

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA DE PRODUÇÃO E SISTEMAS**

FLÁVIO CHIARELLO

**APLICAÇÃO DAS REDES NEURAIS ARTIFICIAIS NA PROGNOSE DE VOLUMES
PARCIAIS E TOTAIS DE PLANTAÇÕES DE *Pinus taeda* L**

**CURITIBA
2019**

FLÁVIO CHIARELLO

**APLICAÇÃO DAS REDES NEURAIS ARTIFICIAIS NA PROGNOSE DE
VOLUMES PARICIAIS E TOTAIS DE PLANTAÇÕES DE *Pinus taeda L***

Dissertação apresentada ao Curso de Pós-Graduação em Engenharia de Produção e Sistemas, área de concentração Métodos de Pesquisa Operacional, da Pontifícia Universidade Católica do Paraná, como requisito parcial à obtenção do título de mestre em Engenharia de Produção e Sistemas.

Orientadora: Prof.^a Dr.^a Maria Teresinha Arns Steiner

CURITIBA

2019

Dados da Catalogação na Publicação
Pontifícia Universidade Católica do Paraná
Sistema Integrado de Bibliotecas – SIBI/PUCPR
Biblioteca Central
Edilene de Oliveira dos Santos CRB/9 1636

C532a
2019 Chiarello, Flávio
Aplicação das redes neurais artificiais na prognose de volumes parciais e totais de plantações de Pinus taeda L / Flávio Chiarello ; orientadora, Maria Teresinha Arns Steiner. -- 2019
127 f. : il. ; 30 cm

Dissertação (mestrado) – Pontifícia Universidade Católica do Paraná, Curitiba, 2019.
Bibliografia: f. 112-127

1. Engenharia da produção. 2. Redes neurais (Computação). 3. Inteligência artificial. 4. Florestas – Manejo. I. Steiner, Maria Teresinha Arns.
II. Pontifícia Universidade Católica do Paraná. Programa de Pós-Graduação em Engenharia de Produção e Sistemas. IV. Título.

CDD 20. ed. – 670

RESUMO

A Inteligência Artificial (IA) tem sido uma importante ferramenta de apoio em diferentes esferas de atuação, possibilitando a agregação de conhecimento, a otimização de processos e a aplicação de metodologias que sejam capazes de resolver problemas reais complexos. Apesar de concentrar um amplo espaço de métricas de sucesso, a abordagem de Redes Neurais Artificiais (RNAs), uma técnica inspirada no sistema nervoso central, vem ganhando notoriedade e relevância no que tange à classificação de padrões, predição de parâmetros intrínsecos, sensoriamento remoto, mineração de dados (*data mining*), entre outras aplicações. O objetivo deste trabalho foi a construção e incorporação de uma rede neural do tipo Função de Base Radial (RBF) aplicada em dois estudos de casos orientados à prognose do volume de madeira de *Pinus taeda* L. sob diferentes condições impostas no manejo florestal. O primeiro caso teve como principal premissa, o uso do *software* SisPinus como agente intermediador, responsável pelo fomento de informações para os processos de identificação e seleção dos atributos mais relevantes (21 ao todo), não só para a determinação do volume final como, também, no assessoramento para a geração de 144 instâncias/padrões que serviram de entrada (*input*) para a rede implementada no *software* Matlab r2017b. O segundo cenário contou com o ajuste de uma função de afilamento para determinar o diâmetro a cada 1% da altura dos fustes. Posteriormente, em conjunto com integrações parciais, foi possível encontrar o volume total e parcial do tronco das árvores associadas aos intervalos de diâmetro previamente estabelecidos. Em termos de acurácia, as arquiteturas de maior *ranking* contabilizaram um Erro Quadrático Médio (EQM) de $2,1631 \times 10^{-9}$ no estudo A e, para o estudo B, $4,3 \times 10^{-04}$; $1,2 \times 10^{-04}$; $1,8 \times 10^{-04}$; $1,00 \times 10^{-04}$ e $3,01 \times 10^{-5}$.

Palavras-chave: SisPinus, Inteligência Artificial, Manejo Florestal.

