha}^{-1}$ e divididos em oito classes com intervalos de $25 \text{ m}^3 \cdot \text{ha}^{-1}$, a presença de áreas (manchas vermelhas) com maior concentração de volume identifica zonas preferenciais para a condução do manejo florestal. O volume de madeira de uma floresta natural varia em função da capacidade produtiva do solo e da distribuição das espécies. Por tais razões, é impossível esperar que uma divisão da área de uma floresta natural em partes iguais terá o volume também correspondido em partes iguais, apropriada para a exploração de acordo com o ciclo corte considerado na lei brasileira. (HOSOKAWA et al., 1998; BRAZ et al., 2012, OLIVEIRA et al., 2021; RODRIGUES et al., 2021). Por isso, no planejamento das unidades de produção anual (UPAs) (do ponto de vista do planejamento de rede de estradas, pátios e trilhas de arraste), deve-se relacionar as produções volumétricas ou

densidade de espécies com subcompartimentos de tamanho variado no caso em questão faixas de comprimento variável dentro das unidades de trabalho (UTs).

Dessa forma, os sítios de alta densidade e os de baixa densidade, devem ser inversamente proporcionais em relação ao tamanho da área (faixas e UTs). Nesse contexto, o uso de mapas de densidade de Kernel pode auxiliar na demarcação das UTs, possibilitando o direcionamento da exploração por lotes de espécies de valor comercial bem como a otimização e alocação dos pátios de estocagem e das redes de estradas.

6.2 Modelagem

6.2.1. Seleção das variáveis independentes

A correlação encontrada entre os índices de vegetação e o volume no presente estudo foi de moderada a fraca, no entanto, significativa, adotando desempenho semelhante em várias pesquisas que envolvem índices de vegetação agregados a diferentes variáveis inerentes a comunidade florestal como, aspectos biofísicos, volume de madeira, biomassa e circunferência do tronco (PANDA et al., 2010; MIGUEL et al., 2015; ZHU; LIU, 2015; MACHADO et al., 2017; MIRELES et al., 2017; PHUA et al., 2017, PEREZ, 2018). Os prováveis motivos para esse comportamento da correlação entre IVs e as variáveis dendrométricas devem-se principalmente a sensibilidade que os sensores remotos sofrem do próprio ambiente, como os efeitos do solo, efeitos da atmosfera e fontes de radiação, bem como os efeitos intrínsecos a própria vegetação, tais como, desuniformidades das copas e dossel, arquitetura e conformação irregulares (PONZONI, 2001; MIGUEL et al., 2015; MACHADO et al., 2017; CARRIJO et al., 2020).

Essa baixa qualidade da correlação pode ser evidenciada pelo relevo a altitude e o declive, que em alguns estudos utilizando dados da Missão Topográfica Radar Shuttle (SRTM), caracterizaram a baixa de correlação dos índices de vegetação com as variáveis de produção da floresta nos locais com maior variação desses atributos edáficos (CANAVESI et al., 2010; TANAKA, et al. 2015; BISPO et al., 2016; CASTILLO et al., 2017). De acordo com esses autores, os resultados evidenciam que os condicionadores topográficos podem influenciar nas relações entre os parâmetros biofísicos e os índices de vegetação.

Quanto aos valores de correlações encontrados entre os IVs e o volume serem significativos e positivos, isso pode ser explicado pela correlação positiva que os IVs têm com o crescimento radial do fuste e área foliar. (BABST et al., 2014a, 2014b; ALMEIDA et al.,

2015; VICENTE-SERRANO et al., 2016). Esses parâmetros têm relação direta com o acúmulo de biomassa, captura de carbono e, conseqüentemente, volume da madeira (VICENTE-SERRANO et al., 2016; GONÇALVES et al., 2019). Portanto, o uso de informações espectrais do sensor MSI do satélite Sentinel-2 tem aumentado significativamente em estudos florestais, por exemplo, nos trabalhos desenvolvidos por (FERNÁNDEZ-MANSO et al., 2016; IMMITZER et al. 2016; LAURIN et al., 2016; KORHONEN et al., 2017; GONÇALVES et al., 2019).

6.2.1. Redes neurais

As RNAs treinadas proporcionaram estatísticas de ajuste e precisão satisfatórias, obtendo valores de coeficiente de correlação a cerca de, $r \geq 0,90$ tanto para floresta como as árvores comerciais e erros de estimativa $RMSE < 15\%$. Dentre as 5 redes para cada categoria de DAP, as redes escolhidas (rede 4 para floresta e rede 1 para as árvores de interesse comercial) apresentaram resultados ainda melhores ($r = 0,97$ para floresta, $r = 0,98$ para as comerciais, $RMSE\% = 11,18\%$ para floresta e $RMSE\% = 13,48\%$ para as comerciais) Tendo em vista a complexidade das variáveis estudadas e a grande variabilidade encontrada em florestas nativas (SYDOW et al., 2017). Os resultados obtidos são consistentes e precisos.

De acordo Draper e Smith, (1998), a análise gráfica dos resíduos é fundamental para corroborar os resultados das estatísticas de precisão, uma vez que erros de tendência podem não ser detectados por essas estatísticas. O comportamento dos gráficos de dispersão do resíduo na (figura 6. A1 treinamento e B1 validação) e na (figura 7. A1 treinamento e B1 validação), para floresta e para as árvores com DAP comercial, respectivamente, apresentou distribuição adequada dos erros, sem tendências visíveis, com pontos compactos e bem distribuídos ao longo da linha de regressão, e erros máximos limitados à $\pm 30\%$, sendo assim muito satisfatório.

Os gráficos, volume observados x preditos demonstra a relação entre os valores, (figuras 6. A2 treinamento e B2 validação) e na (figura 7. A2 treinamento e B2 validação), para floresta e para as árvores com dap comercial, respectivamente. Este resultado indica excelente acurácia da rede neural escolhida para estimar o volume de árvores comerciais (DMC) e também da floresta (DMM).

