



**INTELIGÊNCIA ARTIFICIAL ASSOCIADA À DADOS DE SATÉLITE NA  
PREDIÇÃO DO POTÊNICAL ENERGÉTICO EM ÁREA DE CERRADÃO**

**JOÃO VICTOR NOBRE CARRIJO**

**DISSERTAÇÃO DE MESTRADO  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS  
DEPARTAMENTO DE ENGENHARIA FLORESTA**

**FACULDADE DE TECNOLOGIA**

**UNIVERSIDADE DE BRASÍLIA**

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

**INTELIGÊNCIA ARTIFICIAL ASSOCIADA À DADOS DE  
SATÉLITE NA PREDIÇÃO DO POTÊNCIAL ENERGÉTICO EM  
ÁREA DE CERRADÃO**

**JOÃO VICTOR NOBRE CARRIJO**

**ORIENTADOR: Prof. Dr. EDER PEREIRA MIGUEL**

**COORIENTADOR: Prof. Dr. AILTON TEIXEIRA DO VALE**

**DISSERTAÇÃO DE MESTRADO EM CIÊNCIAS FLORESTAIS**

**BRASÍLIA/DF FEVEREIRO DE 2019**

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

“INTELIGÊNCIA ARTIFICIAL ASSOCIADA A DADOS DE SATÉLITE NA  
PREDIÇÃO DO POTENCIAL ENERGÉTICO EM ÁREA DE CERRADÃO”

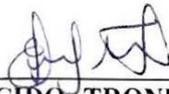
**JOÃO VICTOR NOBRE CARRIJO**

DISSERTAÇÃO DE MESTRADO ACADÊMICO SUBMETIDA AO PROGRAMA DE  
PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS, DO DEPARTAMENTO DE EN-  
GENHARIA FLORESTAL, DA FACULDADE DE TECNOLOGIA DA UNIVERSIDA-  
DE DE BRASÍLIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OB-  
TENÇÃO DO GRAU DE MESTRE.

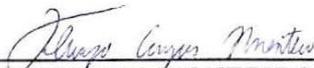
APROVADA POR:



Prof. Dr. EDER PEREIRA MIGUEL (Departamento de Engenharia Florestal –  
EFL/UnB);  
(Orientador)



Prof. Dr. ERALDO APARECIDO TRONDOLI MATRICARDI (Departamento de  
Engenharia Florestal – EFL/UnB);  
(Examinador Interno)



Prof. Dr. THIAGO CAMPOS MONTEIRO (Universidade Federal do Paraná – UFPR);  
(Examinador Externo)

Prof. Dr. RAFAEL RODOLFO DE MELO (Universidade Federal Rural do Semi-Árido  
– Ufersa).  
(Examinador Suplente)

Brasília-DF, 21 de fevereiro de 2019.

Ni Nobre Carrijo, João Victor  
Inteligência artificial associada à dados de satélite na  
predição do potencial energético em área de cerrado / João  
Victor Nobre Carrijo; orientador Eder Pereira Miguel; co  
orientador Ailton Teixeira do Vale. -- Brasília, 2019.  
64 p.

Dissertação (Mestrado - Mestrado em Ciências Florestais)  
- Universidade de Brasília, 2019.

1. Redes Neurais Artificiais. 2. Cerrado. 3. Poder  
Calorífico. 4. Biomassa. 5. Modelagem. I. Pereira Miguel,  
Eder, orient. II. Teixeira do Vale, Ailton, co-orient. III.  
Título.

#### REFERÊNCIA BIBLIOGRÁFICA

CARRIJO, J.V.N. (2019). Inteligência artificial associada à dados de satélite na predição do potencial energético em área de cerrado. Dissertação de Mestrado em Ciências Florestais. Programa de Pós-graduação em Ciências Florestais, Universidade de Brasília, Brasília-DF, 64 p.

#### CESSÃO DE DIREITOS

AUTOR: João Victor Nobre Carrijo

TÍTULO: Inteligência artificial associada à dados de satélite na predição do potencial energético em área de cerrado.

GRAU: Mestre; ANO: 2019; ÁREA DE CONCENTRAÇÃO: Manejo Florestal

Concedo à Universidade de Brasília-UnB permissão para reproduzir cópias desta dissertação de mestrado e para emprestá-las somente para propósitos acadêmicos e científicos. Reservo outros direitos de publicação, de forma que nenhuma parte deste dissertação de mestrado pode ser reproduzida sem minha autorização por escrito.

---

João Victor Nobre Carrijo  
Endereço eletrônico: joao.ncarrijo@gmail.com

**Aos meus pais,  
Carla e Jurandir. Dedico.**

## **AGRADECIMENTOS**

Primeiramente à Deus, pela curiosidade e oportunidade de aqui estar. Aos meus pais e às minhas irmãs, por estarem sempre ao meu lado, oferecendo todo o apoio e inspiração para essa e todas às outras conquistas.

Ao professor Eder Pereira Miguel, não apenas pela orientação, mas também pelo companheirismos, pelo apoio, pelas cobranças, pelos momentos de trabalho e também pelos momentos de descontração. Mais um trabalho juntos, obrigado por todo o incentivo!

Ao professor Ailton Teixeira do Vale, pelos conhecimentos transmitidos e toda a prestatividade.

Aos colegas que dividiram momentos bons e ruins durante esse período. Em especial à Ana Beatriz, Marcela, Jonas e Larissa, que estiveram tão presentes em tantas horas de estudo, trabalho e descontração.

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

### INTELIGÊNCIA ARTIFICIAL ASSOCIADA À DADOS DE SATÉLITE NA PREDIÇÃO DO POTÊNCIAL ENERGÉTICO EM ÁREA DE CERRADÃO

**Autor:** João Victor Nobre Carrijo

**Orientador:** Eder Pereira Miguel

**Coorientador:** Ailton Teixeira do Vale

**Programa de Pós-graduação em Ciências Florestais**

**Brasília, 21 de Fevereiro de 2019**

Os estudos sobre a capacidade produtiva florestal do Cerrado vêm ganhando atenção nos últimos anos, utilizando de inteligência artificial na estimativa de variáveis produtivas da floresta e demonstrando o poder dessa tecnologia para esse fim. Entretanto, maiores esforços de pesquisa devem ser feitos quanto a capacidade energética do mesmo, possibilitando assim a geração de informações importantes para a gestão e o manejo sustentável dessas áreas. Neste sentido, o objetivo deste trabalho foi avaliar a eficácia de redes neurais artificiais associadas à dados de satélites para a estimativa do potencial energético em áreas de cerradão. O estudo foi conduzido em parcelas instaladas em uma área de cerradão em Tocantins, Brasil, onde foi realizado inventário florestal para obtenção de dados dendrométricos e amostras de material lenhoso e casca. O poder calorífico superior do material amostrado foi determinado segundo a norma brasileira NBR 8633 e a biomassa seca a 0% de umidade foi determinada com uso de modelos matemáticos. O produto desses dois valores definiu o potencial energético de cada indivíduo amostrado, posteriormente extrapolada por unidade de área. Seis índices de vegetação foram calculados para cada parcela a partir de uma imagem *RapidEye* e um teste de correlação foi realizado para determinar o índice a ser utilizado na modelagem do potencial energético. A modelagem foi realizada por meio da ferramenta *Intelligent Problem Solver* do software Statistica 7, utilizando a área basal e o Índice de Vegetação da Diferença Normalizada (NDVI) como variáveis preditoras. A seleção da rede neural mais adequada foi feita segundo os critérios da análise gráfica, do erro médio da estimativa e do coeficiente de correlação. Por fim, a validação da rede selecionada foi realizada por meio do teste de *t* de Student e da diferença agregada. Em termos médios, o poder calorífico superior da madeira das espécies do cerradão foi de  $19,234 \pm 0,411$  GJ.ton<sup>-1</sup>, enquanto para a casca foi de  $19,878 \pm 1,090$  GJ.ton<sup>-1</sup>. Os resultados da modelagem revelaram que o potencial energético médio do cerradão é de  $1.022,66$  GJ.ha<sup>-1</sup>  $\pm 560,89$  GJ.ha<sup>-1</sup>. A rede neural mais adequada apresentou erro de 11,27% e uma

estrutura com dois neurônios na camada de entrada, oito na camada oculta e um na camada de saída, com funções de ativação dos tipos tangencial e sigmoidal. Os testes de validação demonstraram que não há diferença significativa entre os valores observados e os valores preditos pela rede neural.

**Palavras-chave:** redes neurais artificiais, cerrado, poder calorífico, biomassa, modelagem.

## **Abstract**

### **ARTIFICIAL INTELLIGENCE ASSOCIATED WITH SATELLITE DATA IN THE PREDICTION OF ENERGY POTENTIAL IN A CERRADÃO AREA**

**Author: João Victor Nobre Carrijo**

**Supervisor: Eder Pereira Miguel**

**Cosupervisor: Ailton Teixeira do Vale**

**Forest Science Graduate Program**

**Brasilia, February 21<sup>st</sup>, 2019**

The studies on the productive capacity of the *Cerrado* have been gaining attention in recent years, using artificial intelligence to estimate productive variables of the forest and demonstrating the efficiency of this technology for this purpose. However, greater research efforts should be dedicated to the biome's energy capacity, which will contribute to generate important information for the sustainable management of those areas. This study intended to assess the application of artificial neural networks associated with remotely sensed data to estimate the energy potential of *cerradão* areas. This study was conducted in plots located in a *cerradão* area in the state of Tocantins, Brazil. A forest inventory was conducted to acquire dendrometric data and samples of woody material and bark. The higher heating value of the sampled material was determined according to the NBR 8633 standard and the dried biomass was determined using mathematical models. The energy potential of each individual sample was calculated based on the product of those two values, which was later extrapolated per unit area. Six vegetation indices were calculated for each plot from a RapidEye image and a correlation test was performed to select the best index to be used in the modeling. The energy potential modeling was performed using the Intelligent Problem Solver tool available on the Statistica 7 software, by using the basal area and the Normalized Difference Vegetation Index (NDVI) as predictor variables. The optimum neural network was selected based on the criteria of the graphical analysis, the average error of the estimate, and the correlation coefficient. Finally, the validation of the selected network was conducted by applying the Student t test and the aggregate difference. The average higher heating value for the wood of the species of *cerradão* was  $19,234 \pm 0,411 \text{ GJ.ton}^{-1}$ , whereas the higher heating value for the bark of those species was  $19,878 \pm 1,090 \text{ GJ.ton}^{-1}$ . This study results indicated that the mean energy potential for the study area is  $1,022.66 \pm 560,89 \text{ GJ.ha}^{-1}$ . The most adequate neural network presented an error of 11.27% and a structure with two neurons in the input layer, eight in the hidden layer and one in the output layer, with activation

functions of the tangential and sigmoidal types. The validation tests demonstrated that there is no significant difference between the observed and predicted values by the neural network.

**Key words:** artificial neural network, *cerrado*, higher heating value, biomass, modeling.

## Sumário

1	INTRODUÇÃO .....	13
1.1	CONTEXTUALIZAÇÃO E APRESENTAÇÃO .....	13
1.2	REFERÊNCIAL TEÓRICO .....	15
1.2.1	Cerrado .....	15
1.2.2	Cerradão.....	17
1.2.3	Densidade energética .....	19
1.2.4	Dados de satélite no meio florestal.....	20
1.2.5	Redes neurais artificiais .....	22
2	MATERIAIS E MÉTODOS .....	23
2.1	Descrição da área de estudo .....	23
2.2	Processo de amostragem e coleta de dados .....	25
2.2.1	Inventário florestal.....	25
2.2.2	Amostragem da madeira .....	26
2.3	Quantificação das variáveis energéticas .....	27
2.3.1	Poder calorífico superior .....	27
2.3.2	Biomassa e potencial energético .....	28
2.4	Processamento da imagem de satélite.....	30
2.5	Modelagem .....	31
2.5.1	Seleção das variáveis independentes .....	31
2.5.2	Treinamento das redes neurais .....	32
2.6	Análise estatística .....	33
3	RESULTADOS .....	34
3.1	Poder calorífico superior.....	34
3.2	Potencial energético .....	35
3.3	Modelagem .....	37
3.3.1	Seleção das variáveis independentes .....	37
3.3.2	Treinamento das redes neurais .....	39
3.4	Análise estatística .....	41
4	DISCUSSÃO.....	41
4.1	Poder calorífico superior e potencial energético.....	41
4.2	Modelagem .....	43

4.2.1	Seleção das variáveis independentes .....	43
4.2.2	Treinamento das redes neurais .....	44
4.3	Análise estatística .....	45
5	CONCLUSÃO .....	46
6	REFERÊNCIAS BIBLIOGRÁFICAS .....	46

## Lista de Tabelas

Tabela 1. Lista das espécies com o respectivo número de indivíduos cortados na área de cerrado estudada. ....	26
Tabela 2. Modelos para determinação de biomassa (MIGUEL et al., 2017a). ....	29
Tabela 3. Dados de poder calorífico superior (PCS) da madeira e da casca das 34 espécies florestais amostradas no Parque Estadual do Lajeado, Tocantins. ....	34
Tabela 4. Valores de potencial energético por unidade de área para as 54 parcelas amostrais. ....	35
Tabela 5. Valores observados das variáveis de estudo para cada parcela amostral. ....	37
Tabela 6. Matriz de correlação segundo Spearman entre as variáveis estudadas. ....	39
Tabela 7. Características e análise de precisão das redes neurais artificiais treinadas. ...	39

## Lista de Figuras

Figura 1. Localização da área de estudo em relação ao município de Palmas e ao estado do Tocantins (TO) (MIGUEL, 2014). ....	24
Figura 2. Localização e posicionamento dos transectos e parcelas amostrais na área de estudo (MIGUEL, 2014). ....	25
Figura 3. Calorímetro utilizado para análise de poder calorífico (A); Amostras compostas utilizadas para análise de poder calorífico (B); Estufa utilizada para secagem das amostras (C). ....	28
Figura 4. Distribuição de resíduos (A), valores observados e preditos (B) e distribuição de classes de erro (C) da estimativa de potencial energético. ....	40
<b>Figura 5.</b> Arquitetura da RNA selecionada para predição de potencial energético por unidade de área em cerrado (2-8-1). ....	40

# **1 INTRODUÇÃO**

## **1.1 CONTEXTUALIZAÇÃO E APRESENTAÇÃO**

O Cerrado é o segundo maior bioma da América do Sul e ocupa mais de 20% do território brasileiro (BATLLE-BAYER et al., 2010; SOUZA et al., 2016; JESUS et al., 2017a). É reconhecido como a savana mais rica em espécies do planeta (FORZZA et al., 2012; ROSATTI et al., 2015; SOUZA et al., 2015; MORAES et al., 2016) e possui vegetação vasta e complexa, caracterizada por um mosaico composto por diversos tipos fisionômicos: savanas, formações campestres e fisionomias florestais, dentre as quais está o cerradão (MIGUEL et al., 2016; MORAES et al., 2016; NEHRING, 2016; MARACAHIPES-SANTOS et al., 2017; ROCHA-ORTEGA et al., 2017).

O cerradão é uma fitofisionomia associada a regiões de interflúvio de áreas planas (RIBEIRO; WALTER, 2008; PINHEIRO; DURIGAN, 2012; SOLÓRZANO et al., 2012) e possui uma grande complexidade em sua vegetação, com espécies características de diversas formações e fitofisionomias do Cerrado (PRADO JÚNIOR et al., 2012; SOLÓRZANO et al., 2012; BALL et al., 2015). Essa complexidade e heterogeneidade em relação à sua estrutura vegetal torna difícil a obtenção de informações dendrométricas na fisionomia e no bioma, elevando os custos e o tempo para coleta de dados necessários para avaliação do caráter produtivo no Cerrado, e por isso, esse tipo de estudo ainda é escasso (REZENDE et al., 2006; MIGUEL et al., 2017a).

O Cerrado e suas fisionomias possuem potencial produtivo comprovado, fornecendo matéria-prima tanto para serrarias quanto para fins energéticos (DUBOC et al., 2007; LÓPEZ et al., 2011, 2013; LÓPEZ; VILLALBA, 2015; LIMA et al., 2016). Os estudos com ênfase no potencial produtivo de áreas florestais são comumente voltados à estimativa de biomassa acima do solo e volume estocado de madeira, por sua importância para o manejo e planejamento florestal, bem como para a rentabilidade da atividade e para políticas florestais (AREVALO et al., 2007; SOUSA et al., 2015). No entanto, maiores esforços de pesquisa podem ser aplicados ao potencial energético de áreas florestais devido à sua importância econômica e ambiental.

Densidade energética representa a quantidade de energia a ser liberada após a completa combustão de um determinado volume de combustível (JANSEN, 2013; PROTÁSIO et al., 2015) e é de grande importância no que diz respeito à seleção de espécies para produção energética, uma vez que se relaciona diretamente com o poder calorífico - variável que está entre os principais critérios de seleção de madeiras para esta atividade (SANTOS et al., 2013; JUIZO et al., 2017; ARAÚJO et al., 2018) - além da

possibilidade de servir como indicador na seleção de áreas a serem exploradas quando expressa o potencial energético por unidade de área.

O potencial energético, aliado à dados de estoque de volume, biomassa e carbono em florestas nativas, são essenciais para o avanço do manejo sustentável e da conservação de áreas como o Cerrado (LÓPEZ et al., 2013; VOGEL et al., 2015; KANDARE et al., 2017; MIGUEL et al., 2017a; SMITH et al., 2018), uma vez que valoriza o bioma que há décadas sofre com o avanço da fronteira agrícola e a consequente substituição da cobertura vegetal por plantios de *commodities* agrícolas e pastagens, principal responsável pela redução de aproximadamente 50% de sua cobertura original (FRANÇOSO et al., 2015; RICHARDS; VANWEY, 2015). Por este motivo, implementar políticas e planejamentos estratégicos de manejo do solo e da vegetação é de suma importância para prover, de forma sustentável, suporte aos meios de subsistência das comunidades, junto à proteção de habitats para biodiversidade (KENNEDY et al., 2016).

Para evitar a exploração do bioma, o Ministério do Meio Ambiente desenvolveu o plano de ação para prevenção e controle do desmatamento e queimadas no Cerrado (PPCerrado), que aborda a necessidade da implantação e/ou melhoria do manejo florestal sustentável em áreas de Cerrado, com enfoque especial para a produção energética (MMA, 2011; COSTA et al., 2014), porém, para garantir que tais práticas sejam implementadas e aprimoradas, estimativas acuradas do seu potencial produtivo e energético são necessárias (LÓPEZ et al., 2013; WHITE et al., 2016; PIQUÉ et al., 2017).

Imagens de satélites e técnicas de sensoriamento remoto são ferramentas com potencial para fornecer acurácia e reduzir o tempo e os custos elevados para coleta de dados em áreas de Cerrado. Os avanços recentes destas técnicas e a tecnologia utilizada por elas permitem hoje uma melhor caracterização da estrutura florestal, logo, da sua biomassa, carbono estocado, dentre outras variáveis (WATZLAWICK et al., 2009; GROOT et al., 2015; WHITE et al., 2016; SANTOS et al., 2017). Diversos trabalhos apresentam resultados satisfatórios para a estimativa de biomassa acima do solo em diversas formações florestais com uso desta tecnologia (FERRAZ et al., 2014; MIGUEL et al., 2015; BENÍTEZ et al., 2016; ENE et al., 2017; NANDY et al., 2017; PHUA et al., 2017; REDDY et al., 2017; DALPONTE et al., 2018).

Alguns autores corrigiram erros e aumentaram o poder de predição desta técnica ao combiná-la com o uso de redes neurais artificiais (RNA). RNAs podem ser definidas como processadores de distribuição paralela e constituídos de unidades de processamento

simples, apresentando propensão natural para aprendizado e armazenamento de conhecimento experimental, tornando-os, assim, uma simulação similar ao cérebro humano (HAYKIN, 2009; PHUKOETPHIM et al., 2014; BINOTI et al., 2015; GITOOE et al., 2018).