ABSTRACT

Artificial Intelligence (AI) has been an important support tool in different spheres of activity, enabling the knowledge aggregation, the process optimization and the application of methodologies capable of solving complex real problems. Although focusing on a wide space of successful metrics, the Artificial Neural Networks (ANN) approach, a technique inspired by the central nervous system, has been gaining notoriety and relevance with regard to the classification of standards, prediction of intrinsic parameters, remote sensing, data mining and other applications. The objective of this work was the construction and incorporation of a neural network of the Radial Basis Function (RBF) type applied in two cases studies oriented to the prognosis of the wood volume of *Pinus taeda L.* under different conditions imposed in the forest management. The first case was based on the use of the SisPinus software as an intermediary agent, responsible for the promotion of informations to the processes of identification and selection of the most relevant attributes (21 in all), not only for volume determination as also as in the advisory for the generation of 144 instances / standards that served as input for the network implemented in Matlab software r2017b. The second scenario involved the adjustment of a tapering function to determine the diameter at each 1% of the height of the bole. Later, together with partial integrations, it was possible to find the volume total and partial of each tree segment associated with the previously established diameter ranges. In terms of accuracy, the highest ranking architectures counted a Mean Square Error (MSE) of $2,1631 \times 10^{-9}$ in study A and , for study B, $4,3 \times 10^{-4}$; $1,2 \times 10^{-4}$; $1,8 \times 10^{-4}$; $1,00 \times 10^{-4}$ and $3,01 \times 10^{-5}$.

Key-words: SisPinus, Artificial Intelligence, Forest Management.

AGRADECIMENTOS

Primeiramente agradeço a Deus por todas as realizações, pelas conquistas obtidas durante a minha vida, pelos sucessos e fracassos que me tornaram uma pessoa melhor.

Pelos meus pais, que sempre procuraram me apoiar e me incentivar a estudar e lutar pelos meus sonhos.

À minha mãe, por sempre estar ao meu lado nos momentos mais difíceis, me apoiando e incentivando a estudar e a lutar contra os obstáculos que a vida me impôs.

Ao meu pai, por me escutar e sempre me dar ideias diferentes que jamais pensei.

À minha vó, por me ajudar nas correções e estar disposta para me ajudar no que for.

À Professora Dr^a. Maria Teresinha Arns Steiner, por toda ajuda, paciência, profissionalismo e orientação durante o período de construção deste trabalho.

Aos meus colegas, Júlio César Ferreira e Fernanda Medeiros Assef, por me darem todo suporte necessário para o desenvolvimento da revisão sistemática de literatura e das redes neurais no Matlab.

Um agradecimento especial para minha Madrinha, Susete Chiarello, ao pesquisador da EMBRAPA, Edilson Batista de Oliveira, ao Professor Júlio Arce e ao chefe da EMBRAPA, Édson Tadeu Iede por todo auxílio e confiança depositada.

Por fim, deixo meu agradecimento aos meus amigos que me deram força e aos demais familiares que, de alguma forma, contribuíram com este trabalho.