Além disso, a frequência de erros se concentrou em sua maioria entre -16% e 14% para o treinamento dos dados da floresta e -17% e 13% para a validação (Figura 6. A1 e B1 respectivamente). Para as árvores com diâmetro comercial entre -15% e 15% para o

treinamento e -10% e 10% para a validação (Figura 7. A1 e B1, respectivamente), sendo que não foram observados erros superiores $\pm 20\%$. A importância da análise dos resíduos em histogramas auxilia e minimiza os erros de interpretação devido à ocorrência de pontos sobrepostos.

Os resultados alcançados neste trabalho, corroboram com as pesquisas de diversos autores (INGRAM et al., 2005; CUTLER et al., 2012; MIGUEL et al., 2015; SANTI et al., 2015; XIE., et al 2017; PEREZ et al., 2018; LY et al., 2020) evidenciando a eficiência da junção de informações do sensoriamento remoto com ferramentas de inteligência artificial na caracterização e estimativas de variáveis de produção em florestas tropicais no Brasil, nos biomas Amazônico, Mata Atlântica, Cerrado, em florestas tropicais no Madagascar, Tailândia e Malásia, e em Florestas do Mediterrâneo na Itália e florestas subtropicais na China. Em todos estes trabalhos, foram encontrados valores de correlação (r) superiores a 0,62 e RMSE inferiores a 20%.

6.3 Análise estatística

Quanto as RNA's selecionadas para a estimativa do volume para floresta e árvores comerciais ambas foram submetidas ao teste de validação, as mesmas retornaram estimativas não significativas de acordo com o resultado do teste t de Student $< (p 0,05)$, logo aceitou-se a hipótese nula de igualdade entre os valores observados e preditos pela rede, por consequência, assume-se que suas estimativas são precisas, conforme mencionado por Serpen e Gao, (2014), os quais afirmam que as RNAs tem grande capacidade de aprender e extrair padrões de um conjunto de dados, generalizá-los e aplicá-los sem perder a precisão.

A eficácia e precisão das RNA's selecionadas também foi confirmada pela diferença agregada (DA%), a qual apresentou um valor percentual pequeno (-0,19%) de subestimação para a RNA selecionada na estimativa do volume para as árvores da floresta e superestimação (0,71%) para a RNA selecionada na estimativa do volume para árvores comerciais, o que não compromete a qualidade da predição já que mostra que os valores estimados estão próximos aos valores reais.

As redes foram treinadas e validadas para uma única área de manejo florestal (AMF) no bioma amazônico, logo devido à variabilidade de espécies, estrutura, arquitetura de copa, formato de dossel e as próprias características das diferentes espécies florestais, novas pesquisas envolvendo essas relações com os índices de vegetação, diferentes inventários

florestais, configurações e arquiteturas de redes devem ser realizados, para garantir maior solidez nas estimativas de volume em áreas de PMFS.

7. CONCLUSÃO

Os modelos derivados das redes neurais artificiais associados a dados de sensoriamento remoto foram eficazes e precisos para estimativas de volume de madeiras em floresta tropical, de acordo com classes diamétricas (DCM) de árvores de interesse comercial. Juntos, os índices de vegetação e a contagem do número de árvores, proporcionaram estimativas mais precisas e consistentes para o modelo de estimativa do volume disponível na floresta.

Independentemente das problemáticas que atribui a dinâmica de uma floresta tropical de grande porte, imagens obtidas pelo sensor MSI a bordo do satélite Sentinel-2, são eficazes estatisticamente nas estimativas do volume nos planos de manejo em florestas na Amazônia brasileira.

Redes neurais artificiais do tipo *Multilayer Perceptron*, utilizando funções de ativação logística e exponencial para a floresta, tangencial e exponencial para as árvores com diâmetro comercial e o algoritmo de treino BFGS, foram eficientes (alta acurácia) na estimativa do volume comercial.

Por fim, os resultados alcançados nessa pesquisa são muito promissores, podendo impactar de forma positiva, como uma ferramenta de gestão, no direcionamento estratégico para áreas de planos de manejo florestal sustentável, alcançando áreas de grande porte e até mesmo de difícil acesso, com alta precisão. Estudos futuros devem confirmar nossas descobertas para diferentes tipos e condições de florestas.

REFERÊNCIAS BIBLIOGRÁFICAS

ADEKUNLE, V. A. J.; NAIR, K. N.; SRIVASTAVA, A. K.; SINGH, N. K. Models and form factors for stand volume estimation in natural forest ecosystems: a case study of Katarniaghat Wildlife Sanctuary (KGWS), Bahraich District, India. **Journal of Forestry Research**, v. 24, n. 2, p. 217-226, 2013.

AKKOÇ, S. An empirical comparison of conventional techniques, neural networks and the three stage hybrid Adaptive Neuro Fuzzy Inference System (ANFIS) model for credit scoring analysis: The case of Turkish credit card data. **European Journal of Operational Research**, v. 222, p. 168–178, 2012.

AKINDELE, S. O.; LEMAY, V. M. Development of tree volume equations for common timber species in the tropical rain forest area of Nigeria. **Forest Ecology and Management**, v. 226, p. 41-48, 2006.

ALMEIDA, TS de; FONTANA, DENISE C. Desempenho dos índices de vegetação NDVI e PVI para a cultura da soja em diferentes condições hídricas e de sistema de manejo do solo. **Simpósio Brasileiro de Sensoriamento Remoto, XIV, Natal. Anais.... São José dos Campos-SP: INPE**, p. 17-22, 2009.

ALMEIDA, A. Q. DE; RIBEIRO, A.; DELGADO, R. C.; RODY, Y. P.; OLIVEIRA, A. S. DE; LEITE, F. P. 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.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. DE M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2014.

ANGELO, H., MORAES, V. S. S. Análise econômica da indústria de madeiras tropicais: o caso do polo de Sinop, MT. **Ciência Florestal**, 14(2), 91-10, (2004).

ARAÚJO, T. M., CARVALHO JR, J. A., HIGUCHI, N., BRASIL JR, A. C. P., & MESQUITA, A. L. A. A tropical rainforest clearing experiment by biomass burning in the state of Pará, Brazil. **Atmospheric Environment**, 33(13), 1991-1999, 1999.

