



**A DENSIDADE DA MADEIRA DE ÁRVORES NO CERRADÃO CONTRIBUI
NA ESTIMATIVA DA BIOMASSA POR INTERMÉDIO DA REGRESSÃO E
REDES NEURAS ARTIFICIAIS?**

Thaís de Azevedo Nazareno

Brasília, 01 de novembro de 2021.

UNIVERSIDADE DE BRASÍLIA

FACULDADE DE TECNOLOGIA



Universidade De Brasília - UnB
Faculdade De Tecnologia - FT
Departamento de Engenharia Florestal – EFL

**A DENSIDADE DA MADEIRA DE ÁRVORES NO CERRADÃO CONTRIBUI
NA ESTIMATIVA DA BIOMASSA POR INTERMÉDIO DA REGRESSÃO E
REDES NEURAIS ARTIFICIAIS?**

Thaís de Azevedo Nazareno

14/0163441

Linha de Pesquisa: Ciências Florestais

Orientador: Prof. Dr. Eder Pereira Miguel

Trabalho apresentado ao Departamento de Engenharia Florestal da Universidade de Brasília, como parte das exigências para obtenção do título de Engenheira Florestal.

Brasília, 01 de novembro de 2021.

NN335d Nazareno, Thaís de Azevedo
A densidade da madeira de árvores no cerrado contribui na estimativa da biomassa por intermédio da regressão e redes neurais artificiais? / Thaís de Azevedo Nazareno; orientador Eder Pereira Miguel. -- Brasília, 2021.
50 p.

Monografia (Graduação - Engenharia Florestal) --
Universidade de Brasília, 2021.

1. Estimativa de Densidade Arbórea. 2. Modelos de Regressão. 3. Redes Neurais Artificiais. 4. Área de Cerradão. I. Pereira Miguel, Eder, orient. II. Título.

REFERÊNCIA BIBLIOGRÁFICA

NAZARENO, T. A. **A densidade da madeira de árvores no cerrado contribui na estimativa da biomassa por intermédio da regressão e redes neurais artificiais?** 2021. Trabalho de conclusão de curso (Graduação em Engenharia Florestal) - Departamento de Engenharia Florestal, Universidade de Brasília, Brasília, DF. 50p. 2021.

CESSÃO DE DIREITOS

AUTOR: Thaís de Azevedo Nazareno.

TÍTULO: A densidade da madeira de árvores no cerrado contribui na estimativa da biomassa por intermédio da regressão e redes neurais artificiais?

GRAU: Engenheira.

ANO: 2021.

Concedo à Universidade de Brasília-UnB permissão para reproduzir cópias deste Trabalho de Conclusão de Curso e para emprestá-las somente para propósitos acadêmicos e científicos. Reservo outros direitos de publicação e nenhuma parte desse Trabalho de Conclusão de Curso pode ser reproduzida sem autorização por escrito.

Thaís de Azevedo Nazareno

DEDICATÓRIA

Dedico este trabalho aos meus pais que nunca desistiram de mim e me incentivaram a seguir em frente. A minha amiga Andressa Valentim que sempre esteve ao meu lado em todos os momentos dessa graduação. E a todos os sonhadores que acreditam na importância da Engenharia Florestal para a construção de um mundo melhor.

AGRADECIMENTOS

Agradeço a todos que me apoiaram nesse trabalho. Aos meus pais, Nilton e Bernadete, que não só me ajudaram, mas estiveram tão ansiosos quanto eu.

A minha irmã Luísa, por me dar várias dicas.

Aos meus familiares, que mesmo de longe, mandaram energias positivas.

Aos meus amigos de curso e vida Andressa, Gabriel, Marcela e Maria Eduarda que fizeram todos esses anos valerem à pena e caminharam junto nessa conquista. E aos tantos outros amigos que passaram por mim.

Aos professores Alexandre Florian e Leonardo Job Biali que mesmo de longe nos mostram que ainda existe amor pelo ensino e nos fazem ter vontade de crescer.

Ao professor Éder, que entre tantos altos e baixos, caminhou até o fim nesse projeto.

A todos da UnB que auxiliaram nesse processo, principalmente a melhor secretária de graduação, Flávia Paula, que não só tornou todos os processos burocráticos de todos esses anos muito mais viáveis, como me auxiliou diretamente na luta estudantil e na melhora da vida acadêmica para a comunidade da florestal da UnB.

Aos meus amigos do trabalho, que me apoiaram, sofreram comigo e ficaram sobrecarregados quando me ausentei para me dedicar a esse.

RESUMO

Apesar do Cerrado ser considerado o segundo bioma brasileiro, estudos na mensuração de dados de biomassa ainda são escassos. Essa escassez se deve parcialmente a sua alta heterogeneidade e ainda necessitar de métodos destrutivos de medição, os quais esbarram na legislação brasileira. O presente trabalho visa avaliar o efeito da densidade da madeira nas estimativas da biomassa individual arbórea em árvores de cerradão, através da predição de modelos de regressão e do treinamento de redes neurais artificiais (RNA). Para tanto, foram coletados dados de diâmetro à 1,30m do solo(dap), altura total (ht) e densidade (d) de 80 indivíduos, distribuídos em 34 espécies, em um fragmento de cerradão de 10,15 hectares no Parque Estadual do Lajeado da Serra do Lajeado, próximo ao município de Palmas – Tocantins – Brasil. Os modelos de regressão e as redes neurais artificiais foram treinadas e validas. Os critérios de ajuste e seleção foram: o coeficiente de correlação (r) entre os valores observados e estimados, o erro padrão residual absoluto (S_{yx}), o erro padrão residual em percentual ($S_{yx\%}$) e a análise gráfica dos resíduos. Os resultados obtidos apontaram moderada a baixa correlação entre a densidade da madeira e a biomassa, logo os modelos e as redes treinadas com e sem a densidade não diferiram estatisticamente. Entre as técnicas de regressão e redes neurais artificiais, não houve diferença significativas, embora as estáticas de ajuste e precisão das RNAs foram mais acuradas na estimativa da biomassa arbórea em área de cerradão. Por fim, os resultados revelaram que a densidade da madeira é uma variável que não implica em melhorias na estimativa da biomassa em árvores individuais em áreas de cerradão, seja por técnicas de regressão ou inteligência artificial.

Palavras-chaves: Acurácia, Bioma Cerrado, Modelagem, Modelos de Regressão, RNAs.

ABSTRACT

While Cerrado is considered the second biome in Brazil, studies measuring its biomass are still scarce. Such a scarcity stems partially due to its high heterogeneity and also to the need for destructive measurement methods, which collide with Brazilian legislation. Distinctly, this study deploys generic models and artificial neural networks (ANN) training to evaluate the effect of wood density on estimates of individual tree biomass in Cerradao trees. For this purpose, data includes diameter at 1.30m (dap), height (ht), and density (d) of 80 individuals, distributed in 34 species in a cerradão fragment of 10.15 hectares in the Park do Lajeado da Serra, near city of Palmas – Tocantins - Brazil. Regression models and artificial neural networks were trained and validated. Criteria for calibration and selection were the correlation coefficient (r), the absolute residual standard error (Syx), the absolute residual standard error in percentage (Syx%) and the normality of the residuals (determined by visual inspection). The results obtained showed moderate to low correlation between wood density and biomass, so the models and networks trained with and without the density between and statistically do not differ.

Results suggest that density does not strongly correlate with any other variable, such that its inclusion in the models does not significantly change conclusions. Although, ANNs seem to be superior to regression models in measuring biomass in cerradão. Finally, our results revealed that wood density is a variable that does not imply improvements in the estimation of individual tree biomass in cerradão areas, either by regression or artificial intelligence techniques.

Key words: Accuracy, Cerrado, Modeling, Regression Models, Artificial Neural Networks (ANNs).

LISTA DE FIGURAS

Figura 1 - Mapa dos biomas brasileiros	16
Figura 2 - Diagrama de perfil (1) e cobertura arbórea (2) representando uma faixa de 80 metros de comprimento e 10 metros de largura.	17
Figura 3 - Representação gráfica de uma rede neural artificial (RNA) multicamada. ...	18
Figura 4 - Localização do fragmento de cerradão, no município de Palmas, estado do Tocantins, Brasil.	23
Figura 5. Disposição dos transectos e parcelas na área de inventário no Parque Estadual da Serra do Lajeado - TO - Brasil.....	24
Figura 6 - Diagramas das RNA	29
Figura 7 - Representação gráfica da correlação entre biomassa observadas e previstas (A), distribuição dos erros de estimativa (B) e histograma da frequência de erros (C), para Equações de Regressão: (1) Spurr sem densidade; (3) Schumacher-Hall sem densidade; (4) Schumacher-Hall com densidade; (5) Husch adaptado sem densidade e (6) Husch adaptado com densidade.	34
Figura 8 - Representação gráfica da correlação entre biomassa observadas e previstas (A), distribuição dos erros de estimativa (B) e histograma da frequência de erros (C), para (1) Rede Neural sem densidade do tipo MLP 2-8-1 e (2) Rede Neural com densidade do tipo MLP 3-8-1, ajustada aos dados obtidos do inventário florestal na APA da Serra do Lajeado – Palmas – TO, Brasil.....	36
Figura 9. Representação gráfica da distribuição dos erros de estimativa para dados validados de (1) Rede Neural sem densidade do tipo MLP 2-8-1, (2) Rede Neural com densidade do tipo MLP 3-8-1, (3) Schumacher-Hall sem densidade e (4) Schumacher-Hall com densidade, ajustada aos dados obtidos do inventário florestal na APA da Serra do Lajeado – Palmas – TO, Brasil.	39

LISTA DE TABELAS

Tabela 1 - Modelos hipsométricos ajustados para a estimativa da variável biomassa com e sem densidade.	28
Tabela 2 - Dados estatísticos das amostras do inventário florestal na APA da Serra do Lajeado – Palmas -TO, Brasil.....	31
Tabela 3. Matriz de correlação entre a variável dependente (biomassa) e as variáveis independentes (dap, ht e d) obtidas do inventário florestal na APA da Serra do Lajeado-Palmas-TO, Brasil.	32
Tabela 4 - Medidas de precisão dos modelos hipsométricos ajustados aos dados obtidas do inventário florestal na APA da Serra do Lajeado – Palmas-TO, Brasil.	33
Tabela 5 - Medidas de precisão das redes neurais artificiais treinadas para os dados obtidos do inventário florestal na APA da Serra do Lajeado – Palmas – TO, Brasil.....	35
Tabela 6 - Análise de variância (ANOVA) aplicada sobre as biomassas reais e estimadas pelo modelo de regressão e rede neural artificial selecionados.....	37
Tabela 7 - Medidas de precisão de Schumacher-Hall e das redes neurais artificiais validadas para os dados obtidos do inventário florestal na APA da Serra do Lajeado – Palmas – TO, Brasil.....	38

SUMÁRIO

1	INTRODUÇÃO	11
2	OBJETIVO.....	14
2.1	Objetivo geral	14
2.2	Objetivos específicos	14
3	REVISÃO BIBLIOGRÁFICA.....	15
3.1	Cerrado.....	15
3.2	Redes neurais artificiais (RNA)	17
3.3	Obtenção da biomassa	20
4	MATERIAIS E MÉTODOS	23
4.1	Localização e caracterização da área de estudo	23
4.2	Coleta de dados	24
4.3	Variáveis independentes	27
4.4	Modelagem da biomassa usando regressão	28
4.5	Modelagem da biomassa estimada usando redes neurais artificiais	29
5	RESULTADOS E DISCUSSÕES	31
5.1	Estatística descritiva	31
5.2	Correlação.....	32
5.3	Estimativa da biomassa utilizando regressão.....	33
5.4	Estimativa da biomassa utilizando redes neurais artificiais.....	35
5.5	Comparação entre a regressão e a RNA	37
6	CONCLUSÕES.....	41
	REFERÊNCIAS BIBLIOGRÁFICAS	42
	ANEXO - Tabela com informações do inventário florestal usadas nesse trabalho.....	48
	ANEXO - Tabela com dados do inventário florestal usadas para validação dos modelos	

1 INTRODUÇÃO

O Cerrado é considerado o segundo maior bioma brasileiro, cobrindo cerca de 25% do território nacional e perfazendo uma área entre 1,8 e 2 milhões de km². Se distribui de forma contínua pelos Estados de Goiás, Tocantins, Mato Grosso do Sul, sul do Mato Grosso, oeste de Minas Gerais, Distrito Federal, oeste da Bahia, sul do Maranhão, oeste do Piauí e porções do Estado de São Paulo. Existe ainda, pequenas porções em outros estados, como é o caso do Paraná e dentro do próprio bioma amazônico (BRASIL, 2014).

Segundo França et al. (2015), o bioma apresenta elevada riqueza de espécies e endemismo, possuindo mais de 11 mil espécies de plantas, o que corresponde a 30% de toda a biodiversidade brasileira, possibilitando uma ampla aptidão de uso sustentável, principalmente para a população tradicional, seja para alimentação, uso medicinal, fornecimento de energia e, até mesmo, matéria-prima para construções.

A baixa fertilidade natural do Cerrado e a falta de meios de transportes mantiveram a densidade demográfica da região baixa, até meados do século XX. Esse panorama muda a partir de 1970 quando se difundiram a correção da acidez e fertilidade dos solos, e o uso de máquinas no cultivo de produtos primários de exportação (SILVA et al., 2013). A partir de então, vem sendo degradado pela expansão da fronteira agrícola, que busca a intensa produção de grãos para exportação, e o fomento para a produção de carne, bem como, a exploração predatória de seu material lenhoso para produção de carvão (MEISTER; 2017).

Para se mensurar o efeito da supressão da vegetação com a consequente modificação do uso do solo, é importante se conhecer a biomassa presente nos ecossistemas. A capacidade de cada um em armazenar ou emitir carbono é determinada por uma série de processos físicos, químicos e bióticos atuando em diferentes direções e intensidades. Neste contexto, o homem pode influenciar de modo significativo alterando a estrutura e composição dos ecossistemas (ROQUETTE; 2018).