LISTA DE ILUSTRAÇÕES

Figura 2.1: Esquemática de algumas das possibilidades de emprego da madeira	18
Figura 2.2: Impacto dos desbastes ao longo do tempo	24
Figura 2.3: Ilustração de um neurônio artificial	31
Figura 2.4: Descrição de um Neurônio não linear	32
Figura 2.5: Exemplo de uma rede feedforward de camada única	33
Figura 2.6: Exemplo de uma rede <i>feedforward</i> de camada única	34
Figura 2.7: Exemplo de uma rede recorrente	35
Figura 2.8: Arquitetura de uma rede do tipo MLP	36
Figura 2.9: Exemplo de uma Rede de Múltiplas Camadas	38
Figura 2.10: Representação de uma rede do tipo RBF	41
Figura 2.11: Classificação por Rede MLP (esquerda) e RBF (direita)	42
Figura 3.1: Metodologia aplicada para as Revisões Sistemática e Bibliométrica	47
Figura 3.2: Critérios para a filtragem dos 43 artigos correlatos	48
Figura 3.3: As 43 publicações florestais analisadas e seus anos de publicação	49
Figura 3.4: Relação (Autor-Objetivos) dos 43 artigos selecionados	50
Figura 3.5: Técnicas complementares abordadas pelos 31 (dos 43) artigos	51
Figura 3.6: Modelos de RNAs mais utilizados pelos 43 trabalhos	52
Figura 3.7: Principais funções de ativação empregadas nos 43 artigos	53
Figura 3.8: Métodos utilizados para a avaliação das RNAs nos 43 artigos	54
Figura 3.9: Distribuição geográfica dos 43 trabalhos, envolvendo diversos autores	55
Figura 3.10: Softwares utilizados para a implementação da linguagem empregada nos 43 trabalhos analisados	56
Figura 5.1: Definição da metodologia para o caso A	85
Figura 5.2: Definição da metodologia para o caso B	89
Figura 6.1: Gráfico sobre o desempenho da RBF para o seu conjunto de treinamento	91
Figura 6.2: Comparação entre os volumes finais de <i>Pinus taeda</i> L. obtidos pelo software SisPinus e pela utilização da rede RBF	93
Figura 6.3: Histograma da média e desvio padrão para os dois resultados obtidos na fase de testes	94
Figura 6.4: Comportamento do Diâmetro (di) em função da Altura (hi/ht)	95
Figura 6.5: Gráfico de dispersão entre o diâmetro observado e calculado	96
Figura 6.6: Comparação entre os volumes parciais calculados e previstos para a classe de diâmetro <8 cm	100
Figura 6.7: Comparação entre os volumes parciais calculados e previstos para a classe de diâmetro entre 8 e 18 cm	103
Figura 6.8: Comparação entre os volumes parciais calculados e previstos para a classe de diâmetro entre 18 e 25 cm	106
Figura 6.9: Comparação entre os volumes parciais calculados e previstos para a classe de diâmetro entre 25 e 35 cm	107
Figura 6.10: Comparação entre os volumes parciais calculados e previstos para a classe de diâmetro acima de 35 cm	110

LISTA DE TABELAS

Tabela 3.1: Levantamento dos periódicos em que os 43 trabalhos foram publicados .	57
Tabela 3.2: Principais afiliações encontradas na amostra de 43 artigos	58
Tabela 3.3: Descrição detalhada de dados/informações relevantes referente ao levantamento dos 43 artigos selecionados pela amostra	59
Tabela 4.1: Geração de algumas das 144 instâncias para a determinação do volume final para o <i>Pinus taeda</i> L.	80
Tabela 4.2: Estratificação dos dados em classes de diâmetro e idade	81
Tabela 6.1: Erros quadráticos e diferenças para as 48 instâncias utilizadas para testar a RBF	92
Tabela 6.2: Características das RNAs selecionadas para as estimativas de volume parcial com casca de <i>Pinus taeda</i> L considerando	99
Tabela 6.3: Características das RNAs selecionadas para as estimativas de volume parcial com casca de <i>Pinus taeda</i> L considerando a classe de diâmetro entre 8 e 18 cm.....	102
Tabela 6.4: Características das RNAs selecionadas para as estimativas de volume parcial com casca de <i>Pinus taeda</i> L considerando a classe de diâmetro entre 18 e 25 cm e de 25 a 35 cm, respectivamente	105
Tabela 6.5 Características das RNAs selecionadas para as estimativas de volume parcial com casca de <i>Pinus taeda</i> L considerando a classe de diâmetro acima de 35 cm, respectivamente.....	109

LISTA DE ABREVIATURAS E SIGLAS

EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
FAO	<i>Food and Agriculture Organization</i>
IA	Inteligência Artificial
IBÁ	Instituto Brasileiro de Árvores
IBGE	Instituto Brasileiro de Geografia e Estatística
MLP	<i>Multilayer Perceptron</i>
NP-HARD	<i>Non- Polynomial Hard</i>
PO	Pesquisa Operacional
RBF	<i>Radial Basis Function</i>
RNA	Rede Neural Artificial
SOBRAPO	Sociedade Brasileira de Pesquisa Operacional