BABST, F.; BOURIAUD, O.; PAPALE, D.; GIELEN, B.; JANSSENS, I. A.; NIKINMAA, E.; IBROM, A.; WU, J.; BERNHOFER, C.; KÖSTNER, B.; GRÜNWARD, T.; SEUFERT, G.; CIAIS, P.; FRANK, D. Above-ground woody carbon sequestration measured from tree rings is coherent with net ecosystem productivity at five eddy-covariance sites. **New Phytologist**, v. 201, p. 1289–1303, 2014a.

BABST, F.; BOURIAUD, O.; ALEXANDER, R.; TROUET, V.; FRANK, D. Toward consistent measurements of carbon accumulation: A multi-site assessment of biomass and basal area increment across Europe. **Dendrochronologia**, v. 32, n. 2, p. 153–161, 2014b.

BANNARI, A., MORIN, D., BONN, F., & HUETE, A. R.. **A review of vegetation indices. Remote sensing reviews**, 13(1-2), 95-120. 1995.

BARRETO, W. F.; LEÃO, F. M.; MENEZES, M. C.; SOUZA, D. V. Equação de volume para apoio ao manejo comunitário de empreendimento florestal em Anapu, Pará. **Pesquisa Florestal Brasileira**, v. 34, n. 80, p. 321 – 329. 2014.

BARROS, B. S. X., GUERRA, S. P. S., DE BARROS, Z. X., CATITA, C. M. S., & FERNANDES, J. C. C. C. Uso de imagens de satélite para cálculo de volume em floresta de eucalipto no Município de Botucatu/SP. **Energia na Agricultura**, 30(1), 60-67, 2015..

BASTIAANSSEN, WILHELMUS GERARDUS MARIA. **Regionalização de densidades de fluxo de superfície e indicadores de umidade em terrenos compostos: Uma abordagem de sensoriamento remoto sob céu claro em climas mediterrâneos**. SC-DLO, 1995.

BELCIUG, Smaranda; GORUNESCU, Florin. Improving performance in neural networks using feature selection based on random forests: application to automated medical diagnosis. **Int J Inf Technol Knowl**, v. 10, n. 1, p. 33-46, 2016.

BINOTI, M. L. M. D. S., BINOTI, D. H. B., LEITE, H. G., GARCIA, S. L. R., FERREIRA, M. Z., RODE, R., & SILVA, A. A. L. D. Redes neurais artificiais para estimação do volume de árvores. **REVISTA ÁRVORE**, 38(2), 283-288, 2014.

BINOTI, M. L. M. DA S.; LEITE, H. G.; BINOTI, D. H. B.; GLERIANI, J. M. Prognose em nível de povoamento de clones de Eucalipto empregando redes neurais artificiais. **Cerne**, v. 21, n. 1, p. 97–105, 2015.

BISPO PC. Dados geomorfométricos como subsídio ao mapeamento da vegetação. dissertação. São José dos Campos: **Instituto Nacional de Pesquisas Espaciais**; 2007

BISPO PC. Efeitos de geomorfometria na caracterização florístico-estrutural da floresta tropical na região de tapajós com dados SRTM e PALSAR tese. São José dos Campos: **Instituto Nacional de Pesquisas Espaciais**; 2012.

BIAZATTI, Scheila Cristina et al. Criterion Dendrometer as a non-destructive method for dendrometric estimations of native species in Western Amazon. **Revista Ibero-Americana de Ciências Ambientais**, v. 11, n. 6, p. 59-70, 2020.

BRASIL. LEI Nº 4.771, LEI Nº 12.651, DE 25 DE MAIO DE 2012.. **Código Florestal Brasileiro** disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/112651.htm>. Acesso em: 06/12/2021.

BRASIL. LEI Nº 11.284, DE 2 DE MARÇO DE 2006. **Dispõe sobre a gestão de florestas públicas para a produção sustentável** disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2006/lei/111284.htm>. Acesso em: 06/12/2021.

Brasil, CONAMA (Conselho Nacional do Meio Ambiente), 2009. **Resolução no 406, de 02 de fevereiro de 2009**. Diário Oficial da União no 26, 2 February 2009. Brasília, DF, Brazil. <http://www.tjpa.jus.br/CMSPortal/VisualizarArquivo?idArquivo=8372> >Acesso em: 06/12/2021.

BRUNDTLAND, GH, & Comum, NF Brundtland Reporter. **Nosso futuro comum: Nações Unidas**, (1987).

CANAVESI V, PONZONI FJ, VALERIANO MM. Estimativa de volume de madeira em plantios de Eucalyptus spp. utilizando dados hiperespectrais e dados topográficos. **Revista Árvore** ; 34(3): 539-549 , 2010.

CARRIJO, J. V. N., MIGUEL, E. P., TEIXEIRA DO VALE, A., MATRICARDI, E. A. T., MONTEIRO, T. C., REZENDE, A. V., INKOTTE, J. Artificial intelligence associated with satellite data in predicting energy potential in the Brazilian savanna woodland area. **iForest-Biogeosciences and Forestry**, 13(1), 48, 2020.

CASTILLO JAA, APAN AA, MARASENI TN, SALMO SG 3rd. Estimation and mapping of above-ground biomass of mangrove forests and their replacement land uses in the Philippines using Sentinel imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, 2017

CASTRO, RENATO VINÍCIUS OLIVEIRA, SOARES, CARLOS PEDRO BOECHAT, MARTINS, FABRINA BOLZAN, LEITE, HELIO GARCIA. Crescimento e produção de plantios comerciais de eucalipto estimados por duas categorias de modelos. **Pesquisa Agropecuária Brasileira**, 48(3), 287-295, 2013.

CIPEM. **CENTRO DAS INDÚSTRIAS PRODUTORAS E EXPORTADORAS DE MADEIRA DE MATO GROSSO**. Disponível em: <https://www.cipem.org.br/planos-de-manejo-florestal-sustentavel-representam-93-da-area-explorada-legalmente-em-mato-grosso/> acesso: 20/10/2019.

CHAGAS, A. L. G. A. et. al. **Roteiro metodológico para a elaboração de planos de manejo para florestas nacionais**. Brasília: IBAMA, 2003

CHÁIDEZ, J. N. Allometric equations and expansion factors for tropical dry forest trees of Eastern Sinaloa, Mexico. **Tropical and Subtropical Agroecosystems**, v. 10, p. 45-52, 2009.