No bioma cerrado, existem poucos estudos quantificando o estoque da biomassa vegetal em suas diferentes fitofisionomias, em função principalmente da dificuldade de mensurar os seus componentes, principalmente pela tortuosidade do tronco e a

profundidade no solo atingida pelo sistema radicular (ABDALA et al., 1998¹; CASTRO.; KAUFFMAN, 1998²; VALE; FELFILI, 2005; REZENDE et al., 2006; PAIVA, et al., 2011; RIBEIRO et al., 2011; MORAIS et al., 2013; SANTANA et al., 2013; MIGUEL et al., 2015; SCOLFORO, et al., 2015; ROQUETTE, 2018 e SOUZA, 2020).

A determinação da biomassa pode ser alcançada por dois caminhos: métodos destrutivos que implicam, necessariamente, na seleção e derrubada de árvores amostras para obtenção de dados e; os métodos indiretos, que procuram através de regressões lineares ou não-lineares definir as equações (modelos) que interligam a variáveis independentes, que podem ser medidas diretamente (diâmetro, altura etc.), com as dependentes, estimadas (a biomassa expressa pelo peso de matéria seca dos seus componentes). Embora mais complexa de ser obtida, a densidade da madeira também vem sendo incorporada como variável preditora da biomassa no bioma, todavia, a sua inserção nos modelos ainda gera dúvidas, quanto a sua efetividade na melhoria das predições.

Ao utilizarmos as técnicas de regressão convencional existem vários modelos que podem ser ajustados para a estimativa da biomassa. Estes modelos podem ser ajustados de forma linear ou não linear, também são subdivididos em modelos de simples e dupla entrada. Todavia, quando analisadas as estatísticas que medem a qualidade do ajuste e a precisão, os modelos de dupla entrada geralmente são mais acurados, conforme corroborado por Thomas et al. (2006), Azevedo et al. (2011) e Miguel et al. (2014). Também vale destacar que para trabalhar com regressão, é necessário a existência de pressupostos estatísticos como a normalidade ou linearidade dos dados (EGRIOGLU et al., 2014).

Uma opção que dispensa os pressupostos da análise de regressão clássica convencional, é a utilização dos recursos e técnicas de Inteligência Artificial (IA). O uso de ferramentas de inteligência artificial no meio florestal é assunto pouco explorado. No entanto, esforços estão sendo feitos nessa direção, com resultados promissores

¹ ABDALA, G. C. et al. Above and belowground organic matter and root: shoot ratio in a cerrado in central Brazil. **Brazilian Journal of Ecology**, Rio Claro, v. 2, n. 1, p. 11-23, 1998.

² CASTRO E. A.; KAUFFMAN, J. B. Ecosystem structure in the Brazilian cerrado: a vegetation gradient of aboveground biomass, root mass and consumption by fire. **Journal of Tropical Ecology**, Cambridge, v. 14, p. 263-283, 1998.

(DIAMANTOPOULOU, 2005; GORGENS et al., 2009; CASTRO et al., 2013). Dentre as técnicas de IA, a adoção de Redes Neurais Artificiais (RNA) tem ganhado destaque (SILVA et al., 2009; BINOTTI et al., 2013; MIGUEL et al., 2015; CARRIJO et al., 2020), e na estimativa de biomassa individual para árvores de cerradão, o comportamento das RNA ainda não é tão conhecido.

2 OBJETIVO

2.1 Objetivo geral

Avaliar a contribuição da densidade da madeira nos modelos de regressão e de redes neurais artificiais (RNAs) na predição de biomassa acima do solo, a partir de dados de inventário florestal, de uma área de vegetação arbórea no cerrado.

2.2 Objetivos específicos

- Ajustar e validar modelos de regressão na estimativa da biomassa individual arbórea incluindo ou não a densidade da madeira como variável preditora;
- Ajustar, treinar e validar RNAs na estimativa da biomassa individual arbórea incluindo ou não a densidade da madeira como variável preditora;
- Analisar o efeito da densidade da madeira nas estimativas da biomassa individual arbórea em árvores de cerrado;
- Analisar a precisão das regressões e RNAs para prever a biomassa individual arbórea em árvores de cerrado.

3 REVISÃO BIBLIOGRÁFICA

3.1 Cerrado

Ao se referir ao termo “cerrado”, se deve ter o entendimento que a palavra pode se referir tanto a um bioma, quanto a um tipo fisionômico de vegetação. O cerrado, enquanto Cerrado *sensu stricto* é um bioma brasileiro, composto por campo tropical, savana e floresta estacional. Já o cerrado *sensu lato* engloba as características fisionômicas de uma determinada vegetação, de modo que em cada bioma, existem subcategorias vegetacionais. De acordo com a classificação de Rideiro e Walter (1998), o Cerrado *sensu stricto*, que cobre 85% da área total, se divide em formações florestais (Mata Ciliar, Mata de Galeria, Mata Seca e cerradão), savânicas (Cerrado sentido restrito, Parque de Cerrado, Palmeiral e Vereda) e campestres (Campo sujo, Campo limpo e Campo Rupestre).

Considerado o segundo maior bioma brasileiro, cobrindo cerca de 25% do território nacional e perfazendo uma área entre 1,8 e 2 milhões de km², o Cerrado abrange, de forma contínua, os Estados de Goiás, Tocantins, Mato Grosso do Sul, sul do Mato Grosso, oeste de Minas Gerais, Distrito Federal, oeste da Bahia, sul do Maranhão, oeste do Piauí e porções do Estado de São Paulo. Pode-se encontrar porções de cerrado em outros estados da federação como no Paraná, ou em áreas disjuntas dentro de outros biomas (Floresta Amazônica). O bioma apresenta elevada riqueza de espécies e endemismo, possuindo mais de 11 mil espécies de plantas, o que corresponde a 30% de toda a biodiversidade brasileira (FRANÇOSO et al., 2015). Este fato proporciona uma ampla aptidão de uso sustentável, principalmente para a população tradicional, seja para alimentação, uso medicinal, fornecimento de energia e, até mesmo, matéria-prima para construções.

Ele é responsável por uma contribuição significativa em oito das doze grandes bacias brasileiras (Amazônica, Tocantins-Araguaia, Parnaíba, São Francisco, Atlântico Nordeste Ocidental, Atlântico Leste, Paraná e Paraguai), com seis delas, possuindo nascentes na região do cerrado. De acordo com Lima e Silva (2005), se for desconsiderada a produção hídrica da bacia Amazônica, onde vive uma pequena parcela da população do país, o Cerrado passa a representar 43% da produção hídrica do território nacional.

Na **Erro! Fonte de referência não encontrada.** pode ser visualizado o Bioma C errado em contraposição aos demais biomas brasileiros.

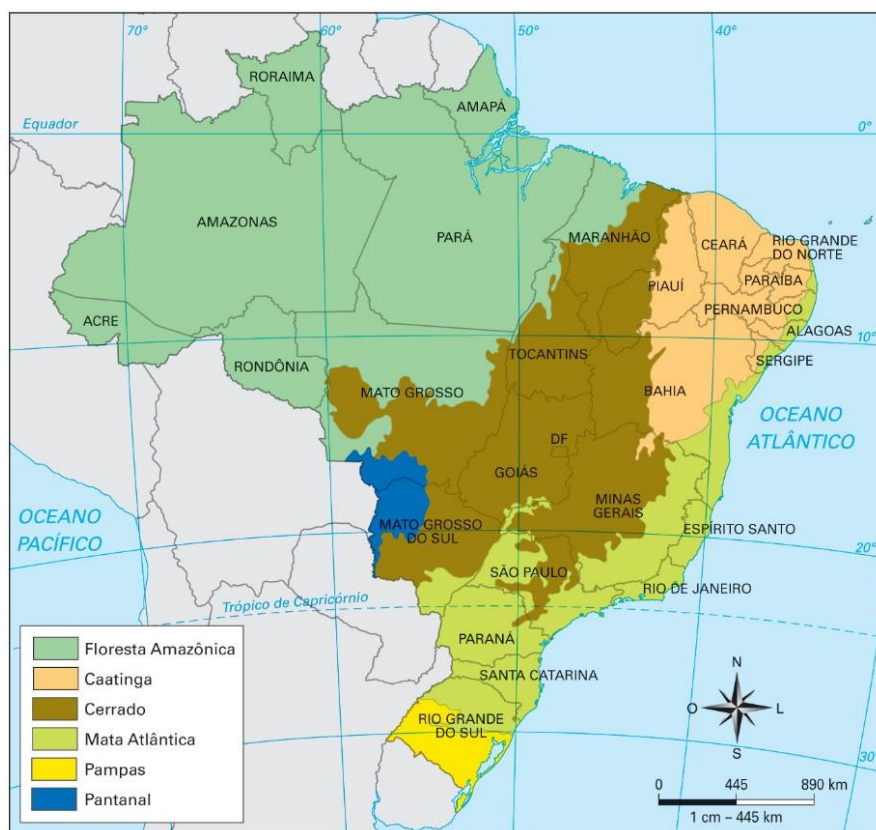


Figura 1 - Mapa dos biomas brasileiros

Fonte: Santa Catarina by Sanderley (<https://lyrics-letra.com/PT/Silveira/Santa-Catarina/Santa-Catarina-Historia-Geografia-31>)

Para Meister (2017) o bioma Cerrado vem sendo degradado pela expansão da fronteira agrícola, que busca a intensa produção de grãos para exportação, e o fomento para a produção de carne, bem como a exploração extremamente predatória de seu material lenhoso para produção de carvão. O Cerrado e suas fisionomias possuem potencial produtivo comprovado, fornecendo matéria-prima tanto para serrarias quanto para fins energéticos, dando assim, margem para estudos com ênfase no potencial produtivo de áreas florestais (CARRIJO, 2019).

Um dos tipos vegetacionais do cerrado de destaque é o cerradão, que segundo Ribeiro e Walter (1998), é uma formação florestal com aspectos xeromórficos, sendo considerada por alguns autores como uma mata mais rala e fraca, caracterizado pela presença de espécies que ocorrem no Cerrado sentido restrito e por espécies de mata. Segundo ele, é uma floresta, mas floristicamente é mais similar a um Cerrado. Os seus indivíduos possuem dossel predominantemente contínuo e cobertura arbórea que pode

oscilar de 50 a 90%. A altura média do extrato varia de 8 a 15 metros, de modo que, as condições de luminosidade são propícias para a formações arbustivas e herbáceas diferenciadas. Os solos por sua vez, em sua maioria, são profundos, bem drenados, de média e baixa fertilidade, ligeiramente ácidos pertencentes às classes dos Latossolos (vermelho-escuro, vermelho-amarelo e roxo) e em menor proporção Cambissolo distrófico (RIBEIRO; VALTER, 1998). Na Figura 2 é apresentado um diagrama mostrando o perfil e a cobertura arbórea de um cerradão típico.

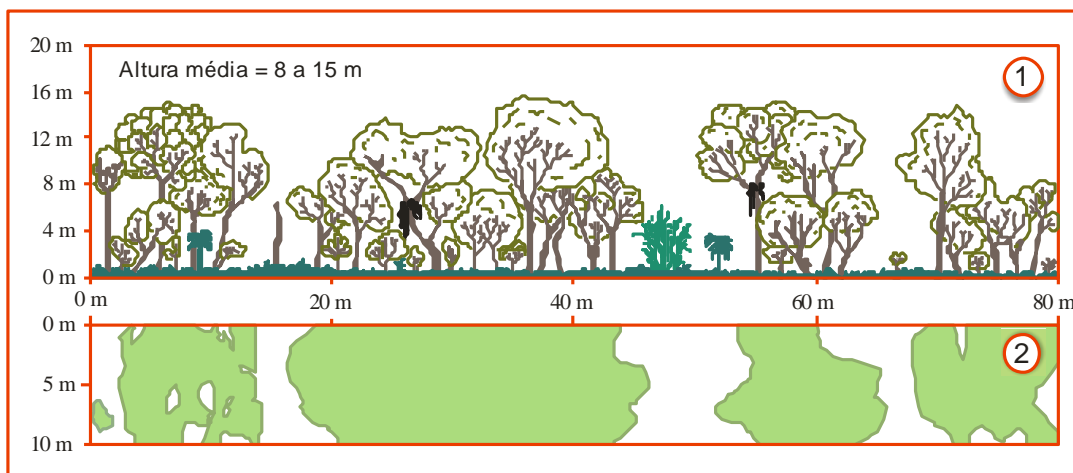


Figura 2 - Diagrama de perfil (1) e cobertura arbórea (2) representando uma faixa de 80 metros de comprimento e 10 metros de largura.

Fonte: Ribeiro e Walter (1998) adaptado.

3.2 Redes neurais artificiais (RNA)

Os primeiros trabalhos em redes neurais artificiais (RNA) apareceram na década de 1940. Embora a ideia de se construir máquinas ou mecanismos autônomos seja um sonho antigo, a temática começou a ser fortemente pesquisada a partir dos anos 1990 e ainda hoje tem um grande potencial (SILVA et al., 2010).

A característica mais atrativa das RNA consiste na sua elevada habilidade de mapear sistemas não-lineares, aprendendo os comportamentos envolvidos, a partir de informações (medidas, amostras ou padrões) obtidas. Isso as torna uma poderosa ferramenta para aplicação em diversas áreas e tipos de problemas (SILVA et al., 2010).

Em síntese, RNA são modelos computacionais inspirados no sistema nervoso de seres vivos. Possuem a capacidade de aquisição e manutenção de conhecimento (baseado em informações) e podem ser definidas como um conjunto de unidades de processamento,

caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões (sinapses artificiais), sendo representadas aqui por vetores/matrizes de pesos sinápticos (SILVA et al., 2010). A Figura 3 ilustra o conceito de RNA.




Figura 3 - Representação gráfica de uma rede neural artificial (RNA) multicamada.

Fonte: Castro Soares de Oliveira, Anderson & Souza, Ademária & Lacerda, Wilian & Gonçalves, Luciene. (2010). Aplicação de redes neurais artificiais na previsão da produção de álcool. *Ciencia E Agrotecnologia - CIENC AGROTEC*. 34. 10.1590/S1413-70542010000200002.

O processo de aprendizagem ocorre com as ativações dos neurônios, de modo que as conexões mais usadas são reforçadas e as demais são enfraquecidas. Isso provoca modificações significativas nas sinapses dos neurônios. Por essa razão, quando uma rede neural é implantada, é necessário um tempo para que ela seja treinada e faz parte do processo de aprendizagem. Esse processo de aprendizagem consiste da aplicação de passos ordenados que sejam necessários para sintonização dos pesos sinápticos e limiares de seus neurônios, tendo-se como objeto final a generalização de soluções a serem produzidas pelas suas saídas, cujas respostas são representativas do sistema físico em que estas estão mapeando (SILVA et al., 2010).