SUMÁRIO

RESUMO	3
1 INTRODUÇÃO	12
1.1 OBJETIVOS	14
1.1.1 Objetivo geral	14
1.1.2 Objetivos específicos	14
1.1.3 Estrutura do trabalho	15
2 REFERENCIAL TEÓRICO	17
2.1 IMPORTÂNCIA DO SETOR FLORESTAL NO BRASIL	17
2.2 PINUS TAEDA	19
2.3 PLANEJAMENTO FLORESTAL	20
2.4 MANEJO FLORESTAL	22
2.5 DESBASTE	23
2.6 VARIAÇÃO DA FORMA DO FUSTE	25
2.7 EQUAÇÕES DE VOLUME	26
2.8 MODELAGEM DA FORMA DO FUSTE	26
2.9 REDES NEURAIS ARTIFICIAIS (RNAs)	28
2.10 Breve histórico sobre as RNAs	29
2.10.1 Modelo de um neurônio	30
2.10.2 Arquiteturas de Redes Neurais Artificiais	33
2.10.3 Fundamentos da aprendizagem das RNAs	35
2.10.4 Redes <i>MultiLayer Perceptron (MLP)</i>	36
2.10.5 Redes do tipo <i>Radial Basis Functions (RBF)</i>	39
3 REVISÃO DA LITERATURA	44
3.1 CONTEXTUALIZAÇÃO DAS RNAs NO CENÁRIO FLORESTAL	44
3.2 REVISÃO SISTEMÁTICA DA LITERATURA	45
3.3 TRABALHOS CORRELATOS EM DIFERENTES ÁREAS	66
4 DESCRIÇÃO DOS ESTUDOS DE CASO (A E B)	78
4.1 COLETA DE DADOS PARA O ESTUDO DE CASO A	79
4.2 COLETA DE DADOS PARA O ESTUDO DE CASO B	80
4.3 DEFINIÇÃO DOS PRINCIPAIS ATRIBUTOS	81
5 METODOLOGIAS PROPOSTAS	83

6	RESULTADOS	90
6.1	ESTIMATIVAS DO VOLUME TOTAL (ESTUDO A)	90
6.2	ESTIMATIVAS DO VOLUME PARCIAL (ESTUDO DE CASO B).....	94
7	CONCLUSÃO	111
	REFERÊNCIAS	113

1 INTRODUÇÃO

Desde a revolução industrial dos séculos XVIII e XIX, a grande competitividade imposta pela globalização passou a exigir das empresas a busca constante por mudanças e implementações de novos processos em todas as áreas de negócio. A construção de sistemas integrados com o emprego da base científica, aliada à flexibilidade proporcionada pelo comportamento do ambiente mercadológico, tem sido considerada uma brilhante estratégia empresarial no que diz respeito à tomada de decisão.

Em um contexto mais singular, a área florestal também tem buscado avanços e medidas para se ajustar a essa nova necessidade. Conforme apresentado por Loureiro (2015), a hegemonia da atividade braçal presente na década de 70 foi sendo substituída, aos poucos, pela mecanização e monitoramento de cultivos e plantações em meados de 1980. Mais tarde, principalmente na virada do século, a automação dos sistemas florestais, em conjunto com o controle biológico de doenças no campo (utilizado para o combate de espécies nocivas), impulsionou o aumento da competitividade e de produtividade das empresas madeireiras.

Segundo Brena & Bom (1991), a estimativa de parâmetros importantes para o inventário florestal que normalmente eram previstos em registros tabulares de produção (a partir da combinação de características mensuráveis como, por exemplo, o índice de sítio, idade e regulação de desbastes), foi substituída por *softwares* baseados em equações matemáticas e em modelos inter-relacionados. O grande propulsor para essa transformação pode ser encontrado em Oliveira (1995), quando retrata a mudança de pensamento do produtor, à medida que passa a existir a conscientização no gerenciamento inteligente das florestas.

Neste contexto, a EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária), na sua unidade, Embrapa Florestas, desenvolveu uma série de *softwares* orientados para o manejo e a análise econômica de plantações

florestais. De acordo com Oliveira (1995) o caráter pragmático dos *softwares* da série “Sis”, seguida pelo nome da espécie ou gênero contemplado (SisPinus, SisEucalipto, SisAraucária, entre outros), é nortear o produtor rural para que ele possa realizar de forma adequada, tanto o manejo quanto o planejamento florestal. O alinhamento com o *know-how* adquirido pelos colaboradores tem possibilitado projeções de ganhos significativos (tempo e recursos).

A premissa destes *softwares* é disponibilizar ao usuário simulações e prognoses presentes e futuras (estimativas quantitativas) sobre os povoamentos, envolvendo o crescimento, produção anual, corte final das árvores, ano dos desbastes e o sortimento de madeira conforme o diâmetro das toras (OLIVEIRA, 1995).