CHAVE, J., C. ANDALO, S. BROWN, M.A. Cairns, J.Q. Chambers, D. Eamus, H. Fölster, et al.. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia** 145(1):87–99, 2005.

CHEN, DANQI; MANNING, Christopher D. A fast and accurate dependency parser using neural networks. In: **Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)**. 2014. p. 740-750, 2014.

CHULES, ERIC LUIS; SCARDUA, FERNANDO PAIVA; DE CRISTO MARTINS, ROSANA DE CARVALHO. Desafios da implementação da política de concessões florestais federais no Brasil. **Revista de Direito Econômico e Socioambiental**, v. 9, n. 1, p. 295-318, 2018.

CLEMENT, CHARLES R.; HIGUCHI, NIRO. A floresta amazônica e o futuro do Brasil. **Ciência e Cultura**, v. 58, n. 3, p. 44-49, 2006.

- COLPINI, C.; TRAVAGIN, D. P.; SOARES, T. S.; SILVA, V. S. M. Determinação do volume, do fator de forma e da porcentagem de casca de árvores individuais em uma Floresta Ombrófila Aberta na região noroeste de Mato Grosso. **Acta Amazonica**, v. 39, n. 1, p. 97-104, 2009.
- CONDE, T. M.; TONINI, H. Fitossociologia de uma Floresta Ombrófila Densa na Amazônia Setentrional, Roraima, Brasil. **Acta Amazonica**, Manaus, v. 43, n. 3, p. 247-260, 2013.
- CONDIT, R.; ASHTON, P.; BAKER, P.; BUNYAVEJCHEWIN, S.; GUNATILLEKE, S.; GUNATILLEKE, N.; HUBBELL, S. P.; FOSTER, R. B.; ITOH, A.; LAFRANKIE, J.V.; LEE, H. S.; LOSOS, E.; MANOKARAN, N.; SUKUMAR, R.; YAMAKURA, T. Spatial patterns in the distribution of tropical tree species. **Science**, v. 288, p. 1414-1418, 2000.
- COLE, T. G.; EWEL, J. J. Allometric equations for four valuable tropical tree species. **Forest Ecology and Management**, v. 229, p. 351-360, 2006.
- CORONA, PIERMARIA et al. Contribuição de inventários florestais em grande escala para avaliação e monitoramento da biodiversidade. **Ecologia e manejo florestal**, v. 262, n. 11, pág. 2061-2069, 2011.
- COSTA, D. H. M., FERREIRA, C. A. P., SILVA, J. N. M., LOPES, J. D. C. A., & DE CARVALHO, J. O. P. Potencial madeireiro de floresta densa no município de Moju, Estado do Pará. In **Embrapa Amazônia Oriental-Artigo em anais de congresso (ALICE)**. In: SIMPÓSIO SILVICULTURA NA AMAZÔNIA ORIENTAL, 1999.
- COUTO, H.T.Z.; Estimativa de volume com diferentes padrões de utilização. In: Seminário sobre atualidade e perspectivas florestais, 5., Curitiba. **Anais...** Curitiba: EMBRAPA/URPFCS. p.57-63, 1982.
- CUNHA, U. S. da. Dendrometria e inventário florestal. Manaus, 2004, 61p. **Apostila** - Escola Agrotécnica Federal de Manaus.
- CUNHA, T. A.; FINGER, C. A. G.; HASENAUER, H. Tree basal area increment models for Cedrela, Amburana, Copaifera and Swietenia growing in the Amazon rain forests. **Forest Ecology and Management**, v. 365, p. 174-183, 2016.
- 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.
- CYSNEIROS, Vinicius Costa. **Estratégias para modelagem do volume comercial em florestas tropicais**. 2016.
- D'OLIVEIRA, M. V. N., FIGUEIREDO, E. O., PAPA, D. D. A. Uso do LIDAR como Ferramenta para o Manejo de Precisão em Florestas Tropicais. **Embrapa Acre-Livro técnico (INFOTECA-E)**, 2014.
- DA SILVA, F. J. L. T., ROCHA, D. F., DE AQUINO, C. M. S.. Geografia, geotecnologias e as novas tendências da geoinformação: indicação de estudos realizados na região Nordeste. Inter Espaço: **Revista de Geografia e Interdisciplinaridade**, 2(6), 176-197, 2017.

DA SILVA, S. T., DE MELLO, J. M., JUNIOR, F. W. A., DOS REIS, A. A., RAIMUNDO, M. R., SILVA, I. L. G., SCOLFORO, J. R. S. Uso de imagens de sensoriamento remoto para estratificação do cerrado em inventários florestais. **Pesquisa Florestal Brasileira**, 34(80), 337-343, 2014.

DE BARROS MONTEIRO, Marcella Gomes. **A contribuição da detecção remota para avaliar o sequestro de carbono em ecossistemas florestais: uma revisão**. 2020.

DIAS, T. L.; CATALDI, M.; FERREIRA, V. H. Aplicação de técnicas de redes neurais e modelagem atmosférica para elaboração de previsões de vazão na Bacia do Rio Grande (MG). **Engenharia Sanitária e Ambiental**, v. 22, n. 1, p. 169–178, 2017.

DRAPER, N. R.; SMITH, H. **Applied regression analysis**. 3. ed. New York: John Willey & Sons, 1998. 716 p.

DRUSCH, MATTHIAS et al. Sentinel-2: missão óptica de alta resolução da ESA para os serviços operacionais do GMES. **Sensoriamento remoto do meio ambiente**, v. 120, p. 25-36, 2012.

ESFE, M. H.; AHANGAR, M. R. H.; REJVANI, M.; TOGHRAIE, D.; HAJMOHAMMAD, M. H. Designing an artificial neural network to predict dynamic viscosity of aqueous nano fluid of TiO₂ using experimental data. **International Communications in Heat and Mass Transfer**, v. 75, p. 192–196, 2016.

EUROPEAN SPACE AGENCY Sentinel-2 User Handbook Document. Technical Report issue 1 revision 2. : **European Space Agency**, 2015.

EUROPEAN SPACE AGENCY (Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services (**ESA SP-1322/2 March 2012**), 2012.