Silva et al. (2010) apresenta os métodos de aprendizado nas RNA:

- **Supervisionado:** a rede neural recebe um conjunto de dados de entradas com as respectivas saídas desejadas. Com essas informações, ocorrem os ajustes nos pesos sinápticos até que o erro entre as saídas calculadas e os valores desejados, tenham um valor menor que um padrão determinado;
- **Não-supervisionado:** a rede neural não tem valores de saída para contrapor aos valores calculados. Como consequência, o próprio sistema deve se auto-organizar

e procurar identificar subconjuntos de dados que tenham alguma similaridade. Os pesos sinápticos e limiares dos neurônios da rede são então ajustados pelo algoritmo de aprendizado de forma a refletir essa representação internamente dentro da própria rede. Alternativamente, pode-se, em função da experiência do projetista do sistema, estabelecer um número máximo desses subconjuntos similares;

- Treinamento com reforço: é uma variação da técnica do treinamento supervisionado onde valores dos pesos sinápticos e limiares são gradualmente adicionados visando reforçar uma determinada condição. Esta técnica é baseada na tentativa e erro, porque a resposta a uma determinada entrada só pode ser satisfatória ou não, uma vez que se tem o parâmetro de saída desejado;
- Treinamento usando lote de padrões: neste treinamento também conhecido por *off-line* ou *batch*, os ajustes são efetuados nos vetores dos pesos e nos limiares após a apresentação de todo o conjunto de treinamento, pois cada passo de ajuste leva em consideração o total de desvios observados nas amostras de treinamento frente aos respectivos valores desejados para suas saídas;
- Treinamento usando padrão-por-padrão (on-line): neste processo de aprendizagem, os ajustes são efetuados após a apresentação das amostras de treinamento que imediatamente são descartadas. Este tipo de técnica é utilizado quando o comportamento do sistema a ser mapeado varia de forma muito rápida, de modo que as amostras utilizadas podem não representar mais o comportamento do processo no instante seguinte. Como os padrões são apresentados um por vez, as ações de ajuste dos pesos e limiares são bem localizadas e pontuais, cujos reflexos remetem a uma determinada circunstância comportamental do sistema. Deste modo a rede só começa a dar resposta mais precisas, após a apresentação de um número significativo de amostras

Vários estudos dendrométricos e morfométricos tem RNAs com o objetivo de estimar alturas, volumes e biomassas em florestas plantadas e nativas, nos diferentes biomas brasileiros.

Gorgents et al. (2009), utilizou RNA com o objetivo de estimar com eficiência o volume de árvores de eucaliptos em diferentes regiões (Bahia, Minas Gerais e São Paulo).

Empregaram redes neurais treinadas por algoritmos de retro programação do erro (*backpropagation*) e concluíram que a modelagem por redes neurais foi viável, e que a capacidade de generalização e conectividade permitiu que fosse utilizada apenas uma rede para realizar a predição de volume de árvores nas diferentes regiões

Miguel et. al. (2015), avaliou a eficácia na aplicação de modelos de análise de regressão linear e RNA na predição de volume de madeira e da biomassa por unidade de área acima do solo, em regiões arbóreas de cerradão, e concluiu a superioridade das RNAs.

Carrijo et al. (2020), avaliou a eficácia de RNAs associadas à dados de satélite para estimar o potencial energético em áreas de cerradão e obteve resultados acurados. A eficiência preditiva das RNAs também foi corroborada por Martins et al. (2020) na estimativa da altura de árvores de *Eucalyptus grandis* W. Hill, e por Valente, E.O. e Valente, G.F.S. (2021), na estimativa do volume de madeira em florestas de eucaliptos.

3.3 Obtenção da biomassa

A determinação da biomassa de áreas florestais tem sido feita por meio de modelos matemáticos que utilizam dados dendrométricos (DAP, altura, densidade) dos indivíduos. Esses modelos são conhecidos por modelos alométricos, sendo o estudo da relação do tamanho do corpo com a forma, fisiologia e o comportamento associados às taxas de crescimento diferencial das partes do corpo de um organismo. Os dados utilizados nos ajustes dos parâmetros desses modelos são oriundos de inventários florestais, onde uma pequena parte de exemplares são derrubados. Nesses exemplares são feitas medidas rigorosas de altura, peso e densidade. Essa prática, embora destrutiva, tem proporcionado contribuições significativas para estimativas de estoques de biomassas em florestas (SOUZA, 2020).

Tashi et al. (2017) e Roitman et al. (2018) afirmam que modelos genéricos são suficientes para estimar a biomassa em áreas maiores quando se têm ausência de modelos desenvolvidos localmente. Figueiredo (2005) menciona que a fase mais importante nos trabalhos de determinação de volumes florestais é a escolha das equações, uma vez que um modelo errado pode induzir a superestimação ou subestimação da grandeza procurada.

Bueno (2020) e Souza (2020) relatam que, embora a utilização de espécies arbóreas dependa do conhecimento detalhado das características dendrométricas e morfométricas, existem poucos trabalhos relativos aos diversos tipos de fitofisionomias do Cerrado para estimativas de biomassa. Bueno (2020) trabalhou no desenvolvimento de algoritmo em linguagem R para calcular as variáveis dendrométricas e morfométricas e Souza (2020) se fixou no desenvolvimento de equações (lineares e não lineares) para o cálculo de biomassa de fitofisionomias específicas (Mata de Galeria, Mata Seca, Cerradão e Cerrado *sensu stricto*).

É importante ressaltar que o entendimento de como a biomassa se comporta nas diferentes fitofisionomias possibilita reduzir incertezas na estimativa dos estoques de carbono, o que contribui para políticas de conservação e manejo no Cerrado.

Santana et al. (2021), evidencia a necessidade de que a consistência biológica nos modelos estimadores de biomassa seja considerada, embora esse fato seja negligenciado, na maioria dos casos, pelos pesquisadores. Foram testados modelos independentes para definir quais eram os mais adequados para calcular a biomassa do fuste, da copa e a total acima do solo. Posteriormente estes modelos foram ajustados simultaneamente através de sistemas de equações para determinação da biomassa total.

Em Miguel et al. (2015) a estimativa de biomassa e volume utilizou as regressões e as redes neurais artificiais, onde foram incorporados a área basal e os índices de vegetação obtidas por técnicas de sensoriamento remoto. Segundo os autores, independentemente da diversidade florística, da heterogeneidade estrutural e da complexidade do dossel, o índice de vegetação e a área basal obtidos por satélite mostraram-se eficazes para obtenção do volume de madeira e biomassa para áreas de cerradão.

Roitman et al. (2018) reavaliou as estimativas da biomassa do Cerrado e para isso reexaminou as equações alométricas e as influências ambientais. A partir dos seus estudos verificou que equações lineares longas forneceram resultados melhores que as não lineares exponenciais. Constataram também que a biomassa do Cerrado é maior nas regiões próximas a Amazônia.

Oliveira et al. (2019) comparou modelos estatísticos para estimativa de biomassa acima do solo em três compartimentos (arbóreo, herbáceo-arbustivo e serapilheira) de um Cerrado *sensu stricto* típico no oeste da Bahia. Constatou que o compartimento arbóreo foi o responsável por 58% do estoque de biomassa, seguido pela serapilheira (26%) e herbáceo-arbustivo (16%). A quantidade de carbono foi estimada pelo fator de conversão da biomassa.

As estimativas para determinação de biomassa são importantes para quantificar o estoque de carbono e posteriormente, a redução de emissões de gases de efeito estufa, e passam necessariamente pela aplicação de modelos matemáticos. A mitigação da degradação e desmatamento das florestas, das mudanças climáticas, de indicadores de produtividade dentre outras medidas, dependem do conhecimento da biomassa seca presente nas florestas, que podem ser obtidas diretamente ou indiretamente através dos modelos alométricos (SOUZA, 2020). Estudos tem sido realizado no Cerrado com o intuito de estimar a biomassa, no entanto, eles não contemplam todas as fitofisionomias em apenas um modelo, o que limita o conhecimento sobre os aspectos globais no estoque de carbono. A dificuldades na modelagem residem principalmente na mensuração das variáveis dendométricas (diâmetro e altura) por causa dos troncos tortos das árvores, da variabilidade entre árvores de uma mesma espécie e da profundidade do solo, além da diversidade de espécies.

4 MATERIAIS E MÉTODOS

4.1 Localização e caracterização da área de estudo

O estudo foi realizado em um fragmento de cerrado de 10,15 hectares situado entre os paralelos $10^{\circ} 10' 55''$ e $10^{\circ} 11' 20''$ de latitude sul e entre os meridianos $48^{\circ} 10' 50''$ e $48^{\circ} 10' 30''$ de longitude oeste, pertencente ao Parque Estadual do Lajeado.

O Parque Estadual do Lajeado está localizado na região centro-oeste do Estado do Tocantins, próximo à cidade de Palmas, na Área de Proteção Ambiental (APA) da Serra do Lajeado, a 500 m de altitude (Figura 4).

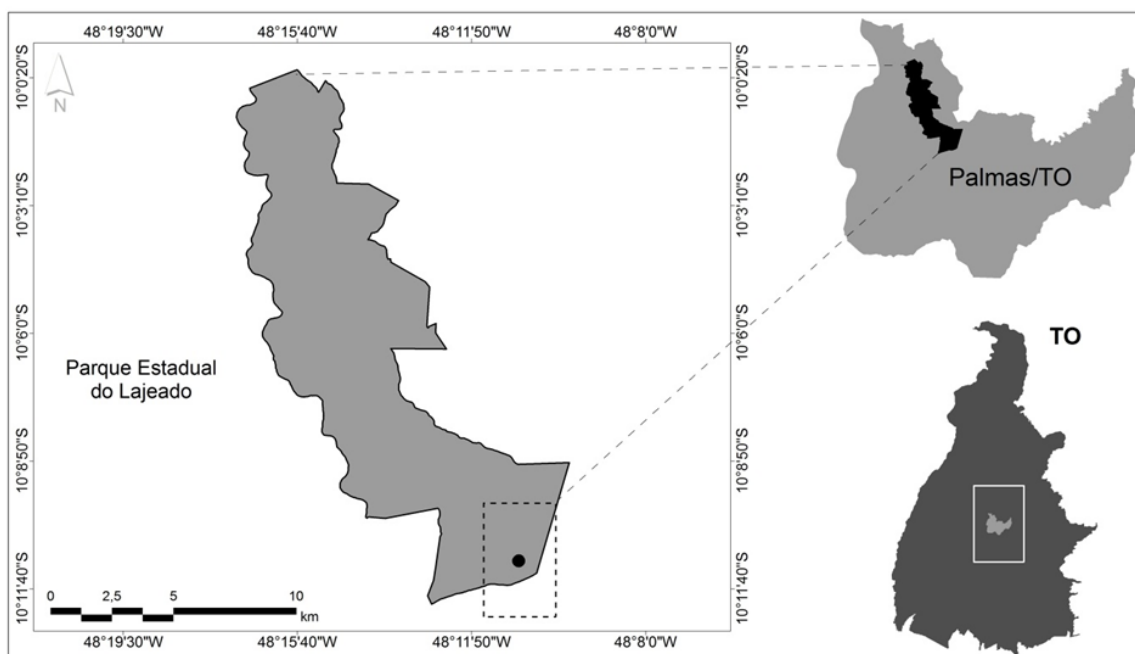


Figura 4 - Localização do fragmento de cerrado, no município de Palmas, estado do Tocantins, Brasil.
Fonte: MIGUEL (2014)

O solo predominante na referida área de estudo, de acordo com a classificação da Embrapa (2007), é o Latossolo Vermelho Escuro, não hidromórfico, com horizonte B latossólico. A região apresenta relevo plano a ondulado e o clima, conforme a classificação de Köppen e Geiger (1928) e Thornthwaite (1948), é do tipo C2wa'a', caracterizado pela ocorrência de duas estações, com uma estação seca de maio a setembro e uma estação chuvosa de outubro a abril, sendo úmido e sub-úmido com moderada

deficiência hídrica no inverno. O índice de umidade positivo varia de 0 a 40%, com total pluviométrico chegando a 1700 mm ao ano.

O cerradão estudado é caracterizado como distrófico (RATTER et al., 1971), sobre solo bem drenado. As árvores atingem cerca de 22 m de altura, com copas que se tocam e sub-bosque ralo e aberto. Predominam na área as espécies *Myrcia splendens*, *Emmotum nitens* e *Qualea parviflora*.

4.2 Coleta de dados

O inventário florestal foi realizado na área do fragmento, considerando um processo de amostragem sistemático em dois estágios (PÉLLICO NETO; BRENA, 1997), onde transectos de 20 m de largura e comprimentos variáveis foram implantados, equidistantes 60 m. Cada transecto foi subdividido em parcelas de 400 m² (20 m x 20 m). No total foram implantados oito transectos equidistantes, de comprimentos variáveis, e 54 parcelas de 400 m², totalizando 2,08 ha amostrados (Figura 5).