As RNAs constantemente apresentam resultados precisos, levando essa técnica a ser utilizada para diversas pesquisas (FERRAZ et al., 2014; LEAL et al., 2015; MIGUEL et al., 2015; ZANUNCIO et al., 2016; NANDY et al., 2017; VENDRUSCOLO et al., 2017; VACCHIANO et al., 2018). Todavia, estudos associando imagens de satélites a ferramentas de inteligência artificial, como por exemplo RNAs, na predição do potencial energético em áreas de vegetação nativas são desconhecidos.

A partir das problemáticas aqui expostas e levando em consideração os avanços científicos e tecnológicos que passam a ser aplicados nos últimos anos, as seguintes questões de pesquisa nortearam este estudo: qual o potencial energético médio do cerrado por unidade de área? RNAs associadas à dados de sensores remotos possuem capacidade de estimar com precisão o potencial energético de áreas de cerrado? Para alcançar as respostas para estas questões o potencial energético por unidade de área no cerrado foi mensurado em laboratório e estes valores foram estimados com o uso de redes neurais artificiais, tendo como variáveis preditoras os índices de vegetação associados à área basal da comunidade. Desta forma, no presente trabalho, objetivou-se avaliar a eficácia das redes neurais artificiais associadas à dados de satélite na predição do potencial energético por unidade de área de cerrado, avaliando as relações entre o potencial energético e diversos índices de vegetação oriundos do processamento de imagens de alta definição e testando diferentes configurações de RNAs de maneira a encontrar aquela que apresenta maior precisão de estimativa.

## **1.2 REFERÊNCIAL TEÓRICO**

### **1.2.1 Cerrado**

O Cerrado é o segundo maior bioma sul-americano, atrás apenas da floresta Amazônica, cobrindo mais de 20% do território nacional (HUNKE et al., 2015; CARVALHO et al., 2017; VIEIRA et al., 2018a), e possui altíssima taxa de riqueza e endemismo de espécies, considerada uma das mais altas em todo o mundo (KENNEDY et al., 2016; DANTAS et al., 2018), englobando cerca de 30% de toda a biodiversidade brasileira (FRANÇOZO et al., 2015).

Diversos estudos apresentam uma descrição aprofundada sobre a fitossociologia e biodiversidade do bioma, com resultados similares. Felfili et al. (2007) identificaram, em parcelas de 5 áreas de cerrado *sensu stricto* no estado de Goiás, 186 diferentes espécies arbóreas de 49 famílias, com uma média de aproximadamente 87 espécies de 34 famílias em cada área estudada, sendo que apenas 21 destas 49 famílias foram comuns às cinco áreas. Já em áreas no estado de Mato Grosso, Finger e Finger (2015) identificaram 114 espécies arbóreas de 37 famílias diferentes, das quais as de maior representatividade foram Fabaceae, Myrtaceae e Vochysiaceae. Sampaio et al. (2018), estudando pontos amostrais também de cerrado *sensu stricto* no Maranhão e no Piauí, identificaram 147 espécies, divididas em 44 famílias.

O Cerrado apresenta clima sazonal, com épocas úmidas de outubro a março e secas entre abril e setembro, temperaturas médias entre 22° e 27° C, e solo distrófico com alto teor de alumínio (KLINK; MACHADO, 2005; BATLLE-BAYER et al., 2010; ALVARES et al., 2014; FINGER; FINGER, 2015), dado que grande parte da sua área de cobertura (aproximadamente 56%) está sobre latossolos (HARIDASAN, 2007; SEVERIANO et al., 2013). Destaque ainda para areias quartzosas (15-20%) e solos litólicos (9%), solos de utilização restrita devido às dificuldades em penetração de raízes, retenção de água e à baixa fertilidade (HARIDASAN, 2007; LENZA et al., 2011; ANACHE et al., 2018).

No entanto, o Cerrado é o bioma que mais sofreu transformações e degradações devido ao agronegócio no mundo (GRECCHI et al., 2014; SOARES FILHO et al., 2014). Com mais de 600.000 km<sup>2</sup> convertidos para pastagens e plantações (KLINK; MACHADO, 2005; MARACAHIPES et al., 2014), o bioma apresenta cerca de 50% da sua cobertura vegetal original remanescente (KLINK; MACHADO, 2005; FRANÇOSO et al., 2015; KENNEDY et al., 2016). O cenário se agrava devido à quantidade de áreas protegidas no Cerrado (menos de 10% de sua área total atual, abaixo do recomendado por convenções internacionais), uma vez que cerca de 40.000.000 ha podem ser legalmente desmatados (BATLLE-BAYER et al., 2010; SOARES FILHO et al., 2014).

Conhecer o potencial produtivo das espécies do Cerrado é importante para a sua conservação, ainda assim, estudos neste âmbito são escassos (RIBEIRO et al., 2011; MIGUEL et al., 2017a), pois a obtenção de dados dendrométricos é dificultada pela elevada heterogeneidade de espécies florestais no bioma, bem como pela grande variedade de forma e dimensões de fuste e copa entre espécies e indivíduos de uma mesma espécie (REZENDE et al., 2006; LACERDA et al., 2017; MIGUEL et al., 2017b).

Esses trabalhos apresentam um amplo intervalo de quantificação da biomassa de espécies arbóreas e arbustivas do Cerrado (ROQUETTE, 2018), variando de 4.800 kg.ha<sup>-1</sup> no Distrito Federal (ROITMAN et al., 2018), 9.559 kg.ha<sup>-1</sup> em Roraima (BARBOSA; FEARNSSIDE, 2005), valor não muito distante aos 9.850 kg.ha<sup>-1</sup> (REZENDE et al., 2006) e 12.393 kg.ha<sup>-1</sup> (VALE et al., 2002a) encontrados também em Brasília, até 67.648 kg.ha<sup>-1</sup> encontrados em Minas Gerais (RIBEIRO et al., 2011).

Segundo Ribeiro et al. (2011) e Morandi et al. (2018), essa variação ocorre devido às diferenças na metodologia de amostragem e nos aspectos e fatores ambientais das diferentes localizações dos experimentos. Os últimos autores encontraram valores médios de 32.400 kg.ha<sup>-1</sup> em áreas de transição Cerrado-Amazônia e 20.400 kg.ha<sup>-1</sup> em áreas centrais do bioma. Modelos matemáticos para a estimativa da biomassa foram aplicados e obtiveram precisão apenas razoável, com coeficiente de determinação variando entre 0,85 e 0,98, porém com elevados valores de erro percentual, variando entre 14% e 26% para os melhores modelos (REZENDE et al., 2006; RIBEIRO et al., 2011; ROITMAN et al., 2018).

Quanto ao volume aéreo de madeira, Rezende et al. (2006) encontraram produtividade média de 25,10 m<sup>3</sup>.ha<sup>-1</sup>, com erros de  $\pm 2,83$  m<sup>3</sup>.ha<sup>-1</sup>, para áreas de cerrado *sensu stricto* no Distrito Federal, enquanto Miguel et al. (2017a) e Santos et al. (2017) encontraram valores médios de 126,71 m<sup>3</sup>.ha<sup>-1</sup> e 74,40 m<sup>3</sup>.ha<sup>-1</sup>, respectivamente, para a mesma fitofisionomia no estado de Tocantins. Modelos de predição de volume nessas áreas apresentaram erros percentuais de estimativa entre 15 e 30% que, apesar de elevados, são condizentes e aceitáveis dado a variabilidade natural apresentada pela formação florestal do bioma em sua estrutura vegetal (REZENDE et al., 2006; MIGUEL et al., 2017a).

### **1.2.2 Cerradão**

O cerradão é uma formação florestal com aspectos xeromórficos, geomorfologicamente associado a regiões de interflúvio de áreas mais planas, com terrenos bem drenados e que apresentem solos profundos (RIBEIRO; WALTER, 2008; SOLÓRZANO et al., 2012; BOTREL et al., 2014; DALL'AGNOL et al., 2016), embora também possa ser encontrado sobre solos menos profundos como neossolos (HARIDASAN, 2007; EMBRAPA, 2018). Além disso, o cerradão apresenta uma característica peculiar: a presença de espécies de características savânicas que ocorrem

no cerrado *sensu stricto* e também espécies de florestas estacionais pertencentes ao bioma (PRADO JÚNIOR et al., 2012; BOTREL et al., 2014). Apesar dessa variedade, o cerrado apresenta maior quantidade de espécie savânicas, demonstrando que, florísticamente, se assemelha ao cerrado sentido restrito (RIBEIRO; WALTER, 2008; ALVES et al., 2013; DALL'AGNOL et al., 2016; FRANÇOSO et al., 2016).

A variação das condições e fatores ambientais nas diferentes localidades em que se encontram áreas de cerrado é o que demonstra ser o principal agente de influência nas peculiaridades florísticas apresentadas pela fisionomia (FELFILI et al., 2007), fazendo com que, por exemplo, o cerrado em regiões do Nordeste apresente mais características savânicas quando comparado à mesma fitofisionomia presente no centro-sul do país (SILVA-MORAES et al., 2018).

Análises florísticas e fitossociológicas realizadas em parcelas de cerrado em duas localidades diferentes (Vila Propício, GO e Alto Paraíso de Goiás, ambas nas proximidades da Chapada dos Veadeiros) mostraram que apenas duas espécies (*Dilodendron bippinatum* e *Dypteryx alata*) das 75 identificadas estiveram presentes entre as 10 com maior valor de importância para as duas localidades, sendo que também houve variação nas espécies com menor valor de índice de valor de importância entre as duas áreas (FELFILI et al., 2007).

Sendo assim, a diversidade e riqueza de espécies em áreas de cerrado é elevada, independentemente da localidade. Cerca de 49 espécies foram identificadas em áreas de transição Cerrado-Amazônia no estado do Mato Grosso (REIS et al., 2015a); em média 65 espécies, de mais de 30 famílias diferentes, são encontradas no cerrado do estado de Minas Gerais (SOUZA et al., 2010; GIÁCOMO et al., 2015); e 82 espécies, pertencentes a 34 famílias, foram identificadas no estado de Tocantins (MIGUEL et al., 2017a).

A fisionomia apresenta um dos maiores potenciais em estoque de biomassa quando comparada às formações savânicas do Cerrado (MIGUEL et al., 2017a), alcançando entre 56.320 kg.ha<sup>-1</sup> e 70.490 kg.ha<sup>-1</sup> de biomassa seca (SCOLFORO et al., 2008; MORAIS et al., 2013; MIGUEL et al., 2017a). Para efeito de comparação, a biomassa aérea do cerrado se encontra pouco abaixo da metade da encontrada para fragmentos de Mata Atlântica no estado do Rio de Janeiro (158.140 kg.ha<sup>-1</sup>) (CUNHA et al., 2009), bioma com espécies arbóreas de maior porte.

Os estudos volumétricos realizados no cerrado encontraram valores médios por unidade de área similares em fragmentos localizados no Tocantins (126,71 m<sup>3</sup>.ha<sup>-1</sup>) (MIGUEL et al., 2017a) e em Minas Gerais (127,22 m<sup>3</sup>.ha<sup>-1</sup> e 117,49 m<sup>3</sup>.ha<sup>-1</sup>)

(SCOLFORO et al., 2008; MORAIS et al., 2013). Segundo os autores, esse volume está mais concentrado no tronco para indivíduos jovens, e com o passar do tempo essa concentração passa a ser maior na porção de copa dos indivíduos maduros. Esses valores são superiores aos encontrados para cerrado *sensu stricto* (REZENDE et al., 2006; SANTOS et al., 2017).

### 1.2.3 Densidade energética

Além de utilizada para mensurar o desempenho de um combustível, por se tratar da quantidade de energia liberada por unidade de volume após a combustão completa deste (PINHEIRO et al., 2005; JANSEN, 2013; PROTÁSIO et al., 2015), a densidade energética é um fator essencial na análise de viabilidade econômica do uso de energia de biomassa (STELTE et al., 2011). Isso porque em sua formulação a granel, a densidade energética é diretamente relacionada à densidade a granel do combustível, como demonstram Pinheiro et al. (2005) e Protásio et al. (2015). A densidade a granel indica a capacidade de carga e transporte do produto, impactando diretamente no custo de transporte.

A densidade energética também possui importância no que diz respeito a seleção de espécies para produção energética, dada sua relação com o poder calorífico, variável que está entre os principais critérios de seleção de madeira para esta atividade (SANTOS et al., 2013; JUIZO et al., 2017; ARAÚJO et al., 2018). A densidade energética expressa por unidade de área pode ser chamada de potencial energético ( $Pe$ ).

A outra variável presente na fórmula da densidade energética, logo diretamente relacionada a esta, é a densidade básica da madeira (PROTÁSIO et al., 2013a; VALE et al., 2017; SILVA; VALE, 2018), a qual possui relação direta com a biomassa florestal. A densidade básica da madeira de espécies do Cerrado brasileiro apresenta grande variação, partindo de valores relativamente baixos, na casa de  $0,3 \text{ kg.m}^{-3}$ , e chegando a madeiras pesadas, com valores que ultrapassam  $1,0 \text{ kg.m}^{-3}$  (VALE et al., 2010; COSTA et al., 2014; SILVA et al., 2015). Esses valores são superiores aos encontrados para espécies de eucalipto, que alcançam, em média,  $0,4 \text{ kg.m}^{-3}$  e  $0,6 \text{ kg.m}^{-3}$  (PROTÁSIO et al., 2013a; JESUS et al., 2017b).

Além de superarem espécies de eucalipto quanto a densidade básica da madeira, algumas espécies do Cerrado também apresentam valores superiores para poder calorífico superior (PCS), aproximadamente  $2.800 \text{ kcal.kg}^{-1}$  acima dos valores de PCS apresentados

por espécies de eucalipto (COSTA et al., 2014; JESUS et al., 2017b). Logo, diversas são as espécies do Cerrado que apresentam potencial para a produção de energia, com capacidade energética equiparada ou superior à espécies de eucalipto (COSTA et al., 2014; SILVA; VALE, 2018).

Ressalta-se que o PCS é um valor teórico, uma vez que representa a energia máxima resultante da combustão completa de um material – com todo seu carbono convertido a CO<sub>2</sub> e todo hidrogênio convertido à H<sub>2</sub>O –, incluindo a entalpia da condensação da água gerada (FRIEDL et al., 2005; BRAND, 2007; DEMIRBAS, 2017).

A evaporação da água formada pelo processo de combustão consome uma parcela da energia gerada, a diferença restante é o poder calorífico inferior (PCI), isto é, o PCI não inclui a entalpia da condensação da água (FRIEDL et al., 2005; MME; EPE, 2005; DEMIRBAS, 2017). Além disso, tanto o PCS quanto o PCI são calculados com base no material lenhoso à 0% de umidade (MME; EPE, 2005) e reduzem em cerca de 2MJ/kg a cada aumento de 10% no teor de umidade da madeira (SWITHENBANK et al., 2011; ZANUNCIO et al., 2013; GÓRNICKI et al., 2016). Todavia, o uso da madeira seca à 0% de umidade não é prático, uma vez que o aumento do poder calorífico a partir de dado ponto de teor de umidade não compensa o esforço e custo necessários para prosseguir com a secagem (BRAND et al., 2011; ZANUNCIO et al., 2013).

A obtenção do poder calorífico e da densidade básica é onerosa e de custo elevado, por esse motivo esforços recentes vêm sendo aplicados no estudo da estimativa de densidade energética, os quais obtiveram resultados promissores. Modelos de regressão linear e redes neurais artificiais, ambos utilizando a densidade básica como variável preditora, apresentaram excelente precisão de estimativa, com erros de 2,15% e 1,10%, respectivamente (VALE et al., 2017; SILVA; VALE, 2018). Os mesmos autores estimaram o valor de potencial energético por unidade de área de cerradão no estado de Tocantins em 1.378,541 GJ.ha<sup>-1</sup>.

#### **1.2.4 Dados de satélite no meio florestal**

A finalidade do emprego de processamento digital de imagens de satélite (PDI) é fornecer ferramentas alternativas para visualizar e extrair dados e informações destas imagens de forma prática, possuindo aplicações importantes no setor florestal que abrangem do manejo florestal à políticas ambientais (LATIFI et al., 2015; SANTOS et al., 2017). O uso de dados provenientes de técnicas de sensoriamento remoto, como o

PDI, para estudos florestais, em especial a predição de parâmetros como volume e biomassa, está em evidência em todo o mundo devido à sua eficiência, capacidade de coleta de dados em grandes áreas e aplicação em escala global (MIGUEL et al., 2015; ZHU; LIU, 2015; BOISVENUE et al., 2016; GALIDAKI et al., 2016; CONDÉS; MCROBERTS, 2017; SANTOS et al., 2017; DEO et al., 2018).

Índices de vegetação (IVs) obtidos pelo processamento de imagens de satélite são ferramentas eficazes na estimativa de diversas variáveis florestais, sendo assim, de extrema importância e muito utilizada em trabalhos científicos (FERRAZ et al., 2014; SANTOS et al., 2017). Estudos como os de Watzlawick et al. (2009), Ferraz et al. (2014), Miguel et al. (2015), Zhu e Liu (2015), Benítez et al. (2016), López-Serrano et al. (2016) e Shen et al. (2016) alcançaram resultados satisfatórios para a estimativa de biomassa acima o solo com a aplicação de IVs em áreas de Floresta de Araucária, Floresta Estacional Semidecidual, Cerrado, Floresta Temperada nos Estados Unidos, Floresta Amazônica, Floresta Temperada no México e Floresta Subtropical na China, respectivamente.

Esses resultados são reflexo dos níveis consistentes de correlação entre índices de vegetação ou valores de reflectância de bandas espectrais e variáveis como volume, altura e área basal que, apesar de geralmente apresentar níveis moderados (ALMEIDA et al., 2014; MIGUEL et al., 2015; REIS et al., 2015b; ZHU; LIU, 2015; MIRELES et al., 2017; PHUA et al., 2017), podem alcançar níveis elevados, como o encontrado por Lima Júnior et al. (2014) entre valores de NDVI (inglês para Índice de Vegetação pela Diferença Normalizada) e biomassa ( $R= 0,84$ ;  $p < 0,01$ ).

A qualidade da imagem é determinada pelo objetivo do trabalho e o custo associado à sua aquisição. O sensor Terra/Modis (TM) do satélite Landsat é amplamente utilizado para avaliação de produtividade, mensuração, identificação e monitoramento de áreas florestais, mesmo com limitações como a saturação dos seus dados e resolução espacial que dificulta o uso em estudos que necessitem de uma abordagem em escalas mais detalhadas, especificamente menores que 1:100.000 (ZHANG et al., 2014; ALMEIDA et al., 2015; OLIVEIRA et al., 2015), sendo assim recomendado para cobrir áreas relativamente grandes (SILVA; SANO, 2016). Em 2008 foi lançada a constelação de satélites equipada com o sensor *RapidEye* que apresenta resolução espacial detalhada, com pixels de 5 metros, contendo bandas do espectro visível e infravermelho próximo, e apresentando um ganho na acurácia de classificação florestal e estimativa de parâmetros florestais (OLIVEIRA et al., 2015; NÆSSET et al., 2016; SILVA; SANO, 2016).

Os erros cometidos pelos processos de estimativa e predição podem ser solucionados pela adoção de informações de melhor qualidade com imagens de sensores de maior resolução, além de algoritmos de processamento e técnicas de análises com maior poder e precisão de estimativa (BACCINI et al., 2007; DUBE; MUTANGA, 2015; MASEMOLA et al., 2016).

### **1.2.5 Redes neurais artificiais**

Redes Neurais Artificiais (RNAs) são modelos criados para simular neurônios biológicos, compostos por uma gama de neurônios interligados por interconexões, que possuem capacidade de aquisição e manutenção de conhecimento, isto é, as RNAs podem aprender por meio de exemplos (SILVA et al., 2010; AKKOÇ, 2012; BRAGA et al., 2014).