EMBRAPA, E. B. DE P. A. Sistema brasileiro de classificação de solos. 5a ed. Brasília: **Embrapa**, 356 p, 2018..

FERNÁNDEZ-MANSO, ALFONSO; FERNÁNDEZ-MANSO, OSCAR; QUINTANO, CARMEN. SENTINEL-2A red-edge spectral indices suitability for discriminating burn severity. **International journal of applied earth observation and geoinformation**, v. 50, p. 170-175, 2016.

FERRAZ, A. S.; SOARES, V. P.; SOARES, C. P. B.; RIBEIRO, C. A. A. S.; BINOTI, D. H. B.; LEITE, H. G. Estimativa do estoque de biomassa em um fragmento florestal usando imagens orbitais. **Floresta e Ambiente**, v. 21, n. 3, p. 286–296, 2014.

FINGER, C.A.G. Fundamentos de biometria florestal. Santa Maria: UFSM / CEPEF – **FATEC**. 269p, 1992.

FREITAS, W. K. D., MAGALHÃES, L. M. S. Métodos e parâmetros para estudo da vegetação com ênfase no estrato arbóreo. **Floresta e Ambiente**, 19(4), 520-539, 2012.

GARRIDO FILHA, IRENE. Manejo florestal: questões econômicas-financeiras e ambientais. **Estud. av.**, São Paulo, v. 16, n. 45, pág. 91-106, 2002.

GITTOEE, A.; FARIDI, A.; FRANCE, J. Mathematical models for response to amino acids: estimating the response of broiler chickens to branched-chain amino acids using support vector regression and neural network models. **Neural Computing and Applications**, v. 30, n. 8, p. 2499–2508, 2018.

GONÇALVES, ANNY FRANCIELLY ATAIDE et al. Wood Volume Estimation in a Semideciduous Seasonal Forest Using MSI and SRTM Data. **Floresta e Ambiente**, v. 26, n. SPE1, 2019.

GORGENS, E. B., LEITE, H. G., SANTOS, H. D. N., GLERIANI, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, 33(6), 1141-1147, 2009.

GORUNESCU, F.; BELCIUG, S. Boosting backpropagation algorithm by stimulus-sampling: Application in computer-aided medical diagnosis. **Journal of Biomedical Informatics**, v. 63, p. 74–81, 2016.

GUERROUT, E. H.; AIT-AOUDIA, S.; MICHELUCCI, D.; MAHIOU, R. Hidden Markov random field model and Broyden–Fletcher–Goldfarb–Shanno algorithm for brain image segmentation. **Journal of Experimental and Theoretical Artificial Intelligence**, v. 30, n. 3, p. 415–427, 2018.

HAGOLLE, Olivier et al. SPOT-4 (Take 5): simulação da série temporal Sentinel-2 em 45 grandes sites. **Sensoriamento remoto**, v. 7, n. 9, pág. 12242-12264, 2015.

HASSOUN, Mohamad H. et al. **Fundamentals of artificial neural networks**. MIT press, 1995.

HAYKIN, SIMON. **Redes Neurais: Princípios e prática**. 2a ed. Hamilton: Bookman. 900 p, 2001.

HAYKIN, SIMON. **Uma introdução à comunicação analógica e digital**. John Wiley, 1994.

HEATON J. Programming neural networks with Encog 3 in Java. 2nd ed. St. Louis: Heaton Research; 2011.

HELIO TONINI, CPAMT; RENATO ALVES BORGES. Equação de volume para espécies comerciais em Floresta Ombrófila Densa no sul de Roraima SEAPA-RR **Pesquisa Florestal Brasileira**, Colombo, v. 35, n. 82, p. 31-37, abr./jun. 2015.

HEIDARI, E.; SOBATI, M. A.; MOVAHEDIRAD, S. Accurate prediction of nanofluid viscosity using a multilayer perceptron artificial neural network (MLP-ANN). **Chemometrics and Intelligent Laboratory Systems**, v. 155, p. 73-85, 2016.

HEINSDIJK, D.; BASTOS, A. M. **Inventários florestais na Amazônia**. Boletim do Serviço Florestal, v. 6, 100 p,1963.

HENTZ, Ângela Maria et al. Técnicas de sensoriamento remoto para estimativa de biomassa em ambientes florestais. **Enciclopédia biosfera**, v. 10, n. 18, 2014.

HUETE, A. R. et al. A Comparison of Vegetation Indices over a Global Set of TM Images for EOS-MODIS. *Remote Sens. Environ*, n.59, p.440-451, 1997.

HUETE, A. R. A soil-adjust vegetation index (Savi). **Remote Sensing of Environment**, v. 25, p. 295–309, 1988

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Amazônia legal**. 2020. Disponível em:
<https://www.ibge.gov.br/geociencias/informacoes-ambientais/geologia/15819-amazonia-legal.html?=&t=o-que-e> Acesso em: 21/07/2020.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Brasil em síntese**. 2020. Disponível em:
<https://brasilemsintese.ibge.gov.br/territorio.html>. Acesso em: 21/11/2020.

ICMBIO. INSTITUTO CHICO MENDES DE CONSERVAÇÃO E BIODIVERSIDADE. **Floresta nacional Araripe Apodi celebra 70 anos**. 2016. Disponível em:
<https://www.icmbio.gov.br/portal/ultimas-noticias/20-geral/7878-floresta-nacional-do-araripe-celebra-70-anos> acesso em 21/07/2020.

IMAZON – INSTITUTO DO HOMEM E MEIO AMABIENTE DA AMAZÔNIA. **custos-e-beneficios-do-manejo-florestal-para-a-producao-de-madeira-na-amazonia-oriental-n-10**. 2013. Disponível em: <https://imazon.org.br/custos-e-beneficios-do-manejo-florestal-para-a-producao-de-madeira-na-amazonia-oriental-n-10/> acesso em: 20/07/2020

IMAZON – INSTITUTO DO HOMEM E MEIO AMABIENTE DA AMAZÔNIA. **Satélites da floresta**. 2016. Disponível em:
<https://imazon.org.br/videos/os-satelites-da-floresta/> acesso em: 21/07/2020

IMMITZER, MARKUS; VUOLO, FRANCESCO; ATZBERGER, CLEMENT. First experience with Sentinel-2 data for crop and tree species classifications in central Europe. **Remote Sensing**, v. 8, n. 3, p. 166, 2016.