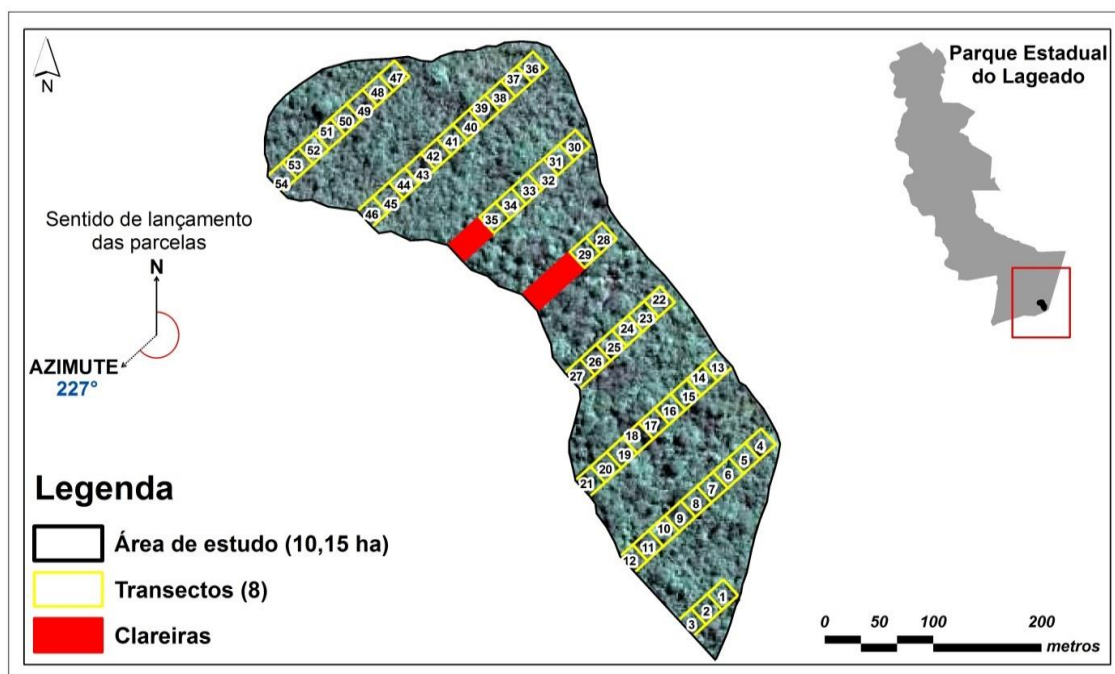


Figura 5. Disposição dos transectos e parcelas na área de inventário no Parque Estadual da Serra do Lajeado - TO - Brasil.

Todas as árvores amostradas tiveram os seus diâmetros à 1,3 m do solo altura total mensuradas. Os diâmetros foram medidos utilizando uma suta e a medição da altura foi

realizada com o auxílio de uma régua telescópica de 15 m. Alturas superiores a 15 m foram estimadas visualmente, tomando como referência à própria régua. A identificação do material botânico aos níveis de família, gênero e espécie (APG IV, 2016) foi realizada *in loco* ou por meio de consultas às chaves analíticas, à herbários e à especialistas. Todo material botânico coletado foi depositado no Herbário da Universidade de Brasília (UnB).

A partir dos dados do inventário florestal realizado na área, foi obtido o número de árvores por espécie e por classe de diâmetro que seriam cubadas rigorosamente, visando determinar os estoques em volume, biomassa e carbono para as árvores do fragmento de cerradão analisado.

Desta forma, todas as árvores mensuradas em campo, com $DAP \geq 5$ cm, foram distribuídas em classes de diâmetro. O número de classes de diâmetro foi obtido a partir da fórmula de Herbert Sturges (1926). Após a distribuição dos dados em classes de diâmetro, foi determinado o número de árvores que deveria ser cubado rigorosamente em cada classe de diâmetro. Foi realizada a cubagem de aproximadamente 10% das árvores de cada classe de diâmetro para representar a área como um todo, sendo que, em cada classe deveria conter, pelo menos, um representante de cada espécie registrada na área, com exceção da espécie *Caryocar coriaceum*, por ser uma espécie que, por lei, é proibido o corte. No total 80 indivíduos foram abatidos.

Após cortadas, as árvores foram seccionadas e pesadas em diferentes compartimentos: folhagem, galhos, fuste e casca. Na separação dos compartimentos foi considerado como fuste, o tronco principal até o início da formação dos galhos. O peso verde dos compartimentos de cada árvore foi obtido com o auxílio de uma balança eletrônica com capacidade máxima de 300 kg, com precisão de 0,05 kg.

Obtido o peso verde dos diferentes compartimentos (folhagem, galhos, fuste e casca), foram retiradas amostras do material vegetal visando a obtenção da biomassa seca. Para o fuste, foram retiradas três amostras de madeira, na forma discos com 5 cm de espessura, coletados na base, no meio e no ápice do fuste. O mesmo procedimento foi feito para os galhos, contudo, os discos foram retirados de três galhos selecionados, sendo um galho grosso, um galho médio e um galho fino. Quanto ao compartimento folhas, foi retirada uma amostra de aproximadamente 300 gramas para a secagem em estufa. A

amostra das folhas foi composta de folhas da parte inferior, médio e superior da copa das árvores.

As amostras foram levadas ao laboratório de Tecnologia da Madeira da Universidade de Brasília e colocadas em estufa, para secagem a uma temperatura de $103 \pm 2^\circ\text{C}$, com exceção das folhas que foram secas a temperatura de $70 \pm 2^\circ\text{C}$, até obtenção da massa constante (variação de 1%) (SMITH, 1954). Após a secagem, cada amostra foi pesada novamente para obter o seu peso seco.

Com os valores de peso úmido e peso seco das amostras, foi calculado o teor de umidade em base seca, para o fuste, para o galho, para a casca, e para folhas de cada indivíduo. De posse deste valor, foi possível estimar a biomassa seca a partir da biomassa verde obtida em campo (VALE, 2000; BARBOSA; FERREIRA, 2004; ROCHA, 2011).

O teor de umidade foi obtido utilizando a seguinte relação (ABNT NBR 11941, 1997):

$$U_{\max} \% = \frac{M_{\text{sat}} - M_0 \%}{M_0 \%} \cdot 100$$

onde: $U_{\max} \% =$ teor de umidade da amostra (%);
 $M_{\text{sat}} =$ peso verde da amostra (g ou Kg);
 $M_0 \% =$ peso seco da amostra (g ou Kg)

Os dados de cubagem foram compostos por 80 indivíduos distribuídas em 34 espécies, variando o DAP entre 5,3 cm a 49,0 cm e a altura entre 3,8 m a 24,5 m. Os dados encontram-se disponíveis no Anexo A.

Os valores de densidade da madeira foram obtidos por dados secundários. Para as 34 espécies foram utilizados trabalhos com amostras de árvores no Cerrado (VALE, BRASIL e LEÃO, 2002; OLIVEIRA, 2014; SILVA, 2014; SOUZA, 2020).

4.3 Variáveis independentes

Chave et al. (2005) define como as principais variáveis preditoras utilizadas em estudos de biomassa: diâmetro do tronco, densidade da madeira, altura total e tipo florestal. Deste modo, foram selecionadas o DAP, altura e densidade para que se pudesse obter um modelo representativo, seja por regressão ou por inteligência artificial na estimativa da biomassa. Ainda segundo Chave et al. (2005), a densidade da madeira é considerada uma variável importante na estimativa da biomassa, uma vez que ela se correlaciona com propriedades morfológicas, mecânicas, fisiológicas e ecológicas das plantas.

Com isso, no presente trabalho, espera-se que as variáveis independentes DAP e altura tenham alta correlação com a variável de interesse, e a variável densidade tenha sua correlação analisada, para um entendimento concreto sobre a real necessidade da sua inclusão na modelagem da biomassa, uma vez que a medição da densidade em campo é um trabalho dispendioso. Para Roitman et al. (2018) as maiores dificuldades na construção dos modelos genéricos e específicos são encontradas principalmente na amostragem destrutiva de árvores, justamente por ser uma tarefa onerosa.

4.4 Modelagem da biomassa usando regressão

Para estimar a biomassa das árvores por regressão foram utilizados 3 modelos, sendo um linear e dois não lineares (Tabela 1 **Erro! Fonte de referência não encontrada.**). Os ajustes dos modelos lineares e não-lineares foram realizados utilizando o programa *Statistica* (14.0.0.15) e o Microsoft Excel através do Método dos Mínimos Quadrados Ordinários (MQO).

Tabela 1 - Modelos hipsométricos ajustados para a estimativa da variável biomassa com e sem densidade.

MODELO	EQUAÇÃO
1 Spurr sem Densidade	$Biomassa = \beta_0 + \beta_1 dap^2 ht + e$
2 Spurr com Densidade	$Biomassa = \beta_0 + \beta_1 dap^2 ht + \beta_2 * d + e$
3 Schumacher-hall sem densidade	$Biomassa = \beta_0 * dap^{\beta_1} * ht^{\beta_2} + e$
4 Schumacher-hall com densidade	$Biomassa = \beta_0 * dap^{\beta_1} * ht^{\beta_2} * d^{\beta_3} + e$
5 Husch modificado sem densidade	$Biomassa = \beta_0 * dap^{\beta_1} + e$
6 Husch modificado com densidade	$Biomassa = \beta_0 * (dap^2 * d)^{\beta_1} + e$

onde: ht = altura total da árvore (m); dap = diâmetro a 1,30 m do solo (cm); d = densidade (kg); β_0 , β_1 , β_2 e β_3 = coeficientes a serem obtidos

Fonte: o autor

A escolha dos melhores modelos para a estimativa de biomassa com e sem a variável densidade foram baseadas nos critérios de ajuste e seleção indicados por Draper e Smith (1981), os quais foram: o coeficiente de correlação (r), o erro padrão residual absoluto em porcentagem (S_{yx} e $S_{yx}\%$), e a análise gráfica dos resíduos (observados versus preditos, histograma de frequência em classes de erros relativos). As equações para cálculo de S_{yx} e $S_{yx}\%$ são as seguintes:

$$S_{yx} = \sqrt{\frac{\sum(B - B_{est})^2}{n - p - 1}} \quad e \quad S_{yx}\% = \frac{S_{yx}}{\bar{B}} \cdot 100$$

- onde:
- B - biomassa de referência
 - B_{est} - biomassa estimada
 - \bar{B} - biomassa de referência média
 - n - tamanho da amostra

p - número de variáveis do modelo

Finalmente foi utilizado o método da diferença agregada (MIGUEL et al., 2015) para verificar a existência de superestimativa ou subestimativa dos modelos. A diferença agregada é calculada pela seguinte equação:

$$DA\% = \frac{\sum Y_{obs} - \sum Y_{est}}{\sum Y_{obs}} \cdot 100$$

onde: DA - diferença agregada em percentagem;

$\sum Y_{obs}$ - somatório dos valores advindos do inventário;

$\sum Y_{est}$ - somatório dos valores estimado pelo modelo.

4.5 Modelagem da biomassa estimada usando redes neurais artificiais

As redes neurais utilizadas para estimar a biomassa das árvores amostradas no cerradão foram treinadas e validadas pelo programa *Neuro Forest* 3.2. A camada de entrada, dependendo da situação, foi formada pelas variáveis dap e ht, ou pelas variáveis dap, ht e d, para o caso de estimação sem densidade e com densidade. A camada de saída foi constituída pela biomassa total observada. As camadas intermediárias foram compostas por 8 neurônios conforme valor Default do programa, formando então as redes conforme mostra a Figura 6.

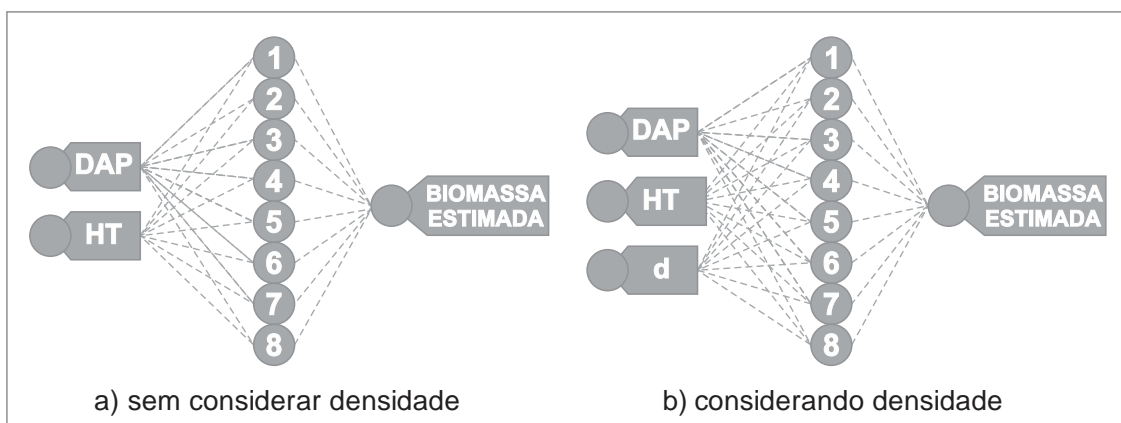


Figura 6 - Diagramas das RNA
Fonte: o autor

O processo de seleção e validação das RNAs, se deu utilizando os mesmos critérios dos modelos de regressão. Neste estudo, o número total de ciclos foi de 3.000 ciclos por variável, tendo assim, 6.000 ciclos na estimativa sem densidade e 9.000 na estimativa com densidade, conforme valor Default. A arquitetura utilizada foi a sigmoideal e a função do tipo *multilayer* perceptron (MLP). Para tanto foram treinadas 100 redes e foram selecionadas a melhor com e sem a variável densidade da madeira.

5 RESULTADOS E DISCUSSÕES

5.1 Estatística descritiva

O trabalho foi desenvolvido no inventário realizado no Parque Estadual da Serra do Lajeado – Palmas -TO resultou em dados de dap, altura (ht) e densidade (d) de 80 indivíduos em área de cerradão.

Uma primeira análise possível se refere a quantificação estatística da amostra calculando valores como média, variância, desvio-padrão, erro padrão, coeficiente de variação e os valores máximo e mínimo para as variáveis predictoras e predita (Tabela 2).

Tabela 2 - Dados estatísticos das amostras do inventário florestal na APA da Serra do Lajeado – Palmas - TO, Brasil.

	Mínimo	Máximo	Média	Desvio Padrão	Variância	Erro Padrão	CV %
Biomassa	9.42	2552.90	183.74	389.76	151909.36	43.58	212.12
dap	5.30	49.00	12.52	7.95	63.28	0.89	63.54
ht	3.80	24.50	10.26	3.40	11.53	0.38	33.08
d	0.35	0.88	0.65	0.12	0.01	0.01	18.52

onde: dap = diâmetro a 1,30 m do solo (cm); ht = altura total da árvore (m); d = densidade (g/cm³); CV = coeficiente de variação(%).

Fonte: o autor.

