

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS E TECNOLOGIAS PARA A SUSTENTABILIDADE
CAMPUS DE SOROCABA
PROGRAMA DE PÓS-GRADUAÇÃO EM PLANEJAMENTO E USO DE RECURSOS
RENOVÁVEIS

ARGEMIRO JOSÉ MORENO ARTEAGA

**APLICAÇÃO DE IMAGENS ORBITAIS NA ESPACIALIZAÇÃO DO VOLUME DE
EUCALYPTUS SP. VIA REDES NEURAS ARTIFICIAIS**

Sorocaba

2019

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS E TECNOLOGIAS PARA A SUSTENTABILIDADE
CAMPUS DE SOROCABA
PROGRAMA DE PÓS-GRADUAÇÃO EM PLANEJAMENTO E USO DE RECURSOS
RENOVÁVEIS

ARGEMIRO JOSÉ MORENO ARTEAGA

**APLICAÇÃO DE IMAGENS ORBITAIS NA ESPACIALIZAÇÃO DO VOLUME DE
EUCALYPTUS SP. VIA REDES NEURAS ARTIFICIAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis, para obtenção do título de Mestre em Planejamento e Uso de Recursos Renováveis.

Orientação: Prof. Dr. Cláudio Roberto Thiersch.

Sorocaba

2019

Moreno Arteaga, Argemiro José

Aplicação de imagens orbitais na espacialização do volume de *Eucalyptus* sp. via redes neurais artificiais / Argemiro José Moreno Arteaga. -- 2019.
91 f. : 30 cm.

Dissertação (mestrado)-Universidade Federal de São Carlos, campus Sorocaba, Sorocaba

Orientador: Cláudio Roberto Thiersch

Banca examinadora: Cláudio Roberto Thiersch, Monica Fabiana Bento Moreira Thiersch, Adriana Leandra de Assis

Bibliografia

1. Volume de madeira . 2. Sensoriamento remoto. 3. Redes neurais artificiais. I. Orientador. II. Universidade Federal de São Carlos. III. Título.

Ficha catalográfica elaborada pelo Programa de Geração Automática da Secretaria Geral de Informática (SIn).

DADOS FORNECIDOS PELO(A) AUTOR(A)

Bibliotecário(a) Responsável: Maria Aparecida de Lourdes Mariano – CRB/8 6979

ARGEMIRO JOSE MORENO ARTEAGA

**APLICAÇÃO DE IMAGENS ORBITAIS NA
ESPACIALIZAÇÃO DO VOLUME DE *Eucalyptus sp.* VIA
REDES NEURAIIS ARTIFICIAIS**

**Dissertação apresentada ao Programa de Pós-Graduação para obtenção do título de
mestre em Planejamento e Uso de Recursos Renováveis.
Universidade Federal de São Carlos.
Sorocaba, 20 de março de 2019.**

Orientador:



Prof. Dr. Cláudio Roberto Thiersch
Presidente da banca examinadora – UFSCar Sorocaba

Examinadores:



Profa. Dra. Monica Fabiana Bento Moreira Thiersch
Universidade Federal de São Carlos - UFSCar Sorocaba

Certifico que a sessão de defesa foi realizada com a participação à distância da Dra. Adriana Leandra de Assis (Universidade Federal de Minas Gerais) e, depois das arguições e deliberações realizadas, a participante à distância está de acordo com o conteúdo do parecer da comissão examinadora redigido no relatório de Defesa de Dissertação de Argemiro José Moreno Arteaga.



Prof. Dr. Cláudio Roberto Thiersch
Presidente da banca examinadora

*Esta investigación es dedicada a mi madre
Almiris Arteaga Hernandez.*

AGRADECIMENTO

A Deus por dar-me a sabedoria necessária e força nos momentos difícil.

À Universidade Federal de São Carlos. Aos funcionários e professores do Campus de Sorocaba pelo auxílio na realização deste trabalho.

Ao Programa de Pós-graduação em Planejamento e Uso de Recursos Renováveis.

Ao professor Prof. Dr. Cláudio Roberto Thiersch pela orientação.

À Prof. Dra. Franciane Andrade de Pádua, Prof. Dra. Monica Fabiana Bento Moreira Thiersch e Prof. Dra. Roberta De Oliveira Avena Valente, por toda a ajuda oferecida.

À Secretaria do PPGPUR, Luciana Missae Kawamura, por toda a disposição oferecida no esclarecimento dos procedimentos regulares do programa.

A meu irmão Alfredo Daniel Moreno Arteaga por toda a ajuda oferecida.

A meus amigos Marco Abreou, Fracis Lai, Juliana Cunha e todas as amigas que fiz na Aliança Bíblica Universitária do Brasil (ABUB) pelo apoio, convivência e motivação.

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

RESUMO

MORENO ARTEAGA, Argemiro José. Aplicação de imagens orbitais na espacialização do volume de *Eucalyptu* sp. via redes neurais artificiais. 2019. 91 f. Dissertação (Mestrado em “Planejamento e uso de recursos renováveis”) – Centro de Ciências e Tecnologias para Sustentabilidade, Universidade Federal de São Carlos, Sorocaba, 2019.

A produção eficiente de plantios florestais exige o monitoramento permanente da quantidade do volume de madeira que se está produzindo, sendo difícil o seguimento a extensas áreas plantadas efetuando somente procedimentos manuais de campo. Pelo que esta investigação procura modelar redes neurais artificiais de perceptron multicamada para a estimativa espacial do volume de madeira em povoamento florestal em plantio de *Eucalyptus* sp. localizado no estado de Mato Grosso do Sul na região Centro-Oeste do Brasil, empregando como variáveis de predição as bandas espectrais, as texturas das bandas obtidos com matriz de Co-ocorrência de nível de cinza e índices de vegetação, que foram derivados de imagem digital de satélite Spot 6. A rede neural resultante com maior eficiência compareceu precisão de 93.32% e coeficiente de determinação de 0.9761, com respeito a valores obtidos com medições de campo. Porém, comparando erro padrão residual de 16.32% (RMSE de 7.85 m³ha⁻¹), mas não sendo a distribuição dos resíduos tendenciosa, pelo que o modelo se apresentou promissório no mapeamento do volume em grandes áreas sem sobrestimar ou subestimar as predições. Comparado com outros métodos de aprendizado de máquina que usaram iguais variáveis de estimativa, a rede construída apresentou superior precisão e exatidão. Inclusive com referencia a modelos neurais que utilizaram bandas espectrais e índices de vegetação, evidenciou-se melhor desempenho, sinalando que as texturas contribuem no aprimoramento das predições.

Palavras-chave: Biomassa. Dendrometria. Sensoriamento remoto. Perceptron multicamada. Texturas.

ABSTRACT

MORENO ARTEAGA, Argemiro José. Application of orbital images in the specialization of the volume of *Eucalyptus* sp. via artificial neural networks. 2019. 91 f. Dissertation (Master in “Planning and Use of Renewable Resources”) – Science and Technology Center of Sustainability, Federal University of São Carlos, Sorocaba, 2019.

The sustainable agriculture of forest plantations demands the permanent monitoring of the quantity of processed wood, thus becoming difficult to monitor large planted areas by using only manual procedures. Therefore, in this research artificial neural networks (RNA) of multilayer perceptrons, were modeled to estimate the spatial of wood volume in a *Eucalyptus*-sp plantation located in the state of Mato Grosso del Sur in the Central-West region of Brazil. As input variables in the RNA spectral bands, the textures of the bands obtained with Gray Level Co-Occurrence Matrices and vegetation index were used, which were derived from digital satellite image Spot 6. The resulting RNA with the best performance presented accuracy of 93.32% and coefficient of determination of 0.9761. However, this network presented a mean square error of 16.32% (RMSE de 7.85 m³ha⁻¹), but with a unbiased distribution of the residuals. So, the model showed to be suitable to monitor the amount of wood in large areas without overestimating or underestimating the prediction. Compared with different machine learning methods using the same variables, the built network seems to have a higher precision and accuracy. Even in the neuronal models using only spectral bands and vegetation indexes, a better performance was evidenced, showing that the textures contribute in the improvement of predictions.

Keywords: Biomass. Dendrometry. Remote sensing. Multilayer perceptrons. Texture.

LISTA DE ABREVIATURAS, SIGLAS E SÍMBOLOS

ARVI	Índice de Vegetação resistente à atmosfera
ASM	Segundo momento angular ou uniformidade
CON	Descritor de textura Contraste
COR	Descritor de textura Correlação
DVI	Índice de vegetação pela diferença
ENT	Descritor de textura Entropia
EVI	Índice de vegetação melhorado
GNDVI	Índice de vegetação por diferença normalizada verde
GLCM	Matriz de co-ocorrência de níveis de cinza
IAF	Índice de área foliar
IDM	Momento inverso de diferença ou homogeneidade
MSAVI	Índice de vegetação modificado pelo solo
ND	Nível digital
NDII	Índice infravermelho de diferença normalizada
NDVI	Índice de vegetação por diferença normalizada
OSAVI	Índice de vegetação otimizado pelo solo
RDVI	Índice de Vegetação de Diferença Renormalizada
RMSE	Erro quadrático médio (RMSE)
RNA	Rede neural artificial
RVI	Índice de vegetação pela razão
SA	Descritor de textura Média da soma
SAVI	Índice de vegetação ajustado ao solo
SE	Descritor de textura Soma da entropia
SRI	Índice de vegetação de diferença
SIG	Sistemas de informação geográfica.
SV	Descritor de textura Variância da Soma
TDVI	Índice de vegetação de diferença transformada
VAR	Descritor de textura Variância
B1	Níveis digitais registrados nos pixels da banda 1
B2	Níveis digitais registrados nos pixels da banda 2
B3	Níveis digitais registrados nos pixels da banda 3
B4	Níveis digitais registrados nos pixels da banda 4
C1	Coefficientes de correção atmosférica
C2	Coefficientes de correção atmosférica
ASM_B1	Descritor de textura Segundo momento angular derivado da B1
IDM_B1	Descritor de textura Momento inverso de diferença derivado da B1
CON_B1	Descritor de textura Contraste derivado da B1
COR_B1	Descritor de textura Correlação derivado da B1
ENT_B1	Descritor de textura Entropia derivado da B1
VAR_B1	Descritor de textura Variância derivado da B1
SA_B1	Descritor de textura Média da soma derivado da B1
SV_B1	Descritor de textura Variância da soma derivado da B1
SE_B1	Descritor de textura Soma da Entropia derivado da B1
ASM_B2	Descritor de textura Segundo momento angular derivado da B2

IDM_B2	Descritor de textura Momento inverso de diferença derivado da B2
CON_B2	Descritor de textura Contraste derivado da B2
COR_B2	Descritor de textura Correlação derivado da B2
ENT_B2	Descritor de textura Entropia derivado da B2
VAR_B2	Descritor de textura Variância derivado da B2
SA_B2	Descritor de textura Média da soma derivado da B2
SV_B2	Descritor de textura Variância da soma derivado da B2
SE_B2	Descritor de textura Soma da Entropia derivado da B2
ASM_B3	Descritor de textura Segundo momento angular derivado da B3
IDM_B3	Descritor de textura Momento inverso de diferença derivado da B3
CON_B3	Descritor de textura Contraste derivado da B3
COR_B3	Descritor de textura Correlação derivado da B3
ENT_B3	Descritor de textura Entropia derivado da B3
VAR_B3	Descritor de textura Variância derivado da B3
SA_B3	Descritor de textura Média da soma derivado da B3
SV_B3	Descritor de textura Variância da soma derivado da B3
SE_B3	Descritor de textura Soma da Entropia derivado da B3
ASM_B4	Descritor de textura Segundo momento angular derivado da B4
IDM_B4	Descritor de textura Momento inverso de diferença derivado da B4
CON_B4	Descritor de textura Contraste derivado da B4
COR_B4	Descritor de textura Correlação derivado da B4
ENT_B4	Descritor de textura Entropia derivado da B4
VAR_B4	Descritor de textura Variância derivado da B4
SA_B4	Descritor de textura Média da soma derivado da B4
SV_B4	Descritor de textura Variância da soma derivado da B4
SE_B4	Descritor de textura Soma da Entropia derivado da B4
A_w	Tipo de classificação climática de Köppen-Geiger
d_{nl}	Valor desejado no neurônio da camada de saída.
e_{nl}	Erro de saída real do neurônio
f	Função de ativação
f_s	Junção somatória
i	Linhas da matriz de co-ocorrência de níveis de cinza
j	Colunas da matriz de co-ocorrência de níveis de cinza
L	Fator de correção
W_p	Peso de conexões nos neurônios
$w_{nm}(t)$	Pesos sinápticos dos neurônios na iteração t
$w_{nm}(t+1)$	Pesos sinápticos corrigidos dos neurônios na iteração t +1
X_p	Variáveis de entradas ao neurônios das redes neurais
y	Resposta neural da rede à rede neural artificial
ynl	Resposta estimada produzida pelo neurônio
γ	Fator de autocorreção atmosférica
$\Delta w_{nm}(t)$	Ajuste dos pesos sinápticos dos neurônios na iteração t
δ_{nm}	Gradiente local dos neurônios
θ	Direção angular na janela de pixels
$P(i, j)$	Pixels na matriz de co-ocorrência de níveis de cinza

LISTA DE FIGURAS

Figura 1	–	Janela de pixels 3x3 com as diferentes variações angulares.....	22
Figura 2	–	Esquema da matriz GLCM.....	23
Figura 3	–	Modelo arquitetônico do neurônio artificial.....	27
Figura 4	–	Rede alimentada adiante com uma única camada.....	29
Figura 5	–	Rede multicamada alimentada adiante.....	29
Figura 6	–	Localização da área de estudo.....	36
Figura 7	–	Distribuição de unidades amostras no povoamento florestal	37
Figura 8	–	Representação a cor natural do povoamento florestal com Imagem Spot 6...38	
Figura 9	–	Esquematização geral da rede neural artificial.....	49
Figura 10	–	Correlação de bandas espectrais com o volume de madeira.....	55
Figura 11	–	Correlação dos descritores de textura da B1 com o volume de madeira.....	56
Figura 12	–	Correlação dos descritores de textura da B2 com o volume de madeira.....	57
Figura 13	–	Correlação dos descritores de textura da B3 com o volume de madeira.....	58
Figura 14	–	Correlação dos descritores de textura da B4 com o volume de madeira.....	59
Figura 15	–	Correlação dos índices de vegetação com o volume de madeira.....	60
Figura 16	–	Correlação das variáveis de entrada à RNA com o volume de madeira.....	62
Figura 17	–	Representação espacial do plantio florestal na Banda 1 da imagem digital...63	
Figura 18	–	Representação espacial do plantio florestal na Banda 2 da imagem digital...63	
Figura 19	–	Representação espacial do plantio florestal na Banda 3 da imagem digital...64	
Figura 20	–	Representação espacial do plantio com a textura SA derivada da Banda 1...64	
Figura 21	–	Representação espacial do plantio com a textura SA derivada da Banda 2...65	
Figura 22	–	Representação espacial do plantio com a textura SA derivada da Banda 3...65	
Figura 23	–	Representação espacial do plantio com a textura SV da Banda 1.....	66
Figura 24	–	Representação espacial do plantio com o índice de vegetação GNDVI.....	67
Figura 25	–	Representação estrutural da RNA arquitetada.....	68
Figura 26	–	Volume inventariado com respeito ao estimado pela RNA.....	69
Figura 27	–	Gráficos de dispersão dos resíduos (a) e Q-Q normal (b).....	70
Figura 28	–	Distribuição espacial do volume de madeira no povoamento florestal.....	74
Figura 29	–	Histograma de frequência dos valores de volume de madeira no plantio.....	75

SUMÁRIO

1. INTRODUÇÃO.....	13
2. FUNDAMENTAÇÃO TEÓRICA.....	16
2.1. PLANTACÕES FLORESTAIS DE EUCALIPTO.....	16
2.2. ESTIMATIVA DO VOLUMEM DE MADEIRA EM PLANTACÕES.....	16
2.3. RADIAÇÃO, SENSORIAMENTO E GEOPROCESSAMENTO.....	17
2.3.1. Interações da radiação com a vegetação.....	19
2.4. IMAGENS DIGITAIS DE SATÉLITE.....	19
2.4.1. Resoluções de imagens digitais.....	20
2.4.2. Imagem Spot 6.....	20
2.5. TEXTURA EM IMAGENS DIGITAIS.....	21
2.5.1. Análises de texturas por matriz de co-ocorrência.....	22
2.5.2. Descritores de textura.....	23
2.6. ÍNDICES DE VEGETAÇÃO.....	24
2.7. ANÁLISES DE CORRELAÇÃO	25
2.8. REDES NEURAIS ARTIFICIAS.....	26
2.8.1. Modelo de um neurônio.....	27
2.8.2. Modelos arquitetônicos de redes neurais artificiais.....	28
2.8.3. Treinamento e aprendizagem de uma rede neural artificial.....	30
2.8.4. Algoritmo de retropropagação do erro.....	31
2.8.5. Generalização de redes neurais artificiais.....	31
2.9. INVESTIGAÇÕES RELACIONADAS.....	32
3. MATERIAL E MÉTODOS.....	36
3.1. ÁREA DE ESTUDO.....	36
3.2. DADOS DE CAMPO.....	37
3.3. IMAGEM DE SATÉLITE.....	38
3.3.1. Pré-processamento da imagem digital.....	39
3.4. CALCULO DOS DESCRITORES DE TEXTURA.....	39
3.5. CALCULO DE ÍNDICES DE VEGETAÇÃO.....	41
3.6. DEFINIÇÃO DE VARIÁVEIS DE ENTRADA À RNA.....	43
3.6.1. Calculo de correlação das variáveis de entrada e saída desejada.....	45

3.6.2. Escalonamento das variáveis de entrada e saída desejada.....	46
3.7. ARQUITECTURA DA RNA.....	46
3.7.1. Camadas e neurônios da RNA.....	47
3.7.2. Função de ativação dos neurônios.....	48
3.7.3. Processo de treinamento e aprendizagem.....	48
3.8. AVALIAÇÃO DA RNA.....	51
3.9. REPRESENTAÇÃO ESPACIAL DO VOLUME DE MADEIRA.....	53
4. RESULTADOS E DISCUSSÃO.....	54
4.1. ANÁLISES DE CORRELAÇÃO.....	54
4.2. VARIÁVEIS DE ENTRADA NA RNA.....	62
4.3. MODELO E AVALIAÇÃO DA RNA.....	67
4.4. ESPACIALIZAÇÃO DO VOLUME DE MADEIRA NO PLANTIO.....	73
5. CONCLUSÕES.....	76
REFERÊNCIAS.....	78
ANEXO.....	89

1. INTRODUÇÃO

A madeira constituiu-se num recurso fundamental para o ser humano, em especial a obtida da cultura de *Eucalyptus* sp., pela série de serviços socioeconômicos que proporciona na fabricação de móveis, papel e geração de energia (JÚNIOR et al., 2017; REZENDE et al., 2018). Além de disponibilizar benefícios ambientais quando está em pé, como a absorção de dióxido de carbono da atmosfera, um dos gases causante da mudança climática do planeta pelo efeito estufa (LÓPEZ-SERRANO et al., 2016; GHOSH; BEHERA, 2018). Causa do aprimoramento de sua produção em massa, economicamente sustentável, com o eficiente manejo florestal das plantações florestais, o que se fundamenta com o monitoramento da quantidade de madeira que se está produzindo.

A estimativa do volume de madeira produzida em extensas áreas de plantios de *Eucalyptus* sp. e de outras espécies, realiza-se tipicamente através da medição em campo amostras de atributos das árvores que permitam fazer uma inferência para todo o conjunto populacional do povoamento com modelos alométricos (TUOMINEN; PEKKARINEN, 2005; LU et al., 2016; GHOSH; BEHERA, 2018). Precisando a amostragem pessoal treinado, material e equipamentos especializados, pelo que tal atividade torna-se muito difícil em extensas áreas (LU et al., 2016). Tendo como fator condicionante nesses aspectos a inversão monetária que deve ser minimizada, mas sem deixar de amostrar o suficiente número de indivíduos (árvores) para conseguir uma estimativa próxima do volume real de madeira disponível (TONINI, 2013; OLIVEIRA et al., 2014; MALTAMO et al., 2015).

O desenvolvimento do conhecimento humano está levando à automatização de processos produtivos com o objetivo de aumentar sua capacidade, isto é, integração de tecnologia no sistema de produção, elevando sua competitividade no mercado, reduzindo custos de atividades que eram feitas de forma manual (PESSÔA, 2014). Com tal particularidade, os produtos obtidos com técnicas de sensoriamento remoto, como as imagens digitais capturadas por meio de satélite, são tecnologias tratadas em ambientes computacionais que auxiliam na aquisição de informações sobre identificação e caracterização de aspectos dos recursos florestais em amplos espaços de área ao longo de períodos de tempo, diminuindo ações manuais de campo que podem incorrer em erros procedimentais (FERREIRA; CARVALHO; BAPTISTA, 2009; GUILHERME et al., 2016; GAO et al., 2017).

Características das imagens digitais como a textura e índices de vegetação derivadas de bandas multiespectrais, são definidos conforme a distribuição das propriedades físicas e biológicas das árvores, portanto, podem ser usados como variáveis para a modelagem espacial de parâmetros da floresta, como o volume da biomassa (HARALICK, 1979; ANAYA; DUQUE; VALENCIA, 2008; BAIEE; ALASADI, 2013; MOHANAIH; SATHYANARAYANA; GURUKUMAR, 2013; DA SILVA et al., 2015; LAN; LIU, 2018). Os índices de vegetação em áreas florestais maximizam a caracterização vegetal das árvores, minimizando ou conseguindo remover a influência de efeitos gerados pela geometria do dossel, fundo do solo, ângulos de iluminação e condições atmosféricas (SARKER; NICHOL, 2011). Por seu lado a textura permite analisar relações espaciais entre pixels próximos, aumentando a discriminação de características entre a vizinhança local, maximizando diferenças espaciais do dossel que aparentemente não tinham distinção, além, pode reduzir fatores de sombra induzidos pela diferença de altura entre as árvores e efeitos causados pela topografia (SOH; TSATSOULIS; MEMBER, 1999; TAHIR; BOURIDANE; KURUGOLLU, 2005; TUOMINEN; PEKKARINEN, 2005; YOUSSEF et al., 2017; PHAM; BRABYN, 2017;). Em geral, a textura da imagem digital proporciona principalmente informação espacial, entretanto, os índices de vegetação contêm informações espectrais, pelo que são fontes de informações complementárias que se relacionam de diferente forma com a floresta e conseqüentemente com seu volume (RODRIGUEZ-GALIANO et al., 2012; GHASEMIAN; AKHOONDZADEH, 2018).

No entanto, relacionar volumetria florestal com dados de sensoriamento remoto representa uma questão complexa empregando modelos que requerem formulações aritméticas fixamente estruturadas (ZHU et al., 2015). Assim, seguindo a linha de automatização de processos produtivos, as redes neurais artificiais (RNAs) são ferramentas que fornecem solução entre variáveis independentes e dependentes, a problemas de interesse que não tem formulação analítica baseadas com equações explícitas, conseguindo estabelecer relações complexas incognoscíveis a partir do aprendizado de padrões com informações subministradas das variáveis (FOODY et al., 2001; HAYKIN, 2009; NEVTIPILOVA, 2014; CZYZOWSKA-WISNIEWSKI et al., 2015; VAHEDI, 2016). Pelo que oferecem o devido suporte no processamento de dados de sensoriamento remoto para gerar previsão espacial da respectiva volumetria da madeira em todo o povoamento onde não é possível ou fica difícil de realizar trabalho de campo (LÓPEZ-SERRANO et al., 2016; GHOSH; BEHERA, 2018).

Portanto, esta pesquisa objetivou modelar e avaliar o desempenho de RNAs na estimativa espacial do volume de madeira sem casca em povoamento florestal de *Eucalyptus* sp. empregando informações de bandas espectrais, textura e índices de vegetação derivadas de imagens digitais de satélite Spot 6.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. PLANTAÇÕES FLORESTAIS DE EUCALIPTO

O *Eucalyptus* sp. é uma espécie nativa da Austrália, cultivada em grande escala por seu rápido crescimento, produtividade e boa capacidade de adaptação no ambiente (KAMGAN; MICHAEL, 2012; CALVIÑO-CANCELA; ETTEN, 2018). É amplamente comercializada no setor do agronegócio, caracterizando-se como uma das principais espécies arbóreas produzidas em plantações florestais no Brasil e em vários países do mundo, sendo especificamente no Brasil a responsável pelo abastecimento da maior parte do setor industrial com base florestal (WILCKEN et al., 2008; SFB, 2016).

Tendo um planejamento adequado, a colheita de madeira dos plantios de *Eucalyptus* sp. ocorre em torno dos sete anos de idade, regime viável de produção comercial que proporciona significativos benefícios econômicos, sociais e ambientais, podendo chegar a ter rentabilidade superior que as culturas agrícolas, impactando altamente na sociedade (SILVA et al., 2016).

As plantações de *Eucalyptus* sp. estão distribuídas por uma extensa gama de países, disseminadas por todos os continentes desde o século passado. Identificam-se diferentes tipos de espécies com produtividade de biomassa dependente do clima, tipo de solo e a intensidade de manejo (PONTES; MENDES, 2016; SFB, 2016). Sua madeira como fonte de matéria-prima é utilizada, sobretudo, como produto para celulose, papel, carvão vegetal, madeira serrada, compensados, aglomerados e chapas. Também as folhas podem ser utilizadas em arranjos florais e na extração de óleo. Em menor escala, também são usados como árvores ornamentais em parques e jardins.

2.2. ESTIMATIVA DO VOLUME DE MADEIRA EM PLANTAÇÕES

A estimativa volumétrica do estoque de madeira em povoamentos florestais é feita por meio de inventários que servem principalmente para a formulação de planos de manejo integrado sustentável e a exploração do plantio, bem como auxiliar nas propostas de desenvolvimento da política florestal de abrangência regional e até nacional (FERREIRA; CARVALHO; BAPTISTA, 2009; SERVIÇO FLORESTAL BRASILEIRO, 2017).

Compete ao inventário florestal o suporte técnico e científico necessários para fornecer informações periódicas sobre a floresta na obtenção de diversos tipos de parâmetros estruturais dendrométricos de acordo com os objetivos abrangentes no alcance de uma boa administração do plantio (QUEIROZ, 2012).

O inventário florestal tradicional é realizado por meio de conceitos e aplicações estatísticas, tendo como base a teoria da amostragem que se sustenta com observações pontuais de árvores levantadas em campo que vão representar a plantação (FERREIRA; CARVALHO; BAPTISTA, 2009). Assim, obtêm-se estimativas da quantidade de madeira distribuída no plantio em volume por área, abordando temas de ponto e espaço amostral, esperança matemática e função de probabilidade de variáveis.

2.3. RADIAÇÃO, SENSORIAMENTO E GEOPROCESSAMENTO.

A radiação eletromagnética se compreende como a propagação da energia pelo espaço em forma de onda sem precisar de material de transporte, como é a fornecida pelo sol ao planeta Terra para ser consumida principalmente nos processos fotossintéticos pelos seres vivos clorofilados (MENESES et al., 2012; PÓÇAS et al., 2012; MACHADO et al., 2014).

Em função de seu comprimento de onda, a radiação eletromagnética se caracteriza em bandas espectrais que têm diversos comportamentos ao interagir com os materiais da superfície terrestre (PEREIRA; ANGELOCCI; SENTELHAS, 2007). Entre os diferentes intervalos de comprimento de onda ressalta-se o espectro eletromagnético do ultravioleta, o visível (contendo a região dos comprimentos de ondas das cores azul, verde e vermelho percebidos pelo olho do ser humano), o infravermelho próximo, o infravermelho de ondas curtas, o infravermelho médio, o infravermelho termal, as micro-ondas e as de rádio (GRENFELL et al., 1998; CHUVIECO, 2016).

O sol emite a maior frequência de radiação eletromagnética de nosso sistema planetário, sendo a Terra também fonte de emissão, mas em muito menor proporção que o sol. A energia emitida pelo sol pertence ao espectro contínuo de comprimentos de onda curta formados pela radiação ultravioleta, visível e infravermelho próximo; e o planeta Terra emite radiação em direção à atmosfera em grande proporção no comprimento de onda do infravermelho termal (PEREIRA; ANGELOCCI; SENTELHAS, 2007; VELOSO, 2009; BALOGH; PEDRIALI; KANEKO, 2011; SCHMID; HUNZIKER; WÜEST, 2014; CHUVIECO, 2016).

A detecção de certos tipos de comprimentos de onda da radiação eletromagnética é utilizada para obter informação da Terra, sendo o sensoriamento remoto a técnica utilizada para representar características da superfície do planeta em imagens digitais por meio da detecção e medição quantitativa de radiações com sensores localizados na atmosfera ou no espaço (MENESES et al., 2012).

Em essência, o sensoriamento remoto é a extração de informações pelo registro da radiação refletida ou emitida pelas feições das coberturas superficiais, aproveitando as distintas assinaturas espectrais pelas diferentes composições físico-químicas que apresentam os materiais para sua possível discriminação e caracterização (CHUVIECO, 2016). A radiação é meio de comunicação entre o objetivo a caracterizar e o sensor detector que identifica os diferentes comprimentos de onda. Esta técnica tem ganhado relevância nos últimos anos na análise de fenômenos ambientais, sociais e econômicos; especialmente a efetuada com sensores equipados em satélites na órbita da Terra.