INGRAM, J. Carter; DAWSON, Terence P.; WHITTAKER, Robert J. 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.

JIANG, ZHANGYAN et al. Development of a two-band enhanced vegetation index without a blue band. **Remote sensing of Environment**, v. 112, n. 10, p. 3833-3845, 2008.

KERSKI, J. J. Geo-awareness, Geo-enablement, Geotechnologies, Citizen Science, and Storytelling: Geography on the World Stage. **Geography Compass**, v. 9, n. 1, p. 14-26, 2015.

KORHONEN, LAURI et al. Comparison of Sentinel-2 and Landsat 8 in the estimation of boreal forest canopy cover and leaf area index. **Remote sensing of environment**, v. 195, p. 259-274, 2017.

LAURIN, GAIA VAGLIO et al. Discrimination of tropical forest types, dominant species, and mapping of functional guilds by hyperspectral and simulated multispectral Sentinel-2 data. **Remote Sensing of Environment**, v. 176, p. 163-176, 2016.

LEITE, H. G.; SILVA, M. L. M.; BINOTI, D. H. B. FARDIN, L.; TAKIZAWA, F. H. **Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. Trees using artificial neural networks**. *European Journal of Forest Research*, v. 130, n.2, p. 263-269, 2011.

LI, Y.; CHAO, L.; ZHENZHEN, L.. Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms. **Sci Rep** 10, 9952, 2020.

LIMA, M. B. DE O.; LUSTOSA JUNIOR, I. M.; OLIVEIRA, E. M.; FERREIRA, J. C. B.; SOARES, K. L.; MIGUEL, E. P. Artificial neural networks in whole-stand level modeling of Eucalyptus plants. **African Journal of Agricultural Research**, v. 12, n. 7, p. 524–534, 2017.

LU, D. S. The potential and challenge of remote sensing-based biomass estimation. **International Journal of Remote Sensing**, v. 27, n. 7, p. 1297–1328, 2006.

MACEDO, F. L. D., SOUSA, A. M. D. O., GONÇALVES, A. C., SILVA, H. R., RODRIGUES, R. A. F. Função alométrica de biomassa com imagens de satélite de alta resolução espacial. **Ciência Florestal**, 28(3), 960-969, 2018.

MACHADO, A.M.; FILHO, A.F. **Dendrometria**. Curitiba: A. Figueiredo Filho. 309p, 2003.

MACIEL, MARIA DE NAZARÉ MARTINS et al. Uso de imagens orbitais na estimativa de parâmetros estruturais de uma floresta primária no município de Paragominas, Estado do Pará. **Revista de Ciências Agrárias Amazonian Journal of Agricultural and Environmental Sciences**, v. 52, n. 1, p. 159-178, 2009.

MATHEUS, M. T. Sequestro de carbono sob a óptica floresta no Brasil. **Revista Trópical-Ciências Agrárias e Biológicas**, Chapadinha, v. 6, n. 1, p. 104-116, 2012.

MELO, R. R. DE; MIGUEL, E. P. Use of artificial neural networks in predicting particleboard quality parameters. **Revista Árvore**, v. 40, n. 5, p. 949–958, 2016.

MIGUEL, EDER PEREIRA et al. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerrado com dados de satélite. **Pesquisa Agropecuária Brasileira**, v. 50, n. 9, p. 829-839, 2015.

MIGUEL, E. P.; REZENDE, A. V.; LEAL, F. A.; MATRICARDI, E. A. T.; ENSINAS, J. M. I.; MIRANDA, J. F. N. Floristic, structural, and allometric equations to estimate arboreal volume and biomass in a cerrado site. *Semina: Ciências Agrárias*, v. 38, n. 4, p. 1691–1702, 2017b.

MIGUEL, E. P.; MELO, R. R. DE; SERENINI JUNIOR, L.; DEL MENEZZI, C. H. S. Using artificial neural networks in estimating wood resistance. *Maderas. Ciencia y tecnología*, v. 20, n. 4, 2018.

MC TAGUE, J.P.; BATISTA, J.L.F.; STEINER, L.H. Equações de volume total, volume comercial e forma do tronco para plantações de Eucalyptus nos Estados de São Paulo e Rio de Janeiro. **IPEF**, n.41/42, p.56-63, 1989.

MACDICKEN, KENNETH G. et al. Global progress towards sustainable forest management.. **Forest Ecology and Management** , v. 352, p. 47-56, 2015.

MACIEL, Maria de Nazaré Martins et al. Uso de imagens orbitais na estimativa de parâmetros estruturais de uma floresta primária no município de Paragominas, Estado do Pará. **Revista de Ciências Agrárias Amazonian Journal of Agricultural and Environmental Sciences**, v. 52, n. 1, p. 159-178, 2009.

MACHADO, I. E. S.; SANTOS, M. M.; GIONGO, M.; CARVALHO, E. V. DE; GANASSOLI NETO, E. Modelos para estimativa de variáveis florestais com a utilização de imagens multiespectrais. **Pesquisa Florestal Brasileira**, v. 37, n. 90, p. 171–181, 2017.

MIRELES, M. A.; MIRANDA, R. P.; SÁNCHEZ, M. E. R.; HERNÁNDEZ, A. G.; ÁNGEL, L. M. Estimación de la densidad forestal mediante imágenes Landsat ETM+ en la región sur del Estado de México. **Revista Mexicana de Ciencias Forestales**, v. 8, n. 41, p. 30–55, 2017.

MORAN, Emilio F. **Meio ambiente & florestas**. Senac, 2017.

NELSON, R. et al. **Estimating Siberian timber volume using MODIS and ICESat/GLAS**. *Remote Sens. Environ.* 113, 691–701, 2009.

NOGUEIRA, M; VIEIRA, V; SOUZA, A; LENTINI, M. – Belém, PA: Instituto Floresta Tropical,. 144p. Manejo de florestas naturais da Amazônia: corte, traçamento e segurança – (**Manual técnico, 1 - IFT**) ISBN 978-85-63521-02-6 1, 2011.