Uma estatística importante a ser observado é o coeficiente de variação em percentagem (CV%), pois ele mostra o quão homogêneo são os dados. Gomes (1990) classifica como CV% baixo, quando é inferior a 10%, médios entre 10 e 20%, altos entre 20 e 30% e, muito altos, acima de 30%. Ao observar o CV% da variável biomassa e da variável dap percebe-se que o valor é considerado muito alto, mostrando que essa variável é formada por dados heterogêneos e por conseguinte apresenta uma dispersão alta. Em menor proporção, a variável ht também apresenta essas mesmas características. Entretanto, no caso da variável d, o coeficiente é considerado médio mostrando uma relativa homogeneidade da variável. Essa constatação é esperada em função das variações entre os valores máximo e mínimo dessas variáveis e por se tratar de uma área nativa.

5.2 Correlação

O coeficiente de correlação de Pearson é um indicador que mostra a probabilidade de interdependência entre duas variáveis contínuas. O intervalo da correlação varia entre +1 e -1, onde o valor 1 indica dependência total e 0 (zero) independência. O sinal positivo indica uma associação positiva, ou seja, quando uma variável aumenta a outra também e, o sinal negativa, a associação é invertida.

Hinkle et al. (2003) estabelece um ranqueamento para definir o grau de interdependência entre variáveis. Se o valor da correlação estiver entre 0,30 e 0,49 a probabilidade de interdependência é considerada baixa; se o valor for entre 0,50 e 0,69 a probabilidade é moderada e, acima de 0,70, a probabilidade é considerada alta.

Na **Erro! Fonte de referência não encontrada.3**, é mostrada a matriz de correlação entre a variável dependente biomassa e as independentes dap, ht e densidade (d).

Tabela 3. Matriz de correlação entre a variável dependente (biomassa) e as variáveis independentes (dap, ht e d) obtidas do inventário florestal na APA da Serra do Lajeado-Palmas-TO, Brasil.

Variável	Biomassa	dap	ht	d
Biomassa	1			
dap	0,900	1		
ht	0,661	0,733	1	
d	0,278	0,236	0,187	1

onde: dap = diâmetro a 1,30 m do solo; ht = altura total da árvore; d = densidade; Coeficientes de correlação significativos para $\alpha = 0,05$.

Fonte: o autor

Na tabela 3 constata-se que a correlação entre a biomassa e a dap é alta, entre a biomassa e a ht é moderada e entre a biomassa e a densidade é baixa. Por outro lado, percebe-se que existe uma correlação alta entre o dap e a ht, o que é explicado pelo fato de o diâmetro dos indivíduos estar associado com suas alturas.

5.3 Estimativa da biomassa utilizando regressão

Os dados referentes aos ajustes dos modelos de regressão bem como suas estatísticas de ajuste e precisão encontram-se na Tabela 4.

Tabela 4 - Medidas de precisão dos modelos hipsométricos ajustados aos dados obtidas do inventário florestal na APA da Serra do Lajeado – Palmas-TO, Brasil.

N	Modelo	Parâmetros	Erro Padrão	F	r	S _{yx}	S _{yx} %	
1	Spurr sem densidade	β0	2,33	9,8573	1.823,34	0,9903	57,60	31,07
		β1	0,06	0,0014				
2	Spurr com densidade	β0	-54,89	49,5851	919,16	0,9996	55,18	29,77
		β1	0,06	0,0015				
		β2	89,40*	76,1184				
3	Schumacher-hall sem densidade	β0	0,09	0,0265	858,30	0,9932	48,87	26,36
		β1	2,15	0,0666				
		β2	0,69	0,0979				
4	Schumacher-hall com densidade	β0	0,16	0,0519	710,75	0,9926	50,49	27,24
		β1	1,88	0,1029				
		β2	0,90	0,1206				
5	Husch modificado sem densidade	β0	0,31	0,0835	1400,532	0,9838	73,12	39,45
		β1	2,33	0,0729				
		β2	0,96	0,3134				
6	Husch modificado com densidade	β0	0,98	0,2433	707,04	0,9759	87,92	47,43
		β1	1,04	0,0352				

onde: β0, β1, β2 e β3 = coeficientes obtidos; F = calculado ($\alpha=0,05$); r = coeficiente de correlação; S_{yx} = erro padrão da estimativa em kg; S_{yx}% = erro padrão da estimativa percentual; * Não significativo

Fonte: o autor

Ao analisarmos os modelos através dos indicadores estatístico, podemos verificar que todos tiveram um alto grau de correlação, sendo todos muito próximo de 1. No entanto, os valores de S_{yx} e S_{yx}% tiveram valores relativamente altos e distinção notável entre os modelos, de modo que a melhor equação para variáveis sem e com densidade foi o de Schumacher-hall, pois além de ter um alto grau de correlação, é o modelo com o menor erro padrão da estimativa percentual (S_{yx}%).

Quando analisamos o gráfico de preditos por observados (Figura 7, gráficos A), primeiramente nota-se a ausência do modelo de Spurr com densidade. Entende-se que o modelo apresentou dados não significativos para inserção da variável densidade da

madeira e, portanto, foi excluído das análises gráficas. Ao analisarmos os demais modelos, nota-se que todos apresentaram uma certa linearidade e proximidade a linha de tendência, tendo ainda os modelos 1, 3 e 4 valores visivelmente mais coesos e perto da linha de inclinação.

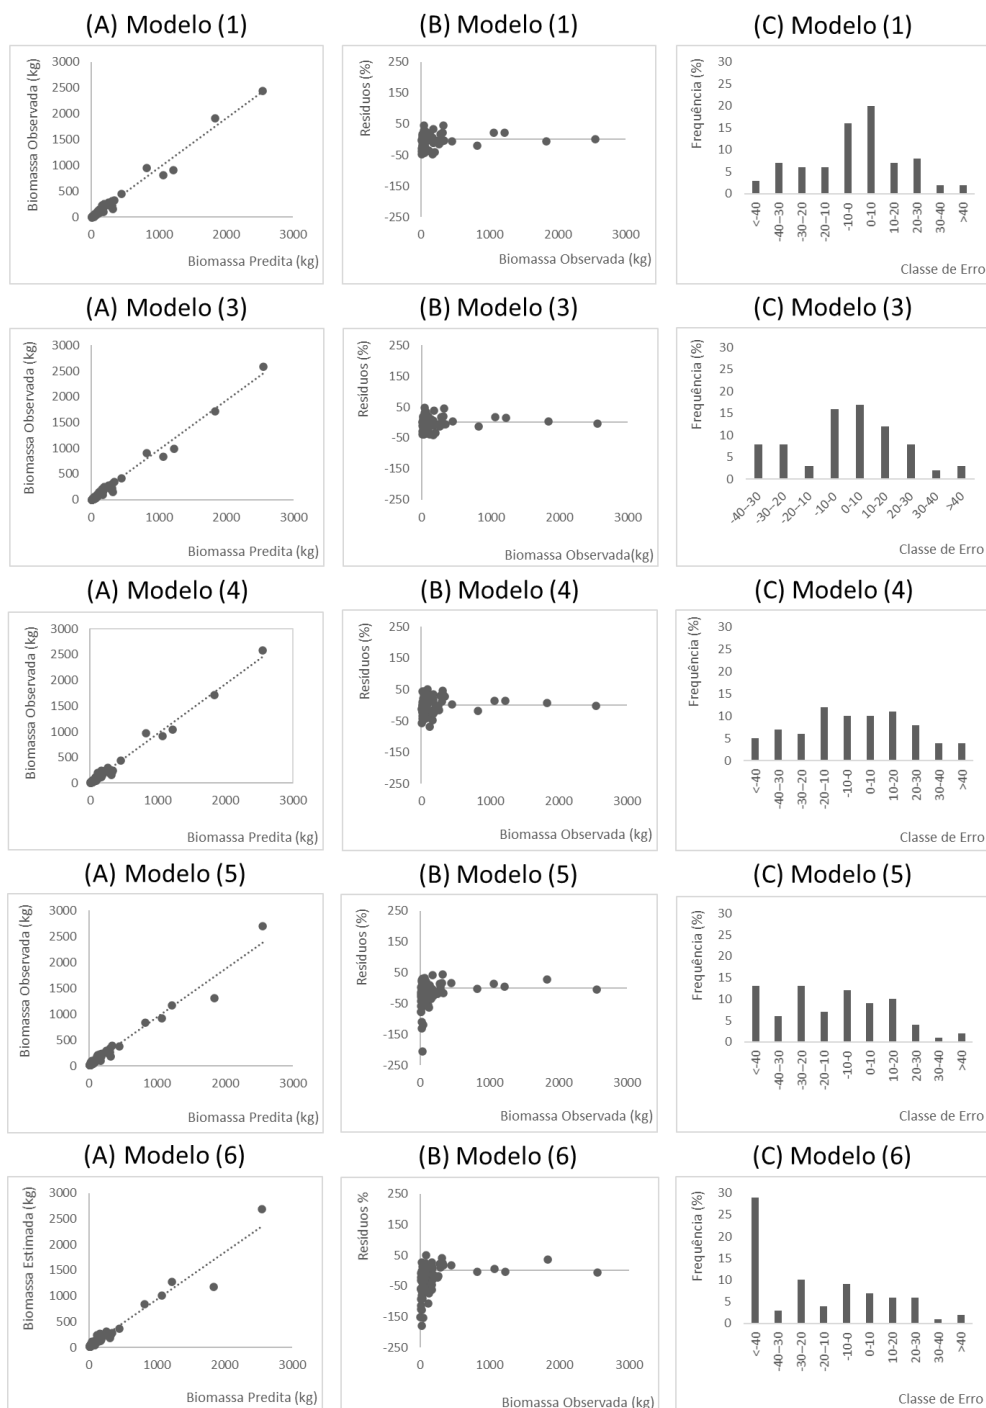


Figura 7 - Representação gráfica da correlação entre biomassa observadas e preditas (A), distribuição dos erros de estimativa (B) e histograma da frequência de erros (C), para Equações de Regressão: (1) Spurr sem densidade; (3) Schumacher-Hall sem densidade; (4) Schumacher-Hall com densidade; (5) Husch adaptado sem densidade e (6) Husch adaptado com densidade.

Fonte: o autor.

Quando se analisa os gráficos de resíduos e classes de erros (gráficos B e C), o comportamento dos modelos é semelhante aos dos gráficos A, tendo uniformidade e a maior parte dos valores distribuídos entre ± 50 em todos os modelos, sobressaindo os modelos 1, 3 e 4. Com isso, confirma-se a superioridade do modelo de Schumacher-Hall sem e com densidade para estimativa da biomassa nesta área de cerrado. Todavia, a variável densidade não trouxe melhoras aos modelos.

Ao compararmos valores de $S_{yx}\%$ com trabalhos semelhantes, encontramos estimativas feitas por Souza (2020) nas quais o erro padrão da estimativa ($S_{yx}\%$) apresentou valores entre 25,64% e 97,73%. Deste modo, entende-se que essa alta dispersão entre valores observados e estimados como citado pela autora, demonstra a heterogeneidade das características dendrométricas do Cerrado (OLIVEIRA et al., 2019). Para Rezende et al. (2006) valores altos de erro padrão, refletem a variabilidade real da natureza, de modo que uma intensidade de amostragem maior poderia melhorar a relação da regressão.

5.4 Estimativa da biomassa utilizando redes neurais artificiais

Observando-se os resultados dos valores estatístico do coeficiente de correlação (r) e dos erros estimados S_{yx} e $S_{yx}\%$, verifica-se que a entrada do parâmetro densidade não melhorou de modo efetivo os valores de biomassas nas RNAs, assim como visto nos modelos de regressão (Tabela 5).

Tabela 5 - Medidas de precisão das redes neurais artificiais treinadas para os dados obtidos do inventário florestal na APA da Serra do Lajeado – Palmas – TO, Brasil.

MODELO	ARQUITETURA	CAMADA DE ENTRADA	S_{yx}	$S_{yx}\%$	r
RNA sem densidade	MLP 2-8-1	dap e ht	21,850	10,823	0,9987
RNA com densidade	MLP 3-8-1	dap, ht e d	20,234	10,023	0,9989

onde: dap = diâmetro a 1,30 m do solo; ht = altura total da árvore; d = densidade; r = coeficiente de correlação; S_{yx} = erro padrão da estimativa (m); $S_{yx}\%$ = erro padrão da estimativa percentual;

Fonte: o autor

É possível observar que tanto para RNA MLP 2-8-1 quanto a MLP 3-8-1 o coeficiente de correlação é alto, com valores superiores a 0,998. Em estudos semelhantes, Cunha (2015) encontrou valores de correlações iguais ou superiores a 0,9722. Citado pela

autora, temos ainda valores comparativos de estudos semelhantes de Almeida et al. (2009), com valores de coeficientes de correlação para estimar volume de biomassa de 0,81, e de Foody et al. (2001) com valores de correlação entre dados de campo e estimados de 0,8033. Em todos os estudos os valores citados foram considerados como tendo uma confiabilidade aceitável ou alta, de modo que, os valores listados na Tabela 5 e referentes ao presente estudos, são superiores aos supracitados. Portanto, com alto grau de confiabilidade, com valores muito próximos à confiabilidade máxima, 1.

O alto grau de correlação encontrado pode ser atrelado à assertividade em se escolher valores de entrada para redes neurais que influenciem diretamente na estimativa de biomassa da vegetação analisada. No entanto, é de se surpreender que a densidade como fator chave de análise dos modelos, não tenha gerado grandes diferenças estatísticas na estimação desses valores, uma vez que a densidade da madeira é comumente correlacionada como um fator importante na estimativa da biomassa. Como citado por Chave et al. (2005), a altura total da árvore (ht) e a densidade básica da madeira (d) são os parâmetros mais importantes na previsão da biomassa. A não significância da densidade também é possível de ser observada na Figura 8, que apresenta a representação gráfica dos resíduos resultantes das RNAs.