O desenvolvimento das tecnologias tornou possível o armazenamento e representação de dados digitais em ambientes virtuais de computadores, aparecendo o geoprocessamento. Constituindo-se o geoprocessamento como uma ferramenta computacional para o processamento informatizado de dados espaço-temporal referenciados geograficamente mediante programas que utilizam técnicas matemáticas que permitem o uso de informações cartográficas para seu tratamento (GONZALEZ; WOODS, 2000; DO SANTOS et al., 2014).

O sensoriamento remoto e o geoprocessamento constituíram-se como tecnologias indispensáveis em estudos aplicados ao monitoramento do ambiente ao longo de períodos de tempo.

Muitos softwares estão disponíveis para atividades de geoprocessamento computacional de informações espaciais, sendo sistemas de informações geográficas (SIG), funcionando para adquirir, armazenar e analisar dados geográficos, mapas, cartas climáticas, censos, entre outros, que permitem e facilitam a análise de dados espaciais. Estes softwares disponibilizam uma gama de ferramentas integradas, de fácil utilização para o tratamento das informações obtidas por sensoriamento remoto, para manipular grandes volumes de dados intrínsecos nas imagens de satélite, podendo-se desenvolver modelos matemáticos e estatísticos para o entendimento de características do ambiente.

2.3.1. Interações da radiação com a vegetação

A vegetação interage de maneira diferenciada com cada faixa da radiação solar que chega à superfície da Terra, assim, absorve em grande proporção o comprimento de onda azul e vermelho do espectro visível graças aos pigmentos de clorofila que regula o processo da fotossíntese, água e espaços intercelulares internos de suas folhas (CHUVIECO, 2016). A faixa do vermelho é o comprimento de máxima absorção e também absorve em menor grau a faixa do verde que é levemente o reflete (MARONEZE et al., 2014).

Na faixa eletromagnética do infravermelho próximo, em geral, a vegetação saudável tem sua máxima refletância devido à baixa absorção da clorofila e à estrutura celular interna das folhas, criando uma condição de alto contraste que favorece a percepção visual entre as coberturas superficiais (SANTIAGO et al., 2009; AQUINO; OLIVEIRA, 2012; ANDRADE, 2015). Pelo que é mais fácil de identificar neste comprimento de onda, com a qual o solo exposto e a água absorvem ou transmitem fortemente o fluxo radiação incidente, exibindo a vegetação notável refletividade que a torna com ótima discriminação em imagens digitais, contrastando-se seus limites na superfície (SHEN et al., 2017).

Em imagens multiespectrais, como padrão geral, as bandas do infravermelho próximo com as do vermelho apresentam notável contraste que possibilita monitorar e quantificar as condições e distribuições espaciais das vegetações para uma eficiente discriminação (DO SANTOS et al., 2014).

2.4. IMAGENS DIGITAIS DE SATÉLITE

As imagens digitais obtidas com técnicas de sensoriamento remoto por meio de satélite são uma representação das feições naturais e construídas da superfície terrestre em escala sobre um plano 2D, a partir da medição com sensores imageadores da radiação emitida ou refletida pelos alvos superficiais, que após são processados a valores digitais discretos (CHUVIECO, 2002; SANTOS; PELUZIO; SAITO, 2010).

Os sensores realizam o registro da radiação, processam e transmitem às estações terrestres onde são gravados e posteriormente processados digitalmente a formato raster para serem distribuídas aos usuários (SANTOS; PELUZIO; SAITO, 2010; MENESES et al., 2012). Essa informação se codifica em unidades denominadas de pixel, ao qual é

atribuído um valor numérico correspondente ao valor radiométrico registrado, e se organizam em matrizes retangulares ou quadradas na disposição de linhas e colunas referenciadas com coordenadas espaciais; tornando possível o uso de computadores para processamentos matemáticos, estatísticos e probabilísticos dos dados (SCHULTZ et al., 2014).

Os pixels na imagem estão configurados em níveis de cinza, onde os valores de cinza claros representam alvos com alta refletância e os de cinza escuros representam alvos com baixa.

Cada sensor mede uma ou várias faixas específicas de comprimento de onda da radiação, estabelecida como bandas espectrais do sensor, que se registram em matrizes de pixels correspondentes para cada intervalo de comprimento, as quais se conformam como componentes da imagem digital (GONZALEZ; WOODS, 2000; DO SANTOS et al., 2014).

2.4.1. Resoluções de imagens digitais

A capacidade ou potencialidade de um sensor imageador para detectar, identificar e representar objetos numa imagem digital se descreve por meio de resolução. Existem quatro tipos de resoluções: resolução espacial, radiométrica, espectral e a temporal.

A resolução espacial, definida pelo campo de visão do sensor, é o tamanho mínimo de área registrada do terreno que se representa num pixel da imagem; a resolução espectral se define conforme o comprimento de onda detectado pelo sensor, diferenciando-se nas imagens conforme as bandas espectrais que registram específicos intervalos do espectro eletromagnético; a resolução radiométrica referisse à medida da intensidade de radiância que digitalmente pode detectar o sensor e representar em cada pixel, e a resolução temporal faz referência à data em que o sensor volta a imagear a mesma área registrada anteriormente (MENESES et al., 2012).

2.4.2. Imagem Spot 6

Existe uma grande variedade de satélites com sensores adjuntos que tem a capacidade de registrar imagens digitais por meio de sensoriamento remoto, entre os

quais está o satélite Spot6, fonte de informação para análises, monitoramento e planejamento dos recursos naturais do planeta e das atividades humanas.

O satélite Spot 6 está em funcionamento desde setembro de 2012, apresentando uma órbita heliosíncrona que segue o sol acompanhando a Terra no movimento de translação em torno de seu eixo de polo a polo, cobrindo praticamente todas as regiões do Globo com uma resolução temporal de 26 dias e resolução radiométrica de 12 bits (ASTRIUM, 2013).

Apresenta quatro bandas espectrais, operando no intervalo da radiação eletromagnética do visível ao infravermelho de ondas curtas, podendo perceber a intensidade de radiância solar refletida por diferentes tipos de materiais que estão na superfície da Terra. Detecta a radiação do espectro visível na faixa do azul com a primeira banda multiespectral (0,450-0,520 μm), a faixa do verde com a segunda banda (0,530-0,590 μm), o comprimento vermelho na terceira banda (0,625-0,695 μm) e o espectro do infravermelho próximo na quarta banda (0,760-0,890 μm) (GONZALEZ; WOODS, 2000; ASTRIUM, 2013). Todas estas bandas com resolução espacial de 6m nos pixel. Além dessas, apresenta uma quinta banda denominada de pancromática, com detecção entre 0,450 a 0,745 μm de longitude, detectando a faixa da radiação visível com resolução de 1,5 m nos pixels e, mediante técnica de geoprocessamento, pode ser combinada com as bandas multiespectrais do visível e o infravermelho a fim de melhorar suas resoluções espaciais de 6 m a 1,5 m (ASTRIUM, 2013).

2.5. TEXTURA EM IMAGENS DIGITAIS

A textura de imagens comumente é definida como a aparência gerada pelos padrões estruturais de conformação e disposição de intensidade dos níveis digitais segundo as propriedades físico-químicas naturais dos objetos da superfície (ALVES; ARAÚJO; LIBRANTZ, 2006; BAIEE; ALASADI, 2013; SAHU et al., 2017).

É uma característica útil para reconhecer e classificar objetos nas cenas de imagens digitais, por variações locais nos valores dos pixels, que pode ser avaliada mediante cálculos com abordagem estatística de medida de distribuição e relação espacial dos níveis digitais (HALL-BEYER, 2017).

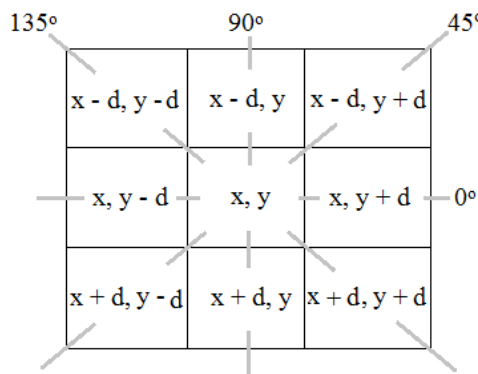
2.5.1. Análises de texturas por matriz de co-ocorrência

Um dos modelos de análise de textura foi definido por meio do estabelecimento de descritores baseados em Matriz de Co-ocorrência de Níveis de Cinza (GLCM), que quantifica as diferenças de nível de cinza entre pixels vizinhos numa imagem digital (HARALICK, 1979; TAHIR; BOURIDANE; KURUGOLLU, 2005; SHIJIN; DHARUN, 2016). Esta quantificação é arranjada em matriz quadrada que considera as relações encontradas entre pixels com variação de níveis de cinza dentre 0 a 255 (SOH; TSATSOULIS; MEMBER, 1999; YOUSSEF et al., 2017).

Para obter as GLCM, nas imagens digitais se define uma janela quadrada com pixel central de referência (x, y) que deve encerrar minimamente uma quantidade de 3×3 pixels, onde segundo o pixel central e os correspondentes vizinhos separados por uma distância d , são consideradas quatro direções cardinais θ (0° , 45° , 90° e 135°), como se pode observar na Figura 1 (ZHANG et al., 2017). Conforme as quais são contadas as diferenças dos níveis de cinza ocorridos entre pixels contíguos para gerar os elementos da GLCM (Figura 2), que após são normalizados com a razão da soma total dos valores contados (ALVES; ARAÚJO; LIBRANTZ, 2006; HALL-BEYER, 2017).

O número de ocorrências entre pixels vizinhos para uma determinada janela pode ser contado independentemente para a horizontal, a vertical, a diagonal de 45° , a diagonal de 135° ou alternativamente para todas as direções de uma vez (ZHANG et al., 2017). Assim, para cada direção angular θ pode ser gerada uma GLCM, resultando quatro matrizes de ocorrências diferentes e obter as representativas imagens de textura, mas também pode se adotar alternativamente uma única matriz que considere juntamente as quatro direções para obter uma única representação de textura.

Figura 1 – Janela de pixels 3×3 com as diferentes variações angulares.



Fonte: Autor.

Figura 2 – Esquema da matriz GLCM.

Valor pixel vizinho referencia	0	1	2	...	j
0	P(0,0)	P(0,1)	P(0,2)	...	P(0,j)
1	P(1,0)	P(1,1)	P(1,2)	...	P(1,j)
2	P(2,0)	P(2,1)	P(2,2)	...	P(2,j)
⋮	⋮	⋮	⋮	⋮	⋮
i	P(i,0)	P(i,1)	P(i,2)	...	P(i,j)

Fonte: Autor.

Na matriz (Figura 2), i representa as linhas da matriz e j às colunas que são correspondentes com os valores de níveis de digitais dos pixels da imagem. Assim, a matriz vai de zero (0) até o máximo valor de nível de digital da imagem, que seria o valor total de coluna e linhas.

2.5.2. Descritores de textura

Há 14 tipos diferentes de descritores de textura que são calculados a partir da matriz de co-ocorrência de Níveis de Cinza. Dentre os mais conhecidos e adotados na descrição de imagens da superfície da Terra estão o Segundo Momento Angular (*ASM*) ou Uniformidade, Momento inverso de diferença (*IDM*) ou homogeneidade, Contraste (*CON*), Correlação (*COR*), Entropia (*ENT*), Variância (*VAR*), Média da Soma (*SA*), Variância da Soma (*SV*) e Soma da entropia (*SE*) (HARALICK, 1979; GAO; XU; HUANG, 2016; GHASEMIAN; AKHOONDZADEH, 2018). Os demais descritores são formulados com base nestes.

De acordo com os descritores, cada elemento ou valor da GLCM é processado conforme operações aritméticas definidas a fim de obter um valor escalar de textura que vai ao pixel central de referência (x, y) da imagem raster original, representando a textura da janela completa. Na imagem digital, subsequentemente, a janela se movimenta e o processo se repete para calcular novas GLCM, até cobrir todos os pixels, que seriam de referência num dado momento de localização da janela.

Os descritores de textura determinam as características da imagem pela organização das tonalidades dos pixels, considerando seu valor e o inter-relacionamento entre eles (MUSCI et al., 2011; OLIVEIRA; FERNANDES, 2014; PATROCINIO; CARNEIRO, 2014).

Particularmente, o ASM mede a organização de tonalidade de cinza dos pixels da imagem, com faixa de valores possíveis de 0 a 1, onde os valores próximos de 1 ocorrem quando os pixels vizinhos são muito uniformes; o IDM denota a similaridade ou homogeneidade da distribuição dos níveis de cinza nos pixels vizinhos, com valores no intervalo de 0 a 1, sendo valores baixos associados a pouca homogeneidade; o CON, inversamente correlacionado com o IDM, analisa as variações ou diferenciação do nível de cinza, tendo valores resultantes a zero quando os pixels são similares; a COR determina a dependência linear dos níveis de cinza dos pixels vizinhos, definido com valores entre 1 com alta dependência até diminuir atingindo a -1; a ENT, que é inversamente proporcional ao ASM, avalia o grau de desordem entre os pixels vizinhos da imagem, sendo mínima quando os valores entre pixels são uniformes; a VAR mede a dispersão dos níveis de cinza contíguos com respeito a média da distribuição de seus valores; a SA estima o valor médio da soma da distribuição dos níveis de cinza de cada pixel na janela; a SV calcula a dispersão dos níveis de cinza dos pixels em relação a média de sua distribuição; e a SE mede a aleatoriedade ou desordem relacionado à distribuição dos níveis de cinza (ALVES; ARAÚJO; LIBRANTZ, 2006; HALL-BEYER, 2017).

Cada um destes descritores representa de maneira diferente as características da imagem.

2.6. ÍNDICES DE VEGETAÇÃO

Existe uma série de combinações de bandas espectrais com a finalidade de obter informações relacionadas à cobertura vegetal, definidos como Índices de vegetação.

Entre os índices mais utilizados na atualidade para caracterizar a vegetação está o Índice de vegetação pela razão (RVI), Índice de vegetação pela diferença (DVI), Índice de vegetação por diferença normalizada (NDVI), Índice de vegetação por diferença normalizada verde (GNDVI), Índice de Vegetação Resistente a Atmosfera (ARVI), Índice de vegetação melhorado (EVI) e o Índice de Vegetação Ajustado ao Solo (SAVI).

O RVI se fundamenta na razão do espectro de maior refletância das folhas verdes com a de maior absorção, pelo que é executada com a divisão da faixa espectral do infravermelho próximo com a do vermelho, respetivamente; Já o DVI se baseia pela diferença do maior espectro de refletância da vegetação com o de maior absorção (THENKABAIL; LYON; HUETE, 2016).

O NDVI é o índice mais utilizado para analisar as condições da cobertura vegetal, avalia a vegetação com respeito ao vigor, ausência ou presença em um instante de tempo (RUDY et al., 2013; QUINTANO et al., 2015; WU; CHEN, 2016). Gera-se com operação aritmética da razão da subtração entre a soma da faixa espectral do infravermelho próximo com a do vermelho visível (KARAN; SAMADDER; MAITI, 2016; WU; CHEN, 2016). Os valores variam num intervalo que vai de -1 a +1, onde os valores próximos de +1 significam presença de cobertura vegetal na superfície e valores próximos ou menores que zero (0) indicam ausência (LANORTE et al., 2014).

O GNDVI, a diferença do NDVI, utiliza a banda verde do espectro visível e não a do vermelho, apresentando as folhas no verde um pequeno pico de refletância não apreciada na banda vermelha (STAFFORD, 2013).

O ARVI é uma combinação de somatória e razão das bandas vermelha, infravermelha próxima e do azul, aumentando a discriminação da vegetação de forma semelhante ao NDVI, mas tem maior potencialidade na minimização dos efeitos de espalhamentos atmosféricos gerados pelos aerossóis na banda vermelha (LIU, 2015).

OSAVI é a introdução de um fator L no NDVI, que incorpora os efeitos da presença do solo na vegetação, minimizando seus efeitos de refletividade (HENTZ et al., 2014).

O EVI, assim como o SAVI, apresenta um fator L que minimiza o efeito de refletância do solo e contém coeficientes de ajuste para efeito de aerossóis da atmosfera, sendo sensível às variações estruturais do dossel da vegetação (BAYMA; SANO, 2015).

2.7. ANÁLISES DE CORRELAÇÃO

Existem várias técnicas de análises de relação entre variáveis, dentre os mais comumente utilizados estão os métodos de Pearson e o de Spearman, que gera um coeficiente de correlação com faixa de valores possíveis entre -1 e 1, referenciando a intensidade de relacionamento que existe, no caso de existir algum, entre duas ou mais variáveis (FIELD, 2009). O valor de um (1) e menos um (-1) significam correlação

perfeita positiva e negativa, respectivamente, entre as variáveis analisadas. O zero (0) denota não dependência das variáveis.

O método de Pearson é utilizado para medir o grau de correlação entre variáveis com dependência linear. Por sua parte, o método de Spearman é adequado para variáveis contínuas e discretas, medindo a quantidade de variação entre dados com estruturação não paramétrica, isto é, não requerem que as observações apresentem distribuição normal, podendo os dados apresentar configuração linear ou não linear (FIELD, 2009; ROGERSON, 2012; GLANTZ, 2015).

2.8. REDES NEURAIS ARTIFICIAS

Uma rede neural artificial (RNA) é um sistema de processamento de informação constituída de unidades operacionais de computação interligadas, chamadas de neurônios, que representam matematicamente o modelo arquitetônico e funcional dos neurônios biológicos do ser humano (MONTAVON; ORR; MÜLLER, 2012).

As RNAs têm a capacidade de adquirir conhecimento experimental mediante mecanismos de aprendizagem para armazená-lo e torná-lo disponível em determinada tarefa (NEVTIPILOVA et al., 2014).

São modelos com estruturação matemática condicionada para trabalhar com dados lineares e não linearmente separáveis, na resolução de problemas de interesse que não se tem formulação analítica baseada com equações aritméticas, tendo um extenso campo de aplicações com variabilidade de problemas pela flexibilidade de ser ajustável a cada enfoque requerido (HAYKIN, 2009).

O emprego das redes neurais é extenso, capazes de resolver problemas no campo da engenharia, ciência, medicina e finanças. Vê sendo utilizadas significativamente desde as duas últimas décadas do século XIX em diversas áreas do conhecimento, mas neste século há um marcante impacto na humanidade, sendo aprimoradas e incluídas como ferramentas fundamentais de desenvolvimento na automatização de processos produtivos (MARENGO, 2006; NGUYEN et al., 2009; BASISTOV; YANOVSKIL, 2016; MURAVYOVA; TIMERBAEV, 2018).

Entre os principais usos das RNA, como exemplo representativo, temos que no setor automotriz guia os sistemas de injeção de combustível nos automóveis, na indústria manufatureira controla sistema de processos de produção, na robótica controla a trajetória dos movimentos dos robôs, nas telecomunicações ajuda a transmitir a

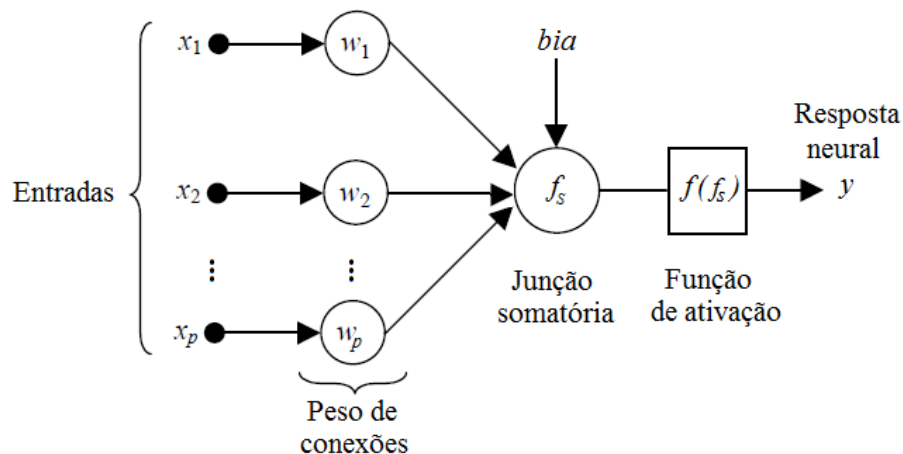
informação pelos canais de comunicação, na medicina serve para as análises de câncer de mama como também na otimização de equipamentos de transplante (HAGAN et al., 2014).

Tem um amplo número de aplicações, pelo que tem motivado atualmente muitos investimentos econômicos no desenvolvimento de seu potencial.

2.8.1. Modelo de um neurônio

O elemento básico que constitui as RNAs são os neurônios, caracterizados por apresentarem tipicamente o seguinte desenho estrutural da Figura 3.

Figura 3 – Modelo arquitetônico do neurônio artificial.



Fonte: Autor.

Os neurônios apresentam um conjunto de parâmetros de entrada que são processados em seu funcionamento ao serem ponderados com valores escalares associados, sinalados como peso das conexões entrantes ou sinapses, que vem sendo a informação codificada e armazenada no neurônio, que podem ser mudados com processo de aprendizagem por meio de treinamento com fatos conhecidos do ambiente (MONTAVON; ORR; MÜLLER, 2012).

No centro do neurônio ou nó artificial, apresenta uma junção somatória que interliga com adição simples a sequência de elementos de entrada que foram ponderados com os respectivos pesos de conexão assinado, cumprindo o papel de interconector linear de dados entrantes (HAYKIN, 2009). Também entre as variáveis entrantes ao neurônio está estabelecida uma entrada fixa, que pode ser de valor positivo ou negativo,

geralmente denominado como bias, a fim de que a junção somatória não seja nula quando as entradas das variáveis se anularam entre si (NEVTIPILOVA, 2014).

A Equação (1) representa num neurônio a união somatória dos valores de entradas x_p multiplicados pelos respectivos pesos de conexões w_p , além do valor fixo b .

$$f_s = \sum_{p=1}^m w_p x_p + b \quad (1)$$

Após, o valor obtido da somatória no nó (f_s), referenciada também como sinal nodal, continua adiante como fluxo de informação passando por uma equação aritmética de caráter linear ou não linear, denominada função de transferência ou de ativação que gera o resultado de saída do neurônio dentro de um intervalo finito limitado (NEVTIPILOVA, 2014). Este dado de saída produzido pode ser usado como informação de entrada para o seguinte neurônio ou tomado como valor final esperado pela rede.


Existem várias funções de ativação ($f(f_s)$) aplicáveis para o desenvolvimento de RNAs, entre as mais destacadas está a função de Limiar, Linear por partes e sigmoide. A função logística se caracteriza por suas propriedades assintóticas, não linearidade, continuidade e diferenciabilidade em todos os pontos, que as tornam adequadas para vários processos de treinamento e aprendizagem das redes. Estas funções recebem o sinal nodal e produzem a resposta do neurônio.

2.8.2. Modelos arquitetônicos de redes neurais artificiais

Conforme a configuração estrutural das ligações estabelecidas pelos neurônios e o fluxo de informação entrante nestes, são distinguidos três tipos básicos estruturais de redes neurais artificiais: as redes alimentadas adiante com camada única, as alimentadas adiante com múltiplas camadas e as recorrentes.

As redes alimentadas adiante com camada única, caracterizam-se por apresentar somente uma camada ou faixa de neurônios distribuídos paralelamente, interligados só pelo conjunto de dados de entrada (Figura 4). O ciclo de alimentação é unidirecional adiante que inicia com a entrada de dados aos nós dos neurônios e finaliza com as respectivas respostas de saída geradas pela função de transferência (HAYKIN, 2009).


Figura 4 – Rede alimentada adiante com uma única camada.



Fonte: Adaptado de Haykin (HAYKIN, 2009).

As redes alimentadas adiante com múltiplas camadas são organizadas com várias camadas de neurônios subsequentes. A última camada de neurônios proporciona os dados esperados pela rede, a qual se denomina como camada de saída, e o resto de camadas se definem como de ocultas (Figura 3). O conjunto de informações de entrada se subministra à primeira camada oculta e de forma unidirecional os transmite à camada seguinte, que pode ser de saída ou outra oculta, sendo as respostas das camadas ocultas os dados de entradas para camadas seguinte da rede. As conexões entre os neurônios são de tipo acíclico, isto é, a saída de um neurônio em determinada camada nunca seria a entrada de outro neurônio de camada anterior, passando o fluxo da informação só uma vez por cada neurônio, podendo os neurônios entre camadas estar total ou parcialmente conectados (HAYKIN, 2009).

Figura 5 – Rede multicamada alimentada adiante.



Fonte: Adaptado de Haykin(HAYKIN, 2009).

As redes neurais recorrentes podem ter uma ou várias camadas de neurônios, mas o fluxo de dados não é unidirecional, há realimentação dos neurônios onde as respostas de uma camada oculta ou de saída podem ser entradas para anteriores ou si mesmas, tendo vários ciclos de alimentação até a rede conseguir um valor estável de saída (MONTAVON; ORR; MÜLLER, 2012).

As redes com configurações de várias camadas derivam na capacidade de aprender a resolver tarefas complexas, com aptidão de extrair estatística de ordem elevada com fontes de entradas representativas do ambiente problematizado em questão que não são linearmente separáveis, ou seja, trabalha com dados com valores próximos (HAYKIN, 2009; HAGAN et al., 2014).

2.8.3. Treinamento e aprendizagem de uma rede neural artificial

A aprendizagem das RNAs é o mecanismo por meio do qual se modificam os pesos das conexões entrantes ou sinapses dos neurônios, com a finalidade de adaptá-los na resolução de problemas instituídos por meio do processo de treinamento subministrando informação do ambiente problematizado, extraindo orientações básicas a partir de dados reais seguindo técnicas pré-estabelecidas encarregadas das modificações (MONTAVON; ORR; MÜLLER, 2012; SOARES et al., 2014). A rede é provida de um conjunto de dados de entrada e também respostas desejadas correspondentes, caracteristicamente representativas do problema assinado, a fim de fazê-la capaz de resolvê-lo e generalizar sua solução para valores não introduzidos ou conhecidos.

Existe uma variedade de algoritmos que fazem esta tarefa por meio de processos iterativos com procedimentos específicos, ajustando todos os pesos da rede conforme a configuração dos neurônios. Dos distintos tipos de algoritmos, entre os mais destacáveis estão algoritmo de retropropagação do erro, o hebbiana, o baseado em memória, o de Boltzmann e o competitivo; sendo o aprendizado por retropropagação do erro o método mais utilizado.

2.8.4. Algoritmo de retropropagação do erro

O algoritmo de aprendizagem por retropropagação do erro se emprega, sobretudo, com RNAs com fluxo de alimentação adiante com únicas ou múltiplas camadas. Realizando o treinamento com um conjunto de iterações, onde cada iteração possui uma fase de propagação que inicia com a introdução dos dados na primeira camada para que sejam difundidos com fluxo adiante sem variar os pesos sinápticos das conexões, até finalizar com a determinação do sinal de erro nos neurônios da camada de saída (HAYKIN, 2009; MONTAVON; ORR; MÜLLER, 2012; HAGAN et al., 2014). Após, imediatamente começa a etapa de retropropagação, que consiste em inverter o fluxo da rede para trás pelas mesmas camadas modificando os pesos sinápticos de cada neurônio com técnicas de correção de erro, fazendo com que a resposta real gerada pela rede se aproxime da resposta desejada (HAYKIN, 2009).

O processo de aprendizagem é contínuo, parando os ciclos de iterações até que o sinal do erro da rede alcance um limiar predefinido ou após haver cumprido um número de séries estabelecido. Pelo que devem ser introduzidos padrões de entrada com sua saída desejada o suficientemente para realizar ciclos que ajustem os pesos sinápticos dos neurônios de todas as conexões, de modo que convergem e se estabilizam (HAGAN et al., 2014).

Depois de cada iteração, o ideal é que a RNA se torne mais eficiente na solução do problema proposto.

2.8.5. Generalização das redes neurais artificiais

A generalização de uma RNA se define como a capacidade adquirida de resolver tarefas de interesse para a qual foi construída com variáveis de entradas nunca antes usada no processo de aprendizagem, ou seja, a rede tem potencial de processamentos de dados não conhecidos, produzindo uma resposta satisfatória de estimação (HAYKIN, 2009; SOARES et al., 2014).

No treinamento a rede é generalizada apresentando exemplos de dados de entrada característicos do ambiente problematizado com o objetivo de capacitá-la a solucionar questões implantadas. Subsequentemente, para examinar a generalização são introduzidos dados novos que se propagam até obter a resposta estimada para ser comparado com o valor real desejado.

2.9. INVESTIGAÇÕES RELACIONADAS

Nas últimas décadas têm sido desenvolvidos vários métodos que focam na estimativa da biomassa em povoamentos florestais usando dados de sensoriamento remoto (SARKER; NICHOL, 2011; FRAZIER et al., 2014; LU et al., 2016). Considerando a biomassa florestal como o carbono acumulado nos troncos, galhos e folhas na parte acima do solo das árvores; estimado em unidades de massa, a qual pode ser convertida a volume de madeira sem casca por meio de equações alométricas (WANG et al., 2011; LÓPEZ-SERRANO et al., 2016). Por tanto, as investigações na literatura se enfatizam na estimação do peso da biomassa acima do solo com a qual se determina o volume de madeira correspondente.