OLIVEIRA, F. S. Uso de imagens do satélite alos para estimativa de parâmetros dendrométricos de plantios de eucalipto. **Tese** doutorado. Universidade Federal de Viçosa, outubro de 2011

ÖZÇELİK, R.; DIAMANTOPOULOU, M. J.; EKER, M.; GÜRLEVIK, N. Artificial neural network models: An alternative approach for reliable aboveground pine tree biomass prediction. **Forest Science**, v. 63, n. 3, p. 291–302, 2017.

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.

PANDIT S, TSUYUKI S, DUBE T. Estimativa de biomassa acima do solo em florestas comunitárias de zona tampão subtropical, Nepal, usando dados do Sentinel 2. **Sensoriamento Remoto**. 10 (4): 1-18, 2018.

PEARSON, R.L., AND L.D., MILLER. Remote mapping of standing crop biomass for estimation of the productivity of the short-grass Prairie, Pawnee National Grasslands, Colorado. In: **Proc. of the 8th International Symposium on Remote Sensing of Environment**, ERIM, Ann Arbor, MI, 1357-1381, 1972.

PEREZ, GABRIEL GUARIGLIA et al. **Dissertação mestrado** Uso de imagens do Sentinel 2 na estimativa de parâmetros biofísicos da vegetação em áreas de Mata Atlântica. 2018

PHILLIPS, Oliver L.; BRIENEN, Roel JW. Carbon uptake by mature Amazon forests has mitigated Amazon nations' carbon emissions. **Carbon balance and management**, v. 12, n. 1, p. 1-9, 2017..

PHUA, M.-H.; JOHARI, S. A.; WONG, O. C.; IOKI, K.; MAHALI, M.; NILUS, R.; COOMES, D. A.; MAYCOCK, C. R.; HASHIM, M. 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.

PLOTKIN, J. B.; POTTS, M. D.; LESLIE, N.; MANOKARAN, N.; LAFRANKIE, J.; ASHTON, P. S. Species-area curves, spatial aggregation, and habitat specialization in tropical forests. **Journal of Theoretical Biology**, v. 207, n. 1, p. 81-99, 2000.

PONZONI, F. J. Comportamento espectral da vegetação. In: MENESES, P. R.; MADEIRA NETTO, J. DA S. (Eds.). **Sensoriamento Remoto: reflectância dos alvos naturais**. Brasília: Editora Universidade de Brasília, 2001. p. 157–199.

PRADO JÚNIOR, J. A. DO; LOPES, S. DE F.; VALE, V. S. DO; DIAS NETTO, O. C.; SCHIAVINI, I. Comparação florística, estrutural e ecológica da vegetação arbórea das fitofisionomias de um remanescente urbano de cerrado. **Bioscience Journal**, v. 28, n. 3, p. 456–471, 2012.

PULETTI, N.; CHIANUCCI, F.; CASTALDI.; C **Annals of Silvicultural Research** vol. 42 Problema 1. pp: 32-38, 2018.

QI, JIAGUO et al. A modified soil adjusted vegetation index. **Remote sensing of environment**, v. 48, n. 2, p. 119-126, 1994.

QUEIROZ, W.T.; PÉLLICO NETTO, S.; VALENTE, M.D.R.; PINHEIRO, J.G.. Análise Estrutural da Unidade Conglomerada Cruz de Malta na Floresta Nacional do Tapajós, Estado do Pará, Brasil. *Revista Floresta*, 4: 9-18, 2011.

REIS, LEONARDO PEQUENO et al. Prognose da distribuição diamétrica na Amazônia utilizando redes neurais artificiais e autômatos celulares. **Floresta**, v. 48, n. 1, p. 93-102, 2018.

ROLIM, S. G.; COUTO, H. T. Z.; JESUS, R. M.; FRANÇA, J. T. Modelos volumétricos para a Floresta Nacional do Tapirapé-Aquirí, Serra dos Carajás (PA). **Acta Amazonica**, v. 36, n. 1, p. 107-114, 2006.

ROSAS, M. A.; BEZERRA, A. F. B.; DUARTE-NETO, P. J. Uso das redes neurais artificiais na aplicação de metodologia para alocação de recursos da saúde. **Revista de Saúde Pública**, v. 47, n. 1, p. 128–136, 2013.

ROTEIRO METODOLÓGICO PARA ELABORAÇÃO DE PLANO DE MANEJO PARA FLORESTAS NACIONAIS – Versão 3.9, **IBAMA**, 1996.

SANTOS, M. M., MACHADO, I. E. S., CARVALHO, E. V., VIOLA, M. R., GIONGO, M. Estimativa de parâmetros florestais em área de cerrado a partir de imagens do sensor Landsat 8. **Floresta**, 47(1), 75-84, 2017.

SCHMINK, MARIANNE; WOOD, CHARLES H. A “ecologia política” da **Amazônia**. Routledge, 2019.

SCHNEIDER, P.R. Introdução ao Manejo Florestal. Santa Maria, **UFSM/CEPEF- FATEC**., 348 p, 1993.

SCHNEIDER, DRESCHER, R.; P.R.; FINGER C.A.G.; QUEIROZ F.L.C. Fator de Forma Artificial de pinus elliottii engelm para a região da serra do sudeste do estado do rio grande do sul. **Ciência rural**. Santa maria, v. 31, n. 1, 2001.

SEGL, Karl et al. S2eteS: Uma ferramenta de modelagem ponta a ponta para a simulação de produtos de imagem Sentinel-2. **IEEE Transactions on Geoscience and Remote Sensing**, v. 53, n. 10, pág. 5560-5571, 2015.

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

SERRANO, A. M. **Importância da reposição florestal sob o aspecto jurídico e da conservação do bioma**, 2019.

SFB - Serviço Florestal Brasileiro, 2017 **Cadastro Nacional de Florestas Públicas - Atualização 2017**. Última atualização em Quarta, 19 de Junho de 2019. Disponível em: <http://www.florestal.gov.br/cadastro-nacional-de-florestas-publicas> acesso em: 20/07/2020.