A aprendizagem é uma das características mais marcantes e importantes das RNAs, e é possibilitada por ajustes iterativos de seus pesos sinápticos, o que gera um aumento em seu desempenho (HAYKIN, 2001; BINOTI et al., 2015; DIAS et al., 2017). A estrutura de uma rede neural é composta por camadas de neurônios, possuindo uma camada de entrada,  $n$  camadas intermediárias (ocultas) e uma camada de saída. Uma RNA linear (*Perceptron*) não possui camadas ocultas e apenas a camada de saída realiza processamento, enquanto que uma RNA múltipla (*Multilayer Perceptron*) possui uma ou mais camadas intermediárias, nas quais os neurônios possuem funções de ativação e recebem informações ajustadas por pesos (BRAGA et al., 2014; BINOTI et al., 2015; TOSUN; DINCER, 2018). Nesse contexto, o funcionamento básico das redes neurais é baseado em seus neurônios, elementos fundamentais de processamento, que recebem dados por meio de conexões ponderadas por pesos que funcionam como sinapses, combinam esses dados e realizando uma operação não-linear, e por fim entregam o resultado final (TOSUN; DINCER, 2018).

O uso de redes neurais artificiais (RNAs) é amplo e abrange diversas áreas da ciência e da indústria, desde a química e engenharia termal até o setor da saúde e as indústrias aeroespaciais e de transporte (ROSAS et al., 2013; ESFE et al., 2016; GITOEE et al., 2018; TOSUN; DINCER, 2018). Essa técnica também é uma realidade crescente nas ciências florestais devido a sua alta precisão na estimativa de diversas variáveis da floresta, se mostrando muitas vezes mais eficaz que os tradicionais modelos de regressão (FERRAZ et al., 2014; MIGUEL et al., 2015; VAHEDI, 2016; LIMA et al., 2017;

ÖZÇELİK et al., 2017; VENDRUSCOLO et al., 2017; SILVA et al., 2018; VIEIRA et al., 2018b).

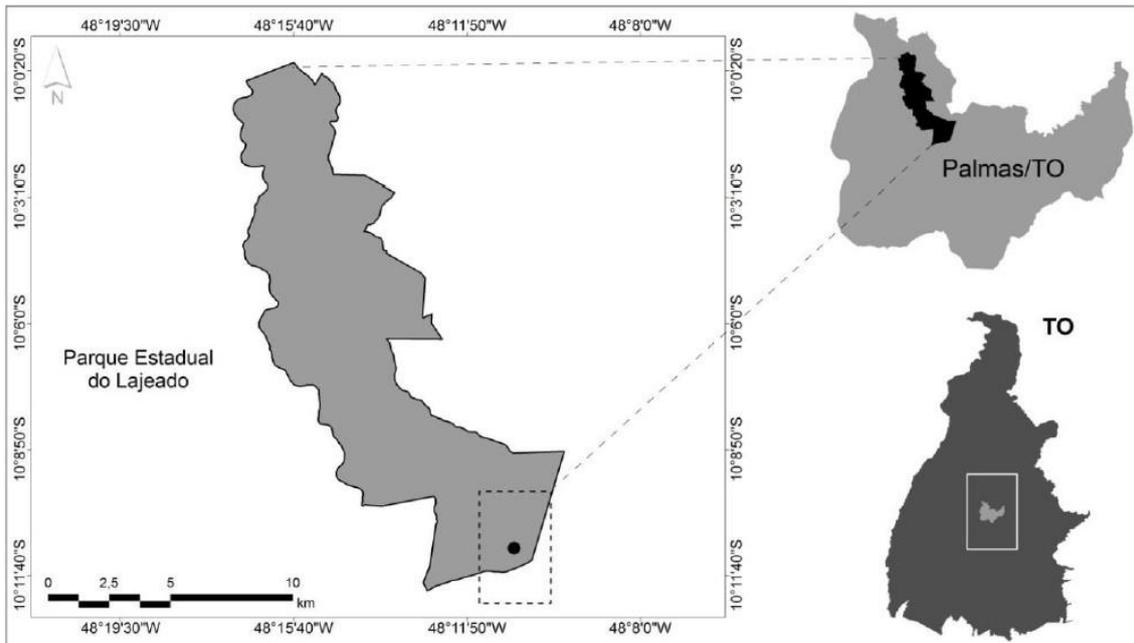
A superioridade em eficácia em relação aos modelos tradicionais pode ser explicada, mas não exclusivamente, pela capacidade de generalização das redes neurais, isto é, a estrutura pode receber dados de entrada diferentes daqueles presente durante seu treinamento que ainda assim será capaz de gerar uma resposta adequada, diferente de algoritmos tradicionais que conseguem processar apenas o que lhes foi ensinado (HAYKIN, 2001; LUDWIG JUNIOR; COSTA, 2007), além de outras características intrínsecas das RNAs como sua robustez, possibilidade de inclusão de variáveis categóricas, capacidade de solucionar problemas de natureza não-linear e o fato de sofrer menos impacto de *outliers* e falhas quando comparadas com modelos tradicionais de regressão (HAYKIN, 2009; CAMPOS; LEITE, 2017; TOSUN; DINCER, 2018). Ressalta-se ainda que as redes neurais artificiais não possuem os pressupostos de normalidade, linearidade e homocedasticidade como os modelos de regressão tradicionais (EGRIOGLU et al., 2015).

## **2 MATERIAIS E MÉTODOS**

### **2.1 Descrição da área de estudo**

Este estudo foi realizado com dados de inventário florestal realizado em 2012 em um fragmento de cerradão de 10,15 hectares situado entre os paralelos 10°10'55'' e 10°11'20'' de latitude Sul e os meridianos 48°10'50'' e 48°10'30'' de longitude Oeste, situado dentro do Parque Estadual do Lajeado, no estado do Tocantins, próximo à capital, Palmas (Figura 1).

A região deste estudo apresenta clima do tipo Aw, segundo a classificação de Köppen (ALVARES et al., 2014), com precipitação mensal média de 250 mm no período compreendido entre dezembro e fevereiro, e um inverno seco entre maio e setembro, com o pico desse clima seco ocorrendo entre junho e agosto. Com relevo plano-ondulado, os solos da área apresentam predominância de Latossolo Vermelho-Escuro distrófico álico de textura média, geralmente profundos ou muito profundos e com presença de horizontes A, B e C (EMBRAPA, 2018).



**Figura 1.** Localização da área de estudo em relação ao município de Palmas e ao estado do Tocantins (TO) (MIGUEL, 2014).

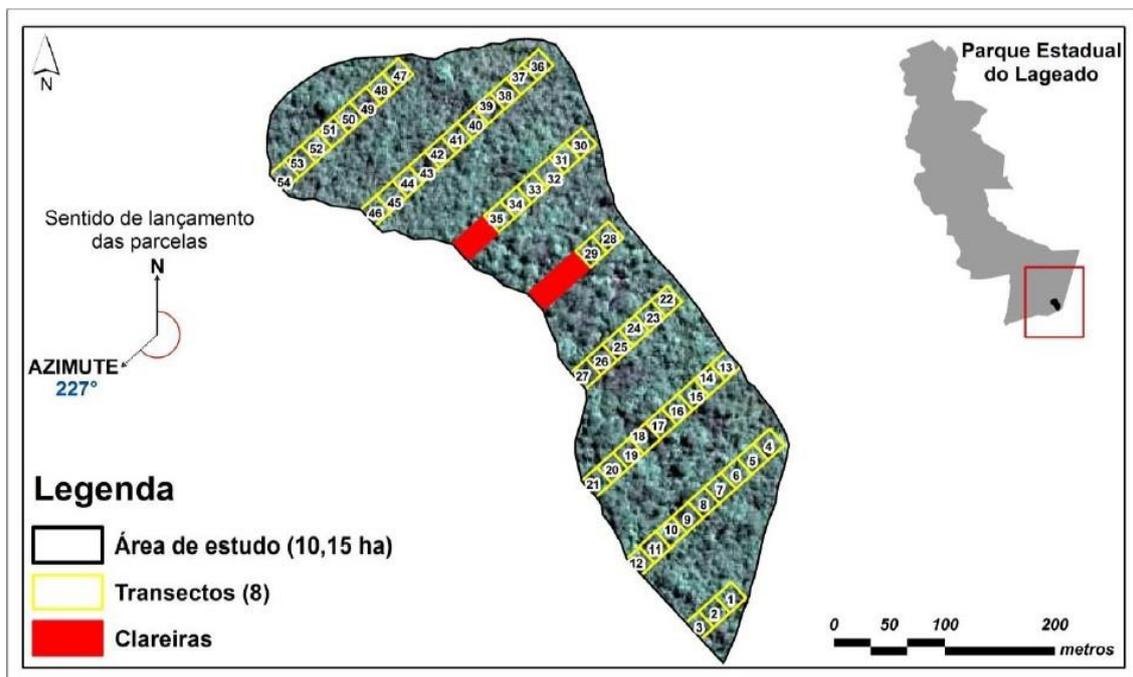
A área de estudo apresenta uma vegetação diversa, estruturada e em bom estado de conservação (MIGUEL et al., 2016). É composta por 34 famílias botânicas, nas quais as Fabaceae (15), Chrysobalanaceae (7), Apocynaceae (5), Melastomataceae (5), Malpighiaceae (4), Vochysiaceae (4), Anacardiaceae (3) e Connaraceae (3) são as famílias mais bem representadas, contando com 56% do total de 82 espécies identificadas e tendo, em média, 1.228 indivíduos.ha<sup>-1</sup>. A espécie mais abundante, responsável por 12,20% de todo o índice de valor de importância da área, é a *Myrcia splendens* seguida por *Emmotum nitens* (10%), *Qualea parviflora* (7%), *Xylopia aromatica* (6%), *Tapirira guianensis* (6%), *Miconia albicans* (7%), *Parkia platycephala* (4%), *Caryocar coriaceum* (4%), *Tachigale vulgaris* (4%) e *Mezilaurus itauba* (3%) as quais juntas representam 63% do índice de valor de importância total da área (MIGUEL et al., 2016, 2017b).

Os indivíduos da área apresentam diâmetro médio de 11,55cm em um intervalo de 5 a 65cm, e altura média de 9 m em um intervalo de 3 a 21 m, sendo que cerca de 13% deles se enquadram em um estrato vertical superior (> 11,54 m) e 63% apresentam altura entre 6,41m e 11,54. Indivíduos pioneiros totalizam 613 árvores.ha<sup>-1</sup>, enquanto os indivíduos de clímax somam 530 árvores.ha<sup>-1</sup>, se distribuindo em 25 e 57 espécies, respectivamente (MIGUEL et al., 2016, 2017b).

## 2.2 Processo de amostragem e coleta de dados

### 2.2.1 Inventário florestal

O inventário florestal conduzido na área de estudo seguiu processo de amostragem sistemático, como sugerido por Felfili et al. (2005), de forma que oito transectos de 20 m de largura e comprimentos variáveis foram demarcados a uma distância de 60 m entre si. Cada transecto foi subdividido em parcelas de dimensões 20 m x 20 m (400 m<sup>2</sup>) totalizando cinquenta e quatro parcelas e uma área amostrada de 2,16 ha (Figura 2).



**Figura 2.** Localização e posicionamento dos transectos e parcelas amostrais na área de estudo (MIGUEL, 2014).

Todas as árvores vivas e mortas em pé que apresentavam diâmetro a 1,30 m a partir do solo (DAP) igual ou superior a 5 cm foram identificadas e seu DAP e sua altura total (Ht) foram mensurados utilizando, respectivamente, suta métrica e régua telescópica de 15 m dentro de cada parcela amostral. Árvores com altura superior foram mensuradas de forma visual, estimando sua altura tomando a própria régua como referência e o DAP foi calculado a partir da média de duas medições perpendiculares, uma vez que grande parte dos troncos apresenta seção irregular.

Indivíduos apresentando bifurcações no tronco abaixo da altura do DAP tiveram seus fustes que apresentavam DAP acima de 5,0 cm mensurados separadamente para diâmetro, altura e área seccional. A área basal foi resultado da soma das duas (ou mais)

áreas seccionais. Todas as árvores amostradas foram georreferenciadas em relação ao canto direito inferior de cada parcela, utilizando coordenadas X e Y.

### 2.2.2 Amostragem da madeira

Para a realização dos ensaios laboratoriais de determinação do potencial energético foram cortados 80 indivíduos pertencentes a 34 espécies arbóreas (Tabela 1) das 82 identificadas na região. A redução do número de espécies amostradas se deu devido à raridade na distribuição e à proibição por lei de corte de indivíduos de determinadas espécies. Informações do inventário florestal conduzido foram cruciais para a determinação do número de indivíduos cortados para cada espécie amostrada, ficando definido como cerca de 3% das árvores com DAP > 5 cm, com no mínimo um indivíduo de cada espécie coletado, mediante autorização da Agência Ambiental do Estado do Tocantins – NATURATINS. De cada indivíduo derrubado foram retiradas amostras em forma de disco com 5 cm de espessura provenientes de diferentes posições do fuste (base, meio e topo), e de diferentes diâmetros de galhos (galho grosso: diâmetro > 10 cm; galho médio: diâmetro de 3 a 10 cm; galho fino: diâmetro menor que 3 cm), das quais a porção de casca foi retirada a fim de ser avaliada separadamente.

**Tabela 1.** Lista das espécies com o respectivo número de indivíduos cortados na área de cerradão estudada.

Nº	Espécie	Nº de indivíduos
1	<i>Aspidosperma subincanum</i> Mart.	1
2	<i>Bocageopsis multiflora</i> (Mart.)	1
3	<i>Bowdichia virgiloides</i> Kunth.	1
4	<i>Byrsonima laxiflora</i> Griseb.	1
5	<i>Byrsonima pachyphylla</i> A. Juss	1
6	<i>Byrsonima sericea</i> A. Juss B	2
7	<i>Connarus perrottetti</i> (DC.) Planch	1
8	<i>Connarus suberosus</i> Planch	1
9	<i>Dalbergia densiflora</i> Benth.	1
10	<i>Emmotum nitens</i> (Benth.) Miers.	7
11	<i>Erythroxylum daphnines</i> Mart.	1
12	<i>Ferdinandusa elliptica</i> Pohl. Pl. Bras.	1
13	<i>Himatanthus sucuuba</i> (Spruce ex Mull. Arg.)	1
14	<i>Inga alba</i> (Sw.) Willd.	1
15	<i>Licania apetala</i> (E. Meyer) Fritsch.	1
16	<i>Mabea fistulífera</i> Mart.	1

Continuação Tabela 1

Nº	Espécie	Nº de indivíduos
17	<i>Maprounea guianensis</i> Aubl.	2
18	<i>Matayba guianensis</i> Aubl.	1
19	<i>Mezilaurus itauba</i> (Meissn.) Taub.	2
20	<i>Miconia albicans</i> (Swartz)	5
21	<i>Miconia cuspidata</i> Mart. Ex Naudin.	3
22	<i>Myrcia splendens</i> (Sw.) DC.	8
23	<i>Ouratea ovallis</i> (Pohl) Engl.	2
24	<i>Parkia pendula</i> (Willd.) Benth.	2
25	<i>Parkia platycephala</i> Benth.	1
26	<i>Pouteria ramiflora</i> (Mart.) Radlk.	5
27	<i>Protium heptaphyllum</i> Mart.	4
28	<i>Qualea parviflora</i> Mart.	2
29	<i>Sacoglottis guianensis</i> Benth.	2
30	<i>Tachigali vulgaris</i> L. G. Silva & H. C. Lima	4
31	<i>Tapirira guianensis</i> Aubl.	4
32	<i>Virola sebifera</i> Aubl.	2
33	<i>Vochysia gardineri</i> Warm.	1
34	<i>Xylopia aromática</i> (Lam.) Mart.	7

As 34 espécies das quais tiveram ao menos um indivíduo derrubado em campo representam aproximadamente 95% dos indivíduos totais amostrados no inventário florestal, acima do mínimo de 80% da vegetação necessário para considerar o número de indivíduos amostradas suficientes para representar as características quantitativas da comunidade (PAKEMAN; QUESTED, 2007). Ressalta-se que essas espécies representam aproximadamente 83% do índice de valor de importância (IVI) da área de estudo.

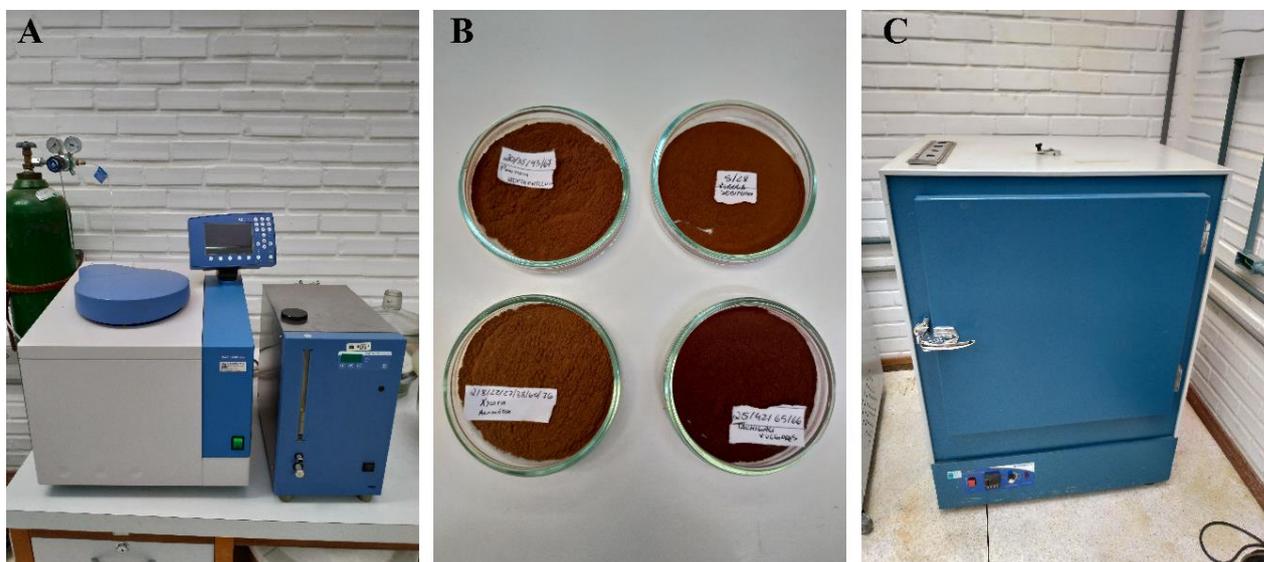
## 2.3 Quantificação das variáveis energéticas

### 2.3.1 Poder calorífico superior

O poder calorífico superior (PCS) da casca de cada espécie amostrada foi determinado segundo a NBR 8633 (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 1984), conforme utilizada em diversos trabalhos (QUIRINO et al., 2004; MEDEIROS NETO et al., 2012; PROTÁSIO et al., 2013a, 2013b; SANTOS et al., 2013; COSTA et al., 2014; EVARISTO et al., 2016; JESUS et al., 2017b). Foi utilizado calorímetro adiabático da marca IKA modelo C2000 basic (Figura 3A), em parceria com o Laboratório de Tecnologia da Madeira da Universidade de Brasília. As amostras de

casca foram picadas, moídas e, em seguida, classificadas pelo uso de peneiras de 60 *mesh*, sendo que os fragmentos retidos na peneira foram utilizados para a formação de amostras mistas para cada espécie (Figura 3B). Essas amostras foram secas em estufa com circulação de ar (Figura 3C) à  $103\pm 2^{\circ}\text{C}$  até apresentarem massa constante e utilizadas como combustível para o ensaio.

Silva (2014) realizou os mesmos ensaios laboratoriais para determinação do PCS da madeira das mesmas 34 espécies amostradas no presente estudo, desta forma, os resultados encontrados pelo autor foram considerados como o PCS da porção lenhosa das espécies neste trabalho. As amostras utilizadas pelo autor foram coletadas na mesma área de estudo utilizando metodologia de coleta similar.



**Figura 3.** Calorímetro utilizado para análise de poder calorífico (A); Amostras compostas utilizadas para análise de poder calorífico (B); Estufa utilizada para secagem das amostras (C).