Há investigações que estimaram a quantidade de biomassa no âmbito regional em ecossistemas florestais nativos e plantados, empregando bandas espectrais e derivados índices de vegetação e texturas obtidas com matriz de co-ocorrência de níveis de cinza, provenientes de sensores ópticos multiespectral (TUOMINEN; PEKKARINEN, 2005; SARKER; NICHOL, 2011; ZHU et al., 2015; PHAM; BRABYN, 2017; GHOSH; BEHERA, 2018). Os métodos baseados em regressão simples ou múltipla e aprendizagem de máquina são as principais técnicas empregadas para relacionar os dados de sensoriamento remoto com os de biomassa (LÓPEZ-SERRANO et al., 2016; LU et al., 2016).

A regressão linear se constituiu a técnica mais utilizada para estimar a biomassa florestal com informações remotas (SKOWRONSKI et al., 2014). Entretanto, o aprendizado de máquina, são métodos que se tem apresentado como alternativa útil, embora faltem aplicações e comparações que definam a técnica de maior eficiência e diretrizes apropriadas de procedimentos para seu desenvolvimento (LÓPEZ-SERRANO et al., 2016; LU et al., 2016). Dentre os mais comuns modelos de aprendizagem relatados na literatura estão as RNA, os algoritmos de floresta aleatória, máquina de vetor de suporte, K-vizinho mais próximo, Árvore de regressão e Entropia Máxima (LU et al., 2016).

No entanto, procedimentos exatos para o mapeamento temático do volume da madeira em povoamento florestal de *Eucalyptus* sp. empregando bandas espectrais juntamente com as derivadas texturas e índice de vegetação por meio da estruturação de RNA não têm sido ainda realizadas ou são desconhecidos (LÓPEZ-SERRANO et al.,

2016). Pelo que existe a necessidade do desenvolvimento de pesquisas com este abordagem para identificar seu potencial na estimativa do volume da madeira.

Especificamente, dentre as pesquisas relacionadas com esta investigação, está a realizada por Ghosh e Behera (2018), onde em floresta tropical densa na Índia foi estimada a biomassa utilizando descritores de textura e índices de vegetação obtidas de bandas espectrais das imagens digitais Sentinel 1 e 2, usando algoritmo de Floresta Aleatória e Estocástico de Aprimoramento de Gradiente no estabelecimento de relações entre parâmetros de sensoriamento remoto e valores de volume da madeira provenientes de inventário florestal feito com medidas de campo. No final, determinaram os índices de vegetação como variáveis mais eficazes para a predição da biomassa com respeito as textura, mas demonstrando-se também que uma combinação entre textura e índices de vegetação faz uma previsão melhor que separadamente, ao final os autores concluíram que informações Sentinel têm notável capacidade de predição da biomassa florestal.

Com tais características mencionadas, Pham e Brabyn (2017), com o objetivo de mapear a biomassa de floresta natural de mangue na região de Cangio no Vietnã, com imagens SPOT 4 e 5, por meio de algoritmos de floresta aleatória desenvolveram um modelo de predição que integrou bandas espectrais com diferentes tipos de descritores de textura e índices de vegetação; obtendo como resultado estimativas da biomassa consideradas apropriadas, chegando à conclusão de que dados de textura cumprem um papel menos significativos na predição do que as bandas espectrais e índices de vegetação, porém, o uso destes parâmetros conjuntamente melhora a predição em comparação com o uso de cada um de forma individual.

Outro estudo representativo de estimação espacial da biomassa foi desenvolvido por López-Serrano et al. (2016), em uma área de floresta (ocupada basicamente por árvores de pinheiros, pinhais e carvalhos com idades variadas), localizada no norte do estado de Durango no México, onde, por meio de características topográficas do terreno, bandas multiespectrais da imagem digital Landsat 5, diferentes índices de vegetação calculados a partir das bandas e descritores de textura derivados dos Índices, foram composto três modelo de predição; construído um com Algoritmo de floresta aleatória, outro com algoritmo de máquina de vetor de suporte e o terceiro com K-vizinho mais próximo, que se treinaram com dados de campo obtidos em parcelas amostrais e compararam-se com um modelo de regressão linear múltipla. Ao termino, obtiveram resultados catalogados de apropriados funcionamento com os distintos métodos, mostrando o algoritmo K-vizinho o mais alto desempenho, confirmando assim

serem ferramentas capazes de estimar a biomassa com conjuntos de dados derivados de imagem digitais, pelo que as sugeriram como alternativas viáveis de predição.

Por outro lado, modelos de regressão também foram experimentados por Zhang (2015), na estimação da biomassa florestal de árvores *Populus Euphratica* em uma região árida de Ejin Banner na China, através descritores de texturas e índices de vegetação derivados de bandas multiespectrais de imagem digital do satélite GaoFen-1, que foram relacionados com dados de biomassa inventariado a partir de medições de campo. As regressões desenvolvidas demonstraram que os índices de vegetação e as texturas, em cenários separados não são tão eficientemente significativos para estimar a biomassa em comparação com a precisão conseguida ao serem integrados conjuntamente.

Também, Sarker e Nichol (2011), aplicaram modelos de regressão linear simples e múltipla para prever a biomassa com dados de bandas espectrais e respectivos descritores de textura e índices de vegetação derivados de imagens digitais do satélite ALOS, em floresta plantada subtropical em Hong Kong na China; conseguindo demonstrar que as relações de banda espectrais simples com índices de vegetação têm melhor desempenho que utilizando as bandas espectrais unicamente, e ainda com eficácia maior quando incluídos os descritores de textura das respectivas bandas espectrais.

Por sua vez, tem-se aplicado método de RNA multicamadas com algoritmo de retropropagação de erro sobre floresta de mangue localizada no estuário do Rio das Pérolas na província de Guangdong da China, para a previsão da biomassa, empregando-se como variáveis de entradas bandas espectrais e índices de vegetação provenientes de imagem digital do satélite Worldview-2; conseguindo-se no estudo demonstrar que existe um grande potencial para o mapeamento da distribuição espacial da biomassa de mangues em escalas regionais, porém, estabelecendo-se que ainda são necessários outros estudos detalhados para melhoria a precisão da estimativa com informações de sensoriamento remoto (ZHU et al., 2015).

Com metodologia semelhante à do estudo anteriormente mencionado, em floresta tropical no nordeste de Bornéu na Malásia, foi desenvolvida uma RNA multicamada para estimar e mapear a biomassa utilizando como variáveis de entrada as bandas espectrais provenientes da imagem Landsat TM e derivados índices de vegetação; concluindo, principalmente, que o sensoriamento remoto tem um potencial considerável para estudos florestais, embora as abordagens baseadas em redes neurais

não sejam isentas de problemas, pelo que sugeriram que se deveriam realizar mais investigações a respeito para refinar os métodos e estender as análises para outros locais diferentes (FOODY et al., 2001).

Desenvolvimento de RNA multicamadas, mas sem considerar dados de sensoriamento remoto, também foi realizado por Vahedi (2016), na floresta natural de faia no norte do Irã, por meio de um estudo que teve como objetivo avaliar precisão de um modelo de RNA na estimativa da biomassa com respeito a método tradicional de equações alométricas construídas com análise de regressão, utilizando como variáveis de entrada na rede as medidas da altura, diâmetro e densidade básica de 174 árvores amostrados da floresta. Os resultados mostraram que a RNA forneceu estimativa mais precisa para a biomassa com referência às equações alométricas, chegando assim à conclusão de que as redes subentendem melhor as relações complexas existentes entre as dimensões dendrométricas das árvores.

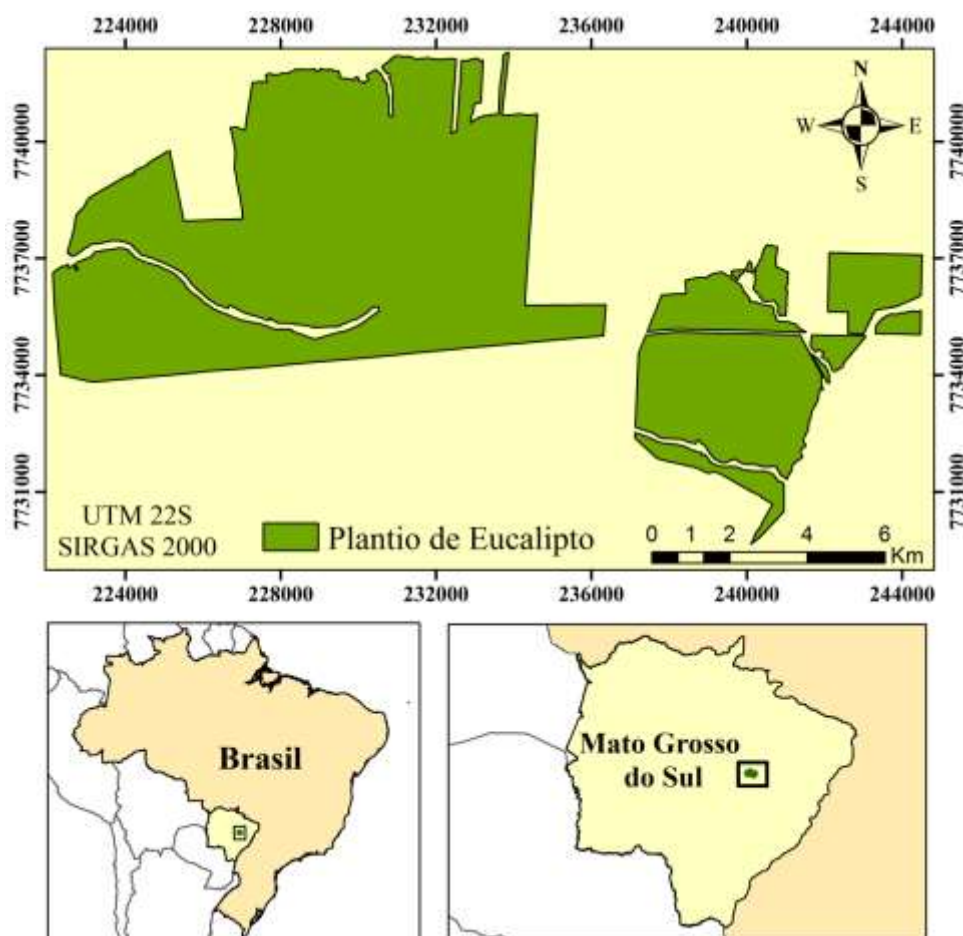
Além de todas as investigações mencionadas, existe uma série de estudos que aplicam fundamentalmente modelos de regressão lineal empregando como variáveis índices de vegetação e descritores de texturas derivados de bandas espectrais procedentes imagens RapidEye, SPOT, Landsat 5 e 8, com o objetivo de classificar a cobertura vegetal de ecossistemas naturais, determinar a riqueza de espécies vegetais, estimar tamanho e altura do dossel das árvores; logrando predições que ficam como referência para as ampliações sobre pesquisa na estimativa espacial de características da floresta com o uso de informações de sensoriamento remoto (TUOMINEN; PEKKARINEN, 2005; RODRIGUEZ-GALIANO et al., 2012; CABEZAS; GALLEGUILLOS; PEREZ-QUEZADA, 2016; OZKAN et al., 2017; ZHANG et al., 2018).

3. MATERIAL E MÉTODOS

3.1. ÁREA DE ESTUDO

A área de estudo foi um plantio de *Eucalyptus* sp., localizado no município de Ribas do Rio Pardo, no Leste do estado de Mato Grosso do Sul, posicionado na região Centro-Oeste do Brasil (Figura 6).

Figura 6 – Localização da área de estudo.



Fonte: Autor.

Apresenta uma extensão de 9.431,21 ha ocupada com plantações de diferentes idades, pertencente à Bacia Hidrográfica do Paraná, sub-bacia do Rio Pardo e Rio Verde. O clima é caracterizado como tropical com estação seca no inverno e chuvosa no verão, Aw de acordo com a classificação climática de Köppen-Geiger; a zona tem uma cota de altitude média de 374 metros e o relevo se constitui, basicamente, de extensão

plana, mas tem alguns pequenos ressaltos topográficos com declividades suaves (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE), 2016).

3.2. DADOS DE CAMPO

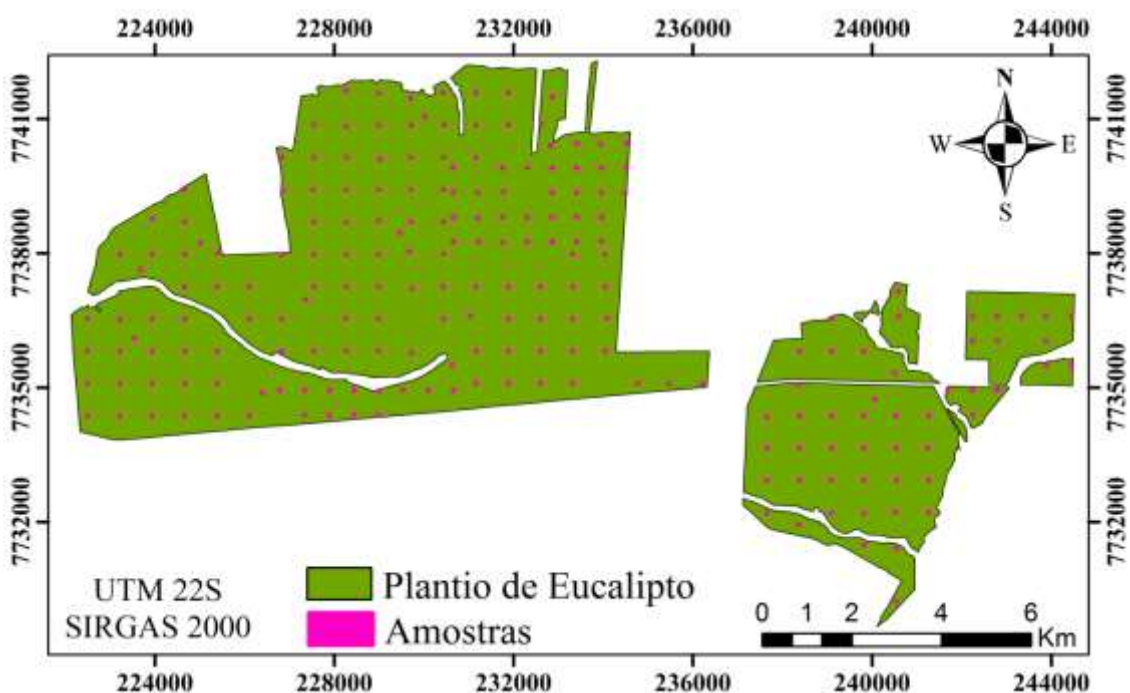
Adotaram-se para a pesquisa informações relativas à idade do plantio e o correspondente volume de madeira sem casca, obtidas de um inventário florestal realizado na área de estudo entre os dias 20 e 29 de agosto de 2015.

O volume foi estimado usando os modelos alométricos baseados em medidas de diâmetro na altura do peito (1,3m) e a altura da árvore, provenientes de 210 unidades amostrais circulares de 500m² distribuídas de forma sistemática no povoamento. As amostras se constituíram com 60 plantas, tendo espaçamento padrão de 3,0m x 3,0m, para um total mensurado de 12600 árvores.

O inventário foi realizado na época de inverno, período de estiagem com as menores precipitações do ano que gera escassez de água para a floresta e baixa umidade no solo.

A distribuição e georreferenciamento das unidades amostrais no plantio podem ser observadas na Figura 7.

Figura 7 – Distribuição de unidades amostras no povoamento florestal.



Fonte: Autor.

3.3. IMAGEM DE SATÉLITE

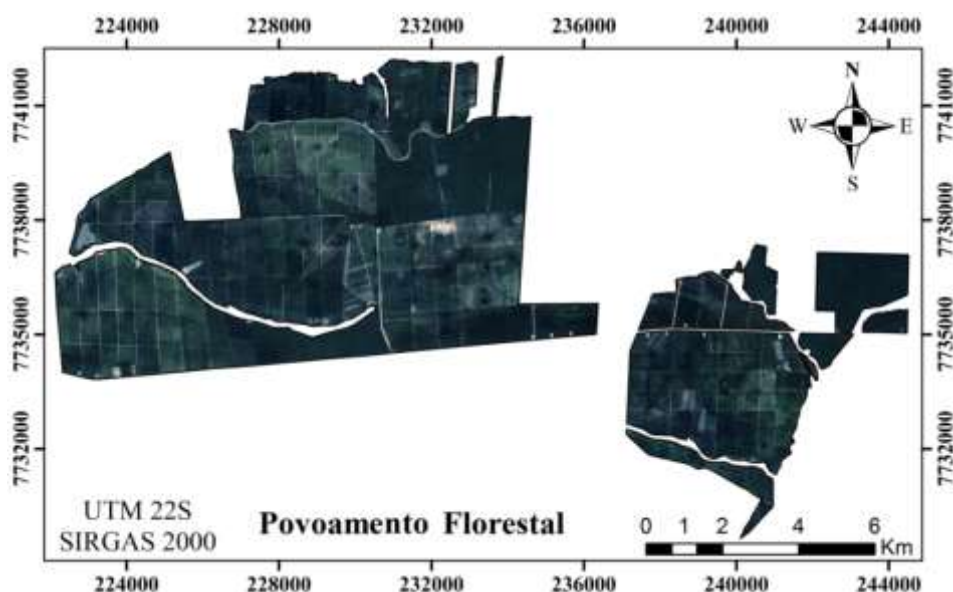
Foi utilizada uma imagem digital do satélite Spot 6 que representa espacialmente a área de estudo, capturada na época de tempo em que foi realizado o inventário florestal utilizado, pelo que são dados temporalmente coincidentes para a data de agosto de 2015. Assim, o povoamento de *Eucalyptus* sp. está representado espacialmente com técnica de sensoriamento remoto com as correspondentes características espectrais quando realizadas as medidas nas unidades amostrais do inventariado.

A imagem apresenta bandas espectrais na faixa do azul (Banda 1), verde (Banda 2), vermelho (Banda 3) e infravermelho próximo (Banda 4); com uma resolução espacial de 1,5m por estar combinada com a banda pancromática de alta resolução da mesma.

A imagem está livre de ruídos decorrentes de erros instrumentais do sensor receptor e no momento da captura as condições meteorológicas foram de céu claro, com mínima interferência da atmosfera no fluxo de radiação solar incidente, absorvida e refletida pela cobertura terrestre.

Na Figura 8 apresenta-se a imagem Spot 6 na cor natural da área de estudo, gerada pela composição RGB com as bandas 1, 2 e 3 correspondentes ao comprimento de onda vermelho, verde e azul do espectro visível, com resolução de 1,5m.

Figura 8 – Representação a cor natural do povoamento florestal com Imagem Spot 6.



Fonte: Autor.

3.3.1. Pré-processamento da imagem digital

As bandas da imagem digital foram adequadas ao sistema de projeção geográfica UTM 23S com Datum SIRGAS 2000, similarmente com o projetado para o inventário florestal, assim poder localizar na imagem a posição das áreas amostradas.

Também a imagem foi redimensionadas a uma resolução radiométrica de 8 bits que apresenta 256 níveis digitais (no intervalo de valores de 0 a 255). Foram feita correção atmosférica com dados de calibração registrada pelo satélite em órbita.

A Projeção e transformação radiométrica foram feitos através do programa Qgis (QGIS DEVELOPMENT TEAM, 2018).

3.4. CÁLCULO DOS DESCRITORES DE TEXTURA

O cálculo dos descritores de textura foi realizado por meio da Matriz de Co-ocorrência (GLMC) derivada de pequenas seções ou janelas quadradas de 3x3 pixels, que se deslocam até cobrir toda a cena de cada uma das bandas da imagem digital, onde se contabilizou a ocorrência de valor entre pixels vizinho, tendo em consideração todas as direções (0°, 45°, 90° e 135°) combinadas de uma vez. Este tamanho de janela definido consegue caracterizar de maneira ótima condições semelhantes de níveis de cinza entre pixels vizinhos onde as diferenças espectrais entre as classes são pequenas (SARKER; NICHOL, 2011; YOUSSEF et al., 2017).

Assim, os descritores de textura estudados foram gerados quantitativamente relacionando os elementos $p(i,j)$ posicionados nas i linhas e j colunas da matrizes de co-ocorrência de níveis de cinza $GLCM$ (Figura 2), com as formulações estatísticas (2) até a (10) (HARALICK, 1979; HAROLD; LIU; CLARK, 2003; ZHANG et al., 2017).

$$ASM = \sum_i^N \sum_j^N p(i,j)^2 \quad (2)$$

$$IDM = \sum_i^N \sum_j^N \frac{p(i,j)}{1 + (i-j)^2} \quad (3)$$

$$CON = \sum_i^N \sum_j^N (i-j)^2 p(i,j) \quad (4)$$

$$COR = \sum_i^N \sum_j^N \frac{(ij)p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (5)$$

$$ENT = - \sum_i^N \sum_j^N p(i,j) \log[p(i,j)] \quad (6)$$

$$VAR = \sum_i^N \sum_j^N \left(i - \sum_i^N \sum_j^N ip(i,j) \right)^2 p(i,j) \quad (7)$$

$$SA = \sum_{k=2}^{2N} kp_{x+y}(k) \quad (8)$$

$$SV = \sum_{k=2}^{2N} p_{x+y}(k) \left(k - \sum_{k=2}^{2N} kp_{x+y}(k) \right)^2 \quad (9)$$

$$SE = - \sum_{k=2}^{2N} p_{x+y}(k) \log[p_{x+y}(k)] \quad (10)$$

Sendo, N o número total de colunas e linhas da GLCM conforme a quantidade de níveis de cinza da imagem.

Os símbolos μ_x e μ_y correspondem aos valores médios das linhas e colunas da GLCM, respectivamente:

$$\mu_x = \sum_{i=1}^N \sum_{j=1}^N (i)p(i,j) \quad (11)$$

$$\mu_y = \sum_{i=1}^N \sum_{j=1}^N (j)p(i, j) \quad (12)$$

Os símbolos σ_x e σ_y representam os desvios-padrão das filas e colunas da matriz, determinadas conforme as médias μ_x e μ_y :

$$\sigma_x^2 = \sum_{i=1}^N \sum_{j=1}^N p(i, j)(i - \mu_x)^2 \quad (13)$$

$$\sigma_y^2 = \sum_{i=1}^N \sum_{j=1}^N p(i, j)(j - \mu_y)^2 \quad (14)$$

E $p_{x+y}(i)$ é a soma da distribuição do nível de cinza adjacentes da imagem (Equação 15).

$$p_{x+y}(k) = \sum_{i=1}^N \sum_{j=1}^N p(i, j) \quad k = 2, 3, \dots, 2N \quad (15)$$

Este processamento aritmético foi realizado com o software Grass GIS 7.0.5 (GRASS DEVELOPMENT TEAM, 2018). Gerou-se um total de 36 imagens de texturas, 9 por cada banda, conforme os diferentes descritores.

3.5. CÁLCULO DE ÍNDICES DE VEGETAÇÃO

O índice RVI foi determinado pela razão das bandas espectrais do infravermelho próximo com a do vermelho, representado para imagem Spot 6 com a equação (16) de Pearson e Miller (1972).

$$RVI = \frac{b_4}{b_3} \quad (16)$$

Sendo b_4 os níveis digitais registrados nos pixels da banda 4, representativos do espectro do infravermelho próximo; e b_3 são os níveis digitais da banda 3 que vem do espectro eletromagnético vermelho do visível.

O DVI, proposto por Richardson e Wiegand (1977), resultou da subtração da refletância do infravermelho próximo com a do vermelho mediante as bandas b_4 e b_3 , respectivamente, como esta na equação (17).

$$DVI = b_4 - b_3 \quad (17)$$

O cálculo do NDVI se obteve pela divisão entre a diferença dos níveis digitais dos pixels da banda 4 e os níveis digitais de cada pixel da banda 3 e a soma das mesmas, conforme a equação (18) formulada por Rouse et al. (1974).

$$NDVI = \frac{b_4 - b_3}{b_4 + b_3} \quad (18)$$

O GNDVI foi determinado com igual formulação matemática que o NDVI, mas trocando a banda b_3 do espectro infravermelho próximo pela banda b_2 , como está na equação (19)(ALBA et al., 2017).

$$GNDVI = \frac{b_4 - b_2}{b_4 + b_2} \quad (19)$$

Sendo b_2 os níveis digitais registrados nos pixels da banda 2, representativos da faixa verde do espectro eletromagnético pertencente do visível.

Por sua vez, o índice ARVI que integra as faixas do infravermelho próximo, vermelho e azul do espectro eletromagnético, efetuou-se com as bandas 4, 3 e 1, como se evidencia na equação empírica (20) (KAUFMAN; TANRÉ, 1992):

$$ARVI = \frac{b_4 + \gamma(b_1 - b_3) - b_3}{b_4 - \gamma(b_1 - b_3) + b_3} \quad (20)$$

Sendo, γ é um fator de autocorreção atmosférica, que normalmente se define com um valor de 1 para sua aplicação (GALVAO; FORMAGGIO; BREUNIG, 2009; ALBA et

al., 2017); e b_1 são os respectivos níveis digitais registrado nos pixels da banda 1, proveniente da faixa azul do espectro eletromagnético pertencente do visível.

No que concerne ao índice de vegetação ajustado ao solo (SAVI), executou-se com as bandas 4 (b_4) e 3 (b_3) de acordo com o estabelecido por Huete (1988) na equação (21).

$$SAVI = \frac{(1+L)(b_4-b_3)}{L+b_4+b_3} \quad (21)$$

Sendo L o fator de correção para SAVI que minimiza o efeito de refletância do solo.

O fator de correção (L) para SAVI varia conforme a condição da cobertura vegetal no solo, sendo para superfícies com solo exposto ou escassa vegetação o valor estipulado em 1, as superfícies com coberturas média da vegetação com 0,5 e completamente cobertas com vegetação o valor estipulado em 0,25 (HUETE, 1988; PAVÃO et al., 2015; HENRIQUE et al., 2018).

O índice EVI, definido por Huete et al. (2002), foi construído com a operação aritmética das faixas do espectro infravermelho próximo, vermelho e azul, o qual foi calculado com os respectivos níveis digitais registrados nos pixels das bandas 4, 3 e 1; também adiciona o fator L de ajuste para o solo igualmente ao SAVI e coeficientes de correção atmosféricos, como se visualiza na equação (22).

$$EVI = G \left(\frac{b_4-b_3}{b_4+C_1(b_3)-C_2(b_1)+L} \right) \quad (22)$$

Onde, C_1 e C_2 são coeficientes de correção atmosférica para as respectivas bandas do azul e o infravermelho próximo, definido comumente com os correspondentes valores escalares de 7,5 e 6; e o G é um fator de ganho estabelecido com valor constante de 2,5 (BAYMA; SANO, 2015).

O processamento aritmético para o cálculo dos índices foi feito no software Qgis 7.0.5, obtendo-se as respectivas representações espaciais.

3.6. DEFINIÇÃO DE VARIÁVEIS DE ENTRADA À RNA

Os dados de entradas à RNA foram definidos em sua maioria derivados da imagem digital, assim, estabeleceu-se como variáveis a média aritmética representativa

dos valores nos pixels das bandas espectrais, derivadas texturas e os correspondentes índices de vegetação fixados dentro do contorno georreferenciado das 210 amostras do inventário florestal.

Considerando que o processamento de RNA pode ser complicado de desenvolver, estando sujeito principalmente ao número de variáveis dependentes introduzidas e a correlação destas com a variável estimada (CZYZOWSKA-WISNIEWSKI et al., 2015); tendo em vista que há variedade de bandas, índices de vegetação e tipos de texturas que poderiam servir como entrada na construção da RNA, para aperfeiçoar seu desenvolvimento, pode-se diminuir a dimensionalidade do número de estimadores com análises de correlação conforme ao método de Spearman, na procura de selecionar os dados que tenham melhor relação com o volume de madeira, especificando as variáveis características preditivas (SARKER; NICHOL, 2011; LU et al., 2012; GREGORUTTI; MICHEL; SAINT-PIERRE, 2015).

A técnica de correlação de Spearman escolheu-se como diretriz para reduzir a dimensão dos dados, na medida em que não se têm claramente definidos outros métodos para determinar a potencialidade de dados de sensoriamento remoto na modelagem de parâmetros de povoamentos florestais (LU, 2006; SARKER; NICHOL, 2011; CHEN et al., 2016). Sendo um método eficiente de correlação de dados de fenômenos naturais com distribuição não normal (SAMIRBHAI; CHEN; LOW, 2018).

O volume de madeira sem casca do povoamento de *Eucalyptus* sp. foi obtido do inventário em metros cúbicos por parcela, sendo dimensionado a valor médio por pixel em cada unidade amostral, efetuando a média aritmética dos valores, para ser usado como resultado desejado durante o treinamento da RNA.

Dos dados obtidos pelo inventário, além do volume, utilizou-se a idade do plantio como fonte de alimentação da rede. Sendo deste modo, pouco dependente de informação gerada com a mensuração direta em campo que precisa de investimentos e de tempo para ser realizado e geralmente são onerosos por demandar pessoal treinado com equipamentos especiais e transportes destes para tal fim.

Enfim, contou-se com um total de 48 possíveis variáveis de entrada de caráter quantitativo (36 textura, 7 índices, 4 bandas espectrais e a idade do plantio), que são associadas às 210 unidades amostrais do inventário. Após, as parcelas com os concernentes dados de cada variável foram distribuídas em dois grupos de 126 (60%) e 84 (40%) unidades, designados correspondentemente para o treinamento e avaliação da generalização da rede, agrupados de tal maneira que o volume ficasse amplamente

representado nas duas porcentagens conforme a dispersão dos valores de volume de madeira presentes no inventário, que se analisaram por meio de histograma de frequência no programa R (R DEVELOPMENT CORE TEAM, 2018).