SHIBLEE M, CHANDRA B, KALRA PK. Learning of geometric mean neuron model using resilient propagation algorithm. *Expert Systems with Applications* 2010; 37(12): 7449-7455. 10.1016/j.eswa.2010.04.018

SILVA, MAYRA LUIZA MARQUES et al. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. **Revista Árvore**, v. 33, n. 6, p. 1133-1139, 2009.

SILVA, J. N. M.; DE CARVALHO, J. O. P.; LOPES, J. do. Inventário florestal de uma área experimental na Floresta Nacional do Tapajós. **Embrapa Amazônia Oriental-Artigo em periódico indexado (ALICE)**, 1985.

SILVA, N., CORTE, A. P., PIVA, L., HENTZ, Â. M., & Sanquetta, C. R. Desempenho de algoritmos para contagem automática de árvores jovens e adultas a partir de dados VANT. **Enciclopédia biosfera**, 15(28), 2018.

SILVA, J.A. **Biometria e estatística florestal**. Santa Maria: UFSM. 235p, 1977.

SILVA, J.N.M. The behavior of the Tropical rain forest of the brazilian amazon after logging. Thesis (PhD). Oxford Forestry Institute. Oxford University. Michaelmas Term, 1989. 304p.

SISTEMA NACIONAL DE INFORMAÇÕES FLORESTAIS – SNIF - **Boletim SNIF 2017 – Produção Florestal**. Disponível em <http://www.florestal.gov.br/documentos/publicacoes/3230-> Acesso em: 21/11/2020.

SOARES, C.P.B.; NETO, F.P.de; SOUZA, A.L. de. **Dendrometria e Inventário Florestal**. Viçosa, UFV,. 276p, 2006.

SOUZA, P. F. D., SILVA, J. A. D., LUCENA, D. D. S., SANTOS, W. D. S., HENRIQUES, Í. G. N., LUCENA, M. D. F. D. A., SOUZA, A. D. D. Estudos fitossociológicos e dendrométricos em um fragmento de caatinga, São José de Espinharas-PB. **Ciência Florestal**, 26(4), 1317-1330, 2016

SOUZA, P. B. DE; SAPORETTI JUNIOR, A. W.; SOARES, M. P.; VIANA, R. H. O.; CAMARGOS, V. L. DE; MEIRA NETO, J. A. A. Florística de uma área de cerrado na Floresta Nacional de Paraopeba - Minas Gerais. **Cerne**, v. 16, n. 1, p. 86–93, 2010

STATSOFT, I. **Statistica: Data analysis software system**, 2011.

SULLIVAN, M.J.P., S.L. LEWIS, W. HUBAU, L. QIE, T.R. BAKER, L.F. BANIN, J. CHAVE, et al. Field methods for sampling tree height for tropical forest biomass estimation. **Methods Ecol. Evol.** 9(5):1179–1189, 2018.

SYDOW, J. D.; SANQUETTA, C. R.; CORTE, A. P. D.; SANQUETTA, M. N. I.; FIGUEIREDO FILHO, A. Comparação de métodos e processos de amostragem para inventário em floresta ombrófila mista. **Biofix Scientific Journal**, v. 2, n. 1, p. 60–68, 2017.

TAQUIA, A. A. L. **Productio Sentinel-2**, 2015.

TAKIKAWA, BRUNO YUJI. Proposta metodológica para elaboração de indicador de fragilidade florestal com o uso de geotecnologias. 2020.

THAINES, F.; BRAZ, E. M.; MATTOS, P. P.; THAINES, A. A. R. Equações para a estimativa de volume de madeira para a região da bacia do Rio Ituxi, Lábrea, AM. **Pesquisa Florestal Brasileira**, v. 30, n. 64, p. 283-289, 2010.

TONINI, HELIO; BORGES, RENATO ALVES. Equação de volume para espécies comerciais em Floresta Ombrófila Densa no sul de Roraima. **Embrapa Agrossilvipastoril**, 2015.

TOSUN, M.; DINCER, K. Determination of sound transmission loss in lightweight concrete walls and modeling artificial neural network. **Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi**, v. 6, n. 3, p. 461–477, 2018.

VAHEDI, A. A. Artificial neural network application in comparison with modeling allometric equations for predicting above-ground biomass in the Hyrcanian mixed-beech forests of Iran. **Biomass and Bioenergy**, v. 88, p. 66–76, 2016.

VALE, A. T. DO; MIGUEL, E. P.; MOREIRA, A. C. DE O.; LIMA, C. M.; ORELLANA, B. B. M. A.; FORTES, M. M.; MACHADO, M. P. O.; GONÇALEZ, J. C.; MARTINS, I. S. Artificial neural networks in predicting energy density of *Bambusa vulgaris* in Brazil. **African Journal of Agricultural Research**, v. 12, n. 10, p. 856–862, 2017.

VERÍSSIMO, A., PEREIRA, D. Produção na Amazônia Florestal: características, desafios e oportunidades. *Parcerias Estratégicas*, 19(38), 13-44, 2015.

VICENTE-SERRANO, S. M.; CAMARERO, J. J.; OLANO, J. M.; MARTÍN-HERNÁNDEZ, N.; PEÑA-GALLARDO, M.; TOMÁS-BURGUERA, M.; GAZOL, A.; AZORIN-MOLINA, C.; BHUYAN, U.; EL KENAWY, A. 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.; MENDONÇA, A. R. DE; SILVA, G. F. DA; ZANETTI, S. S.; SILVA, M. M. DA; SANTOS, A. R. DOS. Prognoses of diameter and height of trees of eucalyptus using artificial intelligence. **Science of the Total Environment**, v. 619–620, p. 1473–1481, 2018b.

VENDRUSCOLO, D. G. S.; CHAVES, A. G. S.; MEDEIROS, R. A.; SILVA, R. S. DA; SOUZA, H. S.; DRESCHER, R.; LEITE, H. G. Estimativa da altura de árvores de *Tectona grandis* L.f. utilizando regressão e redes neurais artificiais. **Nativa**, v. 5, n. 1, p. 52–58, 2017.

XUE, JINRU; SU, BAOFENG. Índices significativos de detecção remota de vegetação: uma revisão dos desenvolvimentos e aplicações. **Jornal de sensores**, v. 2017.

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