### 2.3.2 Biomassa e potencial energético

A biomassa seca da madeira e da casca de cada indivíduo amostrado foi determinada com uso do modelo de Schumacher e Hall (1933) ajustado e validado por Miguel et al. (2017a) (Tabela 2). A equação ajustada pelos autores é referente à biomassa total de um indivíduo arbóreo, porém, utilizando-se do percentual médio de biomassa de madeira (71,7%) e de casca (21,0%) encontrado pelos autores para indivíduos do Cerrado como fatores de ponderação, foi possível encontrar a biomassa seca da madeira e da casca separadamente.

**Tabela 2.** Modelos para determinação de biomassa (MIGUEL et al., 2017a).

Modelo	Equação
Schumacher e Hall – Madeira	$Bm_m = 0,0123307 \cdot DAP^{1,79593} \cdot Ht^{1,54701} \cdot 0,717$
Schumacher e Hall – Casca	$Bm_c = 0,0123307 \cdot DAP^{1,79593} \cdot Ht^{1,54701} \cdot 0,210$

Em que:  $Bm_m$  = biomassa da madeira;  $Bm_c$  = biomassa da casca; DAP = diâmetro à 1,30 metros do solo; Ht = altura total; 0,717 = constante referente ao percentual médio de biomassa de madeira em uma árvore do Cerrado; 0,210 = constante referente ao percentual médio de biomassa de casca em uma árvore do Cerrado.

Em seguida, o potencial energético ( $Pe$ ) da madeira e da casca desses indivíduos foram calculados separadamente por meio da equação (1), sendo que o poder calorífico superior (PCS) da madeira e da casca encontrados para cada espécie foi atribuído para todos os indivíduos da mesma. O PCS atribuído aos indivíduos mortos e das demais espécies não amostradas foi o valor médio do poder calorífico encontrado para as 34 espécies. Foi determinado então o potencial energético para cada indivíduo amostrado, ou sua quantidade de energia estocada, como sendo a soma do potencial energético da madeira e da casca desse indivíduo.

$$Pe = \frac{(\text{PCS} \cdot Bm)}{238.845,9} \quad (1)$$

Onde  $Pe$  é o potencial energético da madeira ou da casca do indivíduo (GJ); PCS é o poder calorífico superior da madeira ou da casca da espécie ( $\text{kcal} \cdot \text{kg}^{-1}$ );  $Bm$  é a massa de biomassa seca a 0% de umidade da madeira ou da casca do indivíduo (kg); e 238.845,8 é a constante de conversão de kcal para GJ.

Por fim, foi quantificado o potencial energético por unidade de área (hectare) para cada parcela amostral, definida pelo somatório do potencial energético individual de cada árvore presente na parcela extrapolada para hectare (2).

$$Pe_i = \sum Pe_{ji} \quad (2)$$

Onde  $Pe_i$  é o potencial energético por unidade de área da parcela  $i$  ( $\text{GJ} \cdot \text{ha}^{-1}$ );  $Pe_{ji}$  é o potencial energético da árvore  $j$  presente na parcela  $i$  (GJ).

## 2.4 Processamento da imagem de satélite

Uma imagem *RapidEye* da área de estudo adquirida em 2012 foi corrigida geométrica e atmosféricamente com o uso do software *ERDAS Imagine* 2011 (ERDAS, 2011) que incluiu a conversão de número digital para radiância e dessa em reflectância, desconsiderando a influência da atmosfera (PLANET, 2016).

$$REF(i) = RAD(i) \frac{\pi.SunDist^2}{EAI(i).cos(SolarZenith)} \quad (3)$$

Onde REF é o valor de reflectância; RAD é o valor de radiância;  $i$  é o número da banda espectral; SunDist é a distância entre a Terra e o Sol no dia da aquisição em unidades astronômicas; EAI é a irradiação exo-atmosférica; e SolarZenith é o ângulo do Zenith solar em graus ( $= 90^\circ$  - elevação do sol). Os valores EAI para cada banda são constantes e pra imagens *RapidEye* são: BLUE = 1.997,8 W/m<sup>2</sup>μm; GREEN = 1.863,5 W/m<sup>2</sup>μm; RED = 1.560,4 W/m<sup>2</sup>μm; RED EDGE = 1.395,0 W/m<sup>2</sup>μm; NIR = 1.124,4 W/m<sup>2</sup>μm. Demais dados foram obtidos por meio do arquivo de metadados que acompanha a imagem.

A imagem *RapidEye* foi escolhida devido à sua resolução espacial de 5 metros, permitindo maior representatividade dos valores obtidos para os índices, além de sua resolução espectral que apresenta uma banda no espectro do RED EDGE, localizada entre as faixas do vermelho e do infravermelho próximo (690-730nm). A banda do RED EDGE aprimora as capacidades do *RapidEye* para avaliação de aspectos da vegetação (BENÍTEZ et al., 2016).

Seis índices de vegetação foram calculados por meio da ferramenta matemática de bandas do software *ERDAS Imagine* 2011 (ERDAS, 2011). Isso permitiu a determinação do valor médio para a área de cada uma das 54 parcelas.

Os índices de vegetação utilizados neste trabalho foram: NDVI, índice de vegetação de diferença normalizada (ROUSE et al., 1974) (4); NDRE, índice RED EDGE de diferença normalizada, variação do NDVI para inclusão da banda RED EDGE e aumento da sensibilidade à presença de clorofila (GITELSON; MERZLYAK, 1994) (5); CI<sub>GREEN</sub>, índice de clorofila com a banda GREEN, possui alta correlação com o conteúdo de clorofila e o índice de área foliar (GITELSON et al., 2003) (6); CI<sub>RED EDGE</sub>, índice RED EDGE de clorofila, variação do CI<sub>GREEN</sub> para inclusão da banda RED EDGE (GITELSON et al., 2003) (7); Savi, índice de vegetação ajustado ao solo, utilizado para corrigir a influência de solo exposto em meio a vegetação (HUETE, 1988) (8); e EVI<sub>2</sub>, índice de vegetação modificado, desenvolvido como uma melhora para o NDVI em sua sensibilidade para atividade fotossintética (JIANG et al., 2008) (9). Esses índices foram

escolhidos devido à sua alta disseminação e sensibilidade à atividade fotossintética, relacionada ao acúmulo de biomassa, melhorada com a inclusão da banda do RED EDGE.

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

$$NDRE = \frac{(NIR-RED\ EDGE)}{(NIR+RED\ EDGE)} \quad (5)$$

$$CI_{GREEN} = \frac{NIR}{GREEN} - 1 \quad (6)$$

$$CI_{RED\ EDGE} = \frac{NIR}{RED\ EDGE} - 1 \quad (7)$$

$$Savi = \frac{(1+L).(NIR-RED)}{NIR+RED+L} \quad (8)$$

$$EVI_2 = 2,5. \frac{(NIR-RED)}{(NIR+2,4.RED+1)} \quad (9)$$

Onde NIR é a reflectância na banda do infravermelho próximo; RED é a reflectância na banda do vermelho; RED EDGE é a reflectância da banda *red edge*; GREEN é a reflectância na banda do verde; L é a constante de ajuste de solo (0,5); 2,5 é o fator de ganho; 2,4 e 1 são constantes.

## 2.5 Modelagem

### 2.5.1 Seleção das variáveis independentes

A predição do potencial energético foi realizada utilizando duas variáveis independentes: a área basal (G) (10), cuja utilização como uma variável preditora se justifica pela facilidade de sua obtenção, pela alta correlação com a biomassa (NI-MEISTER et al., 2010; BALDERAS-TORRES; LOVETT, 2012) e pela associação direta com o grau de aproveitamento dos fatores de crescimento e produção local (HUSCH et al., 1982), e o índice de vegetação mais adequado. A seleção do índice de vegetação foi feita por meio da análise de correlação entre os seis índices calculados e a unidade de interesse (*Pe*), sendo essa análise precedida pelo teste de normalidade de Shappiro-Wilk (SHAPIRO; WILK, 1965) que definiu a metodologia de correlação utilizada (paramétrica ou não-paramétrica) utilizando o *software* RStudio 1.0.143 (RSTUDIO, 2016).

$$G_i = \sum g_{ji} \quad (10)$$

Onde  $G_i$  é a área basal da parcela  $i$  ( $m^2$ ); e  $g_{ji}$  é a área seccional da árvore  $j$  na parcela  $i$  ( $m^2$ ), dado por:

$$g = \frac{\pi \cdot \text{DAP}^2}{40.000} \quad (11)$$

Onde  $\pi$  é a constante igual à 3,14159; DAP é o diâmetro à altura do peito (1,30 m do solo) (cm); e 40.000 é uma constante.

### 2.5.2 Treinamento das redes neurais

Um total de 1.000 (mil) redes neurais foram treinadas de maneira supervisionada, isto é, as variáveis de entrada e de saída foram indicadas para a rede, por meio da ferramenta *Intelligent Problem Solver* (IPS), do software Statistica 7 (STATSOFT, 2007). Esta ferramenta permite a otimização da arquitetura das RNAs, definindo o melhor número de neurônios na camada oculta e as melhores funções de ativação das camadas oculta e de saída, e é de amplo uso pela comunidade científica (ROSAS et al., 2013; BINOTI et al., 2015; VALE et al., 2017; GITOOE et al., 2018).

O algoritmo utilizado pelo IPS para o processamento das redes neurais é algoritmo quasi-Newton de Broyden-Fletcher-Goldfarb-Shanno (BFGS) (BROYDEN, 1970; FLETCHER, 1970; GOLDFARB, 1970; SHANNO, 1970), que possui grande poder de resolução de problemas de otimização e previsões, além de ser o método quasi-Newton mais popular (BAI et al., 2017; GUERROUT et al., 2018).

As redes treinadas possuem arquitetura do tipo Perceptron de Múltiplas Camadas (MLP, sigla em inglês para *Multilayer Perceptron*), com a camada de entrada constituída por dois neurônios (G e índice), uma camada oculta constituída por  $n$  neurônios, e uma camada de saída constituída por um neurônio, o potencial energético ( $Pe$ ).

O neurônio é o elemento fundamental da estrutura de uma RNA, uma representação simplificada de um neurônio biológico, e é responsável pelo processamento dos dados e informações ao receber valores de entrada (área basal e índice de vegetação) até o resultado de interesse (potencial energético). Basicamente, a funcionalidade dos neurônios das RNAs se dá por combinação e reprodução de informações baseada em conexões entre os  $n$  possíveis *inputs* (variáveis de entrada)  $x_1, x_2, \dots, x_n$  e o *output* (variável de saída)  $y$ . Os *inputs* recebem pesos  $w_1, w_2, \dots, w_n$ , representações das sinapses cerebrais e onde, segundo Gorunescu e Belciug (2016), as redes MLP armazenam o conhecimento. O neurônio artificial é dado, matematicamente, por:

$$Y_k = \varphi(V_k) \quad (12)$$

Onde  $Y_k$  é o *output* do neurônio artificial;  $\varphi$  é a função de ativação; e  $V_k$  é o combinador linear do *output*, dado por:

$$V_k = \sum x_m \cdot w_m \quad (13)$$

Onde  $V_k$  é o combinador linear;  $x_m$  é o *input*  $m$ ; e  $w_m$  é o peso sináptico  $m$ .

O uso de uma rede multicamada foi definido devido a sua característica não-linear, sendo considerado mais adequado para a resolução de problemas e situações reais em relação às redes de única camada com características lineares (BRAGA et al., 2014).

## 2.6 Análise estatística

O treinamento das RNAs foi realizado utilizando dados de 40 das 54 parcelas amostrais escolhidas aleatoriamente, correspondendo a cerca de 75% do total. As parcelas restantes foram utilizadas para validação dos resultados, não fazendo parte do treinamento das redes, conforme sugerido por Zucchini (2000), e respeitando o intervalo de 10 a 30% das parcelas amostrais sugerido por Gujarati e Porter (2011) a ser direcionado à validação. A qualidade de estimativa das redes neurais treinadas foi analisada estatisticamente através dos seguintes critérios: erro padrão da estimativa em percentual (RMSE%) (14); a correlação entre os valores estimados e observados (R); e a análise gráfica dos resíduos (DRAPER; SMITH, 1998).

$$RMSE\% = \frac{100}{\bar{Y}} \sqrt{\frac{\sum(Y_i - \hat{Y}_i)^2}{n}} \quad (14)$$

Onde  $\bar{Y}$  é a média dos valores observados de  $Pe$ ;  $Y_i$  é o valor observado de  $Pe$  na parcela  $i$ ; e  $\hat{Y}_i$  é o valor estimado de  $Pe$  pela RNA para a parcela  $i$ .

Por fim, a RNA que apresentou os melhores resultados foi submetida ao processo de validação utilizando o teste de  $t$  de Student, e sequencialmente foi analisada a diferença agregada (DA%), em percentual, valor estatístico indicador de sub ou superestimação (MIGUEL et al., 2015; CARRIJO et al., 2017; VALE et al., 2017). As análises foram realizadas em ambiente Microsoft Excel 2013®.

### 3 RESULTADOS

#### 3.1 Poder calorífico superior

As espécies provenientes da área de estudo apresentaram valores de poder calorífico superior (PCS) do material lenhoso (fuste e galho) entre 18,282 GJ.ton<sup>-1</sup> e 20,121 GJ.ton<sup>-1</sup> (Tabela 3), com valor médio de 19,234 GJ.ton<sup>-1</sup> (atribuído às espécies não amostradas e indivíduos mortos), cujas espécies de maior poder calorífico foram *Pouteria ramiflora* (20,121 GJ.ton<sup>-1</sup>), *Tachigali vulgaris* (20,105 GJ.ton<sup>-1</sup>) e *Mezilaurus itauba* (19,923 GJ.ton<sup>-1</sup>). Os de menores valores foram as espécies *Parkia platycephala* (18,282 GJ.ton<sup>-1</sup>), *Bowdichia virgilioides* (18,434 GJ.ton<sup>-1</sup>) e *Connarus perrottetti* (18,478 GJ.ton<sup>-1</sup>) conforme relatado por Silva (2014).

Os valores de PCS da casca ficaram entre 16,805 GJ.ton<sup>-1</sup> e 21,587 GJ.ton<sup>-1</sup>, com valor médio de 19,878 GJ.ton<sup>-1</sup> (também atribuído às espécies não amostradas e indivíduos mortos) (Tabela 3), sendo que as espécies com maiores valores foram *Bowdichia virgilioides* (21,587 GJ.ton<sup>-1</sup>), *Xylopia aromatica* (21,290 GJ.ton<sup>-1</sup>) e *Connarus suberosus* (21,232 GJ.ton<sup>-1</sup>). As espécies de menor valor foram: *Miconia albicans* (16,805 GJ.ton<sup>-1</sup>), *Miconia cuspidata* (16,857 GJ.ton<sup>-1</sup>) e *Qualea parviflora* (17,997 GJ.ton<sup>-1</sup>).

**Tabela 3.** Dados de poder calorífico superior (PCS) da madeira e da casca das 34 espécies florestais amostradas no Parque Estadual do Lajeado, Tocantins.

Espécie	PCS Madeira (GJ.ton <sup>-1</sup> )*	PCS Casca (GJ.ton <sup>-1</sup> )
<i>Aspidosperma subincanum</i> Mart.	19,515	19,726
<i>Bocageopsis multiflora</i> (Mart.)	19,248	20,122
<i>Bowdichia virgilioides</i> Kunth.	18,434	21,602
<i>Byrsonima laxiflora</i> Griseb.	19,288	19,827
<i>Byrsonima pachyphylla</i> A. Juss	19,012	21,187
<i>Byrsonima sericea</i> A. Juss B	19,300	19,862
<i>Connarus perrottetti</i> (DC.) Planch	18,478	20,850
<i>Connarus suberosus</i> Planch	19,334	21,246
<i>Dalbergia densiflora</i> Benth.	19,317	20,180
<i>Emmotum nitens</i> (Benth.) Miers.	18,987	20,084
<i>Erythroxylum daphnites</i> Mart.	19,220	19,333
<i>Ferdinandusa elliptica</i> Pohl. Pl. Bras.	19,485	19,508
<i>Himatanthus sucuuba</i> (Spruce ex Mull. Arg.)	19,229	20,329
<i>Inga alba</i> (Sw.) Willd.	19,815	19,889
<i>Licania apetala</i> (E. Meyer) Fritsch.	19,018	19,958
<i>Mabea fistulifera</i> Mart.	18,815	18,370
<i>Maprounea guianensis</i> Aubl.	19,395	19,816

Continuação Tabela 3

Espécie	PCS Madeira (GJ.ton <sup>-1</sup> )*	PCS Casca (GJ.ton <sup>-1</sup> )
<i>Matayba guianensis</i> Aubl.	19,553	19,374
<i>Mezilaurus itauba</i> (Meissn.) Taub.	19,923	20,595
<i>Miconia albicans</i> (Swartz)	18,912	16,816
<i>Miconia cuspidata</i> Mart. Ex Naudin.	19,153	16,869
<i>Myrcia splendens</i> (Sw.) DC.	19,130	19,636
<i>Ouratea ovallis</i> (Pohl) Engl.	19,473	20,597
<i>Parkia pendula</i> (Willd.) Benth.	18,975	19,982
<i>Parkia platycephala</i> Benth.	18,282	20,515
<i>Pouteria ramiflora</i> (Mart.) Radlk.	20,121	19,931
<i>Protium heptaphyllum</i> Mart.	19,096	20,488
<i>Qualea parviflora</i> Mart.	19,168	18,010
<i>Sacoglottis guianensis</i> Benth.	19,386	19,651
<i>Tachigali vulgaris</i> L. G. Silva & H. C. Lima	20,105	20,448
<i>Tapirira guianensis</i> Aubl.	18,894	18,878
<i>Virola sebifera</i> Aubl.	19,213	19,927
<i>Vochysia gardineri</i> Warm.	19,500	20,938
<i>Xylopia aromática</i> (Lam.) Mart.	19,165	21,305
Espécies não amostradas e indivíduos mortos	19,234	19,878

\*Fonte: Silva (2014).

### 3.2 Potencial energético

Os valores finais para potencial energético ( $Pe$ ) por unidade de área encontrados para cada uma das 54 parcelas amostrais, já considerando a soma do potencial energético da madeira e da casca para cada indivíduo, podem ser observadas na tabela 4. Uma grande amplitude pode ser vista entre os valores, que ficaram entre 391,39 GJ.ha<sup>-1</sup> e 2.719,18 GJ.ha<sup>-1</sup>, sendo que grande parte das parcelas que apresentaram os maiores valores de  $Pe$  estão localizadas e regiões de borda. O potencial energético média por hectare encontrada para a área estudada é de 1.022,66 GJ.ha<sup>-1</sup>  $\pm$  560,89 GJ.ha<sup>-1</sup>.

**Tabela 4.** Valores de potencial energético por unidade de área para as 54 parcelas amostrais.

Parcela	$Pe$ (GJ.ha <sup>-1</sup> )
T1-P1	2155,84
T1-P2	1230,31
T1-P3	1247,49
T2-P4	1458,27
T2-P5	916,89

*Continuação Tabela 4*

Parcela	Pe (GJ.ha <sup>-1</sup> )
T2-P6	1795,00
T2-P7	1999,38
T2-P8	1164,72
T2-P9	1112,94
T2-P10	1786,69
T2-P11	859,12
T2-P12	1097,78
T3-P13	884,91
T3-P14	2616,53
T3-P15	749,39
T3-P16	1683,65
T3-P17	480,31
T3-P18	715,03
T3-P19	1792,11
T3-P20	1355,62
T3-P21	2719,18
T4-P22	1006,13
T4-P23	781,62
T4-P24	665,69
T4-P25	980,71
T4-P26	837,64
T4-P27	1144,08
T5-P28	1951,68
T5-P29	987,54
T6-P30	1265,76
T6-P31	489,72
T6-P32	871,94
T6-P33	616,38
T6-P34	770,26
T6-P35	822,67
T7-P36	1533,74
T7-P37	558,53
T7-P38	489,05
T7-P39	391,39
T7-P40	602,36
T7-P41	969,91
T7-P42	508,40
T7-P43	630,47
T7-P44	831,70
T7-P45	561,60

Continuação Tabela 4

Parcela	Pe (GJ.ha <sup>-1</sup> )
T7-P46	801,71
T8-P47	455,05
T8-P48	438,47
T8-P49	401,34
T8-P50	450,43
T8-P51	614,91
T8-P52	933,58
T8-P53	447,81
T8-P54	590,21

T = transecto; P = parcela; Pe = potencial energético.