Por outro lado, a verificação da acurácia e precisão da avaliação quantitativa a respeito dos povoamentos florestais, com destinos comerciais, acabam se tornando uma ação extremamente necessária, especialmente no que tange à mensuração do volume individual. Como a quantificação é financeiramente onerosa, através da cubagem, muitos métodos indiretos para sua estimativa são comumente utilizados, podendo destacar as equações de volume, funções de afilamento e o fator de forma (SCHRÖDER et al., 2013), tendo por base variáveis de fácil mensuração como é o caso da altura total e o diâmetro a altura do peito (DAP).

Assim, como comentado por Schikowski (2016), as equações de volume e as funções de afilamento são denotadas como sendo importantes ferramentas para a estimativa do volume inicial. A primeira pela facilidade do ajuste e obtenção do volume com base em variáveis de fácil mensuração. E a segunda por tratar-se de uma descrição matemática do perfil longitudinal de um tronco, sendo capaz de obter o seu volume por meio da integração desta função e também por permitirem a estimativa do diâmetro em qualquer altura do fuste, possibilitando, assim, vantagem de estimar o volume da madeira por sortimento (YOSHITANI JR et al., 2012).

Sob a ótica das linhas de pesquisa, sobretudo na busca por melhores resultados, algumas áreas da estatística e da Pesquisa Operacional (PO), em especial as Redes Neurais Artificiais (RNAs), começaram a ganhar força no segmento florestal (FERRARI e SFEIR, 2017).

As RNAs, em sua essência, são apresentadas como modelos computacionais que possuem analogia com o sistema nervoso central, uma vez que são capazes de adquirirem conhecimento para prognoses e reconhecimento de padrões a partir do aprendizado (Haykin, 2001). O amplo leque de espectros/arquiteturas permite avaliar diferentes configurações de rede como alterações nos dados de entrada, número de neurônios na camada oculta, a realimentação das saídas como sinais de entrada, além dos ajustes nos pesos. Como resultado, as redes permitem o encontro de boas soluções no espaço de busca com amostras pequenas, porém equilibradas, de uma população.

O principal objetivo deste trabalho é apresentar uma aplicação da metodologia de Redes Neurais Artificiais, em especial as Redes de Bases Radiais, para a prognose do volume de madeira de plantações de *Pinus taeda* L., para diferentes condições impostas no manejo florestal.

1.1 OBJETIVOS

1.1.1 Objetivo geral

Desenvolver metodologia utilizando Redes Neurais Artificiais para a prognose de volumes de madeiras totais e para múltiplas finalidades industriais de *Pinus taeda* L., visando à seleção de regimes de manejo de maior rentabilidade econômica.

1.1.2 Objetivos específicos

- Identificar os atributos considerados intrínsecos para a determinação do volume total e por finalidade industrial;
- Estabelecer padrões (instâncias) para o treinamento e validação das RNAs;

- Ajustar uma função de afilamento que consiga descrever o comportamento do diâmetro ao longo do fuste;
- Empregar integrações parciais para obtenção dos volumes por finalidade industrial;
- Projetar as redes do tipo RBF com diferentes configurações no *software* Matlab;
- Criar comparações entre as soluções obtidas pelas redes RBFs com os valores calculados (funções matemáticas) ou previstos (programa de simulação).

1.1.3 Estrutura do trabalho

Este trabalho se divide em sete capítulos. O primeiro traz uma breve introdução a respeito do tema, das evoluções que ocorreram na área florestal com o passar do tempo e a definição do objetivo geral e dos específicos do estudo.

O capítulo 2 retrata o estado da arte, expondo os conteúdos abordados ao longo do desenvolvimento do trabalho (referencial teórico), contextualizando os temas e as ferramentas mais relevantes que envolvem o problema levantado.

O capítulo 3 traz um estudo direcionado às principais aplicações das RNAs no contexto florestal, levantando uma série de informações a respeito dos autores, objetivos, técnicas abordadas, resultados, entre outros. Além disso, são apresentados vários outros trabalhos com ênfase em diferentes áreas de atuação, na qual adotam modelos de MLP, RBF, lógica *fuzzy* e híbridos.