3.6.1 Cálculo de correlação das variáveis de entrada e saída desejada

Nas bandas espectrais da imagem digital e nas respectivas representações espaciais de textura e índices de vegetação calculados, as 210 unidades amostrais do inventário florestal foram identificadas, conforme o seu georreferenciamento, com o propósito de que estas fossem delimitadas e posteriormente isoladas ao ser recortadas com polígonos circulares de 500m², gerados com raios de 12,62 m desde o centro de cada amostra. Sequencialmente, foi achado o valor da média aritmética representativo dos pixels de cada amostra, a fim de serem correlacionadas com o respectivo volume estimado no inventario com as medições de campo, por meio do coeficiente de Spearman.

Adicionalmente, foram feitos gráficos de dispersão para analisar a distribuição dos dados.

O coeficiente de correlação de Spearman para conjuntos de dados de tamanho amostral N de duas variáveis, pode ser calculado com a equação (23) (SIEGEL; JUNIOR., 2006):

$$r = \frac{\sum_{i=1}^N (x_i - \bar{x})^2 + \sum_{i=1}^N (y_i - \bar{y})^2 - \sum_{i=1}^N (x_i - y_i)^2}{2 \sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}} \quad (23)$$

Sendo, x_i e y_i os postos das medições correspondentes das variáveis x e y ; e \bar{x} e \bar{y} os respectivos valores médios de ambas variáveis.

Os postos para cada medida das variáveis x e y são resultantes de um ordenamento numérico desde o menor valor que recebe o posto 1, o segundo menor recebe o 2, e assim sucessivamente até o posto N .

3.6.2. Escalonamento das variáveis de entrada e saída desejadas

As variáveis de entrada e saída desejadas, antes de serem introduzidas para o treinamento e generalização da RNA, foram escalonadas para valores restritos ao intervalo limite da função de ativação escolhida. Isto faz com que os processamentos dos dados na rede sejam feitos com maior eficiência (MONTAVON; ORR; MÜLLER, 2012).

Entre as diferentes formas de escalonamento foi escolhida, por sua simplicidade, a técnica de Mínima-máxima Escala (Equação 24). Com esta, para cada variável definida (x), a normalização efetuou-se subtraindo o valor mínimo (x_{min}) do conjunto total de dados ao qual pertencesse e, subsequentemente, dividindo-o pela magnitude resultante da subtração do mínimo (x_{min}) ao máximo valor escalar (x_{max}) dos dados (ZHANG; LI; WANG, 2014; PATTERSON; GIBSON, 2017):

$$z = \left(\frac{x - x_{min}}{x_{max} - x_{min}} \right) \quad (24)$$

Sendo Z o valor resultante da variável x escalonada.

Ao final do processamento da rede o valor real gerado resulta alocado dentro do intervalo escalonado, pelo que o processo foi invertido para que a resposta estimada volte à unidade do formato expandido original.

3.7. ARQUITETURA DA RNA

Para a arquitetura de uma RNA não existe regulamento ou fatores restritos condicionantes que definam o número de camadas e neurônios que se devem ter, nem como se devem interligar. Em muitos casos a definição da estrutura é um processo de tentativa e verificação de erro, conforme o conhecimento do problema a resolver, usando diferentes alterações dos pesos iniciais dos neurônios e a quantidade de camada, mediante o (HAGAN et al., 2014).

O ambiente computacional para o treinamento e posterior verificação da generalização da RNA foi o *software R* (R DEVELOPMENT CORE TEAM, 2018); programa escolhido por ser gratuito e proporcionar um ambiente capaz, eficiente e flexível para implementação do processamento neural proposto.

3.7.1. Camadas e neurônios da RNA

O tipo básico estrutural da rede definido foi o de multicamada com fluxo de alimentação adiante e interconexões totais acíclicas entre os neurônios. Configuração que deriva de um poder sistemático de aprender a resolver tarefas complicadas com o algoritmo de retropropagação de erro no treinamento (HAYKIN, 2009).

A configuração de múltiplas camadas nas RNA faz aumentar em teoria seu potencial, mas também faz dificultar o treinamento devido ao fato de haver um espaço muito maior de possíveis conexões sinápticas que precisam de maior tempo de processamento, podendo tornar o treinamento e avaliação muito complexos (HAGAN et al., 2014; NEVTIPILOVA et al., 2014; SOARES et al., 2014). Razão pela qual o número de camadas deve ser minimamente reduzido para que a aprendizagem seja eficientemente aceitável sem ser excessivamente arquitetada.

Portanto, de forma prática, definiu-se uma configuração com duas camadas ocultas e uma de saída, considerando-se que mais camada pode torna o treinamento excessivamente complexo.

Para a camada de saída foi estabelecido um neurônio, que combina as respostas produzidas pela última camada oculta para calcular a resposta estimada de volume de madeira.

Para a primeira e segunda camada oculta os neurônios foram estabelecidos testando diferentes combinações possíveis, intentando com quantidades de 1 a 30 neurônios por camadas, resultando em total 900 redes estruturas que foram treinadas e avaliadas. Alguma de estas configurações deve ter o número ótimo de neurônios, que capacite a rede a ter a flexibilidade de ajustar num adequado aprendizagem com dados de entrada não linear com respeito à variável estimada, atingindo uma significativa capacidade de generalização sem tornar complexo o treinamento.

Assim, foram experimentadas redes com diferentes configurações, verificando tendências de resultados para escolher o número de camadas que proporcione o menor erro quadrático, ao ser analisado o desempenho com amostras de validação, achando a melhor estrutura que se ajuste à solução do problema.

3.7.2. Função de ativação dos neurônios

A função de ativação escolhida para o desenvolvimento da rede foi a sigmoide logística, representada na equação (25), sendo a comumente usada nos desenhos de redes por ter fácil diferenciabilidade (Equação 26), que torna viável a aplicação de vários métodos de aprendizagem, como o Algoritmo de retropropagação de erro.

$$f(f_s) = \frac{1}{1+e^{-f_s}} \quad (25)$$

$$f'(f_s) = f_s(1 - f_s) \quad (26)$$

Esta função de ativação tem como retorno o sinal de saída y dos neurônios (Equação 27).

$$y = f(f_s) \quad (27)$$

3.7.3. Processo de treinamento e aprendizagem

A rede foi treinada por meio do Algoritmo de retropropagação do erro ou Back-Propagation (Equações 28 até a 38), conforme o estabelecido por Haykin (2009) e Hagan et al. (2014); sendo a forma mais utilizada no desenho de redes neurais por sua eficiência na resolução de problemas não linearmente separáveis. Com este método, a camada de saída, representada como n_I (Figura 9), num ciclo de iteração t , modifica os pesos sinápticos ($w_{nI}(t)$) do neurônio aplicando-lhe o ajuste ($\Delta w_{nI}(t)$) para gerar novos pesos corrigidos ($w_{nI}(t+1)$):

$$w_{nI}(t + 1) = w_{nI}(t) + \Delta w_{nI}(t) \quad (28)$$

Os valores dos pesos sinápticos iniciais ($w_{nI}(t)$) para a arquitetura predefinida foram adotados de forma aleatória pelo programa *R* (R DEVELOPMENT CORE TEAM, 2018).

A correção $\Delta w_{n1}(t)$ foi dada com a taxa de aprendizagem (η) do algoritmo, o gradiente local de saída (δ_{n1}) e a resposta real produzida pela rede (y_{n1}):


$$\Delta w_{n1}(t) = \eta y_{n1} \delta_{n1} \quad (29)$$

Sendo η um valor escalar de 0,01 para cada iteração t .

O gradiente local δ_{n1} para o neurônio de saída foi obtido simplesmente multiplicando o sinal de erro do mesmo com a corresponde derivada da função de ativação associada do neurônio (f'), como amostra na equação (30).

$$\delta_{n1} = e_{n1} f'(f_{s1}) \quad (30)$$

Figura 9– Esquematização geral da rede neural artificial.



Fonte: Adaptado de Haykin(2009).

Deste modo, o ajuste dos pesos sinápticos do neurônio realizou-se diretamente por meio do erro de saída real (e_{n1}), que foi calculado pela subtração da resposta desejada conhecida do ambiente e a resposta gerada (Equação 31).

$$e_{n1} = y_{n1} - d_{n1} \quad (31)$$

Onde, y_{n1} e d_{n1} se referem à correspondente resposta estimada produzida e desejada do neurônio da respectiva camada de saída. A resposta desejada d_{n1} são os volumes de madeira representativos por parcela que foram inventariados.

A resposta estimada produzida y_{n1} foi obtida com a função de ativação que processa a junção soma (f_{s1}) do neurônio de saída $n1$, determinada pela somatória do número de entradas (x_{n1}) ponderado com os respectivos pesos da iteração t ($w_{n1}(t)$):

$$y_{n1} = f(f_{s1}(t)) = f\left(\sum x_{n1}(t)w_{n1}(t)\right) \quad (32)$$

Diferentemente da camada de saída, para as camadas ocultas das redes os pesos dos neurônios foram ajustados em função do sinal do erro dos neurônios da camada seguinte aos quais se conectam (MONTAVON; ORR; MÜLLER, 2012). Assim, para a camada oculta $n2$ antecedida da camada de saída $n1$ (Figura 9), os pesos $w_{n2}(t)$ associados dos neurônios foram modificados com o ajuste $\Delta w_{n2}(t)$ (HAGAN et al., 2014; NEVTIPILOVA et al., 2014; SOARES et al., 2014):

$$w_{n2}(t + 1) = w_{n2}(t) + \Delta w_{n2}(t) \quad (33)$$

O ajuste $\Delta w_{n2}(t)$ foi calculado com a taxa de aprendizagem do algoritmo (η), o respectivo gradiente local dos neurônios de saída (δ_{n2}) e a resposta real produzida (y_{n2}):

$$\Delta w_{n2}(t) = \eta y_{n2} \delta_{n2} \quad (34)$$

O gradiente local dos neurônios da camada oculta $n2$ foi determinado com a somatória do gradiente local do neurônio da camada de saída (Equação 35).

$$\delta_{n2}(t) = f'(f_{s2}) \sum_{n1 \in C} \delta_{n1} w_{n1}(t) \quad (35)$$

Onde C representa o conjunto que inclui todos os neurônios da camada de saída $n1$ conectados diretamente com os neurônios que se encontram na camada $n2$ e $w_{n1}(t)$ são os respectivos pesos relacionados.

Assim, para outras prováveis camadas ocultas antecedentes a $n2$, o ajuste dos pesos também pode ser realizado subsequentemente em função do sinal do erro dos neurônios das camadas seguintes às quais antecede.

Portanto, para qualquer camada nm resultante anterior a $n2$, o ajuste dos pesos seria:

$$w_{nm}(t + 1) = w_{nm}(t) + \Delta w_{nm}(t) \quad (36)$$

Determinando-se a correção $\Delta w_{nm}(t)$ com a taxa de aprendizagem do algoritmo (η), os respectivos gradientes locais dos neurônios de saída δ_{nm} e a resposta real produzida na camada de saída (y_{nm}):

$$\Delta w_{nm}(t) = \eta y_{nm} \delta_{nm} \quad (37)$$

Sendo o gradiente local δ_{nm} dos neurônios das camadas ocultas determinados igualmente com a somatória do gradiente local dos neurônios da camada posterior às quais antecede, como se visualiza na equação (38):

$$\delta_{nm} = f'(f_{sm}) \left(\sum_{nm \in C} f'(f_{sm}) w_{nm}(t) \left(\dots \sum_{n3 \in C} f'(f_{s3}) w_{n3}(t) \left(\sum_{n2 \in C} f'(f_{s2}) w_{n2}(t) \left(\sum_{n1 \in C} \delta_{n1} w_{n1}(t) \right) \right) \right) \right)$$

O processo de treinamento foi efetuado usando o pacote *neuralnet* (FRITSCH; GUENTHER, 2018) do software *R*, que integra o algoritmo. As iterações foram efetuadas até ser alcançado um limar menor ou igual a 0,05 na mudança da resposta estimada, funcionando como critério de parada para a duração da aprendizagem.

3.8. AVALIAÇÃO DA RNA

Seguido do treinamento e aprendizagem, às redes estruturadas foram testadas, avaliando a capacidade de generalização, ou seja, sua habilidade de estimação com a introdução de dados desconhecido. Isto foi feito, no *software R* usando a função *compute* (FRITSCH; GUENTHER, 2018), com dados fontes que não foram previamente utilizados no treinamento.

Do total de dados de cada variável, utilizou-se 84 valores não empregados no treinamento para serem processadas pelas redes e, posteriormente, as respostas de volume estimado foram avaliadas com as correspondentes do inventário florestal mediante o cálculo de Erro Quadrático Médio (RMSE) e o coeficiente de correlação de Pearson (r).

O RMSE foi calculado coma soma dos quadrados das diferenças entre os resultados preditos pela RNA e o valor inventariado, ponderado pelo número de termos avaliados (CZYZOWSKA-WISNIEWSKI et al., 2015):

$$RMSE = \left(\frac{1}{N} \sum_{d=1}^N (x_i - y_i)^2 \right)^{1/2} \quad (39)$$

Equivalendo, y_i ao volume de madeira inventariado; x_i o valor correspondente de volume estimado pela RNA; e N é o número de unidades de dados avaliados.

Ao ponderar o RMSE pelo valor médio do volume das parcelas avaliadas, é determinado o Erro Quadrático Médio Relativo (RMSEr), que varia de 0 a 1 e pode ser expresso em porcentagem.

Quanto mais próximo de zero a valor do RMSE, maior é a confiabilidade das estimativas fornecidas pela rede treinada.

O coeficiente de correlação de Pearson permitiu medir o grau de relacionamento linear entre o valor do inventário com o estimado mediante a equação (CZYZOWSKA-WISNIEWSKI et al., 2015; FAVERO; FÁVERO, 2015):

$$r = \frac{\sum_{i=1}^N \frac{(x_i - \bar{x})(y_i - \bar{y})}{N-1}}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}} \quad (40)$$

Sendo, \bar{x} e \bar{y} os valores médios correspondente dos dados de volume estimado pela rede e do inventário das parcelas escolhidas para o teste.

O coeficiente de correlação pode variar de -1 a $+1$. Coeficiente com valores próximos de $+1$ ou -1 indica correlação significativa, pela aproximação no valor das duas variáveis.

Continuamente, com o coeficiente de Pearson foi calculado o coeficiente de determinação, que é definido como elevação ao quadrado do coeficiente de Pearson, (PHAM; BRABYN, 2017). O coeficiente de determinação varia de 0 a 1.

Também foi determinado o valor de acurácia ou precisão da estimativa da RNA desenhada, isto é, a capacidade ou grau de concordância entre o valor médio total do volume estimado com o inventariado, o qual se consegue com a equação (41) (ZHANG; CHENG; LI, 2015):

$$A = \left[1 - \frac{1}{N} \sum_{d=1}^N \left(\frac{x_i - y_i}{y_i} \right) \right] * 100\% \quad (41)$$

O intervalo de valores da precisão vai desde zero até cem; sendo entre mais aproximado de cem, a rede tem melhor capacidade de acertar na estimativa do valor calculado no inventario.

A RNA com menor RMSE, maior coeficiente de correlação de Pearson e precisão, foi escolhida como o melhor modelo de aproximação volumétrica da madeira do povoamento florestal.

Além, realizaram-se análises gráficas de dispersão dos erros residuais, gráfica quantil-quantil para avaliar tendência dos erros e gráfica de comparação de valores estimados pela rede com respeito os inventariados.

3.9. REPRESENTAÇÃO ESPACIAL DO VOLUME DE MADEIRA

À resultante RNA, treinada e avaliada, foram introduzidas as respectivas bandas espectrais, índices de vegetação e descritores texturais de toda a área da plantação florestal, previamente escalonadas, para serem geoprocessadas na elaboração do mapa temático que apresenta a variação classificada do volume de madeira em unidades de metros cúbicos por hectare. Processo que foi efetuado no programa R (FRITSCH; GUENTHER, 2018) ou em algum sistema de informação geográfica.

4. RESULTADOS E DISCUSSÃO

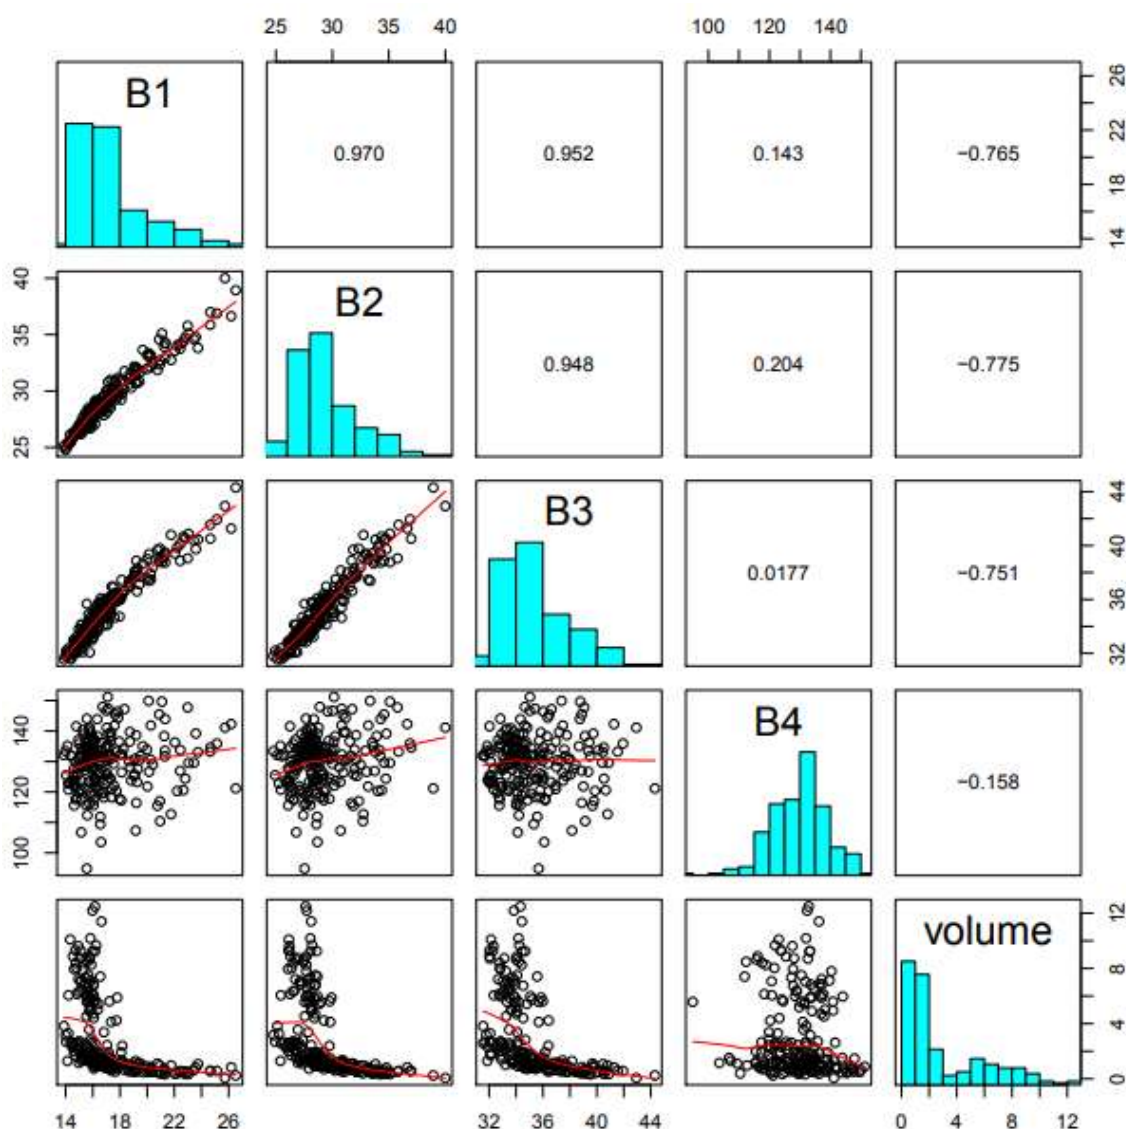
4.1. ANÁLISES DE CORRELAÇÃO

Os valores dos níveis digitais das bandas espectrais da imagem digital, o coeficiente de correlação de Spearman e o gráfico de dispersão dos dados das 210 unidades amostrais do plantio definidos no inventário florestal, podem ser visualizados na matriz de correlação da Figura 10 que apresentam a distribuição dos valores das amostras de forma gráfica, onde se verifica que as bandas B1, B2 e B3 (Que registram comprimentos de onda na faixa do azul, verde e vermelho do espectro eletromagnético), apresentam forte relação linear diretamente proporcional entre elas, isto é, estão associadas na mesma direção de crescimento de magnitude. Com relação ao volume médio (m^3) por parcela, estas bandas exibem uma correlação significativa, exibindo aproximadamente o mesmo coeficiente de dependência (entorno a -0,76), mas sendo correlacionadas com distribuições exponenciais estritamente decrescentes, ou seja, na medida em que diminuem os valores espectrais inversamente aumentaria o volume da madeira. Em contrapartida, na mesma Figura 10, a banda B4 (Infravermelha próxima) não apresenta correlação com as outras bandas nem com o volume, exibindo uma distribuição de dados aglomerados sem tendência definida.

Pela correlação de valores resultantes, a B4 claramente não detecta variação de volume de madeira, por ser o comprimento de radiação infravermelho altamente refletido pelas folhas e insignificamente absorvido pela presença de clorofila conforme os processos biológicos requeridos, assim os diferentes portes das árvores em todo o povoamento reflete com a mesma intensidade a radiação de esta faixa, sem apresentar variação na quantidade consumida (SANTIAGO et al., 2009; AQUINO; OLIVEIRA, 2012; ANDRADE, 2015; CHUVIECO, 2016).

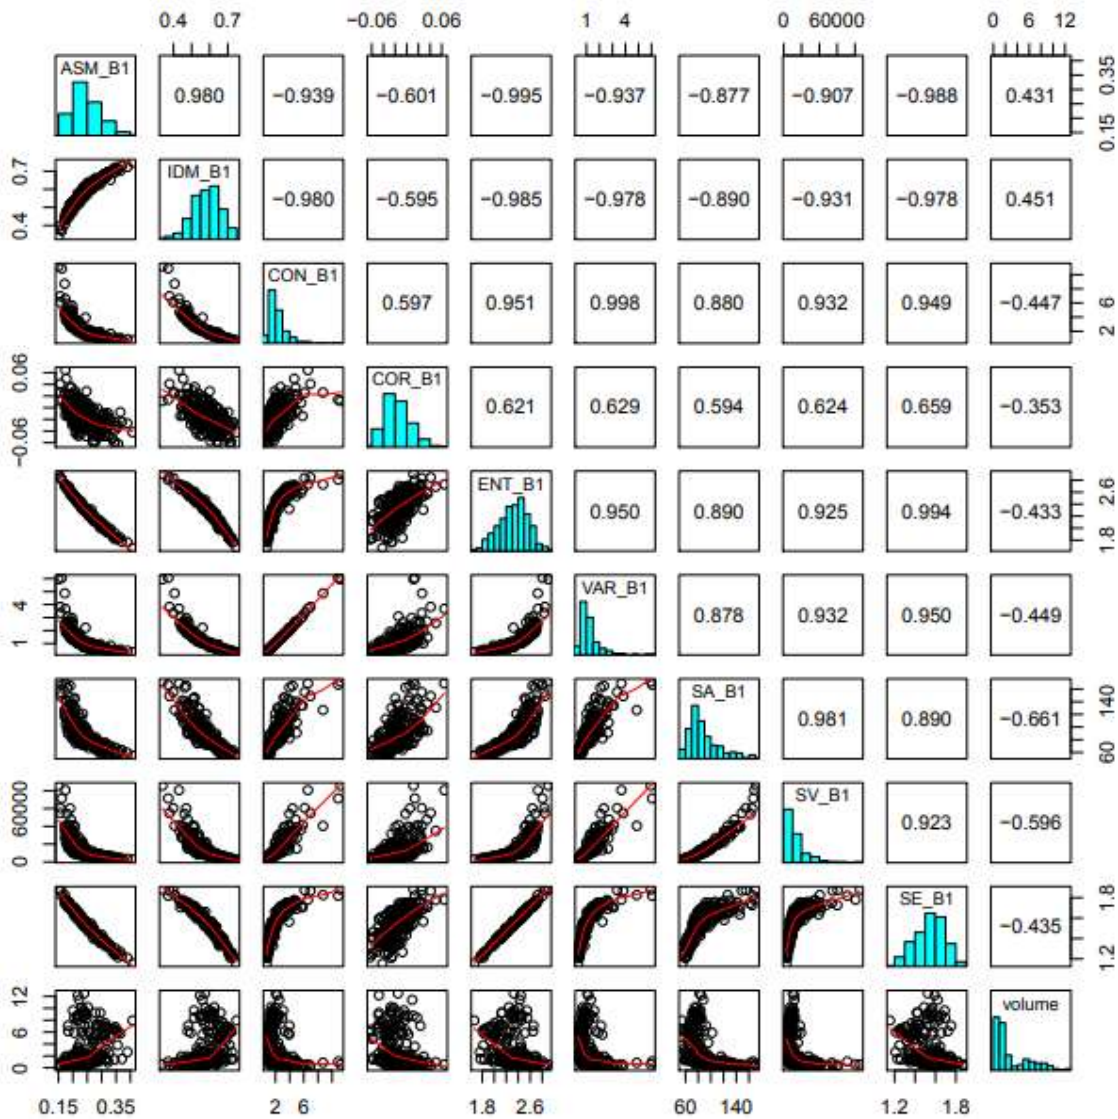
As outras bandas (B1, B2 e B3), detectaram variabilidade da madeira no plantio, aumentando o volume de madeira identificado conforme os valores dos níveis digitais dos pixels são menores. Isto a causa do comprimento de radiação detectada por estas bandas serem absorvido em diferentes proporções pelas folhas da floresta conforme seus processos biológicos, tendo as árvores de maiores porte ou volume de biomassa apresentando as mais altas absorções de radiação e, por conseguinte, as inferiores refletâncias do povoamento florestal (CHUVIECO, 2016).

Figura 10 – Correlação das bandas espectrais com o volume de madeira.



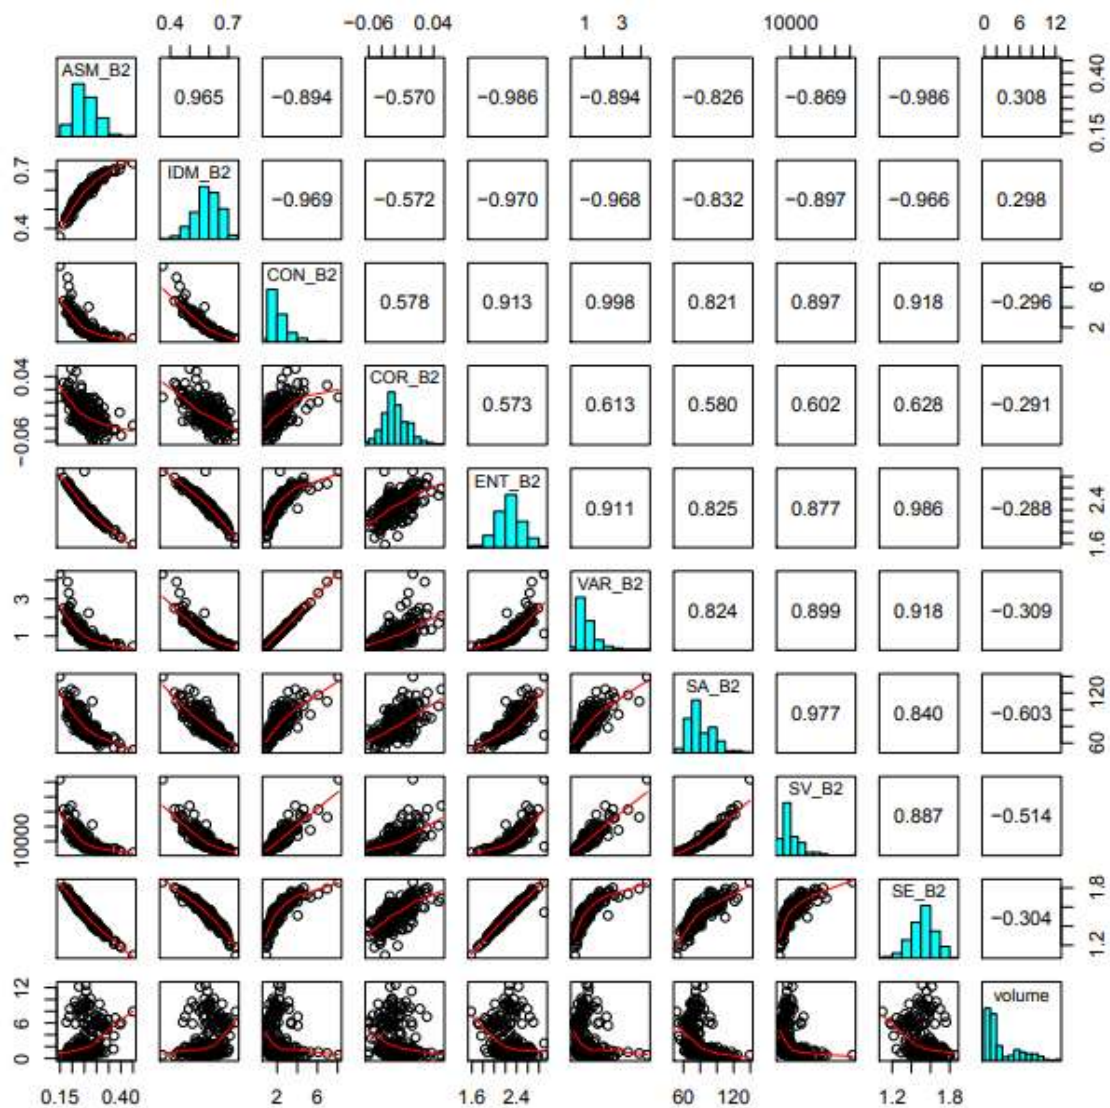
As correlações dos valores médios de textura por parcelas derivados da banda B1 podem ser visualizado na Figura 11, onde claramente os diferentes tipos de descritores entre si apresentam alta correlação positiva e negativa (exceto o descritor COR_B1 que tem grau de relação moderadamente inferior com o resto), tendo distribuições de forma linear e exponencial estritamente crescente e decrescente. Com relação ao volume médio por parcela, a maioria dos tipos de textura derivados de B1 tende a correlacionar-se inversamente de maneira exponencial, dispendo conforme o coeficiente de Spearman, um grau de correlação considerado moderadamente significativo só os descritores SA_B1 e SV_B1, com valores de -0,661 e -0,596, respectivamente, o resto de texturas apresenta relações fracas, variando entre valores de 0,451 a -0,449.