### 3.3 Modelagem

#### 3.3.1 Seleção das variáveis independentes

Na Tabela 5 estão os valores de área basal (G) e índice de vegetação (IV) para cada parcela amostral. Pelo teste de Shappiro-Wilk ficou demonstrado que as variáveis não apresentavam normalidade e, em função deste resultado, a análise da matriz de correlação utilizada foi aquela sugerida por Spearman para dados não-paramétricos (SPEARMAN, 1904).

**Tabela 5.** Valores observados das variáveis de estudo para cada parcela amostral.

Parcela	Pe (GJ.ha <sup>-1</sup> )	G (m <sup>2</sup> )	NDVI	NDRE	CI <sub>GREEN</sub>	CI <sub>RED EDGE</sub>	SAVI	EVI <sub>2</sub>
T1-P1	2155,844	1,025	0,578	0,349	1,924	1,079	0,371	0,365
T1-P2	1230,309	0,735	0,605	0,368	2,055	1,164	0,402	0,399
T1-P3	1247,489	0,759	0,625	0,364	2,174	1,148	0,417	0,416
T2-P4	1458,271	0,946	0,559	0,341	1,834	1,040	0,361	0,354
T2-P5	916,889	0,624	0,598	0,361	2,068	1,129	0,399	0,396
T2-P6	1794,996	1,145	0,632	0,373	2,191	1,189	0,428	0,428
T2-P7	1999,381	1,016	0,627	0,379	2,114	1,221	0,414	0,412
T2-P8	1164,717	0,569	0,645	0,395	2,316	1,306	0,432	0,432
T2-P9	1112,941	0,723	0,651	0,385	2,265	1,255	0,440	0,442
T2-P10	1786,686	1,069	0,636	0,386	2,249	1,260	0,424	0,423
T2-P11	859,125	0,565	0,648	0,398	2,269	1,325	0,425	0,424
T2-P12	1097,784	0,632	0,615	0,379	2,089	1,220	0,396	0,392
T3-P13	884,912	0,653	0,571	0,342	1,855	1,045	0,372	0,366
T3-P14	2616,534	1,400	0,618	0,384	2,229	1,251	0,419	0,419
T3-P15	749,390	0,510	0,639	0,392	2,366	1,290	0,434	0,435
T3-P16	1683,652	1,116	0,650	0,396	2,339	1,313	0,446	0,450
T3-P17	480,305	0,339	0,602	0,362	1,995	1,136	0,390	0,386
T3-P18	715,031	0,430	0,615	0,377	2,166	1,212	0,415	0,414

Continuação Tabela 5

Parcela	Pe (GJ.ha <sup>-1</sup> )	G (m <sup>2</sup> )	NDVI	NDRE	CI <sub>GREEN</sub>	CI <sub>RED EDGE</sub>	SAVI	EVI <sub>2</sub>
T3-P19	1792,111	0,951	0,650	0,398	2,298	1,325	0,437	0,438
T3-P20	1355,618	0,632	0,647	0,384	2,280	1,252	0,439	0,441
T3-P21	2719,175	1,059	0,612	0,373	2,044	1,189	0,401	0,397
T4-P22	1006,129	0,712	0,577	0,351	1,922	1,083	0,380	0,374
T4-P23	781,619	0,572	0,600	0,367	2,057	1,161	0,400	0,397
T4-P24	665,692	0,503	0,650	0,399	2,340	1,327	0,445	0,448
T4-P25	980,707	0,600	0,634	0,393	2,216	1,299	0,422	0,421
T4-P26	837,638	0,588	0,606	0,374	2,022	1,197	0,386	0,380
T4-P27	1144,081	0,679	0,624	0,381	2,077	1,233	0,400	0,396
T5-P28	1951,676	0,790	0,567	0,348	1,866	1,069	0,367	0,361
T5-P29	987,539	0,716	0,561	0,352	1,833	1,092	0,358	0,351
T6-P30	1265,756	0,767	0,509	0,304	1,694	0,874	0,337	0,329
T6-P31	489,724	0,493	0,517	0,302	1,684	0,866	0,342	0,334
T6-P32	871,943	0,618	0,510	0,314	1,717	0,917	0,333	0,323
T6-P33	616,381	0,571	0,540	0,327	1,700	0,974	0,345	0,336
T6-P34	770,261	0,634	0,558	0,344	1,829	1,053	0,363	0,356
T6-P35	822,675	0,696	0,610	0,371	2,102	1,182	0,408	0,406
T7-P36	1533,738	1,007	0,354	0,221	1,028	0,568	0,206	0,192
T7-P37	558,526	0,619	0,397	0,245	1,250	0,648	0,244	0,231
T7-P38	489,053	0,546	0,397	0,252	1,275	0,678	0,248	0,235
T7-P39	391,388	0,457	0,470	0,291	1,532	0,826	0,300	0,289
T7-P40	602,362	0,550	0,497	0,307	1,626	0,888	0,319	0,309
T7-P41	969,909	1,105	0,499	0,310	1,644	0,899	0,323	0,313
T7-P42	508,402	0,459	0,498	0,307	1,604	0,886	0,320	0,310
T7-P43	630,475	0,555	0,486	0,297	1,610	0,844	0,315	0,304
T7-P44	831,703	0,748	0,492	0,293	1,598	0,831	0,321	0,311
T7-P45	561,601	0,529	0,443	0,269	1,451	0,734	0,291	0,280
T7-P46	801,711	0,561	0,432	0,266	1,404	0,724	0,280	0,268
T8-P47	455,048	0,506	0,347	0,218	0,937	0,560	0,196	0,183
T8-P48	438,465	0,412	0,353	0,217	0,950	0,556	0,198	0,184
T8-P49	401,341	0,400	0,361	0,230	1,045	0,602	0,210	0,197
T8-P50	450,435	0,510	0,440	0,278	1,394	0,776	0,272	0,260
T8-P51	614,911	0,621	0,386	0,242	1,242	0,642	0,240	0,227
T8-P52	933,579	0,884	0,409	0,261	1,389	0,707	0,266	0,254
T8-P53	447,813	0,510	0,460	0,284	1,549	0,796	0,304	0,293
T8-P54	590,211	0,665	0,454	0,278	1,581	0,772	0,304	0,294

T = transecto; P = parcela; Pe = potencial energético por unidade de área (GJ/ha); G = área basal (m<sup>2</sup>); NDVI = índice de vegetação de diferença normalizada; NDRE = índice de vegetação de diferença normalizada com RED EDGE; CI<sub>GREEN</sub> = índice de clorofila com a banda do verde; CI<sub>RED EDGE</sub> = índice de clorofila com RED EDGE; Savi = índice de vegetação ajustado ao solo; EVI<sub>2</sub> = índice de vegetação melhorado.

Essa matriz (Tabela 6) apresentou valores moderados e similares para todos os índices de vegetação e alto para a área basal (G) em relação ao potencial energético (rho

> 0,8). Apesar dos valores de correlação entre os seis índices e o potencial energético serem próximos, o índice NDVI apresentou o maior valor de correlação ( $\rho = 0,5987$ ) e, por isso, aliado ao fato de ser o índice de vegetação (IV) de maior uso e difusão no meio florestal (ALMEIDA et al., 2015; ZHU; LIU, 2015; SANTOS et al., 2017; ROCHE et al., 2018; TESTA et al., 2018), foi o índice escolhido como variável preditora para compor o treinamento das redes.

**Tabela 6.** Matriz de correlação segundo Spearman entre as variáveis estudadas.

	$Pe$ (GJ.ha <sup>-1</sup> )	G (m <sup>2</sup> )	NDVI	NDRE	CI <sub>GREEN</sub>	CI <sub>RED EDGE</sub>	SAVI	EVI <sub>2</sub>
$Pe$ (GJ.ha <sup>-1</sup> )	1							
G (m <sup>2</sup> )	0,8709**	1						
NDVI	0,5987**	0,3269*	1					
NDRE	0,5767**	0,2977*	0,9852**	1				
CI <sub>GREEN</sub>	0,5922**	0,3160*	0,9893**	0,9813**	1			
CI <sub>RED EDGE</sub>	0,5788**	0,2996*	0,9854**	0,9998**	0,9812**	1		
SAVI	0,5979**	0,3390*	0,9908**	0,9719**	0,9921**	0,9724**	1	
EVI <sub>2</sub>	0,5979**	0,3390*	0,9908**	0,9719**	0,9921**	0,9724**	1**	1

\*Significante à 5%; \*\*Significante à 1%. Em que:  $Pe$  = potencial energético por unidade de área (GJ/ha); G = área basal (m<sup>2</sup>); NDVI = índice de vegetação de diferença normalizada; NDRE = índice de vegetação de diferença normalizada com RED EDGE; CI<sub>GREEN</sub> = índice de clorofila com a banda do verde; CI<sub>RED EDGE</sub> = índice de clorofila com RED EDGE; Savi = índice de vegetação ajustado ao solo; EVI<sub>2</sub> = índice de vegetação melhorado.

### 3.3.2 Treinamento das redes neurais

As cinco redes de melhor desempenho inicial dentre as 1.000 RNAs treinadas apresentaram estatísticas de ajuste e precisão satisfatórias, com valores de coeficiente de correlação (R) superiores a 0,95 e erros de estimativa abaixo de 15%. Entretanto, a rede neural 3 foi a RNA que demonstrou melhor capacidade preditiva, segundo valores de RMSE% e correlação (Tabela 7).

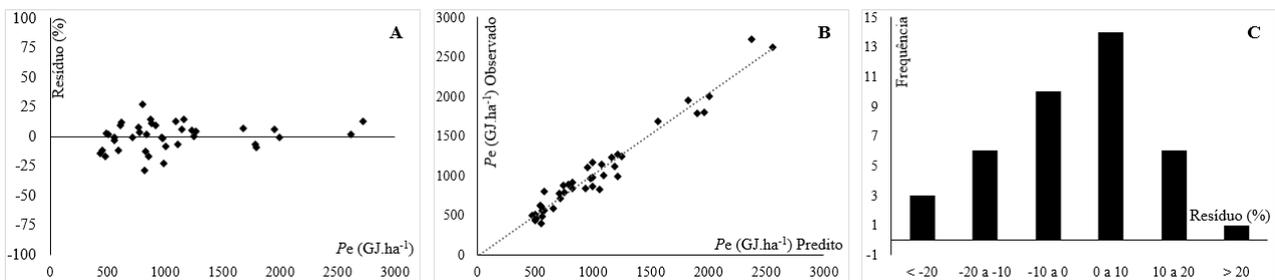
**Tabela 7.** Características e análise de precisão das redes neurais artificiais treinadas.

RNA	Arquitetura	Nº de Ciclos	Ativação Oculta	Ativação Saída	RMSE (GJ.ha <sup>-1</sup> )	RMSE%	R
1	MLP 2-8-1	583	Sigmoidal	Seno	147,91	14,24	0,96
2	MLP 2-7-1	272	Tangente	Sigmoidal	125,96	12,12	0,97
3	MLP 2-8-1	330	Tangente	Sigmoidal	117,05	11,27	0,98
4	MLP 2-9-1	267	Sigmoidal	Sigmoidal	141,60	13,63	0,97
5	MLP 2-8-1	10000	Exponencial	Exponencial	142,54	13,72	0,97

RNA = rede neural artificial; MLP = *Multilayer Perceptron* (Perceptron multicamadas); Ativação Oculta = função de ativação da camada oculta; Ativação Saída = função de ativação da camada de saída; RMSE =

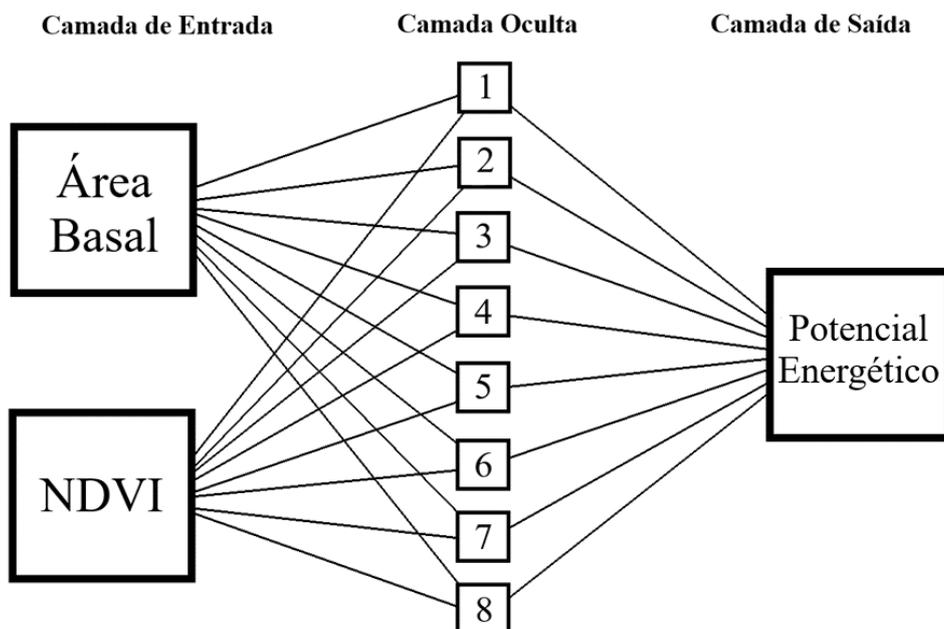
*Root-Mean-Square Error* (Erro médio quadrático); R = coeficiente de correlação entre os valores observados e os valores preditos.

A rede escolhida apresentou um padrão aceitável para distribuição de resíduos (Figura 4A), previsões acuradas da variável de interesse (Figura 4B) e, de acordo com o histograma de classes de erros, apresentou uma concentração maior de resíduos nas classes centrais do gráfico, indicando a ausência de grandes níveis de sub ou superestimativa, abaixo de 20% (Figura 4C).



**Figura 4.** Distribuição de resíduos (A), valores observados e preditos (B) e distribuição de classes de erro (C) da estimativa de potencial energético.

Ela apresenta em sua configuração 8 neurônios na camada oculta, ativada por uma função tangente, enquanto a camada de saída é ativada por uma função sigmoideal (Figura 5).



**Figura 5.** Arquitetura da RNA selecionada para predição de potencial energético por unidade de área em cerradão (2-8-1).

### 3.4 Análise estatística

Subsequentemente o resultado do teste  $t$  de Student mostrou que a RNA selecionada apresentou valor de  $p$  maior que  $\alpha = 0,05$  ( $p = 0,726$ ), logo não existem diferenças estatísticas significativas entre os valores preditos pela rede neural com os valores observados para as parcelas de validação. Já a diferença agregada demonstrou leve viés de superestimação da rede ( $DA\% = -4,63\%$ ), validando os resultados de precisão encontrados para o treinamento da rede neural.

## 4 DISCUSSÃO

### 4.1 Poder calorífico superior e potencial energético

Os valores de poder calorífico do presente estudo (SILVA, 2014), compreendidos entre  $18,282 \text{ GJ.ton}^{-1}$  e  $20,121 \text{ GJ.ton}^{-1}$  (Tabela 3), são semelhantes aos observados por Brito e Barrichelo (1979), que determinaram valores de PCS para madeira entre  $12,560 \text{ GJ.ton}^{-1}$  e  $22,609 \text{ GJ.ton}^{-1}$ , com valor médio de  $17,585 \text{ GJ.ton}^{-1}$ , e por Quirino et al. (2004), que encontraram valores entre  $16,040 \text{ GJ.ton}^{-1}$  e  $22,291 \text{ GJ.ton}^{-1}$ , com valor médio de  $19,812 \text{ GJ.ton}^{-1}$  em levantamento com aproximadamente 200 espécies florestais de diversos biomas. Trabalhos realizados em outras fitofisionomias do bioma cerrado, também apontam valores do PCS da madeira em um intervalo de  $18,807 \text{ GJ.ton}^{-1}$  a  $22,713 \text{ GJ.ton}^{-1}$  (VALE et al., 2002b; MACHADO NETO et al., 2015); para espécies de florestas tropicais do Equador, Suriname, Camarões, Costa do Marfim, Gabão e Indonésia, que indicam um intervalo entre  $18,045 \text{ GJ.ton}^{-1}$  e  $21,646 \text{ GJ.ton}^{-1}$  (DOAT, 1977). E por fim, pra espécies europeias indicam um intervalo entre  $18,29 \text{ GJ.ton}^{-1}$  e  $20,37 \text{ GJ.ton}^{-1}$  (STRANDBERG et al., 2015; TODARO et al., 2015; YILDIZ et al., 2015). Deste modo pode-se afirmar que em termos médios, o poder calorífico para espécies florestais em todo o mundo é de  $19,00 \text{ GJ.ton}^{-1} \pm 4,00 \text{ GJ.ton}^{-1}$ .

Alguns aspectos já avaliados na literatura justificam a padronização dos intervalos de PCS da madeira e da casca, bem como a adequabilidade dos resultados encontrados no presente estudo. Primeiramente, sabe-se que há baixa variação significativa no PCS entre espécies florestais (MACHADO NETO et al., 2015), o que sugere um intervalo de confiança curto, como visto nos trabalhos supracitados. Foi esse o embasamento para a utilização dos valores médios de PCS, tanto da madeira quanto da casca, para as espécies não amostradas e árvores mortas. A intensidade dessas variações ocorre e depende de fatores genéticos, ambientais e também da interação entre esses fatores, conforme relatado por Zobel e Jett (1995).

Além disso, há relação positiva entre a idade dos indivíduos e seu poder calorífico superior, indicando que há aumento na energia por unidade de massa das árvores a medida que essas se tornam mais velhas (SILVA et al., 2012). Diante disso, o fato da população estudada neste trabalho se encontrar em estágio de estabilidade e boa estruturação (MIGUEL et al., 2016) pode explicar os valores condizentes de PCS com a literatura.

O poder calorífico superior encontrado para casca das espécies estudadas, compreendido no intervalo de 16,805 GJ.ton<sup>-1</sup> a 21,587 GJ.ton<sup>-1</sup> (Tabela 3), também está de acordo com o potencial energético desse tipo de material. Espécies do Cerrado e de florestas temperadas da América do Norte apresentam variação similar para o PCS de sua casca em intervalos de 17,530 GJ.ton<sup>-1</sup> a 24.024 GJ.ton<sup>-1</sup>, e 17,254 GJ.ton<sup>-1</sup> a 24,242 GJ.ton<sup>-1</sup>, respectivamente (CORDER, 1976; VALE et al., 2002b). Já espécies de *Eucalyptus* apresentam um intervalo de PCS de suas casca entre 13,849 GJ.ton<sup>-1</sup> e 19,551 GJ.ton<sup>-1</sup> (JUIZO et al., 2017). Todas as espécies se encontram dentro dos limites estabelecidos na literatura, demonstrando adequabilidade dos resultados encontrados.

Mais de 70% das espécies apresentaram valores de poder calorífico da casca superiores aos valores de PCS da madeira, percentual semelhante foi encontrado por Vale et al. (2002a). As diferenças no teor de carbono fixo presente na madeira e na casca de indivíduos florestais, que no Cerrado apresenta uma média de, respectivamente, 20,73% e 25,19% (VALE et al., 2002b), e no conteúdo de lignina entre os dois materiais, que podem chegar a valores de 28% na madeira de fuste e 36% na casca de espécies arbóreas (TELMO; LOUSADA, 2011), sendo essas características altamente correlacionadas com o PCS de combustíveis, em especial o carvão vegetal (PROTÁSIO et al., 2011; TELMO; LOUSADA, 2011; SOARES et al., 2014; SANTOS et al., 2016; SO; EBERHARDT, 2018), são possíveis explicações para esse comportamento.

O valor de potencial energético por unidade de área encontrado no presente estudo (1.022,66 GJ.ha<sup>-1</sup>) é cerca de 25% inferior ao encontrado por Silva e Vale (2018) (1.378,54 GJ.ha<sup>-1</sup>) para a mesma área. Essa diferença pode estar atrelada ao fato de que ambos trabalhos usaram modelos, deixando assim os resultados susceptíveis à possíveis erros de estimativas.