Já os capítulos 4 e 5 alinham a descrição dos estudos de casos com suas respectivas metodologias, norteando os principais passos para a identificação dos atributos, construção de instâncias (padrões), desenvolvimento de funções de afilamento, utilização de integrações parciais (ambas para o caso B) e a implementação das redes RBF no *software* Matlab (em termos de definição dos conjuntos para treinamento e validação).

O capítulo 6 é destinado à discussão dos resultados encontrados para ambos os casos. O cenário A contou com a “alimentação” de 144 instâncias para a fase de aprendizado, enquanto o B englobou cinco análises de segmentos em função das classes de diâmetros (<8 cm; entre 8 e 18 cm; de 18 a 25 cm; entre 25 e 35 cm e > 35cm) contendo, respectivamente, 201, 195, 148, 121 e 79 amostras. Como fonte de avaliação, aplicou-se o erro quadrático médio (EQM) e a análise das diferenças individuais.

Por fim, o capítulo 7 apresenta as considerações finais a respeito deste estudo e as sugestões de melhorias e de implementações para trabalhos futuros.

2 REFERENCIAL TEÓRICO

A construção da revisão de literatura contou com dois segmentos de abordagem. Este processo dicotômico tem como finalidade contextualizar, num primeiro momento, a importância do setor florestal e de algumas definições importantes que envolvem a área, podendo citar: a técnica de manejo, tipos de desbastes, índice de sítio, planejamento e as equações destinadas ao cálculo do afilamento do fuste e volume das árvores. Por outro lado, a segunda parte tem como foco abordar a semântica do que vem as RNAs e sistematizar suas respectivas aplicações.

2.1 IMPORTÂNCIA DO SETOR FLORESTAL NO BRASIL

As coberturas florestais são identificadas como um dos principais recursos naturais do globo terrestre. Embora o clima e o solo permitam a geração de toda diversidade, os estudos da *Food and Agriculture Organization of the United States* (FAO, 2011) revelaram que o predomínio de florestas é tipicamente tropical, somando 44% do montante apresentado, seguido pelas boreais (34%), temperadas (13%) e subtropicais (9%).

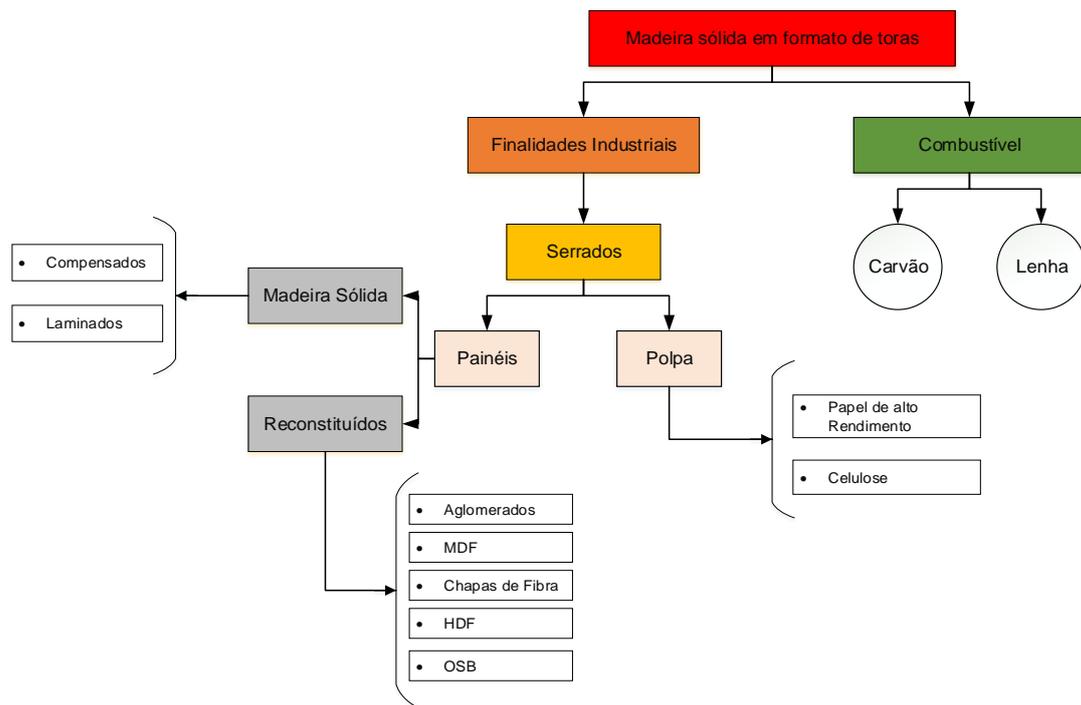
A geografia da distribuição regional certifica a concentração de 50% das coberturas florestais em solos europeus e latino-americanos, deixando a outra metade dividida entre a Ásia, América do Norte, África e, em menor escala, a Oceania (JUVENAL E MATTOS, 2002).