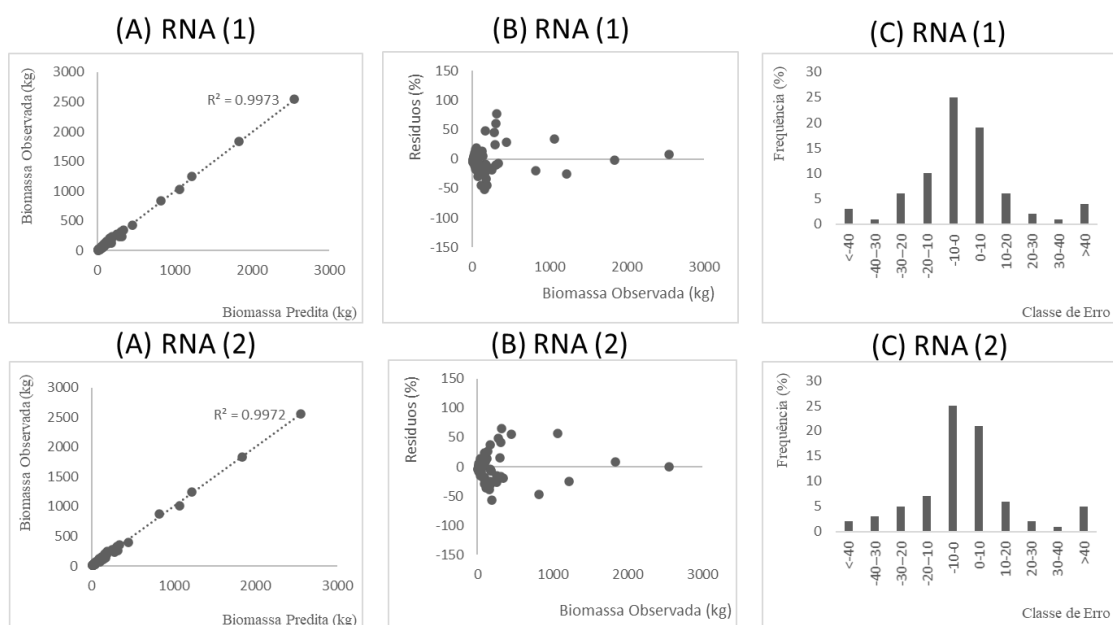


Figura 8 - Representação gráfica da correlação entre biomassa observadas e previstas (A), distribuição dos erros de estimativa (B) e histograma da frequência de erros (C), para (1) Rede Neural sem densidade do tipo MLP 2-8-1 e (2) Rede Neural com densidade do tipo MLP 3-8-1, ajustada aos dados obtidos do inventário florestal na APA da Serra do Lajeado – Palmas – TO, Brasil.

Fonte: o autor

Mesmo com resultados satisfatórios, as RNAs selecionadas apresentam uma tendência a super e subestimar os valores de biomassa (Figura 8- gráficos A e B). É possível notar ainda, que quanto maior a biomassa estimada, menor essa tendência, deixando a entender que os diâmetros menores seriam os que dificultariam essa previsão, uma vez que é o fator com maior correlação com a biomassa. Altura e densidades menores também tendem a um percentual maior de erros, porém em menor proporção. Outro fator que poderia afetar essa estimativa seria a grande diferença entre valores de biomassa, os quais podem gerar altos valores no cálculo do resíduo.

Observa-se ainda que nos gráficos de biomassa observada *versus* biomassa estimada (Figura 8, modelo 1, gráficos A e B) os valores encontrados seguem ou estão próximos da linha de tendência, demonstrando que não houve diferença significativa na estimativa.

Corroborando com os gráficos de preditos por observados e distribuição residual, no histograma de erros, é possível verificar que a maior quantidade de erros ocorreu nas classes ± 10 , demonstrando assim que as RNAs conseguem prever com precisão as estimativas da biomassa individual de árvores em áreas de cerrado.

5.5 Comparação entre a regressão e a RNA

A determinação dos modelos por regressão e redes neurais se mostrou viável, conforme dados estatísticos expostos nas Tabelas 4 e 5. No entanto, para definir a compatibilidade e validação das RNAs e modelos de regressão selecionados, com e sem a presença da variável densidade da madeira, foi realizada uma análise de variância (ANOVA), considerando um delineamento inteiramente casualizado, na qual a biomassa verdadeira de aproximadamente 31% das árvores amostradas foram consideradas como testemunhas (Tabela 6).

Tabela 6 - Análise de variância (ANOVA) aplicada sobre as biomassas reais e estimadas pelo modelo de regressão e rede neural artificial selecionados.

Fonte da variação	SQ	GL	MQ	F	valor-P	F crítico
Tratamentos	5.052,0838	4	1.263,0210	0,0077	0,9999	2,4472
Resíduos	19.777.879,63	120	164.815,6636			
Total	19.782.931,72	124				

onde: SQ = soma dos quadrados; MQ = Quadrado médio, GL = graus de liberdade; F = calculado; $p > 0,05$

Fonte: o autor

Na Tabela 6, verifica-se que o F calculado (0,0077) ao nível de significância de 5%, é inferior ao F crítico (2,4472), o que demonstra a não existência de diferença significativa entre as redes neurais e os modelos de regressão, tanto sem densidade quanto com densidade, frente a biomassa determinada em campo.

Para verificar qual das técnicas, regressão ou RNA, apresentou uma acurácia maior, foi calculada a diferença agregada em percentagem (DA%). Na Tabela 7 estão colocadas as estatísticas r , S_{yx} e $S_{yx}\%$ dos métodos de predição com a presença ou não da densidade da madeira, em análise, além da DA% calculada para cada um deles.

Tabela 7 - Medidas de precisão de Schumacher-Hall e das redes neurais artificiais validadas para os dados obtidos do inventário florestal na APA da Serra do Lajeado – Palmas – TO, Brasil.

	MODELO	r	S_{yx}	$S_{yx}\%$	DA%
3	Schumacher-hall sem densidade	0,996	58,445	28,949	7,42159
4	Schumacher-hall com densidade	0,997	53,735	26,616	4,13213
MLP 2-8-1	RNA sem densidade	0,999	21,850	10,823	-0,3864
MLP 3-8-1	RNA com densidade	0,999	20,234	10,023	-0,45882

Onde: r = coeficiente de correlação; S_{yx} = erro padrão da estimativa em metros; $S_{yx}\%$ = erro padrão da estimativa percentual; DA% = diferença agregada em percentagem.

Fonte: o autor

Apesar de todos os modelos terem alto grau de correlação, existe uma diferença entre o erro padrão da estimativa percentual ($S_{yx}\%$) para modelos de regressão (28,949% e 26,616%) e redes neurais (10,823% e 10,023%). É perceptível também que as diferenças entre $S_{yx}\%$ para os modelos de regressão sem e com densidade, e modelos de RNA sem e com densidade, não apresentam grandes diferenças, todavia, ao ser analisadas as estatísticas de r e S_{yx} entre as técnicas de regressão e as RNAs, as últimas apresentam estatísticas de ajustes e precisão mais acuradas. Ao se analisar a DA% verifica-se a existência de superestimativa ou subestimativa entre os valores preditos e observados.

Dentre os modelos de regressão, a diferença agregada no modelo de Schumacher-hall com densidade (DA% = 4,13%) se mostrou ligeiramente mais acurado que o modelo sem densidade (DA% = 7,42%), tendo assim uma diferença aproximada de 3,5% entre modelos, com ambos subestimando a biomassa em relação a biomassa observada.

Quando analisados os modelos de RNAs, verifica-se que a presença ou ausência da densidade da madeira, pouco influenciou nos valores da estimativa da biomassa ($DA\% = -0,39\%$ e $DA\% = -0,46\%$, respectivamente).

Em função dos valores da $DA\%$ constata-se que as RNAs são mais acuradas que os modelos de regressão, mesmo que superestimem a biomassa calculada em relação a observada. Está subestimação pode ser desconsiderada em função do seu pequeno valor.

Segundo Miguel et al. (2015) por mais que um modelo apresente estatísticas de qualidade, é essencial que seja feita análise gráfica do resíduo, uma vez que os erros de tendência podem ocorrer em determinada amplitude de classe da variável resposta e não serem detectados pelas demais estatísticas. Com isso, faz-se necessária a comparação dos resíduos dos modelos de regressão e RNAs. conforme a Figura 9.

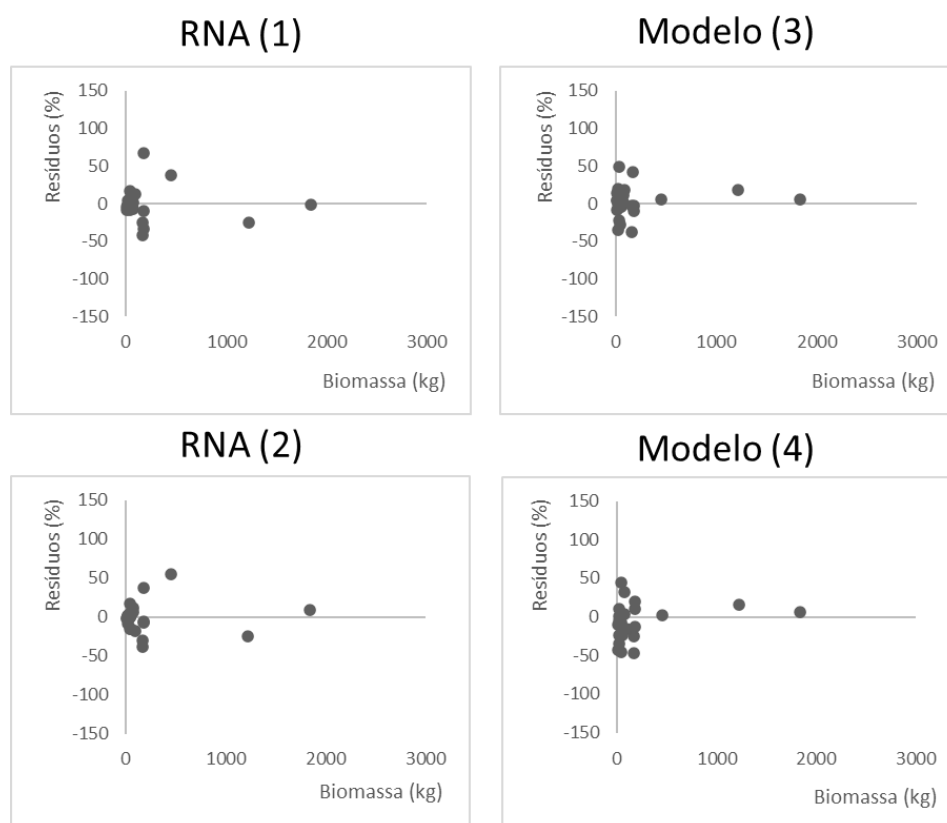


Figura 9. Representação gráfica da distribuição dos erros de estimativa para dados validados de (1) Rede Neural sem densidade do tipo MLP 2-8-1, (2) Rede Neural com densidade do tipo MLP 3-8-1, (3) Schumacher-Hall sem densidade e (4) Schumacher-Hall com densidade, ajustada aos dados obtidos do inventário florestal na APA da Serra do Lajeado – Palmas – TO, Brasil.

Fonte: O Autor

Na análise gráfica da Figura 9, é possível observar certa semelhança na distribuição dos resíduos entre modelos sem e com densidade, e que tanto nos modelos

de RNAs quanto nos de Schumacher-Hall os erros margeiam percentuais de ± 50 . No entanto, sob um olhar mais criterioso, identifica-se que nos modelos das redes neurais os erros tendem a se concentrar mais próximos do eixo das abcissas, enquanto no modelo regressão há uma dispersão maior desses resíduos no intervalo supracitado.

Complementa-se ainda a superioridade das RNAs com relação aos modelos de regressão, por elas possuírem uma etapa a menos no processo, devido ao fato de não necessitarem de um pré-tratamento ou mineração dos dados para o seu treinamento (ALMEIDA, 2020). Em seu trabalho, que trata de estimativas de altura através de modelos de regressão e redes neurais, as duas formas apresentaram estimativas de precisão, no entanto, as RNAs apresentaram indicadores estatísticos superiores, como no presente trabalho.

Essa superioridade das redes neurais também foi constatada no trabalho de Miguel et al. (2015), na qual tanto os modelos de redes quanto os de regressão foram satisfatórios para modelagem de volume e biomassa em área de cerradão. Para o autor, os dados foram satisfatórios para uma área de grande heterogeneidade, no entanto, as predições de RNAs foram superiores por apresentar erros menores e mais homogêneos.

Outros autores encontraram resultados semelhantes da eficiência preditiva das redes neurais, como Martins et.al. (2020) na estimativa da altura de árvores de *Eucalyptus grandis*, e Valente e Valente (2021) na estimativa do volume de madeira em florestas de eucaliptos. Carrijo (2020) corrobora para essa superioridade, tendo obtido acuracidade para estimar o potencial energético em áreas de cerradão, em concordância com os resultados obtidos neste trabalho.

6 CONCLUSÕES

Dentre os modelos de regressão testados, observou-se que o modelo de Schumacher-Hall foi superior aos modelos de Spurr e Husch adaptado, tanto para dados sem densidade como com densidade.

Para RNAs, tanto a MLP 2-8-1 quanto a MLP 3-8-1, apresentaram resultados satisfatórios e semelhantes, de modo que a densidade se torna uma variável dispensável na predição de biomassa em áreas de cerradão.

Embora a análise de variância aponte que modelos de regressão e RNAs não diferem nas estimativas, comparativamente, as redes neurais artificiais treinadas mostraram estatísticas de ajuste e precisão mais acuradas na estimativa da biomassa em área de cerradão. Diferente do preconizado na literatura, os resultados revelaram que a densidade da madeira é uma variável que não implica em melhorias na estimativa da biomassa em árvores individuais em áreas de cerradão, seja por técnicas de regressão ou inteligência artificial.

Por fim, os resultados desse trabalho deverão ser corroborados futuramente por novas pesquisas para diferentes fitofisionomias do Cerrado e, mesmo, para diferentes Biomas. Apesar da constatação que a densidade da madeira não influenciou de modo significativo na estimativa de biomassa neste experimento, ela pode impactar de forma positiva em outros tipos de florestas.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, A. C.; BARROS, P. L. C; MONTEIRO, J. H. A; ROCHA, B. R. P. Estimation of aboveground forest biomass in amazonia with neural networks and remote sensing. In: IEEE Latin America Transactions. Piscataway, v. 7, n. 1, p. 27-32, 2009. Disponível em: <https://doi.org/10.1109/TLA.2009.5173462> Acesso: 16/05/2021.

ALMEIDA, Mariana Pacheco de. **Predição da altura de *Tectona grandis* Linn F. por meio de modelos genéricos e redes neurais artificiais.** 2020. 55 f., il. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Florestal) - Universidade de Brasília, Brasília, 2020. Disponível em: <https://bdm.unb.br/handle/10483/27979> Acesso: 16/05/2021.