Figura 11 – Correlação dos descritores de textura da B1 com o volume de madeira.



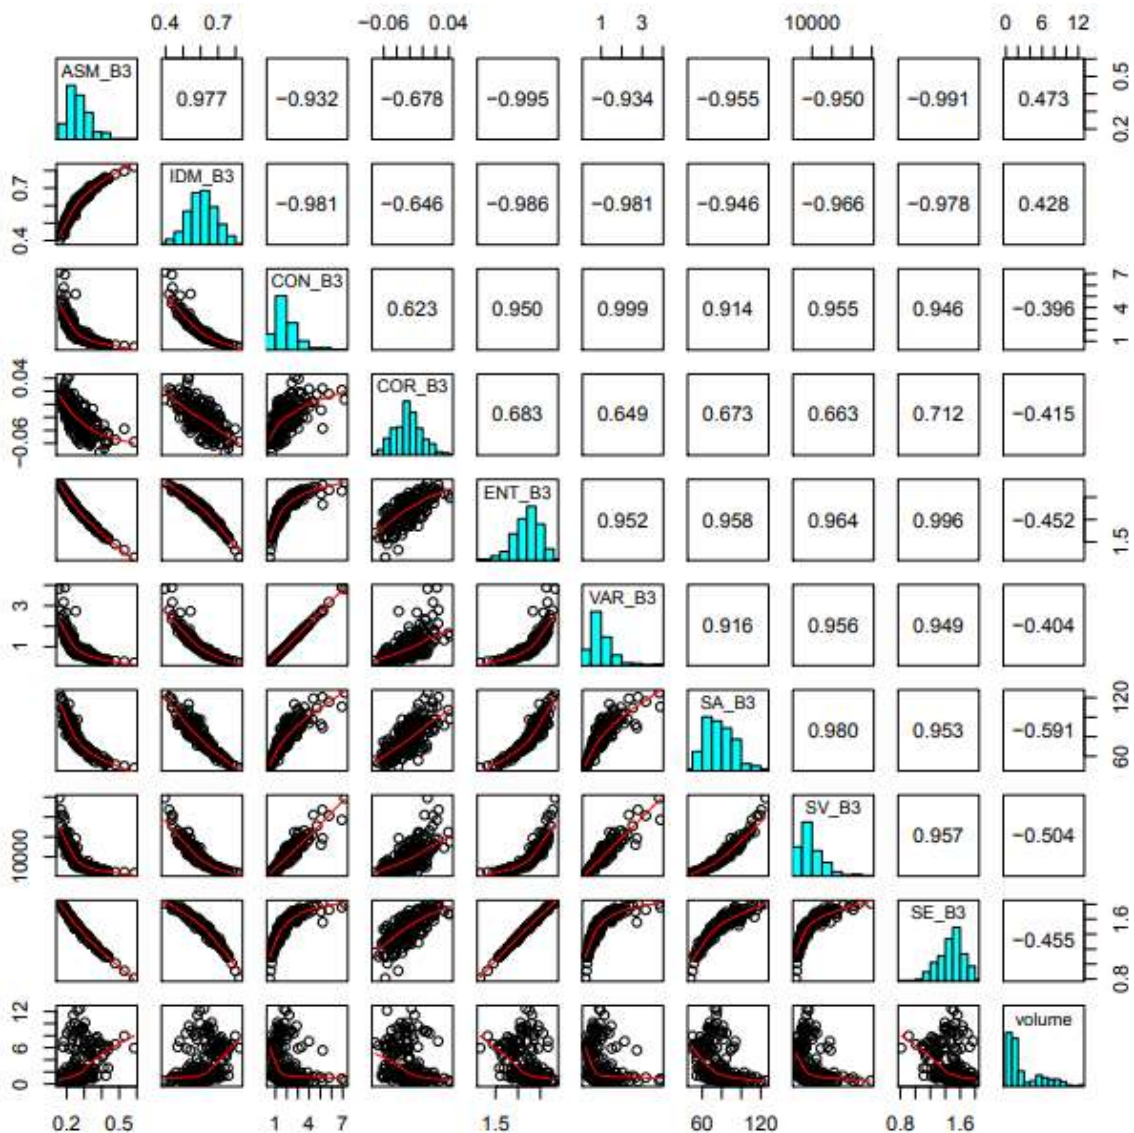
Os descritores de texturas derivados da banda B2 apresentam fortes correlações entre elas (exceto o descritor COR_B2), com distribuições exponenciais e lineares, direta e inversamente proporcionais (Figura 12). Com respeito ao volume médio por parcela, tendo em consideração as relações da banda B1, somente o descritor SA_B2 com um valor de -0,603 conserva relação estimada como de significativa dependência, que é de forma inversamente exponencial, diminuindo o nível de correlação de esta banda com a maioria dos outros descritores de textura.

Figura 12 – Correlação dos descritores de textura da B2 com o volume de madeira.



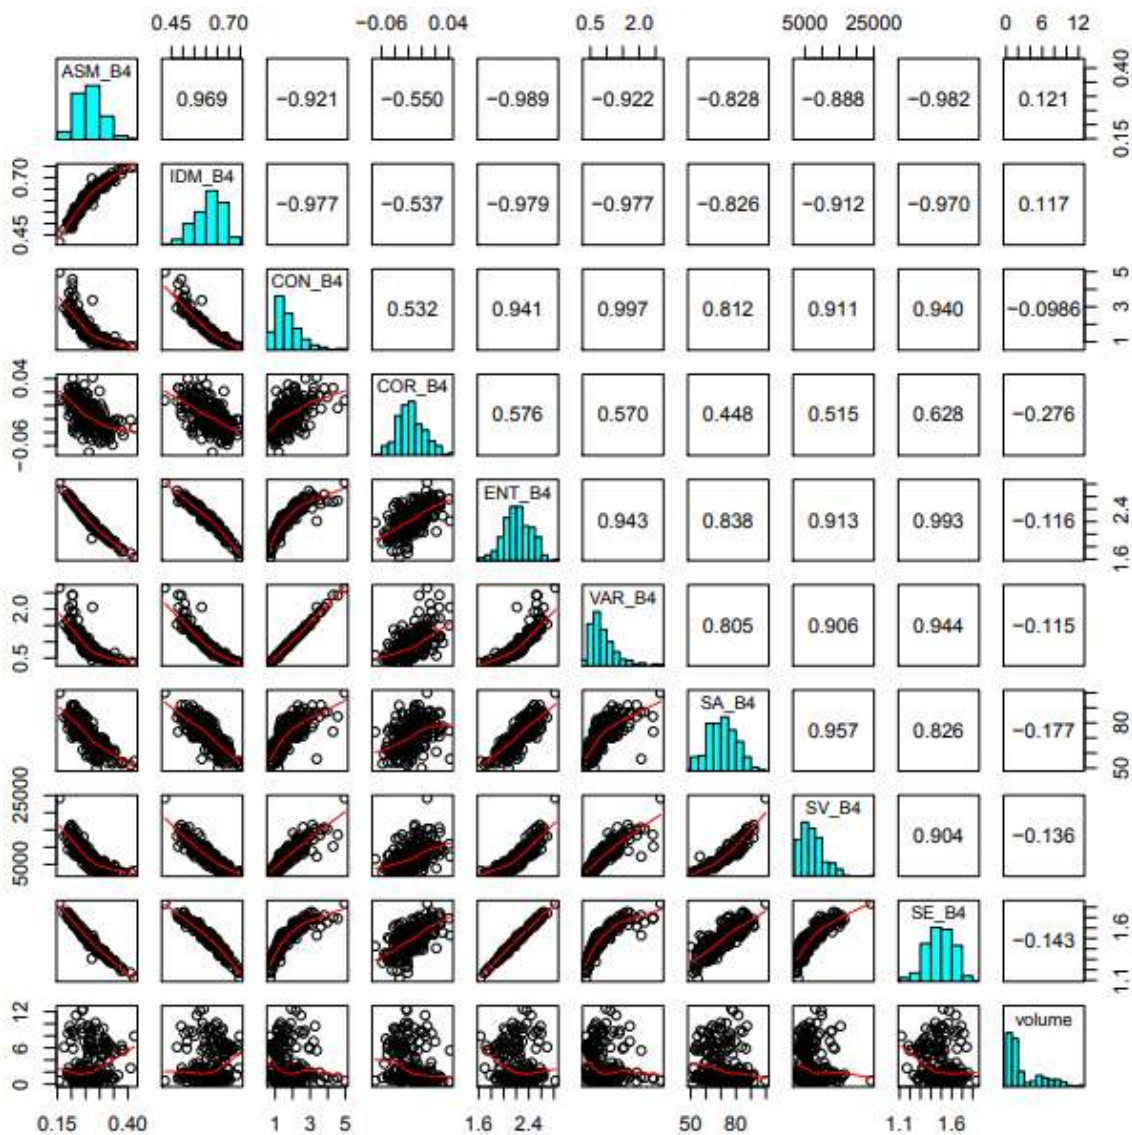
Com relação às texturas derivadas da banda B3 (Figura 13), conforme ao volume médio por parcela, define-se com correlação representativa o descritor SA_B3 apresentando magnitude de -0,591. O resto dos descritores tem dependência pouco relevante (entre 0,473 a -0,504), mas notavelmente são relações superiores às das texturas da B2, assemelhando-se aos valores da B1. As texturas entre si estão bem correlacionadas como nas outras bandas.

Figura 13 – Correlação dos descritores de textura da B3 com o volume de madeira.



As texturas derivadas da B4 (Figura 14), a diferencia dos descritores surgidos das outras bandas, o volume não se correlaciona expressivamente com nenhum descritor de textura, a afinidade é depreciável, com valores que vão de 0,121 a -0,276. Este fato semelhante também foi observado na avaliação direta da relação dos dados de volume com os valores da banda espectral 4, anteriormente mostrada, razão pela qual as texturas calculadas não manifestam grau de significância representativo.

Figura 14 – Correlação dos descritores de textura da B4 com o volume de madeira

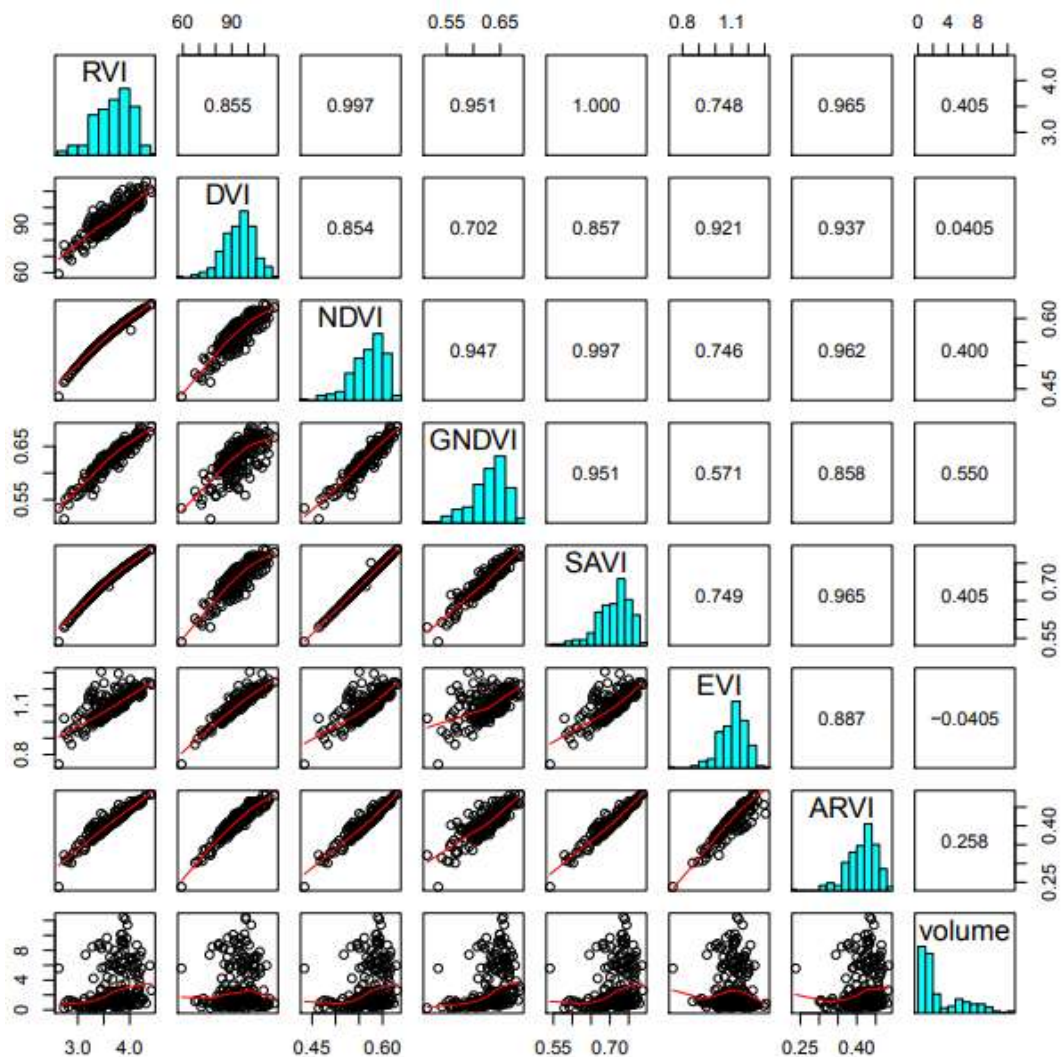


Em geral, de todos os diferentes tipos de texturas relacionadas com os dados de volume, só dois tipos de descritores de texturas, SA e SV, conseguem extrair relações expressivas da variabilidade da volumetria da madeira no povoamento florestal, relacionando-se de forma inversamente exponencial. Isto é dado principalmente porque os descritores SA e SV, como esta expressada em suas equações aritméticas, focalizam em estimar o valor médio da soma dos níveis de cinza de cada pixel, respectivamente, variando seus valores segundo a absorção e reflexão espectral da radiação pelos diferentes portes dos arvores, entretanto os outros descritores enfatizam em analisar a organização espacial entre os valores digitais dos pixels vizinhos conforme similaridade, dependência linear, grau de desordem e dispersão (ALVES; ARAÚJO;

LIBRANTZ, 2006; SHIJIN; DHARUN, 2016; HALL-BEYER, 2017; SAHU et al., 2017; GHASEMIAN; AKHOONDZADEH, 2018).

No que lhe concerne aos índices de vegetação, consigo mesmo, em geral, têm alto coeficiente de correlação positivo, apresentando tendência linear crescente, mas o EVI e o GNDVI mostraram inferiores correspondências com alguns dos outros índices (Figura 15). Em consideração com o volume médio por parcela, o GNDVI foi o que melhor se correlacionou, com um valor de 0,550, relacionando-se de forma exponencial crescente, entretanto a afinidade com os outros índices foi fracamente expressiva. Diferentemente que as bandas espectrais e os descritores de textura que se correlacionaram com tendência inversamente exponencial com o volume, o GNDVI apresenta disposição exponencial crescente, o seja, na medida em que os valores de GNDVI aumentam o volume da madeira se acrescentam de forma exponencial.

Figura 15 – Correlação dos índices de vegetação com o volume de madeira.



Os índices de vegetação, em geral, a variação de suas magnitudes não são mudam-te com respeito ao volume da madeira na floresta, embora sejam altamente competentes na identificação de sua presença. Todos os índices de vegetação consideram como variável para serem calculadas o espectro de radiação infravermelha próxima, sendo registrado pela banda B4 na imagem Sport 6, que claramente não detecta a variação volumétrica da madeira, portanto, os índices também não conseguem fazer a discriminação.

4.2. VARIÁVEIS DE ENTRADA NA RNA

Das diferentes bandas espectrais, índices de vegetação e descritores de texturas, foram escolhidos como variáveis de entradas à RNA, os melhores correlacionados com o volume de madeira médio por parcelas. Deste modo, definiu-se como dados de entradas o conjunto de variáveis apresentados na Figura 16, por ter apresentado coeficiente de correlação com valores absolutos próximos ou maiores que 0,6, considerados com dependência significativa com respeito ao volume da madeira.

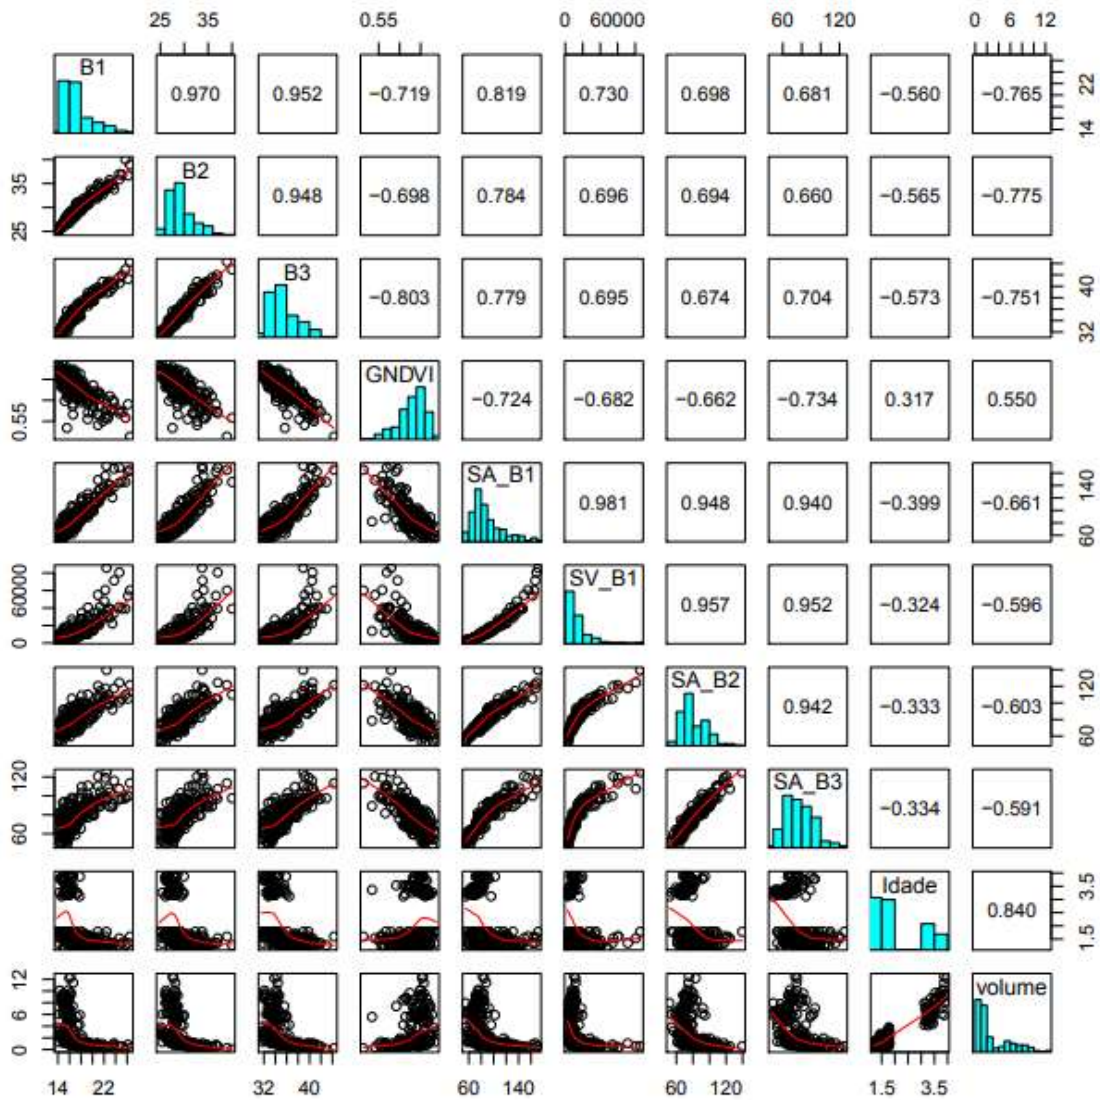
Sendo assim, foram definidas três bandas espectrais (B1, B2 e B3), o índice de vegetação GNDVI, o descritor de textura SV derivado da banda B1 e os três descritores SA proveniente de cada uma das três bandas escolhas, além, foi incluída a idade de cada talhão reportada no inventário florestal da plantação, ficando como a variável de maior correlação com respeito ao volume, apresentando tendência linear diretamente proporcional (Figura 16). Desta forma, passou-se de 48 diferentes variáveis de entrada na RNA, com as qual se precisaria de alto processamento computacional, a ter somente 9 variáveis características de dependência, conseguindo-se assim realizar uma separação da informação importante da redundante do conjunto total de dados disponíveis.

Estas variáveis indicadas apresentam consigo mesmas diferentes graus de correlação, o que indica aporte de variabilidade de características contribuintes para a estimativa da volumetria que pode ser extraídas no treinamento da RNA. Avalia-se, conforme os coeficientes de correlação, que a idade do plantio seja a variável que mais aporte informação de aprendizagem, seguida das bandas espectrais, descritores de textura e em menor grau o índice de vegetação.

Embora muitos tipos de índices de vegetação e descritores de textura foram determinados, não se usaram como variáveis de predição na rede, porque eles são fracamente correlacionados com o volume de madeira das árvores e altamente entre si,

sendo apropriada esta remoção de variáveis irrelevantes para aperfeiçoar o modelo, aumentando o poder preditivo e ter uma interpretação mais fácil de seu funcionamento (HAGAN et al., 2014).

Figura 16 – Correlação das variáveis de entrada à RNA com o volume de madeira.



Nas Figuras 17, 18 e 19 se ilustra o plantio de Eucalipto conforme as bandas espectrais 1, 2 e 3 estabelecidas como variáveis de entradas na RNA.

Como se pode visualizar, as três bandas estão definidas em níveis digitais entre a faixa de valores de 0 a 255, conforme a intensidade de refletividade registrada, o que faz diferenciar sua coloração. Conforme os gráficos de correlação (Figura 10), nas bandas, os valores que tendem a zero (verde claro) estão relacionados com a maior presença de volume de madeira e na medida em que se aproximam a 255 (vermelho), diminui,

associando-se mais com vegetação não florestal e solo exposto, dado que as áreas correspondentes com menores valores de níveis digitais são onde há maior absorção da radiação pela floresta conforme seus processos biológicos e os máximos valores são onde existe maior refletividade da radiação que não foi consumida pelos corpos da superfície e conseguem atingir o sensor do satélite que capturo a imagem digital.

Figura 17 – Representação espacial do plantio florestal na Banda 1 da imagem digital.




Figura 18 – Representação espacial do plantio florestal na Banda 2 da imagem digital.

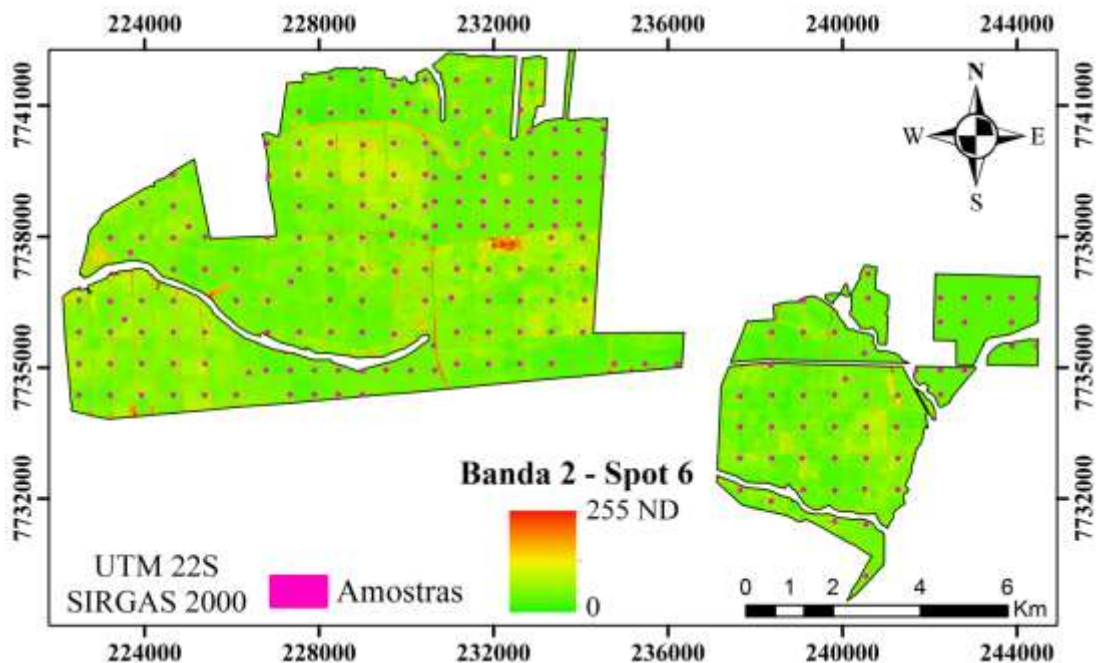
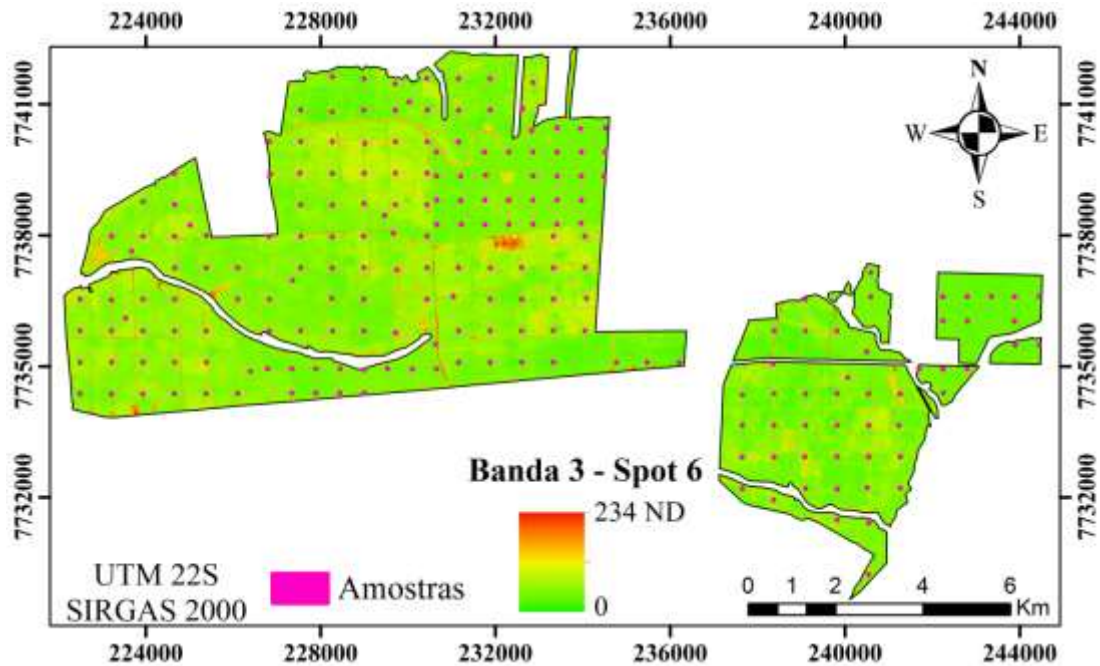


Figura 19 – Representação espacial do plantio florestal na Banda 3 da imagem digital.



No que lhe diz respeito à textura, a distribuição espacial do descritor Média da Soma (SA), derivado da banda 1 compare-se valores numa faixa de zero até 2529 (Figura 20) e os provenientes da banda 2 e 3 foram de zero a 872,3 (Figura 21) e de 16 a 777,5 (Figura 22), respectivamente.

Figura 20 – Representação espacial do plantio com a textura SA derivada da Banda 1.