É importante salientar ainda que esses valores representam o potencial máximo de energia da área, isto é, considerando a biomassa seca a 0% de umidade. Entretanto, essa condição não é atingida na prática, uma vez que o ganho em energia não compensa o esforço necessário para realização da secagem contínua até esse ponto de umidade (BRAND et al., 2011; ZANUNCIO et al., 2013), e a presença de água na biomassa é

prejudicial ao poder calorífico, sendo que este é reduzido em 2MJ/kg a cada 10% de umidade na biomassa (SWITHEBANK et al., 2011; ZANUNCIO et al., 2013; GÓRNICKI et al., 2016)

## **4.2 Modelagem**

### **4.2.1 Seleção das variáveis independentes**

A correlação encontrada entre os índices de vegetação e o potencial energético ( $Pe$ ) no presente estudo foi moderada e significativa (Tabela 6), seguindo o comportamento da correlação encontrado em diversos estudos envolvendo IVs associados a diferentes variáveis da comunidade florestal como circunferência do tronco, volume de madeira e biomassa (PANDA et al., 2010; MIGUEL et al., 2015; ZHU; LIU, 2015; MACHADO et al., 2017; MIRELES et al., 2017; PHUA et al., 2017). As possíveis causas para esse padrão de moderada correlação entre IVs e variáveis da floresta podem ser a influência que os sensores remotos sofrem do próprio ambiente, como o efeitos da atmosfera, fontes de radiação e efeitos do solo, além dos aspectos inerentes a própria vegetação tais como arquitetura e conformação irregulares e desuniformes das copas e dossel (PONZONI, 2001; MIGUEL et al., 2015; MACHADO et al., 2017).

Quanto aos valores de correlações encontrados entre os IVs e o  $Pe$  serem significativos e positivo (Tabela 6), pode ser explicado pelo comportamento da correlação positiva e significativa entre índices de vegetação e o crescimento radial do fuste, além da 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, teor de carbono da madeira (VICENTE-SERRANO et al., 2016), sendo que o crescimento radial da árvore gera regiões no fuste (cerne e lenho estival) que apresenta maior presença de lignina (KLITZKE et al., 2008).

A presença e o conteúdo da lignina é um dos fatores determinantes da reflectância da vegetação para os comprimentos de onda na região do infravermelho (PADOLFI et al., 2018), utilizada no cálculo da maioria dos IVs utilizados nesse estudo, o que também pode explicar o comportamento encontrado para a correlação, pois o teor de carbono e o conteúdo de lignina apresentam forte correlação positiva com o poder calorífico superior (PCS) e, por extensão, com o potencial energética da madeira (PROTÁSIO et al., 2011; TELMO; LOUSADA, 2011; SANTOS et al., 2016; SO; EBERHARDT, 2018).

#### 4.2.2 Treinamento das redes neurais

Todas as RNAs treinadas apresentaram estatísticas de ajuste e precisão aceitáveis, com altos valores de coeficiente de correlação ( $R \geq 0,96$ ) e erros de estimativa abaixo de 15% (Tabela 7). Especificamente a rede escolhida apresentou resultados muito satisfatórios ( $R = 0,98$ ,  $RMSE\% = 11,27\%$ ) tendo em vista a complexidade das variáveis estudadas e a grande variabilidade encontrada em florestas nativas, o que torna aceitável um limite de erro de até 20% (SYDOW et al., 2017).

O poder de predição das RNAs no meio florestal tem sido demonstrado por diversos trabalhos em abrangência global, os quais demonstram a superioridade das redes neurais frente aos modelos de regressão clássicos para a estimativa de diversos atributos da floresta (MIGUEL et al., 2015; VAHEDI, 2016; LIMA et al., 2017; ÖZÇELIK et al., 2017; SILVA et al., 2018; VIEIRA et al., 2018b) e comprovam o grande potencial de seu uso associado a dados provenientes de sensoriamento remoto (CUTLER et al., 2012; FERRAZ et al., 2014; MIGUEL et al., 2015; NANDY et al., 2017; VACCHIANO et al., 2018). O resultados obtidos no presente estudo também demonstram que a associação das técnicas de inteligência artificial e sensoriamento remoto permitiu às RNAs assimilar a grande complexidade e variedade de vegetação (FELFILI et al., 2007; SOUZA et al., 2010; PRADO JÚNIOR et al., 2012; BOTREL et al., 2014; GIÁCOMO et al., 2015; REIS et al., 2015a; MIGUEL et al., 2017a), solos (HARIDASAN, 2007) e demais aspectos ambientais e climáticos (FELFILI et al., 2007).

As redes neurais também têm demonstrado eficiência na predição das características intrínsecas da própria madeira, como teor de umidade (ZANUNCIO et al., 2016; OZSAHIN; MURAT, 2018), poder calorífico superior (ESTIATI et al., 2016; UZUN et al., 2017), densidade básica (SILVA et al., 2018) e densidade energética (VALE et al., 2017) para a qual estes autores encontraram resultados de precisão superiores aos encontrados no presente trabalho ( $RMSE\% = 1,45\%$ ,  $R = 0,98$ ,  $DA\% = 0,14$ ), entretanto, utilizaram a densidade básica da madeira como variável preditora. Também o poder de predição das RNAs foi verificada na predição e qualidade de produtos de placas de fibra de média densidade da madeira (MDF) e seus diferentes processos de colagem resistência (TIRYAKI; HAMZAÇEBI, 2014; MELO; MIGUEL, 2016; TIRYAKI et al., 2016; MIGUEL et al., 2018).

A análise gráfica dos resíduos é fundamental para corroborar os resultados das estatísticas de precisão (DRAPER; SMITH, 1998), uma vez que erros de tendência podem não ser detectados por essas estatísticas.

O gráfico de dispersão de resíduos (Figura 4A) 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  $\pm 30\%$ . Esse poder preditivo é demonstrado pela relação entre valores observados e preditos (Figura 4B), que apresenta a aderência da rede neural selecionada aos dados reais. Além disso, a frequência de erros concentrou-se em sua maioria entre  $-10\%$  e  $10\%$  (Figura 4C), sendo que obteve poucos erros superiores à  $\pm 20\%$ . A análise dos resíduos em histogramas é interessante, pois apenas a avaliação de gráficos de dispersão podem gerar erros de interpretação devido à ocorrência de pontos sobrepostos (CAMPOS; LEITE, 2017).

### 4.3 Análise estatística

Quando a RNA selecionada foi submetida ao teste de validação, a mesma retornou estimativas não significativas de acordo com o resultado do teste *t* de Student ( $p < 0,05$ ), logo não foi possível rejeitar a hipótese nula de igualdade entre os valores observados e preditos pela rede, e, por consequência, assume-se que suas estimativas são precisas, conforme Serpen e Gao (2014), que afirmam que as RNAs tem grande capacidade de aprender e extrair padrões de um conjunto de dados, generalizá-los e aplicá-los a outros sem perder a precisão.

As redes foram treinadas e validas para uma única fitofisionomia do bioma Cerrado, o cerradão, logo devido à variabilidade de espécies, estrutura, arquitetura de copa, formato de dossel e as próprias características físicas e químicas da madeira das diferentes espécies florestais, novos estudos investigando essa relações com IVs, diferentes configurações e arquiteturas de redes devem ser realizados, para garantir assim estimativas sempre mais acuradas nos diferentes biomas com suas diversas fitofisionomias, reforçando e validando o uso geral das RNAs na predição de potencial energético por unidade de área associado a informações de sensores remotos.

Por fim, o resultado desta pesquisa impacta de forma positiva, como uma ferramenta de gestão, no direcionamento estratégico de áreas com maior potencial energético, na redução do tempo e custo dos levantamentos florestais que visam a obtenção do *Pe* como produto final, pois se sabe que a maioria dos modelos usados em predição e os inventários florestais quantificam apenas variáveis como o volume, biomassa e em escala menor o carbono. Nesta pesquisa ficou demonstrado que é possível estimar com precisão o potencial energético indiretamente a partir de dados derivados de

imagens de satélite e a área basal, variável de fácil obtenção na floresta, associados a ferramentas de inteligência artificial, especificamente redes neurais artificiais.

## 5 CONCLUSÃO

O cerradão apresenta potencial energético máximo, ou seja, para madeira seca à 0% de umidade, de  $1.022,66 \pm 560,89$  GJ.ha<sup>-1</sup>.

Redes neurais artificiais do tipo *Multilayer Perceptron*, utilizando funções de ativação tangencial e sigmoideal e o algoritmo de treino BFGS, associadas com índices de vegetação e área basal, são precisas e eficientes na estimativa da potencial energético por unidade de área.

O uso de RNAs e dados de sensores remotos como ferramentas de gestão, otimização do tempo e custos para a estimar o potencial energético em áreas florestais é promissora.

## 6 REFERÊNCIAS BIBLIOGRÁFICAS

- ABNT, Associação Brasileira de Normas Técnicas. **NBR 8633: Carvão vegetal - Determinação do poder calorífico**. Rio de Janeiro, 1984.
- 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.
- ALMEIDA, A. Q. DE; MELLO, A. A. DE; NETO, A. L. D.; FERRAZ, R. C. Relações empíricas entre características dendrométricas da Caatinga Brasileira e dados TM Landsat 5. **Pesquisa Agropecuaria Brasileira**, v. 49, n. 4, p. 306–315, 2014.
- 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.
- ALVES, H. R.; PADRO JÚNIOR, J. A. DO; LOPES, S. DE F.; SILVA, P. P. F. DA; PEPPE, F. B.; SCHIAVINI, I. Fitossociologia e grupos ecológicos da comunidade lenhosa em um remanescente de Cerradão em Uberlândia, MG. **Caminhos da Geografia**, v. 14, n. 46, p. 236–245, 2013.
- ANACHE, J. A. A.; FLANAGAN, D. C.; SRIVASTAVA, A.; WENDLAND, E. C. Land use and climate change impacts on runoff and soil erosion at the hillslope scale in the Brazilian *Cerrado*. **Science of the Total Environment**, v. 622–623, p. 140–151, 2018.
- ARAÚJO, A. C. C. DE; COSTA, L. J.; BRAGA, P. P. DE C.; GUIMARÃES NETO, R.

M.; ROCHA, M. F. V.; TRUGILHO, P. F. Propriedades energéticas da madeira e do carvão vegetal de *Cenostigma macrophyllum*: subsídios ao uso sustentável. **Pesquisa Florestal Brasileira**, v. 38, n. e201701546, p. 1–9, 2018.

AREVALO, C. B. M.; VOLK, T. A.; BEVILACQUA, E.; ABRAHAMSON, L. Development and validation of aboveground biomass estimations for four *Salix* clones in central New York. **Biomass and Bioenergy**, v. 31, n. 1, p. 1–12, 2007.

BABST, F.; BOURIAUD, O.; PAPALE, D.; GIELEN, B.; JANSSENS, I. A.; NIKINMAA, E.; IBROM, A.; WU, J.; BERNHOFER, C.; KÖSTNER, B.; GRÜNWALD, 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.

BACCINI, A.; FRIEDL, M. A.; WOODCOCK, C. E.; ZHU, Z. Scaling field data to calibrate and validate moderate spatial resolution remote sensing models. **Photogrammetric Engineering Remote Sensing**, v. 73, n. 8, p. 945–954, 2007.

BAI, T.; HU, H.; SONG, X. **OFDM MIMO radar waveform design with high range resolution and low sidelobe level**. In: 17th IEEE International Conference on Communication Technology (ICCT). **Anais...Dhaka: IEEE**, 2017

BALDERAS-TORRES, A.; LOVETT, J. C. Using basal area to estimate aboveground carbon stocks in forests: La Primavera Biosphere's Reserve, Mexico. **Forestry**, v. 86, n. 2, p. 267–281, 2012.

BALL, A.; SANCHEZ-AZOFEIFA, A.; PORTILLO-QUINTERO, C.; RIVARD, B.; CASTRO-CONTRERAS, S.; FERNANDES, G. Patterns of leaf biochemical and structural properties of Cerrado life forms: Implications for remote sensing. **PLoS One**, v. 10, n. 2, p. e0117659, 2015.

BARBOSA, R. I.; FEARNSIDE, P. M. Above-ground biomass and the fate of carbon after burning in the savannas of Roraima, Brazilian Amazonia. **Forest Ecology and Management**, v. 216, p. 295–316, 2005.

BATLLE-BAYER, L.; BATJES, N. H.; BINDRABAN, P. S. Changes in organic carbon stocks upon land use conversion in the Brazilian *Cerrado*: A review. **Agriculture, Ecosystems and Environment**, v. 137, n. 1–2, p. 47–58, 2010.

BENÍTEZ, F. L.; ANDERSON, L. O.; FORMAGGIO, A. R. Evaluation of geostatistical techniques to estimate the spatial distribution of aboveground biomass in the Amazon rainforest using high-resolution remote sensing data. **Acta Amazonica**, v. 46, n. 2, p. 151–160, 2016.

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.

BOISVENUE, C.; SMILEY, B. P.; WHITE, J. C.; KURZ, W. A.; WULDER, M. A. Integration of Landsat time series and field plots for forest productivity estimates in

- decision support models. **Forest Ecology and Management**, v. 376, p. 284–297, 2016.
- BOTREL, R. T.; YAMAMOTO, K.; RODRIGUES, R. R. Avaliação de um método de análise silvigenética em um cerradão. **Ciência Florestal**, v. 24, n. 4, p. 899–910, 2014.
- BRAGA, A. DE P.; CARVALHO, A. P. DE L. F. DE; LUDEMIR, T. B. **Redes neurais artificiais: Teoria e aplicações**. 2. ed. Rio de Janeiro: LTC, 2014, 248 p.
- BRAND, M. A. **Qualidade de biomassa florestal para uso na geração de energia em função da estocagem**. 169 f. Tese (Doutorado) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2007.
- BRAND, M. A.; MUÑIZ, G. I. B. DE; QUIRINO, W. F.; BRITO, J. O. Storage as a tool to improve wood fuel quality. **Biomass and Bioenergy**, v. 35, p. 2581–2588, 2011.
- BRITO, J. O.; BARRICHELO, L. E. G. Usos diretos e propriedades da madeira para geração de energia. **IPEF: Circular Técnica**, n. 52, p. 7, 1979.
- BROYDEN, C. G. The convergence of a class of double-rank minimization algorithms 1. General considerations. **IMA Journal of Applied Mathematics**, v. 6, n. 1, p. 76–90, 1970.
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração Florestal: Perguntas e Respostas**. 5. ed. Viçosa: Editora UFV, 2017, 636 p.
- CARRIJO, J. V. N.; MIGUEL, E. P.; REZENDE, A. V.; GASPAR, R. DE O.; MARTINS, I. S.; MEIRA JUNIOR, M. S. DE; ANGELO, H.; JESUS, C. M. DE. Morphometric indexes and dendrometric measures for classification of forest sites of Eucalyptus urophylla stands. **Australian Journal of Crop Science**, v. 11, n. 9, p. 1146–1153, 2017.
- CARVALHO, D. R. DE; LEAL, C. G.; JUNQUEIRA, N. T.; CASTRO, M. A. DE; FAGUNDES, D. C.; ALVES, C. B. M.; HUGHES, R. M.; POMPEU, P. S. A fish-based multimetric index for Brazilian savanna streams. **Ecological Indicators**, v. 77, p. 386–396, 2017.
- CONDÉS, S.; MCROBERTS, R. E. Updating national forest inventory estimates of growing stock volume using hybrid inference. **Forest Ecology and Management**, v. 400, p. 48–57, 2017.
- CORDER, S. E. **Properties and uses of bark as an energy source** Forest Research Laboratory Research Paper 31. Corvallis, 1976. 21 p.
- COSTA, T. G.; BIANCHI, M. L.; PROTÁSIO, T. DE P.; TRUGILHO, P. F.; PEREIRA, A. J. Qualidade da madeira de cinco espécies de ocorrência no cerrado para produção de carvão vegetal. **Cerne**, v. 20, n. 1, p. 37–45, 2014.
- CUNHA, G. DE M.; GAMA-RODRIGUES, A. C.; GAMA-RODRIGUES, E. F.; VELLOSO, A. C. X. Biomassa e estoque de carbono e nutrientes em florestas montanas da Mata Atlântica na região norte do estado do Rio de Janeiro. **Revista Brasileira de Ciência do Solo**, v. 33, p. 1175–1185, 2009.
- CUTLER, M. E. J.; BOYD, D. S.; FOODY, G. M.; VETRIVEL, A. 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.

DALL'AGNOL, R. F.; PLOTTEGHER, F.; SOUZA, R. C.; MENDES, I. C.; REIS JUNIOR, F. B. DOS; BÉNA, G.; MOULIN, L.; HUNGRIA, M. *Paraburkholderia nodosa* is the main N<sub>2</sub>-fixing species trapped by promiscuous common bean (*Phaseolus vulgaris* L.) in the Brazilian “Cerradão”. **FEMS Microbiology Ecology**, v. 92, n. 8, p. fiw108, 2016.

DALPONTE, M.; FRIZZERA, L.; ØRKA, H. O.; GOBAKKEN, T.; NÆSSET, E.; GIANELLE, D. Predicting stem diameters and aboveground biomass of individual trees using remote sensing data. **Ecological Indicators**, v. 85, p. 367–376, 2018.

DANTAS, D.; SOUZA, M. J.; VIEIRA, A.; OLIVEIRA, M.; PEREIRA, I.; MACHADO, E.; SOUZA, C. M.; ROCHA, W. Soil influences on tree species distribution in a rupestrian cerrado area. **Floresta e Ambiente**, v. 25, n. 4, p. e20170605, 2018.

DEMIRBAS, A. Higher heating values of lignin types from wood and non-wood lignocellulosic biomasses. **Energy Sources, Part A: Recovery, Utilization, and Environmental Effects**, v. 39, n. 6, p. 592–598, 2017.

DEO, R. K.; DOMKE, G. M.; RUSSEL, M. B.; WOODALL, C. W.; ANDERSEN, H.-E. Evaluating the influence of spatial resolution of Landsat predictors on the accuracy of biomass models for large-area estimation across the eastern USA. **Environmental Research Letters**, v. 13, p. 055004, 2018.

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.

DOAT, J. Le pouvoir calorifique des bois tropicaux. **Revue Bois et Forêts Tropicaux**, v. 172, p. 33–48, 1977.

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

DUBE, T.; MUTANGA, O. Evaluating the utility of the medium-spatial resolution Landsat 8 multispectral sensor in quantifying aboveground biomass in uMgeni catchment, South Africa. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 101, p. 36–46, 2015.

DUBOC, E.; COSTA, C. J.; VELOSO, R. F.; OLIVEIRA, L. S.; PALUDO, A. **Panorama atual da produção de carvão vegetal no Brasil e no Cerrado**. Planaltina, DF: Embrapa Cerrados, 2007. 37 p.

EGRIOGLU, E.; YOLCU, U.; ALADAG, C. H.; BAS, E. Recurrent multiplicative neuron model artificial neural network for non-linear time series forecasting. **Neural Processing Letters**, v. 41, n. 2, p. 249–258, 2015.

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

ENE, L. T.; NÆSSET, E.; GOBAKKEN, T.; BOLLANDSÅS, O. M.; MAUYA, E. W.; ZAHABU, E. Large-scale estimation of change in aboveground biomass in miombo

woodlands using airborne laser scanning and national forest inventory data. **Remote Sensing of Environment**, v. 188, p. 106–117, 2017.

ERDAS. **ERDAS Imagine 2011**. Norcross, 2011.

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 TiO<sub>2</sub> using experimental data. **International Communications in Heat and Mass Transfer**, v. 75, p. 192–196, 2016.

ESTIATI, I.; FREIRE, F. B.; FREIRE, J. T.; AGUADO, R.; OLAZAR, M. Fitting performance of artificial neural networks and empirical correlations to estimate higher heating values of biomass. **Fuel**, v. 180, p. 377–383, 2016.