AZEVEDO, T. L. et al. Equações hipsométricas e volumétricas para um povoamento de Eucalyptus sp. localizado na FLONA do Ibura, Sergipe. **Revista Brasileira de Ciências Agrárias**, Recife, v. 6, n. 1, p. 105-112, 2011 Disponível em: http://www.agraria.pro.br/ojs-2.4.6/index.php?journal=agraria&page=article&op=view&path%5B%5D=agraria_v6i1a861 Acesso: 16/05/2021.

BARBOSA, R.I.; FERREIRA, C.A.C. 2004. Biomassa acima do solo de um ecossistema de “campina” em Roraima, norte da Amazônia Brasileira. **Acta Amazônica**, v.34, n.4, p.577-586. Disponível em: <https://doi.org/10.1590/S0044-59672004000400009> Acesso : 01/10/2021.

BATALHA, Marco. (2011). **O cerrado não é um bioma.** Biota Neotropica. 11. 10.1590/S1676-06032011000100001. Disponível em: https://www.researchgate.net/publication/267265390_O_cerrado_nao_e_um_bioma Acesso : 16/05/2021.

BINOTI, Mayra Luiza Marques da Silva. **Emprego de Redes Neurais Artificiais em mensuração e manejo florestal.** 2012. 138 f., Tese (Doutorado em Manejo Florestal; Meio Ambiente e Conservação da Natureza; Silvicultura; Tecnologia e Utilização de) - Universidade Federal de Viçosa, Viçosa, 2012. Disponível em: <https://locus.ufv.br/handle/123456789/579> Acesso: 16/05/2021.

BUENO, Gabriel Fernandes. **Redes Neurais Artificiais aplicadas na modelagem de relações dendrométricas e morfométricas de espécies arbóreas do Cerrado.** 2020. 45 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Florestal) - Universidade Federal de Uberlândia, 2020. Disponível em: <https://repositorio.ufu.br/handle/123456789/30810> Acesso: 16/05/2021.

BRASIL, Instituto Chico Mendes de Conservação da Biodiversidade. Centro Nacional de Pesquisa e Conservação de Aves Silvestres (Org.). **Biodiversidade do Cerrado.** Cabedelo - PB: Cemave/icmbio, 2014. 88 p. Disponível em: <https://www.icmbio.gov.br/cbc/conservacao-da-biodiversidade/biodiversidade.html#conteudo> . Acesso: 16/05/2021.

CARRIJO, J. V. N. **Inteligência artificial associada à dados de satélite na predição do potencial energético em áreas de cerradão.** 2019. 63 f., Dissertação (Mestrado em Ciências Florestais) - Universidade de Brasília. Brasília, 2019. Disponível em: <https://repositorio.unb.br/handle/10482/35322> Acesso: 16/05/2021.

CARRIJO, J. V. N. et al.. Artificial intelligence associated with satellite data in predicting energy potential in the Brazilian savanna woodland area. **iForest-Biogeosciences and Forestry**, 2020: 13(1), 48-55. <https://doi.org/10.3832/ifor3209-012> Acesso: 01/10/2021.

CASTRO, R.V.O.; SOARES, C.P.B.; LEITE, H.G.; SOUZA, A.L.; NOGUEIRA, G.S.; MARTINS, F.B. (2013). Individual Growth Model for Eucalyptus Stands in Brazil Using Artificial Neural Network. **ISRN Forestry**. 2013: 1-12. <https://doi.org/10.1155/2013/196832> Acesso: 01/10/2021.

CASTRO SOARES DE OLIVEIRA, ANDERSON & SOUZA, ADEMÁRIA & LACERDA, WILIAN & GONÇALVES, LUCIENE. (2010). **Aplicação de redes neurais artificiais na previsão da produção de álcool**. Ciencia E Agrotecnologia - CIENC AGROTEC. 34. 10.1590/S1413-70542010000200002.

CHAVE, J. et al. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. *Oecologia*, v. 145, n. 1, p. 87–99, 2005. Disponível em: <http://www.fao.org/docrep/W4095E/W4095E00.htm> Acesso: 15/10/2021.

CUNHA, Eduarda Gabriela Santos. Quantificação de biomassa em Floresta estacional semidecidual por meio de redes neurais artificiais. Dissertação (mestrado) – Universidade Federal dos Vales do Jequitinhonha e Mucuri. Programa de Pós-Graduação em Ciência Florestal. Diamantina, p.75, 2015. Disponível em: <http://acervo.ufvjm.edu.br/jspui/handle/1/1015> Acesso: 15/10/2021

DIAMANTOPOULOU, M.J.. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and Electronics in Agriculture**. 2005: 10 (3): 235-244. Disponível em: <https://doi.org/10.1016/j.compag.2005.04.002> Acesso: 01/10/2021

DRAPER, N.; SMITH, H. Applied regression Analysis 3rd Edition John Wiley and Sons. **New York**, 1997.

EGRIOGLU, E.; YOLCU, U.; ALADAG, C.H.; BAS, E. Recurrent multiplicative neuron model artificial neural network for non-linear time series forecasting. **Procedia - Social and Behavioral Sciences**, v.109, p.1094-1100, 2014. Disponível: <https://doi.org/10.1016/j.sbspro.2013.12.593> Acessado em: 01/10/2021.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. 2006. **Sistema Brasileiro de classificação de Solos**. 2 ed. Rio de Janeiro: Embrapa Solos, 306 p. Disponível em: <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/338818> Acessado em: 16/05/2021.

FIGUEIREDO, E. O. **Avaliação de povoamentos de teca (Tectona grandis L.f.) na microrregião do Baixo Rio Acre**. 301 f. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal de Lavras. Lavras, 2005. Disponível em: http://iquiri.cpfac.embrapa.br/pdf/evandro_dissertacao.pdf Acesso: 01/10/2021.

FOODY, G. M et al. Mapping the biomass of Bornean tropical rain forest from remotely sensed data. **Global Ecology and Biogeography**, v. 10, n. 4, p. 379-387, 2001. Disponível em: <http://dx.doi.org/10.1046/j.1466-822X.2001.00248.x> Acesso: 01/10/2021.

FRANÇOSO, R. D. et al. Habitat loss and the effectiveness of protected areas in the Cerrado biodiversity hotspot. **Natureza & Conservação**, v. 13, p. 35-40, Jan./June 2015. DOI: 10.1016/j.ncon.2015.04.001 Disponível em: <https://doi.org/10.1016/j.ncon.2015.04.001> Acesso:01/10/2021.

GOMES, F.P. **Curso de estatística experimental**. 12.ed. São Paulo: Nobel, 1990. 467p.

GORGENS, E. B.; LEITE, H. G.; SANTOS, H. N.; GLERIANI, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, Viçosa-MG, v.33, n.6, p.1141-1147, 2009. Disponível em: <https://doi.org/10.1590/S0100-67622009000600016> Acesso: 16/05/2021.

HINKLE, D. E., et al. Applied statistics for the behavioral sciences. **Cengage Learning**, Boston: [s. n.], v. 5, p. 756, 2003.

KLINK, Carlos; MACHADO, Ricardo. (2005). **A conservação do Cerrado brasileiro**. Megadiversidade. 1. Disponível em: https://www.researchgate.net/publication/228342037_A_conservacao_do_Cerrado_brasileiro Acesso:16/05/2021.

LIMA, Jorge Enoch Furquim Werneck; SILVA, Euzébio Medrado da. **Estimativa da produção hídrica superficial do Cerrado brasileiro**. In: SCARIOT, A.; SOUSA-SILVA, J. C.; FELFILI, J. M. (Orgs.). Cerrado: ecologia, biodiversidade e conservação. Brasília: Ministério do Meio Ambiente, 2005.

MARTINS, M. T. et al. **Estimação da altura de plantios florestais de eucalipto por regressão e redes neurais**. Biofix Scientific journal, v.5, n. 1 (2020) Disponível em: <http://dx.doi.org/10.5380/biofix.v5i1.68839> Acesso: 01/10/2021

MEISTER, Schelen Gressel. **A degradação de nascentes e a crise hídrica do cerrado**. 2017. 62 f. Monografia (Especialização em Análise Ambiental e Desenvolvimento Sustentável) – Instituto CEUB de Pesquisa e Desenvolvimento, Centro Universitário de Brasília, Brasília, 2017. Disponível em: <https://repositorio.uniceub.br/jspui/handle/235/11527> Acessado em: 16/05/2021.

MIGUEL, E. P. **Avaliação Biométrica e Prognose da Produção de *Eucalyptus urophylla* (S.T. Blake) na região norte do estado de Goiás**. Dissertação (Mestrado em Engenharia Florestal) – Programa de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná. Curitiba, p. 161. 2009. Disponível em: <http://hdl.handle.net/1884/18326>. Acesso: 16/05/2021.

MIGUEL, Eder Pereira. **Caracterização da flora e da produção em volume, biomassa e carbono da vegetação arbórea em área de Cerradão no estado do Tocantins**. 2014. xiv, 81 f., il. Tese (Doutorado em Engenharia Florestal) - Universidade de Brasília, Brasília, 2014. Disponível em: <https://repositorio.unb.br/handle/10482/16656> Acesso: Acesso: 16/05/2021.

MIGUEL, E. P.; REZENDE, A. V.; LEAL, F. A.; MATRICARDI, E. A. T.; VALE, A. T.; PEREIRA, R. S. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerradão com dados de satélite. **Pesquisa Agropecuária Brasileira**, Brasília

– DF, v.50, n.9, p.829-839, set. 2015. Disponível em: <https://doi.org/10.1590/S0100-204X2015000900012>. Acesso: 16/05/2021.

MORAIS, V. A. et al. Carbon and biomass stocks in a fragment of Cerradão in Minas Gerais state, Brazil. **Cerne**, Lavras, v. 19, n. 2, p. 237-245, abr./jun. 2013. Disponível em: <https://doi.org/10.1590/S0104-77602013000200007> Acesso: 01/10/2021.

MORANDI, P.S.; MARIMON, B. S.; MARIMON JUNIOR, B. H. Tree diversity and above-ground biomass in the South America Cerrado biome and their conservation implications. **Biodiversity and Conservation** 2020: 29, 1519–1536 Disponível em: <https://doi.org/10.1007/s10531-018-1589-8> Acesso: 01/10/2021.

OLIVEIRA, C. P. et al. Comparação de modelos estatísticos para estimativa da biomassa de árvores, e estimativa do estoque de carbono acima do solo em cerrado. **Ciência Florestal**, 2019: 29(1), 255-269. Disponível em: <https://doi.org/10.5902/1980509827065> Acesso: 01/10/2021.

OLIVEIRA, G. M. V. **Densidade da madeira em Minas Gerais: amostragem, espacialização e relação com variáveis ambientais**. 2014. 125 p. Tese (Doutorado em Engenharia Florestal) - Universidade Federal de Lavras, Lavras, 2014. Disponível em: <http://repositorio.ufla.br/jspui/handle/1/4880> Acesso: 01/10/2021.

PAIVA, A. O.; REZENDE, A. V.; PEREIRA, R. S. Estoque de carbono em Cerrado sentido restrito do Distrito Federal. **Revista Árvore**, Viçosa, MG, v. 35, n. 3, p. 527-538, 2011. Disponível em: <https://doi.org/10.1590/S0100-67622011000300015> Acesso: 01/10/2021.

PÉLICO NETTO, S.; BRENA, D. A. 1997. **Inventário Florestal**. Curitiba, 316 p.

PIRES, Paulo de Tarso de Lara et. al. (org). **Dicionário de Termos Florestais**. Curitiba, FUPEF, 2018. Disponível em: https://www.apreflorestas.com.br/wp-content/uploads/2018/03/APRE_dicionario_2018_digital-1.pdf. Acesso: 04/09/2021.

RATTER, J. A. 1971. Some notes on two types of cerradão occurring in northeastern Mato Grosso. In: FERRI, M.G. (org.). **III Simpósio sobre o Cerrado**. São Paulo, Ed. Edgard Blucher Ltda. p. 100-102.

REZENDE, A. V. et al. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado sentido restrito em Brasília, DF. **Scientia Forestalis**, Piracicaba, n. 71, p. 65-76, 2006. Disponível em : <https://www.ipef.br/publicacoes/scientia/nr71/cap07.pdf?fbclid=IwAR0t1SI7lcfQEhS> Acesso: 01/10/2021.

RIBEIRO, J. F.; WALTER, B. M. T. As Principais Fitofisionomias do Bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P. de; RIBEIRO, J. F. (Ed.). **Cerrado: ecologia e flora** v. 2. Brasília: EMBRAPA-CERRADOS, 1998. p. 89-166. Disponível em: <http://www.alice.cnptia.embrapa.br/alice/handle/doc/554094> Acesso: 16/05/2021.

RIBEIRO, S. C. et al. Above and belowground biomass in a Brazilian Cerrado. *Forest Ecology and Management*, Amsterdam, v. 262, p. 491-499, 2011. Disponível em: <http://www.sidalc.net/repdoc/A11108i/A11108i.pdf> Acesso: 01/10/2021.

ROCHA, C.C.C. **Estimativa de volume, biomassa e carbono da vegetação lenhosa de floresta estacional no estado de Goiás**. Dissertação (Mestrado em Ciências Florestais). Universidade de Brasília, Brasília, DF-2011. 80 p. Disponível em: <https://repositorio.unb.br/handle/10482/9345> Acesso: 16/05/2021.

ROITMAN, I. et al. Optimizing biomass estimates of savanna woodland at different spatial scales in the Brazilian Cerrado: Re-evaluating allometric equations and environmental influences. *Plos One*, v. 13, n. 8, p. e0196742, 2018. Disponível em: <https://doi.org/10.1371/journal.pone.0196742> Acesso: 01/10/2021.

ROQUETTE, José Guilherme. Distribuição da biomassa no Cerrado e a sua importância na armazenagem do carbono. **Ciência Florestal**, Santa Maria - RS, v. 28, n. 3, p. 1350-1363, jul – set, 2018. Disponível em: <http://dx.doi.org/10.5902/1980509833354> Acesso: 01/10/2021.

SANTANA, G. M. et al. Ajuste independente e simultâneo para estimar biomassa acima do solo no cerrado, fitofisionomia Parque Cerrado. **RAMA - Revista em Agronegócio e Meio Ambiente**, 2021: v. 14, n. 3 Disponível em: <https://doi.org/10.17765/2176-9168.2021v14n3e8125> Acessado em: 01/10/2021.