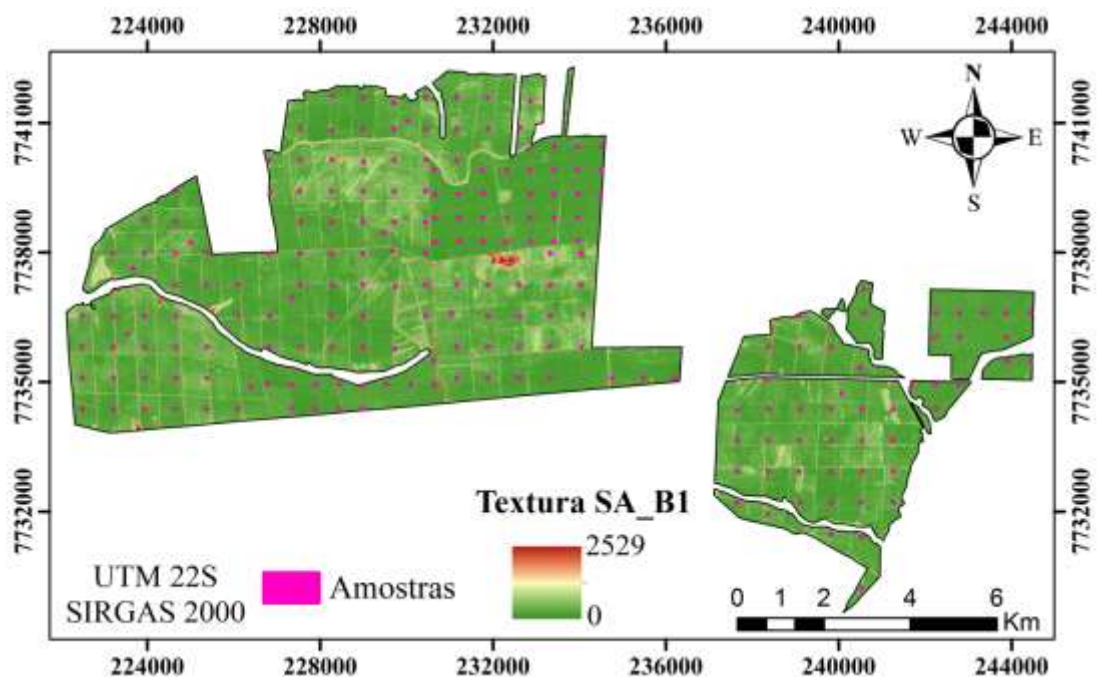


Figura 21– Representação espacial do plantio com a textura SA derivada da Banda 2.

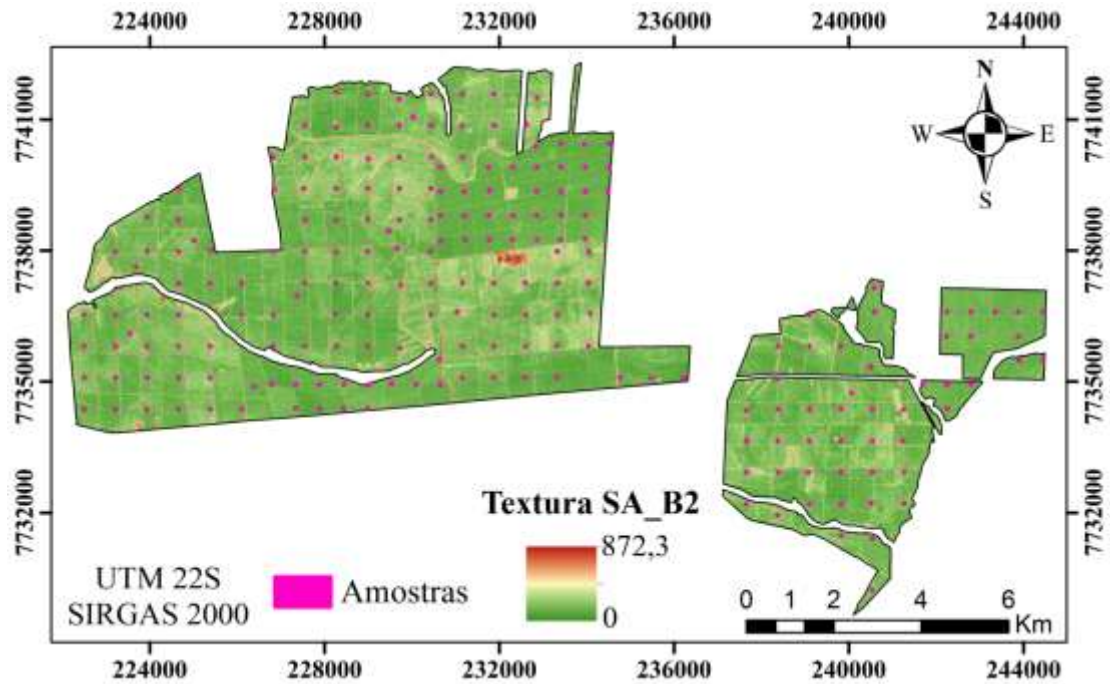



Figura 22 – Representação espacial do plantio com a textura SA derivada da Banda 3.

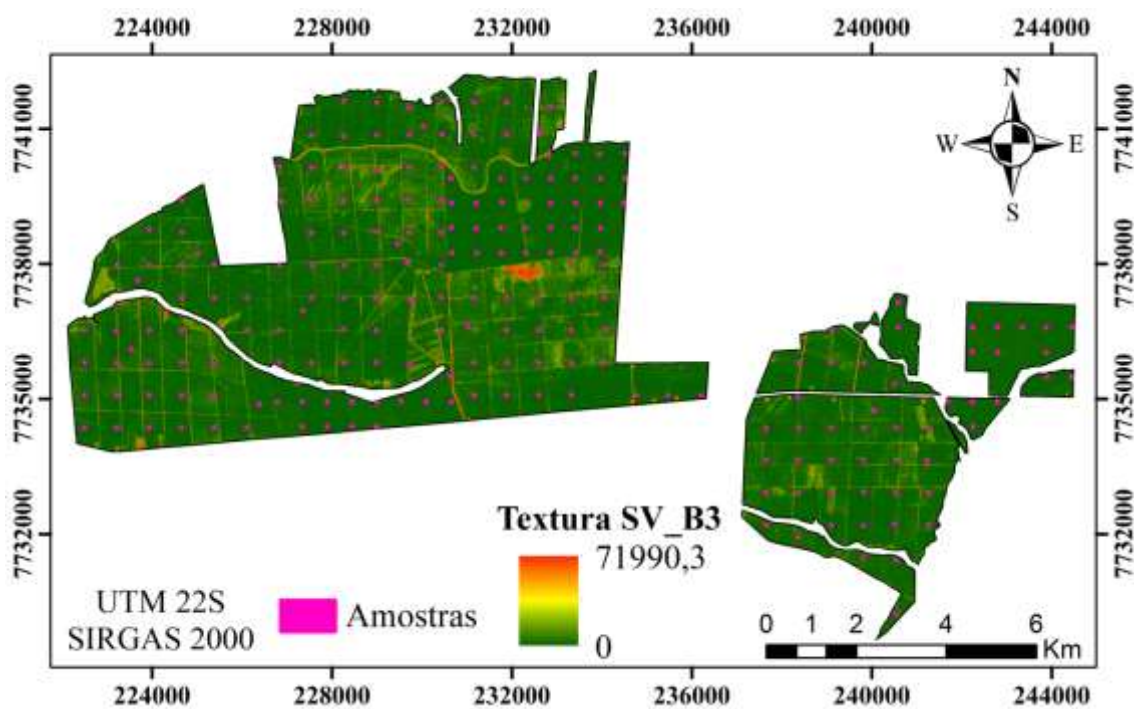


Apresentaram-se, visivelmente, diferença na magnitude nos intervalos dos descritores SA das diferentes bandas, que é relativamente de grande proporção, mas sendo igualmente em todos os inferiores valores de textura (Verde) correspondente a

maior presença de biomassa de madeira nas árvores e os máximos (vermelho) onde menos se tem presença, por serem inversamente correlacionados com o volume, conforme foi avaliado no gráfico de dispersão e no coeficiente de correlação (Figura 11, 12 e 13).


Também o descritor Variância da Soma (SV) do plantio (Figura 23), o inferior valor de textura (verde) se relaciona com a maior quantidade do volume de madeira na plantação e o superior (vermelho) ao inferior, conforme foi evidenciado na correspondência da Figura 11.

Figura 23 – Representação espacial do plantio com a textura SV da Banda 1.



Por outro lado o GNDVI oferece discriminação do plantio com uma variação de entre -0,367 a 0,730 (Figura 24). Associada a maior quantidade de volume de madeira no povoamento florestal aos mais altos valores do índice, representados com azul escuro, e na medida em que diminui sua magnitude os volumes se reduzem, ficando minimamente presente ou completamente ausente nos GNDVI negativos e/ou próximos ao zero, representadas pelas partes em vermelho.

Figura 24 – Representação espacial do plantio com o índice de vegetação GNDVI.



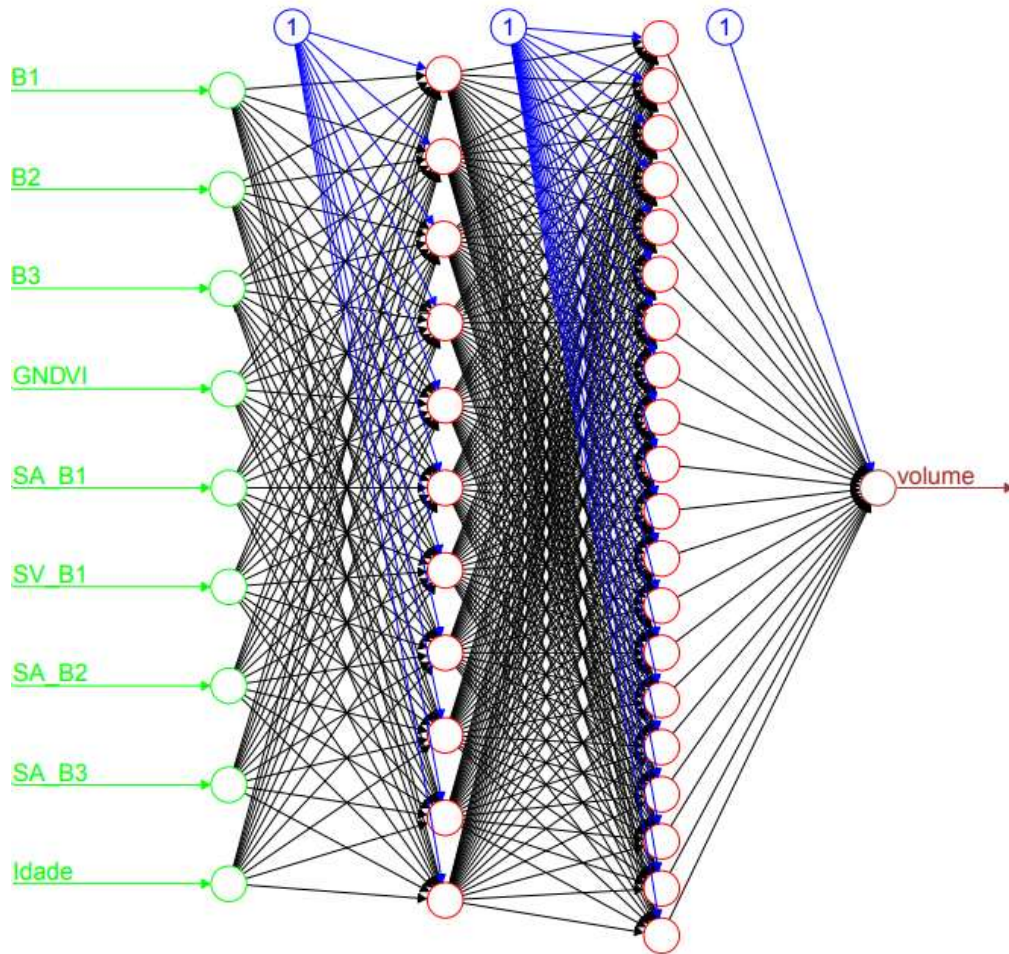
4.3. MODELO E AVALIAÇÃO DA RNA

Definidas as nove diferentes variáveis de entrada fixas gerou-se 900 diferentes redes que foram treinadas e avaliadas, resultadas da combinação possível de 1 até 30 neurônios em cada camada oculta. Assim, do total de configurações estruturadas, a RNA constituída com 11 neurônios na primeira camada oculta e 20 na segunda, além do respectivo neurônio na camada de saída, foi a que teve a estimativa de mais alta precisão, apresentando o menor %RMSE, maior coeficiente de correlação e acurácia ao ser introduzido o conjunto de dados teste que avalia sua capacidade de predição.

O valor resultante do RMSE foi de $7,85 \text{ m}^3 \text{ ha}^{-1}$, o que representa um 16,45% em média de inexatidão na comparação dos 84 valores de volume de madeira por parcela inventariados que não foram apresentados à rede na etapa de treinamento com os respectivos valores predito. Em outros termos, em média, os conjuntos de valores estimados estão 16,45% diferenciados com respeito aos inventariados.

Na Figura 25 está representada a estrutura neural 11-20-1 com o melhor desempenho, onde as variáveis de entrada estão representadas em cor verde, neurônios ocultos em vermelho, as respectivas bias em azul e de cor castanho o neurônio de saída. No anexo I estão os respectivos valores de pesos sinápticos e bias que foram calculados para cada neurônio.

Figura 25 – Representação estrutural da RNA.




Das diferentes tentativas de RNA estruturadas, houve configurações mais complexas por implicar uma quantidade maior de neurônios por camada oculta que incrementam a capacidade do processamento das variáveis de entrada, mas não foram as estruturas com as máximas eficiências nas predições.

O coeficiente de correlação de Pearson resultante da relação entre os valores inventariados das parcelas e as respectivas estimações da RNA foi de 0,988 sendo, portanto o coeficiente de determinação de 0,9761. O que representa alto grau de correlação ou linearidade da predição. Além, a precisão da estimativa resultou em 93,32% de concordância ou exatidão entre o valor médio total do volumem estimado com o inventariado.

Na Figura 26 se pode observar a comparação gráfica da dispersão dos volumes de madeira teste de avaliação com os respectivos valores estimados empregando a RNA com a maior eficiência. A distribuição ideal dos pontos na Figura seria sobre a linha reta

representada, o que da para ressaltar claramente quão próximo estão às previsões da rede dos alvos inventariados. A confrontação da para ver que as maiorias das predições não correspondem exatamente com as inventariadas, porem, as estimativas são valores próximos aos que deveriam de se houver predito, além, há varias estimativa que foram justamente precisas.

Figura 26 – Volume inventariado com respeito ao estimado pela RNA.




O gráfico de dispersão dos resíduos ou erros da estimativa esta apresentada na Figura 27 (a), onde se pode visualizar claramente diferença porcentual (%) dos valores de volume inventariados menos os estimados para cada parcela. Evidencia-se que a maioria dos resíduos se concentra entre 0 a $\pm 20\%$ e quase o restante de erro entre ± 20 a $\pm 40\%$, estando só cinco parcelas com porcentagem de erro fora destes intervalos. Os valores de volume mais baixos do povoamento foram o que tiveram estimativas com porcentagem de erro maior.

Na Figura 27 (b) também é possível observar o gráfico quantil-quantil (Q-Q plots) da distribuição dos resíduos, que demonstra que o erro segue aproximadamente uma distribuição normal pelo fato dos pontos tenderem a uma formação de linearidade. Assim, permite-se constatar que a variabilidade das estimativas apresenta resíduos com tendência central entorno de zero, o que demonstra a que a RNA não é tendenciosa em

subestimar ou superestimar os valores de volume da madeira das parcelas do povoamento florestal. Isto significa que a RNA pode apresentar a capacidade de realizar estimativas atingindo valores não muito discrepantes dos determinados no inventario florestal com medidas de campo utilizando equações alométricas.

Figura 27 – Gráfica de dispersão dos resíduos (a) e Q-Q normal (b).



Os resultados mostram que a RNA desenhada pode ser recomendável para previsão volumétrica da madeira do povoamento florestal sem ter resultados tendenciosos de erros, sujeito à discordância do erro médio esperado. É um método que funciona com dados de diferentes fontes, relacionando informação de sensoriamento remoto e dados de inventario florestal efetuado com trabalho de campo.

O erro mínimo quadrático resultado da predição pela RNA, deve-se em parte, possivelmente, à característica dos dados de entrada, que seguramente precisavam ser mais significativamente correlacionados com os dados de volume para conseguir aumentar a eficiência da aprendizagem na procura de atingir uma generalização mais aprimorada com o treinamento.

Com referencia a estudos semelhantes de técnicas de aprendizado de máquina, Ghosh e Behera (2018), mas aplicando algoritmo de Floresta Aleatória e o Estocástico de Aprimoramento de Gradiente, estimaram a quantidade de biomassa florestal em

unidade de massa (Mg ha^{-1}), em 40000 ha de povoamento de floresta tropical densa (Ocupada por árvores de *Shorea Robusta* e *Tectona Grandis*) no Santuário natural *Katarniaghat Wildlife*, na Índia, utilizando índices de vegetação (NDVI, GNDVI, RDVI e SAVI) e descritores de textura (CON, ENT e SA), derivados das bandas espectrais das imagens Sentinel 1 e 2 com resolução espacial de 10 m. Resultando o modelo proposto com algoritmo Estocástico para áreas ocupadas com *S. Robusta* apresentando uma predição com coeficiente de determinação de 0,73 (RMSE de 121,79 Mg/ha) e as áreas com *T. Grandis* de 0,57 (RMSE de 88,18 Mg/ha), sendo, respectivamente, com o algoritmo de Floresta Aleatória de 0,6 (RMSE de 112,05 Mg/ha) e 0,74 (RMSE de 73,49 Mg/ha). Valores que são bem inferiores com respeito ao coeficiente obtido neste estúdio de volume da madeira, pelo que a utilização de RNA seria melhor modelo de previsão no estabelecimento de relações entre parâmetros característicos da floresta com informações provenientes de textura e índices de vegetação obtidos com técnicas de sensoriamento remoto.

Do mesmo modo que a anterior pesquisa mencionada, Pham e Brabyn (2017), utilizando algoritmos de floresta aleatória, desenvolveram um modelo que incluía como variáveis de predição bandas espectrais e derivados descritores de textura (AS, IDM, ENT, CON, COR) e índices de vegetação (NDVI, EVI, SAVI, NDII, OSAVI, MSAVI), provenientes de imagens SPOT 4 e 5, para mapear a biomassa de um povoamento de floresta natural de mague com 72000 ha na região de Cangio, Vietnã. Conseguindo a investigação uma estimativa com coeficiente de determinação de 0,73 e precisão de 77,1% que corresponde a RMSE de $78,2 \text{ Mg ha}^{-1}$. Essa previsão é claramente menos eficiente que há resultante na presente pesquisa utilizando o mesmo tipo de imagem digital, o que indica que o uso de RNA pode proporcionar estimativas significativamente mais eficazes de propriedades da floresta.

Outro estudo representativo na estimativa da quantidade de biomassa baseados em diferentes técnicas do aprendizado de máquina (Algoritmo de floresta aleatória, algoritmo máquina de vetor de suporte e algoritmo K-vizinho mais próximo), foi proposto por Lu et al. (2016), desenvolvendo modelos de predição a partir de bandas espectrais da imagem Landsat 5, diferentes índices de vegetação (NDVI, MSAVI, SAVI, IAF) e descritores de textura derivadas dos Índice de vegetação (CON, ASM, ENT, COR, IDM, AS, SV), em 1.142.916 ha de floresta, no estado de Durango no México, ocupada por basicamente por pinheiros, pinhais e carvalhos. Mostrando como resultado que o método mais eficaz foi o construído com o algoritmo K-vizinho

apresentando coeficiente de determinação de 0,66 (RMSE = 26,64 Mg ha⁻¹). Valor do coeficiente que também foi inferior ao obtido nesta pesquisa, o que sinaliza a RNA como método de aprendizagem com funcionamento mais competente de predição com atributos da floresta obtidos remotamente.

Os estudos anteriores que empregam aprendizados de máquina, como de fato são as RNA, na previsão da quantidade de biomassa da florestal utilizando como variáveis de entrada bandas espectrais, derivadas de texturas e índices de vegetação, resultaram menos exatos e precisos na predição. Isto expõe, embora que as espécies florestais estudadas não foram de *Eucalyptus* sp., que modelos com RNA podem ser mecanismo de aprendizado computacional mais eficientes no relacionamento entre as variáveis de predição obtidas com técnica de sensoriamento remoto e o parâmetro a ser estimado do povoamento florestal.

Exemplos de modelos de regressão linear usando bandas espectrais (4 multiespectrais com resolução espacial de 8 m) e os decorrentes índices de vegetação (NDVI, DVI, RVI, EVI, SAVI, MSAVI, ARVI, TDVI) e descritores de textura (IDM, CON, ENT, ASM, COR, SV, SA), no prognóstico da biomassa em povoamentos de *Populus Euphratica* na Mongólia, China, foram experimentados por Zhang, Cheng e Li (2015); onde através de dados do satélite GaoFen-1, desenvolveram uma equação com precisão de 91,54% dos dados determinado em campo, correspondente a erro quadrático médio relativo de 8,46% (RMSE = 25,22 Mg / ha). Mostrando-se assim, dito modelo de regressão, com maior desempenho na estimativa de parâmetros da floresta com respeito ao baseado em RNA do presente estudo, por ter inferior erro médio relativo.

Também aplicando métodos de regressão linear simples e múltipla, Sarker e Nichol (2011), utilizando como variáveis independentes bandas espectrais provenientes do sensor AVNIR-2 (Resolução espacial de 10 m), índices de vegetação (NDVI, RVI, DVI, SAVI, MSAVI, entre outros) e todos os descritores de textura derivados da GLCM; conseguiram estimar a biomassa de 110000 ha de floresta subtropical plantada em Hong Kong, obtendo como resultado um modelo de regressão com eficiência máxima de explicação de 88% da variabilidade dos dados de campo ($r^2 = 0,88$ e RMSE = 32 t / ha). Potencial de estimação do modelo que é mais baixo que o obtido na atual investigação com RNA.

Como se pode analisar das duas investigações anteriores, as regressões lineares alcançam a ter uma estimativa com desempenho que podem ser até superiores com referentes às comparadas com as fundamentadas com técnicas de aprendizagem de

maquina. Mas, assumir uma relação linear entre variáveis de predição provenientes de sensoriamento remoto com as preditas da floresta é uma suposição que deprecia relações não lineares complexas que o aprendizado de maquinas como as RNA podem subentender, e não configurar-se em modelos de estimativas tendenciosos (CHEN et al., 2016; LÓPEZ-SERRANO et al., 2016; PHAM; BRABYN, 2017).

Tem-se pesquisas desenvolvidas com RNA multicamada com algoritmo de retropropagação de erro, como a realizada por Zhu et al. (2015), no mapeamento da biomassa de 700 ha de floresta de mangue (Principalmente *Kandelia Candel* e *Sonneratia Apetala*), na província de Guangdong na China, mas somente utilizando como variáveis de entrada bandas multiespectrais e índices de vegetação (NDVI, DVI, SRI) da imagem digital do satélite Worldview-2. Onde conseguiram como melhor desempenho RMSE relativo de 18,17% (RMSE = 24,32 t / ha). Este desempenho resultante foi próximo do conseguido na atual pesquisa na estimativa de volume de madeira da floresta, diferenciando-se o erro médio quadrático relativo em tão só 1,77%, pelo que a predição de esta pesquisa utilizando conjuntamente bandas e índices de vegetação com descritores de texturas foi levemente superior.

Igualmente, com RNA multicamadas foi estimada e mapeada a biomassa de florestas tropical de Bornéu na Malásia, mas utilizando como variável de entrada as seis bandas espectrais proveniente da imagem Landsat TM e derivados índices de vegetação (NDVI, DVI, entre outros); sendo de 0,8 o coeficiente de correlação definido entre os valores preditos pela RNA e os determinados em campo através de equações alométricas (FOODY et al., 2001). Valor do coeficiente que foi inferior ao obtido nesta pesquisa.

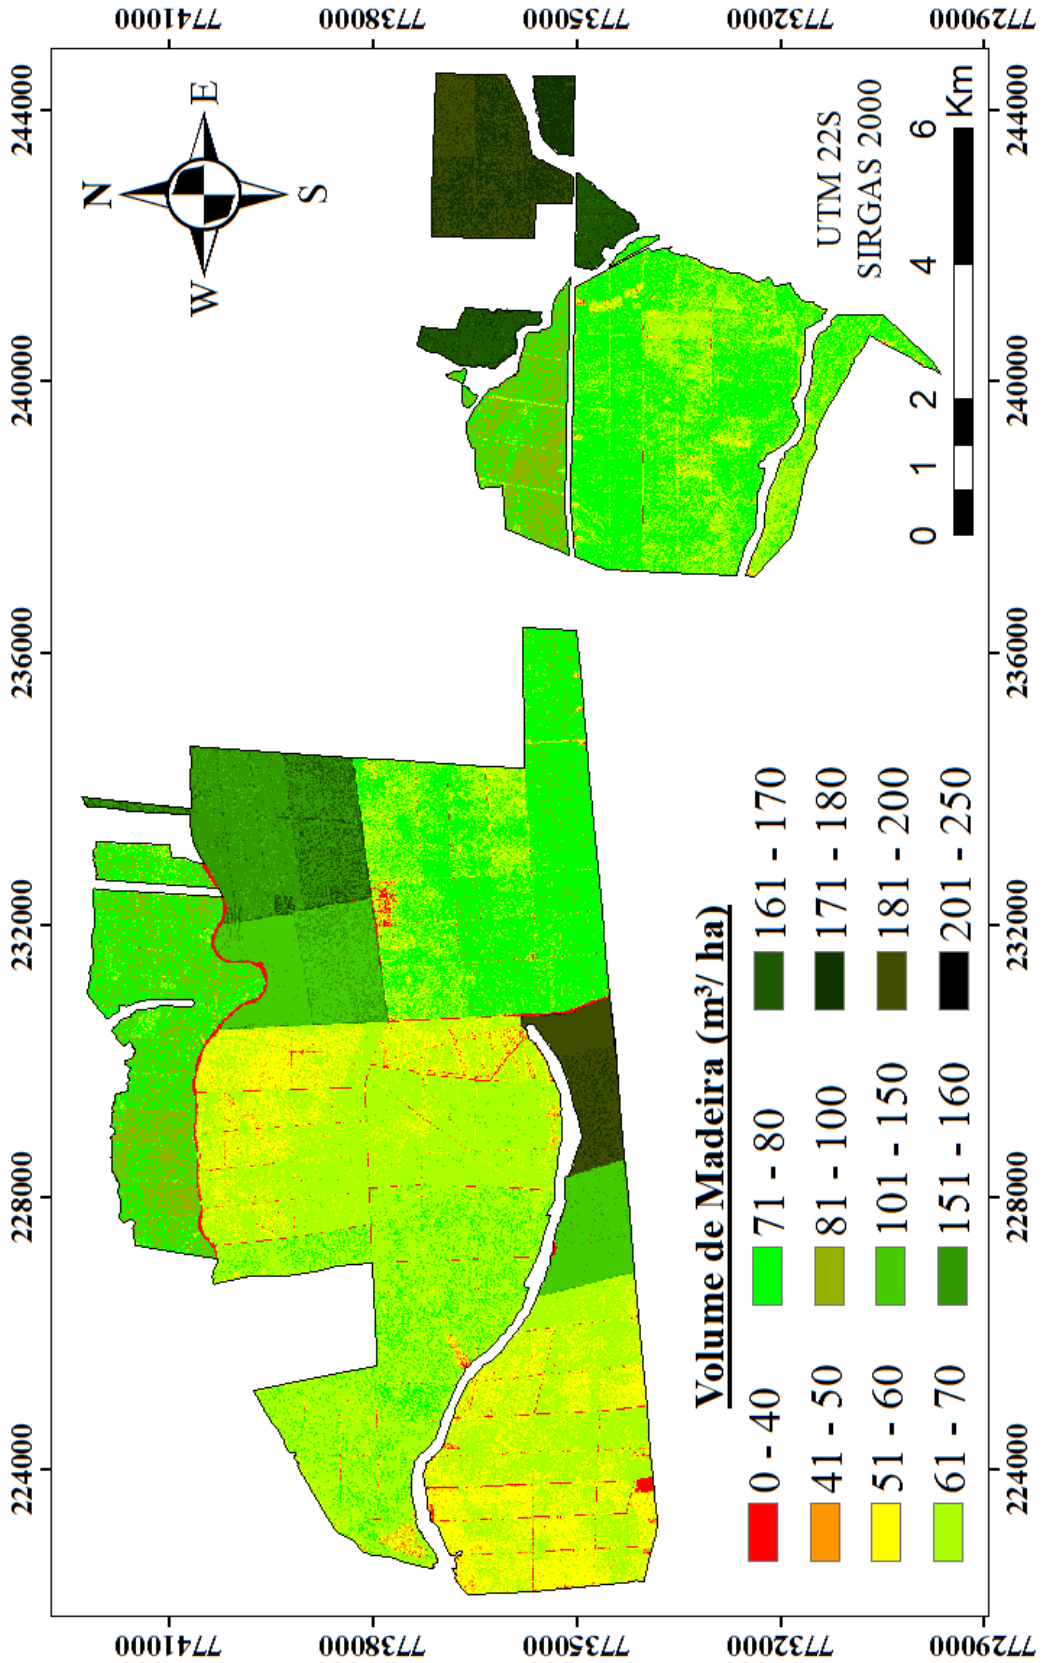
Como se pode analisar, estas investigações mencionadas não considerem o uso sinérgico de bandas e índices juntamente com a textura, sendo mais reduzida a quantidade de informação apresentada à RNA para a predição do parâmetro florestal, pelo que possivelmente os desempenhos obtidos foram inferiores com respeito aos de esta pesquisa.