EVARISTO, A. B.; MARTINO, D. C.; FERRAREZ, A. H.; DONATO, D. B.; CARNEIRO, A. DE C. O.; GROSSI, J. A. S. Potencial energético dos resíduos do fruto da macaúba e sua utilização na produção de carvão vegetal. **Ciencia Florestal**, v. 26, n. 2, p. 571–577, 2016.

FELFILI, J. M.; REZENDE, A. V.; SILVA JÚNIOR, M. C. DA; SILVA, P. E. N. DA; WALTER, B. M. T.; ENCINAS, J. I.; SILVA, M. A. Fitossociologia da vegetação arbórea. In: FELFILI, J. M.; REZENDE, A. V.; SILVA JÚNIOR, M. C. DA (Eds.). **Biogeografia do bioma Cerrado: Vegetação e solos da Chapada dos Veadeiros**. 1<sup>a</sup> ed. Brasília: Editora Universidade de Brasília : Finatec, 2007. p. 45–96.

FELFILI, J. M.; CARVALHO, F. A.; HAIDAR, R. F. **Manual para o monitoramento de parcelas permanentes nos biomas Cerrado e Pantanal**. 1. ed. Brasília: Universidade de Brasília, Departamento de Engenharia Florestal, 2005. 51 p.

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, Z.; FINGER, F. A. Fitossociologia em comunidades arbóreas remanescentes de cerrado sensu stricto no Brasil central. **Floresta**, v. 45, n. 4, p. 769–780, 2015.

FLETCHER, R. A new approach to variable metric algorithms. **The Computer Journal**, v. 13, n. 3, p. 317–322, 1970.

FORZZA, R. C. et al. New Brazilian floristic list highlights conservation challenges. **BioScience**, v. 62, n. 1, p. 39–45, 2012.

FRANÇOSO, R. D.; BRANDÃO, R.; NOGUEIRA, C. C.; SALMONA, Y. B.; MACHADO, R. B.; COLLI, G. R. Habitat loss and the effectiveness of protected areas in the Cerrado Biodiversity Hotspot. **Natureza e Conservação**, v. 13, n. 1, p. 35–40, 2015.

FRANÇOSO, R. D.; HAIDAR, R. F.; MACHADO, R. B. Tree species of South America central savanna: endemism, marginal areas and the relationship with other biomes. **Acta Botanica Brasilica**, v. 30, n. 1, p. 78–86, 2016.

FRIEDL, A.; PADOUVAS, E.; ROTTER, H.; VARMUZA, K. Prediction of heating values of biomass fuel from elemental composition. **Analytica Chimica Acta**, v. 544, p. 191–198, 2005.

- GALIDAKI, G.; ZIANIS, D.; GITAS, I.; RADOGLU, K.; KARATHANASSI, V.; TSAKIRI-STRATI, M.; WOODHOUSE, I.; MALLINIS, G. Vegetation biomass estimation with remote sensing: focus on forest and other wooded land over the Mediterranean ecosystem. **International Journal of Remote Sensing**, v. 38, n. 7, p. 1940–1966, 2016.
- GIÁCOMO, R. G.; PEREIRA, M. G.; CARVALHO, D. C. DE; MEDEIROS, V. S. DE; GAUI, T. D. Florística e fitossociologia em áreas de cerradão e mata mesofítica na Estação Ecológica de Pirapitinga, MG. **Floresta e Ambiente**, v. 22, n. 3, p. 287–298, 2015.
- GITELSON, A. A.; GRITZ, Y.; MERZLYAK, M. N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. **Journal of Plant Physiology**, v. 160, n. 3, p. 271–282, 2003.
- GITELSON, A. A.; MERZLYAK, M. N. Quantitative estimation of chlorophyll-a using reflectance spectra: Experiments with autumn chestnut and maple leaves. **Journal of Photochemistry and Photobiology**, v. 22, p. 247–252, 1994.
- GITOE, 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.
- GOLDFARB, D. A family of variable-metric methods derived by variational means. **Mathematics of Computation**, v. 24, n. 109, p. 23, 1970.
- GÓRNICKI, K.; KALETA, A.; BRYŚ, A.; WINICZENKO, R. Thin-layer drying of sawdust mixture. **Polish Journal of Chemical Technology**, v. 18, n. 4, p. 65–70, 2016.
- 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.
- GRECCHI, R. C.; GWYN, Q. H. J.; BÉNIÉ, G. B.; FORMAGGIO, A. R.; FAHL, F. C. Land use and land cover changes in the Brazilian Cerrado: A multidisciplinary approach to assess the impacts of agricultural expansion. **Applied Geography**, v. 55, p. 300–312, 2014.
- GROOT, A.; CORTINI, F.; WULDER, M. A. Crown-fibre attribute relationships for enhanced forest inventory: Progress and prospects. **The Forestry Chronicle**, v. 91, n. 3, p. 266–279, 2015.
- 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.
- GUJARATI, D. N.; PORTER, D. C. **Econometria básica**. 5a. ed. New York: AMGH, 2011. 920 p.
- HARIDASAN, M. Solos. In: FELFILI, J. M.; REZENDE, A. V.; SILVA JÚNIOR, M. C. DA (Eds.). **Biogeografia do bioma Cerrado: Vegetação e solos da Chapada dos**

- Veadeiros**. 1ª ed. Brasília: Editora Universidade de Brasília : Finatec, 2007. p. 25–43.
- HAYKIN, S. **Redes Neurais: Princípios e prática**. 2ª ed. Hamilton: Bookman, 2001. 900 p.
- HAYKIN, S. **Neural Networks and Learning Machines**. 3ª ed. New Jersey: Pearson Educational, 2009. 906 p.
- HUETE, A. R. A soil-adjust vegetation index (Savi). **Remote Sensing of Environment**, v. 25, p. 295–309, 1988.
- HUNKE, P.; MUELLER, E. N.; SCHRÖDER, B.; ZEILHOFER, P. The Brazilian Cerrado: assessment of water and soil degradation in catchments under intensive agricultural use. **Ecohydrology**, v. 8, p. 1154–1180, 2015.
- HUSCH, B.; MILLER, C. L.; BEERS, T. W. **Forest mensuration**. 3ª ed. New York: J. Willey, 1982. 402 p.
- JANSEN, R. A. **Second generation biofuels and biomass: Essential guide for investors, scientists and decision makers**. 1ª ed. Weinheim: Wiley-VCH Verlag GmbH & Co. KGaA, 2013. 272 p.
- JESUS, M. S. DE; COSTA, L. J.; FERREIRA, J. C.; FREITAS, F. P. DE; SANTOS, L. C.; ROCHA, M. F. V. Caracterização energética de diferentes espécies de Eucalyptus. **Floresta**, v. 47, n. 1, p. 11–16, 2017b.
- JESUS, T. C. L. DE; SENNA, M. C. A.; CATALDI, M.; PAIVA, C. M.; FRANZ, B. Impacto do aumento da concentração atmosférica de CO<sub>2</sub> no balanço hídrico climatológico do Cerrado. **Revista Brasileira de Climatologia**, v. 21, p. 313–326, 2017a.
- JIANG, Z.; HUETE, A. R.; DIDAN, K.; MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, p. 3833–3845, 2008.
- JUIZO, C. G. F.; LIMA, M. R.; SILVA, D. A. DA. Qualidade da casca e da madeira de nove espécies de Eucalipto para produção de carvão vegetal. **Revista Brasileira de Ciências Agrárias**, v. 12, n. 3, p. 386–390, 27 set. 2017.
- KANDARE, K.; ØRKA, H. O.; DALPONTE, M.; NÆSSET, E.; GOBAKKEN, T. Individual tree crown approach for predicting site index in boreal forests using airborne laser scanning and hyperspectral data. **International Journal of Applied Earth Observation and Geoinformation**, v. 60, p. 72–82, 2017.
- KENNEDY, C. M.; HAWTHORNE, P. L.; MITEVA, D. A.; BAUMGARTEN, L.; SOCHI, K.; MATSUMOTO, M.; EVANS, J. S.; POLASKY, S.; HAMEL, P.; VIEIRA, E. M.; DEVELEY, P. F.; SEKERCIOGLU, C. H.; DAVIDSON, A. D.; UHLHORN, E. M.; KIESECKER, J. Optimizing land use decision-making to sustain Brazilian agricultural profits, biodiversity and ecosystem services. **Biological Conservation**, v. 204, p. 221–230, 2016.
- KLINK, C. A.; MACHADO, R. B. Conservation of the Brazilian Cerrado. **Conservation Biology**, v. 19, n. 3, p. 707–713, 2005.
- KLITZKE, R. J.; SAVIOLI, D. L.; MUÑIZ, G. I. B. DE; BATISTA, D. C. Caracterização

dos lenhos de cerne, alburno e transição de jatobá (*Hymenaea* sp.) visando ao agrupamento para fins de secagem convencional. **Scientia Forestalis**, v. 36, n. 80, p. 279–284, 2008.

LACERDA, T. H. S.; CABACINHA, C. D.; ARAÚJO JÚNIOR, C. A.; MAIA, R. D.; LACERDA, K. W. DE S. Artificial neural networks for estimating tree volume in the Brazilian savanna. **Cerne**, v. 23, n. 4, p. 483–491, 2017.

LATIFI, H.; FASSNACHT, F. E.; HARTIG, F.; BERGER, C.; HERNÁNDEZ, J.; CORVALÁN, P.; KOCH, B. Stratified aboveground forest biomass estimation by remote sensing data. **International Journal of Applied Earth Observation and Geoinformation**, v. 38, p. 229–241, 2015.

LEAL, F. A.; MIGUEL, E. P.; MATRICARDI, E. A. T.; PEREIRA, R. S. Redes neurais artificiais na estimativa de volume em um plantio de eucalipto em função de fotografias hemisféricas e número de árvores. **Revista Brasileira de Biometria**, v. 33, n. 2, p. 233–249, 2015.

LENZA, E.; PINTO, J. R. R.; PINTO, A. DE S.; MARACAHIPES, L.; BRUZIGUESSI, E. P. Comparação da vegetação arbustivo-arbórea de uma área de cerrado rupestre na Chapada dos Veadeiros, Goiás, e áreas de cerrado sentido restrito do Bioma Cerrado. **Revista Brasileira de Botânica**, v. 34, n. 3, p. 247–259, 2011.

LIMA, A. DE S.; SANTOS, K. P. P.; CASTRO, A. A. J. F. Aspectos socioambientais da produção de carvão vegetal de origem nativa em uma área de Cerrado em Jerumenha, Piauí/Brasil. **Espacios**, v. 37, n. 3, p. 18, 2016.

LIMA JÚNIOR, C. DE; ACCIOLY, L. J. DE O.; GIONGO, V.; LIMA, R. L. F. DE A.; SAMPAIO, E. V. DE S. B.; MENEZES, R. S. C. Estimativa de biomassa lenhosa da caatinga com uso de equações alométricas e índice de vegetação. **Scientia Forestalis**, v. 42, n. 102, p. 289–298, 2014.

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.

LÓPEZ-SERRANO, P. M.; CORRAL-RIVAS, J. J.; DÍAZ-VARELA, R. A.; ÁLVAREZ-GONZÁLEZ, J. G.; LÓPEZ-SÁNCHEZ, C. A. Evaluation of radiometric and atmospheric correction algorithms for aboveground forest biomass estimation using Landsat 5 TM data. **Remote Sensing**, v. 8, n. 5, p. 369–387, 2016.

LÓPEZ, L.; VILLALBA, R. Criterios de gestión forestal para 12 especies de los Bosques Nativos Tropicales de Bolivia a través de métodos dendrocronológicos. **Ecosistemas**, v. 24, n. 2, p. 24–29, 2015.

LÓPEZ, L.; VILLALBA, R.; BRAVO, F. Cumulative diameter growth and biological rotation age for seven tree species in the *Cerrado* biogeographical province of Bolivia. **Forest Ecology and Management**, v. 292, p. 49–55, 2013.

LÓPEZ, L.; VILLALBA, R.; PEÑA-CLAROS, M. Los anillos de crecimiento de *Centrolobium microchaete* (*Fabaceae*, *Papilionoideae*), una herramienta para evaluar el manejo forestal de los bosques secos tropicales del Cerrado boliviano. **Ecología en**

**Bolivia**, v. 46, n. 2, p. 77–94, 2011.

LUDWIG JUNIOR, O.; COSTA, E. M. M. **Redes Neurais: Fundamentos e aplicações com programas em C**. Rio de Janeiro: Editora Ciência Moderna, 2007. 125 p.

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.

MACHADO NETO, A. DE P.; BRANDÃO, C. F. L. E S.; DUARTE, B.; ALMIR, J.; MARANGON, L. C.; FELICIANO, A. L. P. Densidade e poder calorífico como base para prevenção de incêndios florestais sob linhas de transmissão. **Nativa**, v. 3, n. 1, p. 10–15, 2015.

MARACAHIPES-SANTOS, L.; LENZA, E.; SANTOS, J. O.; MEWS, H. A.; OLIVEIRA, B. Effects of soil and space on the woody species composition and vegetation structure of three Cerrado phytophysiognomies in the Cerrado-Amazon transition. **Brazilian Journal of Biology**, v. 77, n. 4, p. 830–839, 2017.

MARACAHIPES, L.; MARIMON, B. S.; LENZA, E.; MARIMON-JUNIOR, B. H.; DE OLIVEIRA, E. A.; MEWS, H. A.; GOMES, L.; FELDPAUSCH, T. R. Post-fire dynamics of woody vegetation in seasonally flooded forests (impucas) in the *Cerrado*-Amazonian Forest transition zone. **Flora: Morphology, Distribution, Functional Ecology of Plants**, v. 209, n. 5–6, p. 260–270, 2014.

MASEMOLA, C.; CHO, M. A.; RAMOELO, A. Comparison of Landsat 8 OLI and Landsat 7 ETM+ for estimating grassland LAI using model inversion and spectral indices: case study of Mpumalanga, South Africa. **International Journal of Remote Sensing**, v. 37, n. 18, p. 4401–4419, 16 set. 2016.

MEDEIROS NETO, P. N.; OLIVEIRA, E. DE; CALEGARI, L.; ALMEIA, A. M. C. DE; PIMENTA, A. S.; CARNEIRO, A. DE C. O. Características físico-químicas e energéticas de duas espécies de ocorrência no semiárido brasileiro. **Ciência Florestal**, v. 22, n. 3, p. 579–588, 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, E. P. **Caracterização da flora e da produção em volume, biomassa e carbono da vegetação arbórea em área de cerradão no estado do Tocantins**. 95 f. Tese (Doutorado) - Departamento de Engenharia Florestal, Universidade de Brasília, Brasília, 2014.

MIGUEL, E. P.; REZENDE, A. V.; LEAL, F. A.; MATRICARDI, E. A. T.; VALE, A. T. DO; PEREIRA, R. S. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerradão com dados de satélite. **Pesquisa Agropecuária Brasileira**, v. 50, n. 9, p. 829–839, 2015.

MIGUEL, E. P.; REZENDE, A. V.; LEAL, F. A.; PEREIRA, R. S.; MELO, R. R. DE. Floristic-structural characterization and successional group of tree species in the Cerrado biome of Tocantins state, Brazil. **Revista Caatinga**, v. 29, n. 2, p. 393–404, 2016.

MIGUEL, E. P.; REZENDE, A. V.; PEREIRA, R. S.; DE AZEVEDO, G. B.; MOTA, F.

- C. M.; DE SOUZA, Á. N.; JOAQUIM, M. S. Modeling and prediction of volume and aerial biomass of the tree vegetation in a cerrado area of central Brazil. **Interciencia**, v. 42, n. 1, p. 21–27, 2017a.
- 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.
- 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.
- MMA, Ministério do Meio-Ambiente. **Plano de ação para prevenção e controle do desmatamento e das queimadas: Cerrado**. Brasília: MMA, 2011. 200 p.
- MME, Ministério de Minas e Energia; EPE, Empresa de Pesquisa Energética. **Balanco Energético Nacional 2005 (ano base 2004)**. Rio de Janeiro: EPE, 2005. 188 p. Disponível em: <<http://www.mme.gov.br/web/guest/publicacoes-e-indicadores/balanco-energetico-nacional>>. Acesso em: 17 out. 2017.
- MORAES, M. G. DE; CARVALHO, M. A. M. DE; FRANCO, A. C.; POLLOCK, C. J.; FIGUEIREDO-RIBEIRO, R. DE C. L. Fire and drought: Soluble carbohydrate storage and survival mechanisms in herbaceous plants from the Cerrado. **BioScience**, v. 66, n. 2, p. 107–117, 2016.
- MORAIS, V. A.; SCOLFORO, J. R. S.; SILVA, C. A.; MELLO, J. M. DE; GOMIDE, L. R.; OLIVEIRA, A. D. DE. Carbon and biomass stocks in a fragment of Cerradão in Minas Gerais state, Brazil. **Cerne**, v. 19, n. 2, p. 237–245, 2013.
- MORANDI, P. S. et al. Tree diversity and above-ground biomass in the South America Cerrado biome and their conservation implications. **Biodiversity and Conservation**, v. Online, p. 1–18, 2018.
- NÆSSET, E.; ØRKA, H. O.; SOLBERG, S.; BOLLANDSÅS, O. M.; HANSEN, E. H.; MAUYA, E.; ZAHABU, E.; MALIMBWI, R.; CHAMUYA, N.; OLSSON, H.; GOBAKKEN, T. Mapping and estimating forest area and aboveground biomass in miombo woodlands in Tanzania using data from airborne laser scanning, TanDEM-X, RapidEye, and global forest maps: A comparison of estimated precision. **Remote Sensing of Environment**, v. 175, p. 282–300, 2016.
- NANDY, S.; SINGH, R.; GHOSH, S.; WATHAM, T.; KUSHWAHA, S. P. S.; KUMAR, A. S.; DADHWAL, V. K. Neural network-based modelling for forest biomass assessment. **Carbon Management**, v. 8, n. 4, p. 305–317, 2017.
- NEHRING, R. Yield of dreams: Marching west and the politics of scientific knowledge in the Brazilian Agricultural Research Corporation (Embrapa). **Geoforum**, v. 77, p. 206–217, 2016.

- NI-MEISTER, W.; LEE, S.; STRAHLER, A. H.; WOODCOCK, C. E.; SCHAAF, C.; YAO, T.; RANSON, K. J.; SUN, G.; BLAIR, J. B. Assessing general relationships between aboveground biomass and vegetation structure parameters for improved carbon estimate from lidar remote sensing. **Journal of Geophysical Research: Biogeosciences**, v. 115, n. G2, p. 1–12, 2010.
- OLIVEIRA, F. P. DE; FILHO, E. I. F.; SOUZA, A. L. DE; SOARES, V. P. Mapeamento de florestas monodominadas por *Myracrodruon urundeuva* com imagens TM-Landsat 5 e Rapideye. **Floresta e Ambiente**, v. 22, n. 3, p. 322–333, 2015.
- 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.
- OZSAHIN, S.; MURAT, M. Prediction of equilibrium moisture content and specific gravity of heat treated wood by artificial neural networks. **European Journal of Wood and Wood Products**, v. 76, n. 2, p. 563–572, 2018.
- PADOLFI, A. S.; RAMALDES, G. P.; SANTOS, O. L. DOS. Análise de índice de vegetação através de imagens obtidas por VANT. **Revista Científica da FAESA**, v. 14, n. 1, p. 145–165, 2018.
- PAKEMAN, R. J.; QUESTED, H. M. Sampling plant functional traits: What proportion of the species need to be measured? **Applied Vegetation Science**, v. 10, n. 1, p. 91–96, 2007.
- PANDA, S. S.; AMES, D. P.; PANIGRAHI, S. Application of vegetation indices for agricultural crop yield prediction using neural network techniques. **Remote Sensing**, v. 2, n. 3, p. 673–696, 2010.
- PHUA, M.-H.; 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.
- PHUKOETPHIM, P.; SHAMSELDIN, A. Y.; MELVILLE, B. W. Knowledge extraction from artificial neural networks for Rainfall-Runoff model combination systems. **Journal of Hydrologic Engineering**, v. 19, p. 1422–1429, 2014.
- PINHEIRO, E. DA S.; DURIGAN, G. Diferenças florísticas e estruturais entre fitofisionomias do cerrado em Assis, SP, Brasil. **Revista Árvore**, v. 36, n. 1, p. 181–193, 2012.
- PINHEIRO, G. F.; RENDEIRO, G.; PINHO, J. T. Densidade energética de resíduos vegetais. **Biomassa & Energia**, v. 2, n. 2, p. 113–123, 2005.
- PIQUÉ, M.; VERICAT, P.; BELTRÁN, M. ORGEST: Regional guidelines and silvicultural models for sustainable forest management. **Forest Systems**, v. 26, n. 2, p. 1–6, 2017.
- PLANET. **RapidEye™ imagery product specifications**. 2016. 50 p. Disponível em: <[https://www.planet.com/products/satellite-imagery/files/160625-RapidEye Image-Product-Specifications.pdf](https://www.planet.com/products/satellite-imagery/files/160625-RapidEye_Image-Product-Specifications.pdf)> Acesso em: 10/10/2018.