SANTANA, O. A. et al. Relação entre o índice de avermelhamento do solo e o estoque de carbono na biomassa aérea da vegetação do Cerrado. **Ciência Florestal**, Santa Maria, v. 23, n. 4, p. 783-794, out./dez. 2013. Disponível em: <https://doi.org/10.5902/1980509812362> Acessado: 01/10/2021.

SCOLFORO, H. F. et al. Spatial distribution of aboveground carbon stock of the arboreal vegetation in Brazilian biomes of Savanna, Atlantic Forest and Semi-arid Woodland. *PLoS ONE*, San Francisco, v. 10, n. 6, p. e0128781, 2015. Disponível em: <https://doi.org/10.1371/journal.pone.0128781> Acessado: 01/10/2021.

SILVA, C. J. DA. **Densidade básica e potencial energético de espécies lenhosas do cerrado do estado de Tocantins**. Tese (Doutorado em Ciências Florestais), UNB, Brasília, p. 66, 2014. Disponível em: <http://dx.doi.org/10.26512/2014.12.T.17934> Acesso: 01/10/2021.

SILVA, E. B. da; FERREIRA JÚNIOR, L. G.; ANJOS, A.F. dos; MIZIARA, F. A expansão da fronteira agrícola e a mudança de uso e cobertura no centro-sul de Goiás, entre 1975 e 2010. **Ateliê Geográfico – Goiânia-GO**, v. 7, n. 2, p. 116-138. Ago. 2013. Disponível em: <http://www.revistas.ufg.br/infex.php/atelie> Acesso: 01/10/2021.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais: para engenharia e ciências aplicadas. 2. ed. São Paulo: Artel Editora, 2010.**

SILVA, L. M. S. BINOTI, D. H. B.; GLERIANI, J. M.; LEITE, H. G. (2009). Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume

de árvores de eucalipto. **Rev. Árvore.** 33 (6):1133-1139. Dez 2009
<https://doi.org/10.1590/S0100-67622009000600015> Acesso: 01/10/2021.

SOUZA, J. C.; MARTINS, P. T. A.; Druciaki, V. P. Uso e cobertura do solo no Cerrado: panorama do período de 1985 a 2018. **Élisée, Rev. Geo. UEG** – Goiás, v.9, n.2, jul./dez. 2020 Disponível em: <https://www.revista.ueg.br/index.php/elisee/issue/view/564>. Acesso: 19/09/2021

SOUZA, Y. F. **Equações alométricas para estimativa de volume e biomassa em diferentes fitofisionomias do Cerrado.** 2020. 123 f., Dissertação (Mestrado em Ciências Florestais) —Universidade de Brasília, Brasília, 2020. Disponível em: <https://repositorio.unb.br/handle/10482/41036>. Acesso: 16/05/2021.

TASHI, S.; KEITEL, C.; SINGH, B.; ADAMS, M. Allometric equations for biomass and carbon stocks of forests along an altitudinal gradient in the eastern Himalayas. **Forestry: An International Journal of Forest Research**, v. 90, n. 3, p. 445–454, 2017. Disponível em: <https://doi.org/10.1093/forestry/cpx003> Acesso: 01/10/2021.

THOMAS, C., C. M et al. 2006. Comparação de equações volumétricas ajustadas com dados de cubagem e análise de tronco. **Ciência Florestal** 16(3): 319-327. Disponível em: <https://doi.org/10.5902/198050981911> Acesso: 16/05/2021

VALENTE, E. O.; VALENTE, G. de F. S. **Simulação de redes neurais artificiais para estimativa de volume de madeira florestal a partir do DAP.** Brazilian Journal of Animal and Environmental Research, Curitiba, v.4, n.3, p. 3748-3757 jul. /set. 2021. Disponível em: <https://doi.org/10.34188/bjaerv4n3-080> Acesso: 04 set. 2021

VALE, A.T. **Caracterização da biomassa lenhosa de um cerrado sensu stricto da região de Brasília para uso energético.** 2000. 111p. Tese (Doutorado em Agronomia) - Universidade Estadual de São Paulo, Botucatu, 2000.

VALE, A. T. D.; BRASIL, M. A. M.; LEÃO, A. L. Quantificação e caracterização energética da madeira e casca de espécies do cerrado. **Ciência Florestal**, v. 12, n. 1, p. 71, 2002. Disponível em: <https://doi.org/10.5902/198050981702> Acesso: 01/10/2021.

VALE, A. T.; FELFILI, J. M. Dry biomass distribution in a cerrado sentido restrito site in central Brazil. **Revista Árvore**, Viçosa, MG, v. 29, n. 5, p. 661-669, 2005. Disponível em: <https://doi.org/10.1590/S0100-67622005000500001> Acesso: 01/10/2021.

ANEXO - Tabela com informações do inventário florestal usadas nesse trabalho

N	Espécie	Dap (cm)	HT (m)	Biomassa total	Densidade
1	<i>Aspidosperma subincanum</i>	7,00	8,50	27,129	0,880
2	<i>Birsonima laxiflora</i>	6,00	7,62	20,696	0,390
3	<i>Birsonima Pachifylla</i>	9,00	6,10	42,772	0,670
4	<i>Birsonima sericia</i>	8,10	10,5	41,166	0,68
5	<i>Birsonima sericia</i>	21,10	17,20	450,896	0,680
6	<i>Bocageopsis multiflora</i>	6,00	10,50	20,116	0,640
7	<i>Bowdichia virgiliodeis</i>	30,80	14,30	1070,027	0,827
8	<i>Conarus perrotetti</i>	5,80	7,00	10,547	0,453
9	<i>Conarus suberosos</i>	11,50	3,80	30,167	0,450
10	<i>Dalbergia densiflora</i>	8,10	10,80	61,182	0,760
11	<i>Emotun nitens</i>	8,10	9,77	44,822	0,841
12	<i>Emotun nitens</i>	15,50	10,80	117,839	0,841
13	<i>Emotun nitens</i>	15,70	11,80	171,379	0,841
14	<i>Emotun nitens</i>	49,00	16,90	2552,898	0,841
15	<i>Emotun nitens</i>	10,30	12,40	89,209	0,841
16	<i>Emotun nitens</i>	16,20	10,30	164,965	0,841
17	<i>Emotun nitens</i>	34,20	13,00	1223,668	0,841
18	<i>Ferdinadusa elliptica</i>	6,20	10,60	27,861	0,660
19	<i>Erythroxylum daphnites Mart.</i>	8,20	12,00	51,185	0,630
20	<i>Himatanthus sucuuba</i>	10,30	10,50	73,739	0,462
21	<i>Inga alba</i>	11,00	8,60	52,794	0,620
22	<i>Licania apetala</i>	18,60	13,50	296,53	0,640
23	<i>Mabea Fistolifera</i>	6,00	8,90	15,905	0,640
24	<i>Maprounea guianensis</i>	6,60	9,00	27,151	0,588
25	<i>Maprounea guianensis</i>	13,00	12,00	135,684	0,588
26	<i>Matayba guianensis</i>	5,90	12,40	25,942	0,820
27	<i>Meziraulus Itauba</i>	8,60	11,25	37,89	0,680
28	<i>Meziraulus Itauba</i>	9,20	7,60	40,881	0,680
29	<i>Miconia albicans</i>	7,00	8,00	36,041	0,680
30	<i>Miconia albicans</i>	5,70	5,80	12,623	0,680
31	<i>Miconia albicans</i>	6,10	6,50	17,616	0,680
32	<i>Miconia albicans</i>	8,90	5,30	22,126	0,680
33	<i>Miconia cuspidata</i>	7,50	10,00	42,04	0,845
34	<i>Miconia cuspidata</i>	15,30	12,00	321,009	0,845
35	<i>Miconia cuspidata</i>	12,00	12,60	175,014	0,845
36	<i>Myrsia spends</i>	5,30	5,00	9,658	0,700
37	<i>Myrsia spends</i>	6,70	8,00	21,418	0,700
38	<i>Myrsia spends</i>	7,50	7,00	26,752	0,700
39	<i>Myrsia spends</i>	9,00	8,30	34,388	0,700
40	<i>Myrsia spends</i>	12,00	6,17	46,732	0,700
41	<i>Myrsia spends</i>	19,00	11,60	251,965	0,700
42	<i>Myrsia spends</i>	16,30	6,20	128,409	0,700

Continua ...

... continuação

N	Espécie	Dap (cm)	Ht (m)	Biomassa total	Densidade
43	<i>Myrsia spends</i>	7,90	9,00	35,926	0,700
44	<i>Ouratea ovallis</i>	7,50	5,60	13,725	0,620
45	<i>Ouratea ovallis</i>	10,70	7,00	51,57	0,620
46	<i>Parkia Pendula</i>	13,40	9,00	99,736	0,500
47	<i>Parkia pendula</i>	21,50	12,20	340,373	0,500
48	<i>Parkia platycephala</i>	29,60	18,10	822,085	0,760
49	<i>Pouteria Ramiflora</i>	12,40	11,40	81,864	0,700
50	<i>Pouteria Ramiflora</i>	30,50	15,80	392,603	0,700
51	<i>Pouteria Ramiflora</i>	5,40	9,40	13,997	0,700
52	<i>Pouteria Ramiflora</i>	16,70	11,70	182,16	0,700
53	<i>Pouteria Ramiflora</i>	16,70	14,00	163,495	0,700
54	<i>Protino heptaphylum</i>	6,00	8,55	19,408	0,600
55	<i>Protino heptaphylum</i>	17,50	12,10	282,929	0,600
56	<i>Protino heptaphylum</i>	17,50	14,50	194,691	0,600
57	<i>Protino heptaphylum</i>	10,90	10,60	75,347	0,600
58	<i>Qualea Parviflora</i>	10,20	8,20	52,705	0,690
59	<i>Qualea Parviflora</i>	7,00	6,00	23,904	0,690
60	<i>Sacoglottis guianensis</i>	11,00	10,50	95,94	0,650
61	<i>Sacoglottis guianensis</i>	6,70	6,70	37,24	0,650
62	<i>Tachy vulgari</i>	5,50	6,37	9,417	0,710
63	<i>Tachy vulgari</i>	11,00	9,60	75,654	0,710
64	<i>Tachy vulgari</i>	18,70	13,80	258,466	0,710
65	<i>Tachy vulgari</i>	36,00	24,50	1839,46	0,710
66	<i>Tapirira guianensis</i>	9,30	10,40	56,06	0,466
67	<i>Tapirira guianensis</i>	12,50	13,00	93,568	0,466
68	<i>Tapirira guianensis</i>	15,20	11,30	171,017	0,466
69	<i>Tapirira guianensis</i>	18,00	12,10	310,338	0,466
70	<i>Virola sebifera</i>	8,40	6,50	33,746	0,480
71	<i>Virola sebifera</i>	20,10	13,00	308,897	0,480
72	<i>Volchisia gardineri</i>	10,40	11,20	86,403	0,352
73	<i>Xylopi aromatica</i>	6,40	7,10	19,21	0,561
74	<i>Xylopi aromatica</i>	8,00	6,00	18,992	0,561
75	<i>Xylopi aromatica</i>	8,00	9,00	18,978	0,561
76	<i>Xylopi aromatica</i>	9,70	10,00	48,779	0,561
77	<i>Xylopi aromatica</i>	10,20	11,90	55,514	0,561
78	<i>Xylopi aromatica</i>	5,50	10,00	17,052	0,561
79	<i>Xylopi aromatica</i>	9,70	11,90	48,682	0,561
80	<i>Xylopi aromatica</i>	15,60	13,00	178,458	0,561

Variável	Média	Máximo	Mínimo	Espécies
DAP	12,5 cm	49 cm	5,3 cm	34
HT	10,26 m	24,5 m	3,8 m	

ANEXO - Tabela com dados do inventário florestal usadas para validação dos modelos

N	Espécie	Dap (cm)	HT (m)	Biomassa total	Densidade
1	<i>Birsonima sericia</i>	21,10	17,20	450,896	0,680
2	<i>Bocageopsis multiflora</i>	6,00	10,50	20,116	0,640
3	<i>Emotun nitens</i>	10,30	12,40	89,209	0,841
4	<i>Emotun nitens</i>	16,20	10,30	164,965	0,841
5	<i>Emotun nitens</i>	34,20	13,00	1223,668	0,841
6	<i>Helitroxun dafinitis</i>	8,20	12,00	51,185	-
7	<i>Himatanthus sucuuba</i>	10,30	10,50	73,739	0,462
8	<i>Meziraulus Itauba</i>	8,60	11,25	37,890	0,680
9	<i>Meziraulus Itauba</i>	9,20	7,60	40,881	0,680
10	<i>Miconia albicans</i>	5,70	5,80	12,623	0,680
11	<i>Miconia albicans</i>	6,10	6,50	17,616	0,680
12	<i>Miconia albicans</i>	8,90	5,30	22,126	0,680
13	<i>Miconia cuspidata</i>	12,00	12,60	175,014	0,845
14	<i>Myrsia spends</i>	7,90	9,00	35,926	0,700
15	<i>Ouratea ovallis</i>	10,70	7,00	51,570	0,620
16	<i>Pouteria Ramiflora</i>	5,40	9,40	13,997	0,700
17	<i>Pouteria Ramiflora</i>	16,70	11,70	182,160	0,700
18	<i>Pouteria Ramiflora</i>	16,70	14,00	163,495	0,700
19	<i>Protino heptaphylum</i>	10,90	10,60	75,347	0,600
20	<i>Qualea Parviflora</i>	7,00	6,00	23,904	0,690
21	<i>Sacoglottis guianensis</i>	6,70	6,70	37,240	0,650
22	<i>Tachy vulgari</i>	36,00	24,50	1839,460	0,710
23	<i>Xylophia aromatica</i>	5,50	10,00	17,052	0,561
24	<i>Xylophia aromatica</i>	9,70	11,90	48,682	0,561
25	<i>Xylophia aromatica</i>	15,60	13,00	178,458	0,561

Variável	Média	Máximo	Mínimo	Espécies
DAP	12,22 cm	36 cm	5,4 cm	16
HT	10,75 m	24,5 m	5,3 m	