4.4. ESPACIALIZAÇÃO DO VOLUME DE MADEIRA NO PLANTIO

Definida a RNA, aplicou-se o modelo para toda a área do povoamento, integrando-o ao ambiente SIG para realizar a espacialização do volume da madeira. As variáveis de predição de toda a área florestal foram normalizadas para serem

ingressadas à rede, resultando a distribuição espacial do volume madeireiro do plantio mostrado no mapa temático da Figura 28, representado em metros cúbicos por hectare.

Figura 28 – Distribuição espacial do volume de madeira no povoamento florestal.

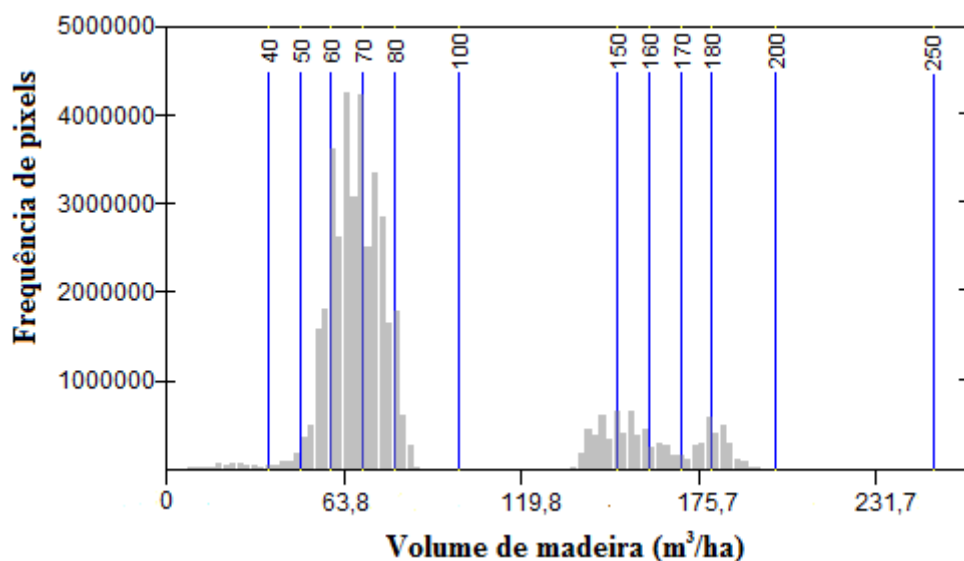


A variação do volume vai desde as maiores quantidades de volume, representados com a cor verde escuro e preto, até os inferiores valores nas zonas com coloração vermelha onde possivelmente se ausenta a presença da madeira.

Com este mapa ficam referenciadas as áreas com os altos e baixos estoques de madeira dentro da plantação, que pode ser usado no apoio de seu manejo.

Na Figura 29 está o histograma de frequência dos valores de volume do plantio conforme a frequência da quantidade de volume por pixels presente no mapa anterior.

Figura 29 – Histograma de frequência dos valores de volume de madeira no plantio.



Conforme isto, identifica-se que ocorre maior frequência de valores entre 50 a 80 m³/ha. Também ocorre frequência notória entorno dos 150 e 180 m³/ha, o resto de magnitudes apresenta pouca representatividade ao longo da extensão do povoamento florestal.

O mapa e histograma de frequência dos valores demonstram que a RNA são capazes de estimar volume de madeira do povoamento florestal, como também georreferenciar sua distribuição espacial, incluso até em áreas difícil onde o trabalho de campo resulta muito caro ou não pode ser realizado.

Desta forma, as RNA podem ajudar no uso conjunto de dados de sensoriamento remoto (bandas, índices e texturas), na estimativa de características ambientais da floresta, obtendo-se resultados que podem ser de grande importância para o manejo de plantios, mas ainda falta claramente aprimorar a eficiência de seu desempenho através de mais investigações.

5. CONCLUSÕES

Conseguiu-se construir um modelo baseado com RNA capaz de estimar espacialmente a quantidade do volume de madeira em plantação florestal de *Eucalyptus* sp com o uso sinérgico de bandas multiespectrais de imagem digital de satélite e as derivadas textura obtidas com matriz GLCM e índices de vegetação, além de dados de idade do plantio.

Especificamente por médio do método de correlação de Spearman, como variáveis de entradas ou de predição para a RNA foram escolhidas as banda espectrais azul, verde e vermelho do visível, por demonstrarem correlação significativa com o volume de madeira da floresta. Também, entre mais de 36 texturas analisadas (Derivadas dos descritores ASM, IDM, CON, COR, ENT, VAR, SA, SV e SE), definiu-se como variáveis a textura derivada do descritor Média da soma (SA) de cada um das bandas anteriormente mencionadas e a determinada do descritor Soma da variância (SV) do espectro azul, por exporem relevante correspondência com a volumetria, mas em menor proporção que a apresentada pelas bandas espectrais. Sucessivamente, o GNDVI, em meio de sete índices de vegetação examinados (RVI, DVI, NDVI, GNDVI, SAVI, EVI e ARVI), foi o único adotado para a predição da rede por manifestar apreciável relação de correspondência com a quantidade de madeira, porém, em inferior proporção que a observada com as bandas e texturas selecionadas. Em geral, os índices vegetação e descritores de texturas analisados não mostraram ser tão eficientes na caracterização da quantidade de madeira do plantio, embora que são ótimos em detectar a cobertura florestal na superfície.

Foram testadas 900 diferentes arquiteturas de RNAs utilizando função de ativação sigmoide, obtendo-se com o superior desempenho o modelo construído por duas camadas ocultas, contendo 11 neurônios na primeira e 20 na segunda e, o respetivo neurônio da camada de saída. Decorrendo com erro padrão residual de 16,32% (RMSE de $7,85 \text{ m}^3\text{ha}^{-1}$), mas oferecendo um coeficiente de determinação de 0,9761 e precisão de 93,32% de concordância entre os valores estimados e os determinados com medidas de campo por meio de equações alométricas. Sendo este rendimento promissor porque a distribuição dos resíduos das estimativas indica boa qualidade de ajuste, comprovando que o modelo não atende às suposições tendenciosas, o que designa aceitável sua aplicação. Pelo que se torna como modelo disponível para o mapeamento da distribuição espacial do volume da biomassa em grandes áreas com as respetivas

variáveis de predição definidas, podendo proporcionar substancial apoio no manejo florestal de plantios.

O modelo elaborado ao ser comparado com outros semelhantes, que empregam outro tipo de aprendizado de máquina, mas utilizando similares variáveis de entrada, ostenta maior potencial de estimativa, tendo superior precisão e exatidão. Inclusive confrontado com modelos de RNA que usam como variáveis somente as bandas espectrais e os índices de vegetação, evidenciou-se predição com desempenho mais exato, sinalando que a textura contribuiu em aperfeiçoar a predição da volumetria. Ao ser confrontado com diferentes modelos de regressão lineal, apresentou com alguns predições com superiores e inferiores eficiências, manifestando capacidade de poder superar os métodos tradicionais de predição de parâmetros florestais estabelecidos com equações explícitas.

Contudo, acredita-se que o modelo de RNA construída poderia ser eficiente ao ser aplicado em outras regiões com plantios de *Eucalyptus* sp., resultando as estimativas com a margem de erro esperado, funcionando assim como uma ferramenta de modelação ambiental de volume florestal com iguais variáveis fontes. Não obstante, precisasse de investigações para testar e aperfeiçoar seu uso em plantios de floresta plantada como naturais de diversas espécies, em distintas regiões geográficas do mundo, com diferentes tipos de imagens de satélites, a fim de potencializar sua implementação. Servindo esta investigação como diretriz de suporte para o desenvolvimento de futuras pesquisas para modelagem da volumetria florestal utilizando como método de aprendizado de máquinas as RNA.

REFERÊNCIAS

- ALBA, E.; MELLO, E. P.; MARCHESAN, J.; SILVA, E. A.; TRAMONTINA, J.; PEREIRA, R. S. Spectral characterization of forest plantations with Landsat 8/OLI images for forest planning and management. **Pesquisa Agropecuaria Brasileira**, v. 52, n. 11, p. 1072–1079, 2017.
- ALVES, W. A. L.; ARAÚJO, S. A. de; LIBRANTZ, A. F. H. Reconhecimento de padrões de texturas em imagens digitais usando uma rede neural artificial híbrida. **Exacta**, v. 4, n. 2, p. 325–332, 2006.
- ALBA, E.; MELLO, E. P.; MARCHESAN, J.; SILVA, E. A.; TRAMONTINA, J.; PEREIRA, R. S. Spectral characterization of forest plantations with Landsat 8/OLI images for forest planning and management. **Pesquisa Agropecuaria Brasileira**, Brasília, v. 52, n. 11, p. 1072–1079, 2017.
- ALVES, W. A. L.; ARAÚJO, S. A. de; LIBRANTZ, A. F. H. Reconhecimento de padrões de texturas em imagens digitais usando uma rede neural artificial híbrida. **Exacta**, São Paulo, v. 4, n. 2, p. 325–332, 2006.
- ANAYA, J. A.; DUQUE, R. A.; VALENCIA, G. M. Análisis de textura en imágenes de satélite en el ámbito de la biodiversidad y la estructura en un bosque de los Andes Colombianos. **Gestión y Ambiente**, Bogotá, v. 11, n. 3, p. 137–146, 2008.
- ANDRADE, D. D. de. Estimativas de carbono na cobertura vegetal da APA Fernão Dias (MG) por meio de dados espectrais e de campo. **Caderno de Estudos Geoambientais**, Fluminense, v. 5, n. 1, p. 05-16, 2015.
- AQUINO, C.; OLIVEIRA, J. Estudo Da Dinâmica Do Índice De Vegetação Por Diferença. **GEOUSP - Espaço e Tempo**, São Paulo, n. 31, p. 157-168, 2012.
- ASTRIUM. **SPOT 6 & SPOT 7 Imagery - User Guide**. Ed. 1. Toulouse: Astrium Services, Julho 2017. 120 p.
- BAIEE, W.; ALASADI, T. Classification of GIS Image using GLCM and Neural Network. **Basrah Journal of Science**, v. 31, n. 2, p. 110–119, 2013.
- BALOGH, T. S.; PEDRIALI, C. A.; KANEKO, T. M. Proteção à radiação ultravioleta: recursos disponíveis na atualidade em fotoproteção. **Anais Brasileiros de Dermatologia**, v. 8, p. 732–742, 2011.
- BASISTOV, Y. A.; YANOVSKII, Y. G. Comparison of Image Recognition Efficiency of Bayes, Correlation, and Modified Hopfield Network Algorithms. **Pattern Recognition and Image Analysis**, v. 26, n. 4, p. 697–704, 2016.
- BAYMA, A. P.; SANO, E. E. Séries temporais de índices de vegetação (NDVI e EVI) do sensor modis para detecção de desmatamentos no bioma cerrado. **Boletim de Ciências Geodesicas**, v. 21, n. 4, p. 797–893, 2015.
- BERRA, E. F.; BRANDELERO, C.; PEREIRA, R. S.; SEBEM, E.; GOERGEN, L. C. de G.; BENEDETTI, A. C. P.; LIPPERT, D. B. Estimativa do volume total de madeira em espécies de eucalipto a partir de imagens de satélite Landsat. **Ciência Florestal**, v.

22, n. 4, p. 853–864, 2012.

CABEZAS, J.; GALLEGUILLOS, M.; PEREZ-QUEZADA, J. F. Predicting Vascular Plant Richness in a Heterogeneous Wetland Using Spectral and Textural Features and a Random Forest Algorithm. **IEEE Geoscience and Remote Sensing Letters**, v. 13, n. 5, p. 646–650, 2016.

CALVIÑO-CANCELA, M.; ETTEN, E. J. B. Van. Forest Ecology and Management Invasive potential of *Eucalyptus globulus* and *Pinus radiata* into native eucalypt forests in Western Australia. **Forest Ecology and Management**, v. 424, n. April, p. 246–258, 2018. Disponível em: <<https://doi.org/10.1016/j.foreco.2018.05.001>>.

CHEN, Q.; WANG, G.; LIU, L.; LI, G.; MORAN, E. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems AU - Lu, Dengsheng. **International Journal of Digital Earth**, v. 9, n. 1, p. 63–105, 2 jan. 2016. Disponível em: <<https://doi.org/10.1080/17538947.2014.990526>>.

CHUVIECO, E. **Fundamentals of Satellite Remote Sensing: An Environmental Approach**. 2. ed. CRC Press. Boca Raton (USA), ISBN:9781498728058, 2016.

CHUVIECO, E. **Teledetección Ambiental: La observación de la tierra desde el espacio**. 1. ed. Editorial Ariel (España), ISBN: 8434480476, 2002. 586 p.

CZYZOWSKA-WISNIEWSKI, E. H.; LEEUWEN, W. J. D. Van; HIRSCHBOECK, K. K.; MARSH, S. E.; WISNIEWSKI, W. T. Remote Sensing of Environment Fractional snow cover estimation in complex alpine-forested environments using an artificial neural network. **Remote Sensing of Environment**, v. 156, p. 403–417, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2014.09.026>>.

DA SILVA, B.; MONTENEGRO, S. M. G. L.; DA SILVA, V. de P. R.; DA ROCHA, H. R.; GALVÍNCIO, J. D.; DE OLIVEIRA, L. M. M. Determination of instantaneous and daily net radiation from TM - Landsat 5 data in a subtropical watershed. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 135, p. 42–49, 2015.

FAVERO, L.; FÁVERO, P. **Estatística Aplicada: Para Cursos de Administração, Contabilidade e Economia com Excel e SPSS**. 11. ed. São Paulo: Elsevier Editora Ltda. (Brasil), 2015. 480 p.

FERREIRA, C.; CARVALHO, J.; BAPTISTA, M. **Instruções para o trabalho de campo do inventário florestal nacional**. 1. ed. Autoridade Florestal Nacional (Brasil), 2009.

FIELD, A. **Descobrimo a estatística usando o SPSS**. 2. ed. Porto Alegre: Bookman Editora, 2009. 453 p.

FOODY, G. M.; CUTLER, M. E.; MCMORROW, J.; PELZ, D.; TANGKI, H.; BOYD, D. S.; DOUGLAS, I. Mapping the Biomass of Bornean Tropical Rain Forest from Remotely Sensed Data Published by : Blackwell Publishing Stable. **Global Ecology & Biogeography**, v. 10, n. 4, p. 379–387, 2001.

FRAZIER, R. J.; COOPS, N. C.; WULDER, M. A.; KENNEDY, R. Characterization of aboveground biomass in an unmanaged boreal forest using Landsat temporal

segmentation metrics. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 137–146, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2014.03.003>>.

FRITSCH, S.; GUENTHER, F. **Neuralnet: Training of Neural Networks - R package version 1.33**. Disponível em: <<https://CRAN.R-project.org/package=neuralnet>>. Acesso em: 25 nov. 2018.

GALVAO, L. S.; FORMAGGIO, A. R.; BREUNIG, F. M. Relações entre índices de vegetação e produtividade de soja com dados de visada fora do nadir do sensor Hyperion/EO-1. **XIV Simpósio Brasileiro de Sensoriamento Remoto**, v. 1, p. 1095–1102, 2009. Disponível em: <<http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.12.10.45/doc/1095-1102.pdf>>.

GAO, J.; XU, L.; HUANG, F. A spectral–textural kernel-based classification method of remotely sensed images. **Neural Computing and Applications**, v. 27, n. 2, p. 431–446, 2016.

GAO, Y.; GAO, J.; WANG, J.; WANG, S.; LI, Q.; ZHAI, S.; ZHOU, Y. Estimating the biomass of unevenly distributed aquatic vegetation in a lake using the normalized water-adjusted vegetation index and scale transformation method. **Science of the Total Environment**, v. 601–602, p. 998–1007, 2017.

GHASEMIAN, N.; AKHOONDZADEH, M. Introducing two Random Forest based methods for cloud detection in remote sensing images. **Advances in Space Research**, v. 62, n. 2, p. 288–303, 2018.

GHOSH, S. M.; BEHERA, M. D. Aboveground biomass estimation using multi-sensor data synergy and machine learning algorithms in a dense tropical forest. **Applied Geography**, v. 96, n. May, p. 29–40, 2018. Disponível em: <<https://doi.org/10.1016/j.apgeog.2018.05.011>>.

GLANTZ, S. A. **Princípios de Bioestatística**. 7. ed. Porto Alegre: AMGH Editora Ltda, 2015. 314 p.

GRASS DEVELOPMENT TEAM. **GRASS GIS: Bringing advanced geospatial technologies to the world. Versao 7.4**. Disponível em: <<https://grass.osgeo.org/>>. Acesso em: 25 nov. 2018.

GREGORUTTI, B.; MICHEL, B.; SAINT-PIERRE, P. Grouped variable importance with random forests and application to multiple functional data analysis. **Computational Statistics and Data Analysis**, v. 90, p. 15–35, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.csda.2015.04.002>>.

GRENFELL, T. C.; MEMBER, A.; BARBER, D. G.; FUNG, A. K.; GOW, A. J.; JEZEK, K. C.; MEMBER, A.; KNAPP, E. J.; NGHIEM, S. V.; ONSTOTT, R. G.; PEROVICH, D. K.; ROESLER, C. S.; SWIFT, C. T.; TANIS, F. Evolution of Electromagnetic Signatures of Sea Ice from Initial Formation to the Establishment of Thick First-Year Ice. **IEEE Transactions on geoscience and remote sensing**, v. 36, n. 5, p. 1642–1654, 1998.

- GONÇALVES, W.; RIBEIRO, H. M. C.; SO, J. A. S. de; MORALES, G. P.; FILHO, H. R. F.; ALMEIDA, A. da C. Classificação de estratos florestais utilizando redes neurais artificiais e dados de sensoriamento remoto. **Revista Ambiente e Água**, v. 11, n. 3, p. 612–624, 2016.
- GUILHERME, A. P.; MOTA, A. B. dos S.; MOTA, D. DOS S.; MACHADO, N. G.; SACARDI, B. M. uso de índice de vegetação para caracterizar a mudança no uso do solo em Coari-AM. **Soc. & Nat**, Uberlândia, v. 28, n. 2, p. 301–310, 2016.
- GUREVITCH, J.; SCHEINER, S. M.; FOX, G. A. **Ecologia Vegetal**. 2. ed. Porto Alegre: Artmed Editor, 2009. 592 p.
- HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H.; DE JESÚS, O. **Neural Network Design**. 2. ed. Oklahoma: Martin Hagan, 2014. 802 p. ISBN-10: 0971732116
- HALL-BEYER, M. **GLCM Texture : A tutorial**. 3. ed. Calgary: Mryka Hall-Beyer, 2017. 74 p.
- HARALICK, R. M. Statistical and structural approaches to texture. **Proceedings of the IEEE**, v. 67, n. 5, p. 786–804, 1979.
- HAROLD, M.; LIU, X.; CLARK, K. C. Spatial Metrics and Image Texture for Mapping Urban Land Use. **Photogrammetric Engineering and Remote Sensing**, v. 69, n. 9, p. 991–1001, 2003.
- HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. Ontario: PEARSON, 2009. 937 p.
- HENRIQUE, S.; SANTANA, C. De; REGINA, E.; CAVALCANTI, A.; LUCIELLE, M.; LAURENTINO, S.; GUSTAVO, J.; DOMICIANO, J.; ATLÂNTICA, A. M. Identificação dos índices de vegetação com melhores respostas espectrais para a Mata Atlântica na cidade de São Paulo-SP. **Journal of Environmental**, v. 2, p. 200–209, 2018.
- HENTZ, Â. M. K.; RUZA, M. S.; CORTE, A. P. D.; SANQUETTA, C. R. Técnicas de sensoriamento remoto para estimativa de biomassa em ambientes florestais. **Enciclopédia Biosfera**, v. 10, n. 18, p. 2810–2833, 2014.
- HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195–213, 2002.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988. Disponível em: <<http://www.sciencedirect.com/science/article/pii/003442578890106X>>.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Município de Ribas do Rio Pardo**. Disponível em: <<https://cidades.ibge.gov.br/brasil/ms/ribas-do-rio-pardo/panorama>>. Acesso em: 24 set. 2018.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Estimativa da população 2016**. Disponível em: <<http://cidades.ibge.gov.br/xtras/temas.php?lang=&codmun=355220&idtema=130&search=sao-paulo%7Csorocaba%7Cestimativa-da-populacao-2016->>. Acesso em: 18 jul. 2018.
- JÚNIOR, A. F. D.; LANA, A. Q.; BERNARDES, F. F.; BRITO, J. O. Madeira, Energia

E Geração De Termoeletricidade. **Energia Na Agricultura**, v. 32, n. 2, p. 157–163, 2017. Disponível em: <<https://doi.org/10.17224/EnergAgric.2017v32n2p157-163>>.

KAMGAN, G.; MICHAEL, N. Ceratocystis species , including two new species associated with nitidulid beetles , on eucalypts in Australia. *Antonie van Leeuwenhoek*, v. 101, p. 217–241, 2012.

KARAN, S. K.; SAMADDER, S. R.; MAITI, S. K. Assessment of the capability of remote sensing and GIS techniques for monitoring reclamation success in coal mine degraded lands. **Journal of Environmental Management**, v. 182, p. 272–283, 2016.

KAUFMAN, Y. J.; TANRÉ, D. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 261–270, 1992.

LAN, Z.; LIU, Y. Study on Multi-Scale Window Determination for GLCM Texture Description in High-Resolution Remote Sensing Image Geo-Analysis Supported by GIS and Domain Knowledge. **International Journal of Geo-Information**, v. 7, n. 175, p. 1–24, 2018.

LANORTE, A.; LASAPONARA, R.; LOVALLO, M.; TELESCA, L. Fisher-Shannon information plane analysis of SPOT/VEGETATION normalized difference vegetation index (NDVI) time series to characterize vegetation recovery after fire disturbance. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, n. 1, p. 441–446, 2014.

LIU, W. T. H. **Aplicações de sensoriamento remoto**. 2. ed. São Paulo: Oficina de Textos, 2015. 908 p. ISBN: 978-85-7975-177-6

LÓPEZ-SERRANO, P. M.; LÓPEZ-SÁNCHEZ, C. A.; ÁLVAREZ-GONZÁLEZ, J. G.; GARCÍA-GUTIÉRREZ, J. A Comparison of Machine Learning Techniques Applied to Landsat-5 TM Spectral Data for Biomass Estimation. **Canadian Journal of Remote Sensing**, v. 42, n. 6, p. 690–705, 2016.

LU, D. The potential and challenge of remote sensing-based biomass estimation. **International Journal of Remote Sensing**, v. 27, n. 7, p. 1297–1328, 1 abr. 2006. Disponível em: <<https://doi.org/10.1080/01431160500486732>>.

LU, D.; CHEN, Q.; WANG, G.; LIU, L.; LI, G.; MORAN, E. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. **International Journal of Digital Earth**, v. 9, n. 1, p. 63–105, 2016. Disponível em: <<http://dx.doi.org/10.1080/17538947.2014.990526>>.

LU, D.; CHEN, Q.; WANG, G.; MORAN, E.; BATISTELLA, M.; ZHANG, M.; VAGLIO LAURIN, G.; SAAH, D. Aboveground Forest Biomass Estimation with Landsat and LiDAR Data and Uncertainty Analysis of the Estimates. **International Journal of Forestry Research**, v. 2012, n. 1, p. 1–16, 2012. Disponível em: <<http://www.hindawi.com/journals/ijfr/2012/436537/>>.

MACHADO, C. C.; DA SILVA, B. B.; DE ALBUQUERQUE, M. B.; GALVÍNCIO, J. D. Estimativa do balanço de energia utilizando imagens TM - Landsat 5 e o algoritmo SEBAL no litoral sul de pernambuco. **Revista Brasileira de Meteorologia**, v. 29, n. 1,

p. 55–67, 2014.

MALTAMO, M.; PESONEN, A.; KORHONEN, L.; KOUKI, J.; VEHMAS, M.; EERIKÄINEN, K. Inventory of aspen trees in spruce dominated stands in conservation area. **Forest Ecosystems** (2015), v. 12, n. 2, p. 2–12, 2015.

MARENGO, J. A. **Mudanças Climáticas Globais e seus Efeitos sobre a Biodiversidade: Caracterização do Clima Atual e Definição das Alterações Climáticas para o Território Brasileiro ao Longo do Século XXI**. 2. ed. Brasília: MMA, 2006. 212 p. ISBN 85-7738-038-6

MARONEZE, M. M.; ZEPKA, L. Q.; VIEIRA, J. G.; QUEIROZ, M. I.; JACOB-LOPES, E. A tecnologia de remoção de fósforo: Gerenciamento do elemento em resíduos industriais. **Revista Ambiente e Agua**, v. 9, n. 3, p. 445–458, 2014.

MENESES, P. R.; ALMEIDA, T. De. **Introdução ao processamento de imagem de sensoriamento remoto**. 1. ed. Brasília: Cnpq/Unb, 2012. 266 p.

MOHANAIHAH, P.; SATHYANARAYANA, P.; GURUKUMAR, L. Image Texture Feature Extraction Using GLCM Approach. **International Journal of Scientific and Research Publications**, v. 3, n. 5, p. 1–5, 2013.

MONTAVON, G.; ORR, G. B.; MÜLLER, K.-R. **Neural Networks: Tricks of the Trade**. 2. ed. Berlin: Springer, 2012. 769 p.

MURAVYOVA, E. A.; TIMERBAEV, R. R. Application of Artificial Neural Networks in the Process of Catalytic Cracking. **Optical Memory and Neural Networks**, v. 27, n. 3, p. 203–208, 2018.

MUSCI, M.; FEITOSA, R. Q.; VELLOSO, M. L. F.; NOVACK, T.; COSTA, G. A. O. P. Uma avaliação de descritores de textura baseados em códigos binários locais para classificação de imagens de sensoriamento remoto. **Bol. Ciênc. Geod.**, v. 17, n. 4, p. 549–570, 2011.

NEVTIPILOVA, V.; PASTWA, J.; BOORI, M. S.; VOZENILEK, V. Testing Artificial Neural Network (ANN) for Spatial Interpolation. **Geology & Geosciences**, v. 3, n. 2, p. 1–9, 2014.

NGUYEN, T.; YANG, Y.; BAE, K.; CHOI, S. Prediction of deformations of steel plate by artificial neural network in forming process with induction heating †. **Technology Journal of Mechanical Science and Technology**, v. 23, p. 1211–1221, 2009.

OLIVEIRA, M. M. de; HIGUCHI, N.; CELES, C. H.; HIGUCHI, F. G. TAMANHO E FORMAS DE PARCELAS PARA INVENTÁRIOS FLORESTAIS DE ESPÉCIES ARBÓREAS NA AMAZÔNIA CENTRAL. **Ciência Florestal**, v. 24, n. 3, p. 645–653, 2014.

OLIVEIRA, L. T. De; FERREIRA, M. Z.; CARVALHO, L. M. T. de; FILHO, A. C. F.; OLIVEIRA, T. C. de A. Determinação do volume de madeira em povoamento de eucalipto por escâner a laser aerotransportado. **Pesq. agropec. bras.**, v. 49, n. 1, p. 692–699, 2014.

OLIVEIRA, W. E. B.; FERNANDES, S. R. Classificação de Imagens de Satélite Utilizando Descritores de Textura. 2014.

OZKAN, U. Y.; OZDEMIR, I.; DEMIREL, T.; SAGLAM, S.; YESIL, A. Comparison of satellite images with different spatial resolutions to estimate stand structural diversity in urban forests. **Journal of Forestry Research**, v. 28, n. 4, p. 805–814, 2017.

PATROCINIO, A. C.; CARNEIRO, P. C. Análise de atributos de intensidade e textura na classificação de densidade mamária. **XXIV Congresso Brasileiro de Engenharia Biomédica – CBEB**, p. 634–637, 2014.

PATTERSON, J.; GIBSON, A. **Deep Learning: A Practitioner’s Approach**. 1. ed. O’Reilly Media, 2017. 532 p.

PAVÃO, L. L.; QUERINO, C. A. S.; PAVÃO, V. M.; BENEDITTI, C. A.; QUERINO, J. K. A. D. S.; MACHADO, N. G.; BIUDES, M. S.; UNIVERSIDADE. Índices de vegetação, NDVI e SAVI, em áreas de campos naturais e floresta densa em Humaitá - AM nos anos de 2009 e 2010. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, n. 1, p. 4115–4122, 2015.

PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C. **Meteorologia Agrícola 306**. 1 ed. Piracicaba: Escola Superior de Agricultura “Luiz de Queiroz” - USP, Fevereiro de 2007. 202 p.

PESSÔA, M. S. de P. **Introdução à Automação para Cursos de Engenharia e Gestão**. 1ª ed. São Paulo: Elsevier, 2014. 352 p.