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 NETO, 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.

PROTÁSIO, T. DE P.; BUFALINO, L.; TONOLI, G. H. D.; COUTO, A. M.; TRUGILHO, P. F.; GUIMARÃES JÚNIOR, M. Relação entre o poder calorífico superior e os componentes elementares e minerais da biomassa vegetal. **Pesquisa Florestal Brasileira**, v. 31, n. 66, p. 113–122, 2011.

PROTÁSIO, T. DE P.; COUTO, A. M.; REIS, A. A. DOS; TRUGILHO, P. F. Seleção de clones de *Eucalyptus* para a produção e carvão vegetal e bionergia por meio de técnicas univariadas e multivariadas. **Scientia Forestalis**, v. 41, n. 97, p. 15–28, 2013a.

PROTÁSIO, T. DE P.; BUFALINO, L.; TONOLI, G. H. D.; GUIMARÃES JUNIOR, M.; TRUGILHO, P. F.; MENDES, L. M. Brazilian lignocellulosic wastes for bioenergy production: Characterization and comparison with fossil fuels. **BioResources**, v. 8, n. 1, p. 1166–1185, 2013b.

PROTÁSIO, T. DE P.; TRUGILHO, P. F.; DE SIQUEIRA, H. F.; DE MELO, I. C. N. A.; ANDRADE, C. R.; GUIMARÃES JUNIOR, J. B. Caracterização energética de pellets in natura e torreficados produzidos com madeira residual de Pinus. **Pesquisa Florestal Brasileira**, v. 35, n. 84, p. 435, 2015.

QUIRINO, W. F.; VALE, A. T. DO; ANDRADE, A. P. A. DE; ABREU, V. L. S.; AZEVEDO, A. C. DOS S. Poder calorífico da madeira e de resíduos lignocelulósicos. **Biomassa & Energia**, v. 1, n. 2, p. 173–182, 2004.

REDDY, R. S.; RAJASHEKAR, G.; JHA, C. S.; DADHWAL, V. K.; PELISSIER, R.; COUTERON, P. Estimation of above ground biomass using texture metrics derived from IRS Cartosat-1 panchromatic data in evergreen forests of Western Ghats, India. **Journal of the Indian Society of Remote Sensing**, v. 45, n. 4, p. 657–665, 2017.

REIS, A. A. DOS; MELLO, J. M. DE; JÚNIOR, F. W. A.; CARVALHO, L. M. T. DE. Estratificação em cerrado sensu stricto a partir de imagens de sensoriamento remoto e técnicas geoestatísticas. **Scientia Forestalis**, v. 43, n. 106, p. 377–386, 2015b.

REIS, S. M.; LENZA, E.; MARIMON, B. S.; GOMES, L.; FORSTHOFER, M.; MORANDI, P. S.; MARIMON JUNIOR, B. H.; FELDPAUSCH, T. R.; ELIAS, F. Post-fire dynamics of the woody vegetation of a savanna forest (*cerradão*) in the Cerrado-Amazon transition zone. **Acta Botanica Brasílica**, v. 29, n. 3, p. 408–416, 2015a.

REZENDE, A. V.; VALE, A. T. DO; SANQUETTA, C. R.; FIGUEIREDO FILHO, A.; FELFILI, J. M. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado sensu stricto em Brasília, DF. **Scientia Forestalis**, v. 71, p. 65–76, 2006.

RIBEIRO, J. F.; WALTER, B. M. T. As principais fitofisionomias do bioma cerrado. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. (Eds.). **Cerrado: ecologia e flora**.

Brasília: Embrapa Informação Tecnológica, 2008. p. 151–212.

RIBEIRO, S. C.; FEHRMANN, L.; SOARES, C. P. B.; JACOVINE, L. A. G.; KLEINN, C.; DE OLIVEIRA GASPARGAR, R. Above- and belowground biomass in a Brazilian Cerrado. **Forest Ecology and Management**, v. 262, n. 3, p. 491–499, 2011.

RICHARDS, P.; VANWEY, L. Where deforestation leads to urbanization: How resource extraction is leading to urban growth in the Brazilian Amazon. **Annals of the Association of American Geographers**, v. 105, n. 4, p. 806–823, 2015.

ROCHA-ORTEGA, M.; BARTIMACHI, A.; NEVES, J.; BRUNA, E. M.; VASCONCELOS, H. L. Seed removal patterns of pioneer trees in an agricultural landscape. **Plant Ecology**, v. 218, n. 6, p. 737–748, 2017.

ROCHE, J. W.; GOULDEN, M. L.; BALES, R. C. Estimating evapotranspiration change due to forest treatment and fire at the basin scale in the Sierra Nevada, California. **Ecohydrology**, v. 11, n. 7, p. e1978, 2018.

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. 3, p. e0196742, 2018.

ROQUETTE, J. G. Distribuição da biomassa no cerrado e a sua importância na armazenagem do carbono. **Ciência Florestal**, v. 28, n. 3, p. 1350–1363, 2018.

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.

ROSATTI, N. B.; SILVA, D. M.; BATALHA, M. A. Loss of phylogenetic and functional originalities of woody cerrado species in simulated extinction scenarios. **Austral Ecology**, v. 40, p. 267–274, 2015.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In: **Earth resources technology Satellite-1 Symposium, 3., 1973**. Washington: Proceedings. Washington: NASA. v.1, 1974. p. 309–317.

RSTUDIO Team. **RStudio: Integrated Development for R 1.0.143**. Boston: RStudio Inc., 2016. Disponível em: <<http://www.rstudio.com/>> Acesso em 10 nov. 2017.

SAMPAIO, A. C. F.; BIANCHIN, J. E.; SANTOS, P. M.; ARIATI, V.; SANTOS, L. M. Fitossociologia do Cerrado sensu stricto na bacia do Rio Parnaíba no nordeste brasileiro. **Advances in Forestry Science**, v. 5, n. 2, p. 299–307, 2018.

SANTOS, R. C. DOS; CARNEIRO, A. D. C. O.; PIMENTA, A. S.; CASTRO, R. V. O.; MARINHO, I. V.; TRUGILHO, P. F.; ALVES, I. C. N.; CASTRO, A. F. N. M. Potencial energético da madeira de espécies oriundas de plano de manejo florestal no estado do Rio Grande do Norte. **Ciência Florestal**, v. 23, n. 2, p. 491–502, 2013.

SANTOS, R. C. DOS; CARNEIRO, A. DE C. O.; VITAL, B. R.; CASTRO, R. V. O.; VIDAURRE, G. B.; TRUGILHO, P. F.; CASTRO, A. F. N. M. Influência das propriedades químicas e da relação siringil/guaiacil da madeira de Eucalipto na produção de carvão vegetal. **Ciência Florestal**, v. 26, n. 2, p. 657, 20 jun. 2016.

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 OLI Landsat 8. **Floresta**, v. 47, n. 1, p. 75–83, 2017.

SCHUMACHER, F. X.; HALL, F. S. Logarithmic expression of timber-tree volume. **Journal of Agricultural Research**, v. 47, p. 719–734, 1933.

SCOLFORO, J. R. S.; MELLO, J. M. DE; OLIVEIRA, A. D. DE; PEREIRA, R. M.; SOUZA, F. N. DE; GUEDES, I. C. DE L. Volumetria, peso de matéria seca e carbono. In: SCOLFORO, J. R. S.; MELLO, J. M. DE; OLIVEIRA, A. D. DE (Eds.). **Inventário Florestal de Minas Gerais: Cerrado - Florística, estrutura, diversidade, similaridade, distribuição diamétrica e de altura, volumetria, tendência de crescimento e áreas aptas para manejo florestal**. Lavras: UFLA, 2008. p. 361–438.

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.

SEVERIANO, E. DA C.; OLIVEIRA, G. C. DE; DIAS JUNIOR, M. DE S.; CURI, N.; COSTA, K. A. DE P.; CARDUCCI, C. E. Preconsolidation pressure, soil water retention characteristics, and texture of Latosols in the Brazilian Cerrado. **Soil Research**, v. 51, p. 193–202, 2013.

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

SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality. **Biometrika**, v. 52, n. 3/4, p. 591–611, 1965.

SHEN, X.; CAO, L.; LIU, K.; SHE, G.; RUAN, H. **Aboveground biomass estimation in a subtropical forest using airborne hyperspectral data**. In: 4th International Workshop on Earth Observation and Remote Sensing Applications (EORSA). **Anais...Guangzhou: IEEE, jul. 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7552836/>>** Acesso em: 24 nov. 2018.

SILVA-MORAES, H. G.; CORDEIRO, I.; FIGUEIREDO, I. Flora and floristic affinities of the cerrados of Maranhão state, Brazil. **Edinburgh Journal of Botany**, v. Online, p. 1–21, 2018.

SILVA, C. J. DA. **Densidade básica e potencial energético de espécies lenhosas do Cerrado do estado de Tocantins**. 66 f. Tese (Doutorado) - Departamento de Engenharia Florestal, Universidade de Brasília, Brasília, 2014.

SILVA, C. J. DA; VALE, A. T. DO. Energy density model for forest species from cerrado. **Revista Caatinga**, v. 31, n. 2, p. 396–404, 2018.

SILVA, C. J. DA; VALE, A. T. DO; MIGUEL, E. P. Densidade básica da madeira de espécies arbóreas de Cerradão no estado de Tocantins. **Pesquisa Florestal Brasileira**, v. 35, n. 82, p. 63–75, 2015.

SILVA, D. A. DA; CARON, B. O.; BEHLING, A.; SOUZA, V. Q. DE; ELOY, E. Ponto de amostragem ao longo do fuste para estimativa do poder calorífico da madeira. **Ciência Rural**, v. 42, n. 9, p. 1588–1595, 2012.

SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas: curso prático**. São Paulo: Artliber, 2010. 399 p.

SILVA, L. DA R. DA; SANO, E. E. Análise das imagens do satélite Rapideye para discriminação da cobertura vegetal do bioma Cerrado. **Revista Brasileira de Cartografia**, v. 68, n. 7, p. 1269–1283, 2016.

SILVA, J. P. M.; CABACINHA, C. D.; ASSIS, A. L.; MONTEIRO, T. C.; ARAÚJO JÚNIOR, C. A.; MAIA, R. D. Redes neurais artificiais para estimar a densidade básica de madeiras do cerrado. **Pesquisa Florestal Brasileira**, v. 38, n. e201701656, p. 1–10, 2018.

SMITH, W. B.; LARA, R. A. C.; CABALLERO, C. E. D.; VALDIVIA, C. I. G.; KAPRON, J. S.; REYES, J. C. L.; TOVAR, C. L. M.; MILES, P. D.; OSWALT, S. N.; SALGADO, M. R.; SONG, X. A.; STINSON, G.; GAYTÁN, S. A. V. The North American forest fatabase: going beyond national-level forest resource assessment statistics. **Environmental Monitoring and Assessment**, v. 190, p. 350, 2018.

SO, C. L.; EBERHARDT, T. L. FTIR-based models for assessment of mass yield and biofuel properties of torrefied wood. **Wood Science and Technology**, v. 52, n. 1, p. 209–227, 2018.

SOARES FILHO, B.; RAJÃO, R.; MACEDO, M.; CARNEIRO, A.; COSTA, W.; COE, M.; RODRIGUES, H.; ALENCAR, A. Cracking Brazil's forest code. **Science**, v. 344, p. 363–364, 2014.

SOARES, V. C.; BIANCHI, M. L.; TRUGILHO, P. F.; PEREIRA, A. J.; HÖFLER, J. Correlações entre as propriedades da madeira e do carvão vegetal de híbridos de Eucalipto. **Revista Árvore**, v. 38, n. 3, p. 543–549, 2014.

SOLÓRZANO, A.; PINTO, J. R. R.; FELFILI, J. M.; HAY, J. D. V. Perfil florístico e estrutural do componente lenhoso em seis áreas de cerradão ao longo do bioma Cerrado. **Acta Botanica Brasilica**, v. 26, n. 2, p. 328–341, 2012.

SOUSA, A. M. O.; GONÇALVES, A. C.; MESQUITA, P.; MARQUES DA SILVA, J. R. Biomass estimation with high resolution satellite images: A case study of *Quercus rotundifolia*. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 101, p. 69–79, 2015.

SOUZA, A. P. DE; STANGERLIN, D. M.; MELO, R. R. DE; ULIANA, E. M. Sazonalidade da umidade de equilíbrio da madeira para o estado de Mato Grosso. **Pesquisa Florestal Brasileira**, v. 36, n. 88, p. 423–433, 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 cerradão na Floresta Nacional de Paraopeba - Minas Gerais. **Cerne**, v. 16, n. 1, p. 86–93, 2010.

SOUZA, M. C.; FRANCO, A. C.; HARIDASAN, M.; ROSSATTO, D. R.; ARAÚJO, J. F. DE; MORELLATO, L. P. C.; HABERMANN, G. The length of the dry season may be associated with leaf scleromorphism in cerrado plants. **Anais da Academia Brasileira de Ciências**, v. 87, n. 3, p. 1691–1699, 2015.

SPEARMAN, C. The proof and measurement of association between two things. **The American Journal of Psychology**, v. 15, n. 1, p. 72–101, 1904.

STATSOFT, I. **Statistica: Data analysis software system**, 2007.

STELTE, W.; HOLM, J. K.; SANADI, A. R.; BARSBERG, S.; AHRENFELDT, J.; HENRIKSEN, U. B. Fuel pellets from biomass: The importance of the pelletizing pressure and its dependency on the processing conditions. **Fuel**, v. 90, n. 11, p. 3285–3290, 2011.

STRANDBERG, M.; OLOFSSON, I.; POMMER, L.; WIKLUND-LINDSTRÖM, S.; ÅBERG, K.; NORDIN, A. Effects of temperature and residence time on continuous torrefaction of spruce wood. **Fuel Processing Technology**, v. 134, p. 387–398, 2015.

SWITHENBANK, J.; CHEN, Q.; ZHANG, X.; SHARIFI, V.; POURKASHANIAN, M. Wood would burn. **Biomass and Bioenergy**, v. 35, p. 999–1007, 2011.

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.

TELMO, C.; LOUSADA, J. The explained variation by lignin and extractive contents on higher heating value of wood. **Biomass and Bioenergy**, v. 35, n. 5, p. 1663–1667, 2011.

TESTA, S.; SOUDANI, K.; BOSCHETTI, L.; BORGOGNO MONDINO, E. MODIS-derived EVI, NDVI and WDRVI time series to estimate phenological metrics in French deciduous forests. **International Journal of Applied Earth Observation and Geoinformation**, v. 64, p. 132–144, 2018.

TIRYAKI, S.; BARDAK, S.; AYDIN, A.; NEMLI, G. Analysis of volumetric swelling and shrinkage of heat treated woods: Experimental and artificial neural network modeling approach. **Maderas. Ciencia y tecnología**, v. 18, n. 3, p. 477–492, 2016.

TIRYAKI, S.; HAMZAÇEBI, C. Predicting modulus of rupture (MOR) and modulus of elasticity (MOE) of heat treated woods by artificial neural networks. **Measurement**, v. 49, n. 1, p. 266–274, 2014.

TODARO, L.; RITA, A.; CETERA, P.; D'AURIA, M. Thermal treatment modifies the calorific value and ash content in some wood species. **Fuel**, v. 140, p. 1–3, 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.

UZUN, H.; YILDIZ, Z.; GOLDFARB, J. L.; CEYLAN, S. Improved prediction of higher heating value of biomass using an artificial neural network model based on proximate analysis. **Bioresource Technology**, v. 234, p. 122–130, 2017.

VACCHIANO, G.; BERRETI, R.; MOTTA, R.; MONDINO, E. B. Assessing the availability of forest biomass for bioenergy by publicly available satellite imagery. **iForest**, v. 11, p. 459–468, 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.
- VALE, A. T. DO; 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. 71–80, 2002b.
- VALE, A. T. DO; DIAS, I. S.; SANTANA, M. A. E. Relações entre propriedades químicas, físicas e energéticas da madeira de cinco espécies de cerrado. **Ciencia Florestal**, v. 20, n. 1, p. 137–146, 2010.
- VALE, A. T. DO; FIEDLER, N. C.; SILVA, G. F. DA. Avaliação energética da biomassa do Cerrado em função do diâmetro das árvores. **Ciência Florestal**, v. 12, n. 2, p. 115–126, 2002a.
- 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.
- 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, C. K.; BORGES, L. G. DOS A.; MARCONATTO, L.; GIONGO, A.; STÜRMER, S. L. Microbiome of a revegetated iron-mining site and pristine ecosystems from the Brazilian Cerrado. **Applied Soil Ecology**, v. 131, p. 55–65, 2018a.
- 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.
- VOGEL, H. L. M.; SCHUMACHER, M. V.; TRÜBY, P. Micronutrientes na biomassa acima do solo em uma floresta estacional subtropical. **Cerne**, v. 21, n. 2, p. 175–182, 2015.
- WATZLAWICK, L. F.; KIRCHNER, F. F.; SANQUETTA, C. R. Estimativa de biomassa e carbono em floresta com araucaria utilizando imagens do satélite Ikonos II. **Ciencia Florestal**, v. 19, n. 2, p. 169–181, 2009.
- WHITE, J. C.; COOPS, N. C.; WULDER, M. A.; VASTARANTA, M.; HILKER, T.; TOMPALSKI, P. Remote Sensing Technologies for Enhancing Forest Inventories: A Review. **Canadian Journal of Remote Sensing**, v. 42, n. 5, p. 619–641, 2016.
- YILDIZ, G.; RONSSE, F.; VENDERBOSCH, R.; DUREN, R. VAN; KERSTEN, S. R. A.; PRINS, W. Effect of biomass ash in catalytic fast pyrolysis of pine wood. **Applied Catalysis B: Environmental**, v. 168, p. 203–211, 2015.

ZANUNCIO, A. J. V.; MONTEIRO, T. C.; LIMA, J. T.; ANDRADE, H. B.; CARVALHO, A. G. Drying biomass for energy use of *Eucalyptus urophylla* and *Corymbia citriodora* logs. **BioResources**, v. 8, n. 4, p. 5159–5168, 2013.

ZANUNCIO, A. J. V.; CARVALHO, A. G.; SILVA, L. F. DA; CARNEIRO, A. DE C. O.; COLODETTE, J. L.; ZANUNCIO, A. J. V.; CARVALHO, A. G.; SILVA, L. F. DA; CARNEIRO, A. DE C. O.; COLODETTE, J. L. Artificial neural networks as a new tool for assessing and monitoring wood moisture content. **Revista Árvore**, v. 40, n. 3, p. 543–549, 2016.

ZHANG, Z.; WANG, X.; ZHAO, X.; LIU, B.; YI, L.; ZUO, L.; WEN, Q.; LIU, F.; XU, J.; HU, S. A 2010 update of National Land Use/Cover Database of China at 1:100000 scale using medium spatial resolution satellite images. **Remote Sensing of Environment**, v. 149, p. 142–154, 2014.

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.

ZOBEL, B. J.; JETT, J. B. **Genetics of wood production**. Berlin: Springer-Verlag, 1995. 337 p.

ZUCCHINI, W. An introduction to model selection. **Journal of Mathematical Psychology**, v. 44, p. 41–61, 2000.