PHAM, L. T. H.; BRABYN, L. Monitoring mangrove biomass change in Vietnam using SPOT images and an object-based approach combined with machine learning algorithms. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 128, p. 86–97, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2017.03.013>>.

PÖÇAS, I.; CUNHA, M.; PEREIRA, L. S.; ALLEN, R. G. Using remote sensing energy balance and evapotranspiration to characterize montane landscape vegetation with focus on grass and pasture lands. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, n. 1, p. 159–172, 2012.

PONTES, F. M.; MENDES, C. **Manual de Implantação de Cultivos Florestais – Cultura de Eucalipto**. Curitiba: Instituto de florestas do Paraná, 2016. 23 p.

QGIS Development Team. **QGIS(Geographic Information System):Open Source Geospatial Foundation Project.Versao 2.18.5**. Disponível em:<<http://www.qgis.org/>>. Acesso em: 25 nov. 2018.

QUEIROZ, W. T. De. **Amostragem em Inventário Florestal**. Belém: Edufra, 2012. 441 p.

QUINTANO, C.; FERNÁNDEZ-MANSO, A.; CALVO, L.; MARCOS, E.; VALBUENA, L. Land surface temperature as potential indicator of burn severity in forest Mediterranean ecosystems. **International Journal of Applied Earth Observation and Geoinformation**, v. 36, p. 1–12, 2015.

REZENDE, R. N.; LIMA, J. T.; ELÍS, L.; RAMOS, D.; RICARDO, P.; HEIN, G.; REINALDO, J. Wood Permeability in Eucalyptus grandis and Eucalyptus dunnii. **Floresta e Ambiente**, v. 25, n. 1, p. 1–7, 2018.

RICHARDSON, A. J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. **Photogrammetric Engineering and Remote Sensing**, v.

43, n. 2, p. 1541–1552, 1977.

RODRIGUEZ-GALIANO, V. F.; CHICA-OLMO, M.; ABARCA-HERNANDEZ, F.; ATKINSON, P. M.; JEGANATHAN, C. Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. **Remote Sensing of Environment**, v. 121, p. 93–107, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2011.12.003>>.

ROGERSON, P. A. **Métodos Estatísticos Para Geografia: Um Guia Para o Estudante**. 7. ed. Porto Alegre: Bookman Editora, 2012. 348 p.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W.; HARLAN, J. C. Monitoring the vernal advancement of retrogradation (greenwave effect) of natural vegetation. **NASA/GSFC Type III Final Report**, p. 371, 1974.

RUDY, A. C. A.; LAMOUREUX, S. F.; TREITZ, P.; COLLINGWOOD, A. Identifying permafrost slope disturbance using multi-temporal optical satellite images and change detection techniques. **Cold Regions Science and Technology**, v. 88, p. 37–49, 2013.

R DEVELOPMENT CORE TEAM. **R:Project** for Statistical Computing. Versão 3.5.1. Disponível em: <<http://www.R-project.org/>>. Acesso em: 25 nov. 2018.

SAHU, B. K.; BALIARSINGH, S. K.; LOTLIKER, A. A.; PARIDA, C. Winter Thermal Inversion and Trichodesmium Dominance in North-Western Bay of Bengal. **Ocean Science Journal**, v. 52, n. 2, p. 301–306, 2017.

SAMIRBHAI, M. D.; CHEN, S.; LOW, K. S. A hamming distance and spearman-correlation based star identification algorithm. **IEEE Transactions on Aerospace and Electronic Systems**, v. 9251, p. 1–13, 2018.

SANTIAGO, M. M.; SILVA, H. A.; GALVINCIO, J. D.; OLIVEIRA, T. H. Análise da Cobertura Vegetal Através dos Índices de Vegetação (NDVI, SAVI e IAF) no Entorno da Barragem do Botafogo-PE. **Xiv Sbsr**, p. 3003–3009, 2009.

SANTOS, A. R.; PELUZIO, T. M.O.; SAITO, N. S. **SPRING 5.1.2 passo a passo aplicações práticas**. 2. ed. CAUFES: Alegre, ES. 153 p.

SANTOS, A. R. D. et al. **Sensoriamento Remoto no Arcgis 10.2.2: Passo a passo**. 1. ed. CAUFES: Alegre, ES, 2014. 107 p.

SARKER, L. R.; NICHOL, J. E. Improved forest biomass estimates using ALOS AVNIR-2 texture indices. **Remote Sensing of Environment**, v. 115, n. 4, p. 968–977, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2010.11.010>>.

(SBF) SERVIÇO FLORESTAL BRASILEIRO. **Relatório de gestão 2016**. 1. ed. Brasília: SBF, 2017. 138 p.

SCHMID, M.; HUNZIKER, S.; WÜEST, A. Lake surface temperatures in a changing climate: A global sensitivity analysis. **Climatic Change**, v. 124, n. 1–2, p. 301–315, 2014.

SCHULTZ, K. I.; KELLY, M. W.; BAKER, J. J.; BLACKWELL, M. H.; BROWN, M.

G.; COLONERO, C. B.; DAVID, C. L.; TYRRELL, B. M.; WEY, J. R. Digital-Pixel Focal Plane Array Technology. **Lincoln laboratory Journal**, v. 20, n. 2, p. 36–51, 2014.

SERVIÇO FLORESTAL BRASILEIRO. **Manual de campo: procedimentos para a coleta de dados biofísicos e socioambientais**. Belém: Edufra, 2012. 441 p. ISBN 978-85-7295-070-1

SHEN, Q.; GAO, G.; LÜ, Y.; WANG, S.; JIANG, X.; FU, B. Science of the Total Environment River flow is critical for vegetation dynamics : Lessons from multi-scale analysis in a hyper-arid endorheic basin. v. 604, p. 290–298, 2017.

SHIJIN, K. P. S.; DHARUN, V. S. Extraction of Texture Features using GLCM and Shape Features using Connected Regions. **International Journal of Engineering and Technology**, v. 8, n. 6, p. 2926–2930, 2016. Disponível em: <<http://www.enggjournals.com/ijet/abstract.html?file=16-08-06-254>>.

SIEGEL, S.; JUNIOR., N. J. C. **Estatística não-Paramétrica Para Ciências do Comportamento**. 2. ed. São Paulo: Artmed Editora, 2006. 448 p.

SILVA, B. B. da; BRAGA, A. C.; BRAGA, C. C.; OLIVEIRA, L. M. M. de; MONTENEGRO, S. M. G. L.; JUNIOR, B. B. Procedures for calculation of the albedo with OLI-Landsat 8 images: Application to the Brazilian semi-arid. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 20, n. 1, p. 3–8, 2016.

SILVA, B. B. da; MONTENEGRO, S. M. G. L.; DA SILVA, V. de P. R.; DA ROCHA, H. R.; GALVANCIO, J. D.; DE OLIVEIRA, L. M. M. Determination of instantaneous and daily net radiation from TM - Landsat 5 data in a subtropical watershed. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 135, p. 42–49, 2015.

SKOWRONSKI, N. S.; CLARK, K. L.; GALLAGHER, M.; BIRDSEY, R. A.; HOM, J. L. Airborne laser scanner-assisted estimation of aboveground biomass change in a temperate oak-pine forest. **Remote Sensing of Environment**, v. 151, p. 166–174, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2013.12.015>>.

SOARES, C.; ROBAINA, D.; PEITER, X.; LUIS, J.; MARIA, S. Redes neurais artificiais na estimativa da retenção de água do solo. **Ciência Rural**, v. 44, n. 2, p. 293–300, 2014.

SOUSA, C.L.; PONZONI, F.J. Avaliação de índices de vegetação e de bandas TM/Landsat para estimativa de volume de madeira em floresta implantada de Pinus spp. Anais IX Simpósio Brasileiro de Sensoriamento Remoto. São José dos Campos: INPE, 1998. 1537-1547 p.

SOH, L.; TSATSOUKIS, C.; MEMBER, S. Texture Analysis of SAR Sea Ice Imagery Using Gray Level Co-Occurrence Matrices. **Ieee Transactions on Geoscience and Remote Sensing**, v. 37, n. 2, p. 780–795, 1999.

STAFFORD, J. V. **Precision agriculture '13**. 1. ed. Catasalonia (Espanha): Wageningen Academic Pub, 2013.823 p.

TAHIR, M. A.; BOURIDANE, A.; KURUGOLLU, F. An FPGA Based Coprocessor for GLCM and Haralick Texture Features and their Application in Prostate Cancer

Classificatio. **Analog Integrated Circuits and Signal Processing**, v. 43, p. 205–215, 2005.

THENKABAIL, P. S.; LYON, J. G.; HUETE, A. **Hyperspectral Remote Sensing of Vegetation**. 1. ed. New York: CRC Press, 2016. 782 p.

TONINI, H. Amostragem para a estimativa de produção de sementes de castanheira - do - brasil em floresta nativa. **Pesq. agropec. bras.**, v. 48, n. 5, p. 519–527, 2013.

TUOMINEN, S.; PEKKARINEN, A. Performance of different spectral and textural aerial photograph features in multi-source forest inventory. **Remote Sensing of Environment**, v. 94, n. 2, p. 256–268, 2005.

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.

VELOSO, T. fluxos de calor na superfície e evapotranspiração diária em áreas agrícolas e de vegetação nativa na bacia do jacuí jacuí por meio de imagens orbitais. 2009. 85 f. Dissertação (Mestrado em Sensoriamento Remoto) – Área de concentração em Sensoriamento Remoto Aplicado a Recursos Naturais e do Ambiente, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

WANG, G.; ZHANG, M.; GERTNER, G. Z.; OYANA, T.; MCROBERTS, R. E.; GE, H. Uncertainties of mapping aboveground forest carbon due to plot locations using national forest inventory plot and remotely sensed data. **Scandinavian Journal of Forest Research**, v. 26, n. 4, p. 360–373, 1 ago. 2011. Disponível em: <<https://doi.org/10.1080/02827581.2011.564204>>.

WICKHAM, H.; FRANÇOIS, R.; HENRY, L.; MÜLLER, K. **dplyr: A Grammar of Data Manipulation - R package version 0.7.6**. Disponível em: <<https://CRAN.R-project.org/package=dplyr>>. Acesso em: 25 nov. 2018.

WILCKEN, C. F.; POGETTO, M. F. A. D.; LIMA, A. C. V.; DIAS, T. K. R.; MASSON, M. V.; FILHO, P. J. F. **Guia Prático de Manejo de Plantações de Eucalipto**. 21. ed. Botucatu: FEPAF, 2008. 25 p. ISBN: 978-85-98187-10-5

WU, S.-T.; CHEN, Y.-S. Examining eco-environmental changes at major recreational sites in Kenting National Park in Taiwan by integrating SPOT satellite images and NDVI. **Tourism Management**, v. 57, p. 23–36, 2016.

YOUSSEF, D.; EL-GHANDOOR, H.; KANDEL, H.; EL-AZAB, J.; HASSAB-ELNABY, S. Estimation of articular cartilage surface roughness using gray-level co-occurrence matrix of laser speckle image. **Materials**, v. 10, n. 7, p. 1–13, 2017.

ZHANG, H.; LI, Q.; LIU, J.; DU, X.; DONG, T.; MCNAIRN, H.; CHAMPAGNE, C.; LIU, M.; SHANG, J. Object-based crop classification using multi-temporal SPOT-5 imagery and textural features with a Random Forest classifier. **Geocarto International**, v. 33, n. 10, p. 1017–1035, 2018. Disponível em: <<http://doi.org/10.1080/10106049.2017.1333533>>.

ZHANG, J.; LI, P.; WANG, J. Urban built-Up area extraction from landsat TM/ETM+ images using spectral information and multivariate texture. **Remote Sensing**, v. 6, n. 8, p. 7339–7359, 2014.

ZHANG, L.; CHENG, Q.; LI, C. Improved model for estimating the biomass of *Populus euphratica* forest using the integration of spectral and textural features from the Chinese high-resolution remote sensing satellite GaoFen-1. **Journal of Applied Remote Sensing**, v. 9, n. 1, 2015.

ZHANG, X.; CUI, J.; WANG, W.; LIN, C. A study for texture feature extraction of high-resolution satellite images based on a direction measure and gray level co-occurrence matrix fusion algorithm. **Sensors (Switzerland)**, v. 17, n. 7, 2017.

ZHU, Y.; LIU, K.; LIU, L.; WANG, S.; LIU, H. Retrieval of mangrove aboveground biomass at the individual species level with worldview-2 images. **Remote Sensing**, v. 7, n. 9, p. 12192–12214, 2015.

ANEXO I

Bias e pesos sinápticos resultantes da RNA construída. Organizados na ordem gerada pelo programa R.

Bias e pesos sinápticos		Bias e pesos sinápticos		Bias e pesos sinápticos	
Intercept,to,1layhid1	0,529	Idade,to,1layhid4	-1,298	SA_B3,to,1layhid8	-0,138
B1,to,1layhid1	-1,105	Intercept,to,1layhid5	0,493	Idade,to,1layhid8	1,622
B2,to,1layhid1	-0,241	B1,to,1layhid5	-0,785	Intercept,to,1layhid9	0,771
B3,to,1layhid1	-2,673	B2,to,1layhid5	-1,569	B1,to,1layhid9	-0,167
GNDVI,to,1layhid1	-1,110	B3,to,1layhid5	0,236	B2,to,1layhid9	-2,222
SA_B1,to,1layhid1	-0,256	GNDVI,to,1layhid5	-0,620	B3,to,1layhid9	1,057
SV_B1,to,1layhid1	-1,243	SA_B1,to,1layhid5	-0,533	GNDVI,to,1layhid9	-0,777
SA_B2,to,1layhid1	0,629	SV_B1,to,1layhid5	-0,262	SA_B1,to,1layhid9	0,613
SA_B3,to,1layhid1	-1,231	SA_B2,to,1layhid5	-0,784	SV_B1,to,1layhid9	1,044
Idade,to,1layhid1	-0,025	SA_B3,to,1layhid5	0,924	SA_B2,to,1layhid9	-0,144
Intercept,to,1layhid2	-0,813	Idade,to,1layhid5	-1,848	SA_B3,to,1layhid9	0,897
B1,to,1layhid2	1,155	Intercept,to,1layhid6	0,490	Idade,to,1layhid9	0,553
B2,to,1layhid2	-1,388	B1,to,1layhid6	0,712	Intercept,to,1layhid10	0,134
B3,to,1layhid2	-0,065	B2,to,1layhid6	1,519	B1,to,1layhid10	0,454
GNDVI,to,1layhid2	-0,070	B3,to,1layhid6	-0,892	B2,to,1layhid10	-0,717
SA_B1,to,1layhid2	1,592	GNDVI,to,1layhid6	0,226	B3,to,1layhid10	0,156
SV_B1,to,1layhid2	0,459	SA_B1,to,1layhid6	0,870	GNDVI,to,1layhid10	0,502
SA_B2,to,1layhid2	-2,011	SV_B1,to,1layhid6	0,228	SA_B1,to,1layhid10	-1,192
SA_B3,to,1layhid2	-1,596	SA_B2,to,1layhid6	-0,317	SV_B1,to,1layhid10	-0,085
Idade,to,1layhid2	1,785	SA_B3,to,1layhid6	0,536	SA_B2,to,1layhid10	-1,257
Intercept,to,1layhid3	-1,757	Idade,to,1layhid6	-1,597	SA_B3,to,1layhid10	-0,860
B1,to,1layhid3	-0,183	Intercept,to,1layhid7	3,053	Idade,to,1layhid10	1,066
B2,to,1layhid3	0,661	B1,to,1layhid7	0,924	Intercept,to,1layhid11	0,043
B3,to,1layhid3	0,556	B2,to,1layhid7	2,856	B1,to,1layhid11	-0,069
GNDVI,to,1layhid3	0,531	B3,to,1layhid7	-1,205	B2,to,1layhid11	0,488
SA_B1,to,1layhid3	1,483	GNDVI,to,1layhid7	-0,057	B3,to,1layhid11	1,406
SV_B1,to,1layhid3	0,076	SA_B1,to,1layhid7	-0,276	GNDVI,to,1layhid11	-2,198
SA_B2,to,1layhid3	-0,376	SV_B1,to,1layhid7	0,627	SA_B1,to,1layhid11	0,524
SA_B3,to,1layhid3	2,243	SA_B2,to,1layhid7	0,534	SV_B1,to,1layhid11	-1,091
Idade,to,1layhid3	-0,596	SA_B3,to,1layhid7	0,098	SA_B2,to,1layhid11	0,264
Intercept,to,1layhid4	0,571	Idade,to,1layhid7	2,175	SA_B3,to,1layhid11	2,149
B1,to,1layhid4	1,068	Intercept,to,1layhid8	1,066	Idade,to,1layhid11	-0,198
B2,to,1layhid4	2,541	B1,to,1layhid8	-0,102	Intercept,to,2layhid1	-0,691
B3,to,1layhid4	-0,303	B2,to,1layhid8	0,409	1layhid,1,to,2layhid1	0,389
GNDVI,to,1layhid4	0,697	B3,to,1layhid8	-1,588	1layhid,2,to,2layhid1	0,407
SA_B1,to,1layhid4	-1,371	GNDVI,to,1layhid8	0,414	1layhid,3,to,2layhid1	-0,611
SV_B1,to,1layhid4	-0,001	SA_B1,to,1layhid8	1,081	1layhid,4,to,2layhid1	-0,611
SA_B2,to,1layhid4	-2,829	SV_B1,to,1layhid8	-0,201	1layhid,5,to,2layhid1	-1,281
SA_B3,to,1layhid4	-2,222	SA_B2,to,1layhid8	0,169	1layhid,6,to,2layhid1	1,845

Bias e pesos sinápticos		Bias e pesos sinápticos		Bias e pesos sinápticos	
1layhid,7,to,2layhid1	-0,693	1layhid,2,to,2layhid5	0,535	1layhid,9,to,2layhid8	0,349
1layhid,8,to,2layhid1	0,143	1layhid,3,to,2layhid5	2,282	1layhid,10,to,2layhid8	-0,655
1layhid,9,to,2layhid1	-0,306	1layhid,4,to,2layhid5	-0,022	1layhid,11,to,2layhid8	-0,436
1layhid,10,to,2layhid1	-1,191	1layhid,5,to,2layhid5	0,889	Intercept,to,2layhid9	0,065
1layhid,11,to,2layhid1	1,266	1layhid,6,to,2layhid5	1,658	1layhid,1,to,2layhid9	-0,260
Intercept,to,2layhid2	1,060	1layhid,7,to,2layhid5	-0,301	1layhid,2,to,2layhid9	0,275
1layhid,1,to,2layhid2	0,449	1layhid,8,to,2layhid5	1,578	1layhid,3,to,2layhid9	-1,291
1layhid,2,to,2layhid2	-1,432	1layhid,9,to,2layhid5	0,171	1layhid,4,to,2layhid9	-1,040
1layhid,3,to,2layhid2	1,204	1layhid,10,to,2layhid5	1,152	1layhid,5,to,2layhid9	-0,895
1layhid,4,to,2layhid2	0,770	1layhid,11,to,2layhid5	0,626	1layhid,6,to,2layhid9	-0,712
1layhid,5,to,2layhid2	-0,199	Intercept,to,2layhid6	0,437	1layhid,7,to,2layhid9	-0,787
1layhid,6,to,2layhid2	-0,630	1layhid,1,to,2layhid6	1,832	1layhid,8,to,2layhid9	-0,439
1layhid,7,to,2layhid2	0,348	1layhid,2,to,2layhid6	-0,883	1layhid,9,to,2layhid9	-0,350
1layhid,8,to,2layhid2	-0,616	1layhid,3,to,2layhid6	0,225	1layhid,10,to,2layhid9	1,491
1layhid,9,to,2layhid2	-0,341	1layhid,4,to,2layhid6	1,792	1layhid,11,to,2layhid9	1,470
1layhid,10,to,2layhid2	-1,738	1layhid,5,to,2layhid6	-0,583	Intercept,to,2layhid10	0,329
1layhid,11,to,2layhid2	0,770	1layhid,6,to,2layhid6	0,635	1layhid,1,to,2layhid10	1,042
Intercept,to,2layhid3	-0,209	1layhid,7,to,2layhid6	-0,983	1layhid,2,to,2layhid10	-0,239
1layhid,1,to,2layhid3	-0,736	1layhid,8,to,2layhid6	1,686	1layhid,3,to,2layhid10	-0,411
1layhid,2,to,2layhid3	2,038	1layhid,9,to,2layhid6	-1,233	1layhid,4,to,2layhid10	-0,037
1layhid,3,to,2layhid3	0,064	1layhid,10,to,2layhid6	-1,461	1layhid,5,to,2layhid10	0,872
1layhid,4,to,2layhid3	0,665	1layhid,11,to,2layhid6	1,291	1layhid,6,to,2layhid10	0,598
1layhid,5,to,2layhid3	0,479	Intercept,to,2layhid7	0,587	1layhid,7,to,2layhid10	1,735
1layhid,6,to,2layhid3	1,194	1layhid,1,to,2layhid7	-1,595	1layhid,8,to,2layhid10	-0,589
1layhid,7,to,2layhid3	1,086	1layhid,2,to,2layhid7	0,943	1layhid,9,to,2layhid10	-1,606
1layhid,8,to,2layhid3	0,444	1layhid,3,to,2layhid7	-0,798	1layhid,10,to,2layhid10	1,291
1layhid,9,to,2layhid3	0,104	1layhid,4,to,2layhid7	2,362	1layhid,11,to,2layhid10	0,792
1layhid,10,to,2layhid3	0,218	1layhid,5,to,2layhid7	-0,338	Intercept,to,2layhid11	-0,199
1layhid,11,to,2layhid3	2,018	1layhid,6,to,2layhid7	0,631	1layhid,1,to,2layhid11	0,508
Intercept,to,2layhid4	-0,085	1layhid,7,to,2layhid7	1,760	1layhid,2,to,2layhid11	-0,162
1layhid,1,to,2layhid4	0,559	1layhid,8,to,2layhid7	-0,905	1layhid,3,to,2layhid11	-0,515
1layhid,2,to,2layhid4	0,979	1layhid,9,to,2layhid7	-0,457	1layhid,4,to,2layhid11	1,241
1layhid,3,to,2layhid4	0,957	1layhid,10,to,2layhid7	0,161	1layhid,5,to,2layhid11	-0,083
1layhid,4,to,2layhid4	-1,105	1layhid,11,to,2layhid7	-0,471	1layhid,6,to,2layhid11	2,647
1layhid,5,to,2layhid4	2,211	Intercept,to,2layhid8	-1,375	1layhid,7,to,2layhid11	2,212
1layhid,6,to,2layhid4	0,898	1layhid,1,to,2layhid8	0,622	1layhid,8,to,2layhid11	-0,017
1layhid,7,to,2layhid4	-0,543	1layhid,2,to,2layhid8	-1,938	1layhid,9,to,2layhid11	0,110
1layhid,8,to,2layhid4	0,721	1layhid,3,to,2layhid8	-0,841	1layhid,10,to,2layhid11	-0,009
1layhid,9,to,2layhid4	-0,240	1layhid,4,to,2layhid8	1,176	1layhid,11,to,2layhid11	2,502
1layhid,10,to,2layhid4	0,247	1layhid,5,to,2layhid8	-1,044	Intercept,to,2layhid12	1,015
1layhid,11,to,2layhid4	-0,191	1layhid,6,to,2layhid8	1,180	1layhid,1,to,2layhid12	2,265
Intercept,to,2layhid5	-0,958	1layhid,7,to,2layhid8	0,638	1layhid,2,to,2layhid12	-0,343
1layhid,1,to,2layhid5	0,264	1layhid,8,to,2layhid8	2,788	1layhid,3,to,2layhid12	-1,042

Bias e pesos sinápticos		Bias e pesos sinápticos		Bias e pesos sinápticos	
1layhid,4,to,2layhid12	1,828	1layhid,11,to,2layhid15	-0,608	1layhid,6,to,2layhid19	0,451
1layhid,5,to,2layhid12	1,803	Intercept,to,2layhid16	0,509	1layhid,7,to,2layhid19	0,027
1layhid,6,to,2layhid12	0,228	1layhid,1,to,2layhid16	0,071	1layhid,8,to,2layhid19	0,212
1layhid,7,to,2layhid12	0,932	1layhid,2,to,2layhid16	-2,106	1layhid,9,to,2layhid19	0,575
1layhid,8,to,2layhid12	-0,153	1layhid,3,to,2layhid16	-1,360	1layhid,10,to,2layhid19	0,293
1layhid,9,to,2layhid12	-0,400	1layhid,4,to,2layhid16	0,305	1layhid,11,to,2layhid19	1,232
1layhid,10,to,2layhid12	-2,075	1layhid,5,to,2layhid16	-1,742	Intercept,to,2layhid20	0,559
1layhid,11,to,2layhid12	-0,348	1layhid,6,to,2layhid16	-0,124	1layhid,1,to,2layhid20	0,363
Intercept,to,2layhid13	1,085	1layhid,7,to,2layhid16	0,557	1layhid,2,to,2layhid20	1,342
1layhid,1,to,2layhid13	0,156	1layhid,8,to,2layhid16	0,018	1layhid,3,to,2layhid20	-0,330
1layhid,2,to,2layhid13	-0,139	1layhid,9,to,2layhid16	-0,725	1layhid,4,to,2layhid20	0,665
1layhid,3,to,2layhid13	0,387	1layhid,10,to,2layhid16	0,358	1layhid,5,to,2layhid20	0,580
1layhid,4,to,2layhid13	0,563	1layhid,11,to,2layhid16	1,839	1layhid,6,to,2layhid20	-0,258
1layhid,5,to,2layhid13	-0,993	Intercept,to,2layhid17	0,664	1layhid,7,to,2layhid20	-0,820
1layhid,6,to,2layhid13	0,218	1layhid,1,to,2layhid17	1,697	1layhid,8,to,2layhid20	0,699
1layhid,7,to,2layhid13	0,349	1layhid,2,to,2layhid17	0,615	1layhid,9,to,2layhid20	-0,073
1layhid,8,to,2layhid13	-1,052	1layhid,3,to,2layhid17	0,714	1layhid,10,to,2layhid20	1,064
1layhid,9,to,2layhid13	0,423	1layhid,4,to,2layhid17	-0,061	1layhid,11,to,2layhid20	-1,479
1layhid,10,to,2layhid13	0,518	1layhid,5,to,2layhid17	0,940	Intercept,to,volume	0,497
1layhid,11,to,2layhid13	0,071	1layhid,6,to,2layhid17	0,274	2layhid,1,to,volume	-1,090
Intercept,to,2layhid14	0,046	1layhid,7,to,2layhid17	0,194	2layhid,2,to,volume	-2,122
1layhid,1,to,2layhid14	-1,555	1layhid,8,to,2layhid17	-1,505	2layhid,3,to,volume	-0,078
1layhid,2,to,2layhid14	3,211	1layhid,9,to,2layhid17	-0,505	2layhid,4,to,volume	0,388
1layhid,3,to,2layhid14	-1,102	1layhid,10,to,2layhid17	1,152	2layhid,5,to,volume	0,690
1layhid,4,to,2layhid14	-2,586	1layhid,11,to,2layhid17	-0,074	2layhid,6,to,volume	-2,388
1layhid,5,to,2layhid14	-0,357	Intercept,to,2layhid18	-0,062	2layhid,7,to,volume	0,539
1layhid,6,to,2layhid14	-1,566	1layhid,1,to,2layhid18	-1,717	2layhid,8,to,volume	-0,835
1layhid,7,to,2layhid14	0,365	1layhid,2,to,2layhid18	-0,564	2layhid,9,to,volume	0,989
1layhid,8,to,2layhid14	-1,445	1layhid,3,to,2layhid18	0,731	2layhid,10,to,volume	-0,634
1layhid,9,to,2layhid14	0,465	1layhid,4,to,2layhid18	0,322	2layhid,11,to,volume	1,514
1layhid,10,to,2layhid14	0,327	1layhid,5,to,2layhid18	0,460	2layhid,12,to,volume	-0,802
1layhid,11,to,2layhid14	0,473	1layhid,6,to,2layhid18	-2,780	2layhid,13,to,volume	-1,755
Intercept,to,2layhid15	-0,745	1layhid,7,to,2layhid18	0,825	2layhid,14,to,volume	3,462
1layhid,1,to,2layhid15	-0,608	1layhid,8,to,2layhid18	0,288	2layhid,15,to,volume	0,460
1layhid,2,to,2layhid15	-0,142	1layhid,9,to,2layhid18	0,773	2layhid,16,to,volume	-1,296
1layhid,3,to,2layhid15	-0,957	1layhid,10,to,2layhid18	-0,071	2layhid,17,to,volume	-0,732
1layhid,4,to,2layhid15	-0,648	1layhid,11,to,2layhid18	0,244	2layhid,18,to,volume	0,082
1layhid,5,to,2layhid15	2,277	Intercept,to,2layhid19	-0,563	2layhid,19,to,volume	1,430
1layhid,6,to,2layhid15	0,504	1layhid,1,to,2layhid19	1,522	2layhid,20,to,volume	1,639
1layhid,7,to,2layhid15	-0,090	1layhid,2,to,2layhid19	0,223		
1layhid,8,to,2layhid15	0,315	1layhid,3,to,2layhid19	1,812		
1layhid,9,to,2layhid15	-0,121	1layhid,4,to,2layhid19	-1,183		
1layhid,10,to,2layhid15	-0,366	1layhid,5,to,2layhid19	-0,618		