Em referência ao Brasil, pode-se dizer que o país é o detentor da segunda maior extensão florestal do planeta, com aproximadamente 69% de potencial produtivo, estando apenas atrás da Rússia. Contando com inúmeras condições edafoclimáticas (solo e clima) favoráveis, incrementos tecnológicos nas práticas silviculturais e melhoramento genético, o Brasil vem alcançando o potencial de transformar as vantagens naturais em consolidação real de competitividade. A subsistência desses benefícios na cadeia produtiva da madeira provém de formulações estratégicas e de instrumentos de suporte à atividade florestal, enfrentando questões relativas ao uso de florestas e de reflorestamento (JUVENAL e MATTOS, 2002).

O setor florestal brasileiro é composto por um grande aglomerado de espécies responsáveis em proporcionar diversas vantagens, sobretudo no que diz respeito à exportação de produtos diferenciados (resultando em superávit na ordem de 9 bilhões de dólares na balança comercial, avanço de 15% em relação ao ano anterior, de acordo com o levantamento de dados realizado pela Indústria Brasileira de Árvores, o IBÁ, em 2018).

O alinhamento deste cenário com a concepção de que o setor é considerado um dos principais pilares e fornecedores de insumos para a indústria em geral (Figura 2.1), destacando a produção de energia e construção civil, pode-se dizer que há uma considerável agregação de prestígio e relevância tanto no abastecimento interno da economia (subsidiando positivamente o aumento de 6,1% do produto interno bruto (PIB)), quanto na geração de 3,7 milhões de empregos diretos e indiretos (IBÁ, 2018).

Figura 2.1: Esquemática de algumas das possibilidades de emprego da madeira



Fonte: O autor (2019).

2.2 PINUS TAEDA

Originalmente da região sul e sudeste, o *Pinus taeda* é apontado como a mais importante e valorizada classe comercial entre as florestas plantadas dos Estados Unidos, especialmente no que tange ao emprego na fabricação de papel de alta resistência (KRONKA et al., 2005)

Capazes de apresentar características morfológicas bem definidas, essa tradicional espécie contempla uma ordenação genética com cascas gretadas, ramos acinzentados, troncos retilíneos em formato cilíndrico apto em sustentar copas extensas, que podem alcançar de 30 a 40 metros de altura na fase adulta em excelentes condições de clima e solo (FOELKEL, 2008).

De acordo com Shimizu (2008), as estimativas apontaram que a grande faixa de terra e os diferentes tipos de solo permitiram o avanço da espécie em quase 11,7 milhões de hectares por todo território norte americano, abrangendo desde o nordeste até o Estado do Mississippi. Ainda conforme o autor, essa extensão territorial é caracterizada por conglomerar ecossistemas díspares como a planície costeira Atlântica e os montes Apalaches em localidades de 0m a 2500m de altitude.

O primeiro contato da espécie em solo brasileiro ocorreu em 1936, consoante às várias pesquisas elaboradas pelo Instituto Florestal de São Paulo. No entanto, foi em 1955 que os estudos de iniciação científica encontraram tratativas para que novas espécies de *Pinus taeda* fossem introduzidas para a prática de ensaios e experimentações orientados à adaptação e crescimento (KRONKA et al., 2005).

O *Pinus taeda* é uma das árvores mais plantadas na região sul do Brasil, tendo como ápice a promulgação do programa de incentivo fiscal e as intensificadas atividades de reflorestamento durante a década de 60 que serviram de alicerce para a propagação dos plantios comerciais e industriais (FOELKEL, 2008).

2.3 PLANEJAMENTO FLORESTAL

Independentemente da área ou ciência de estudo, o planejamento corrobora o sucesso ou fracasso de qualquer negócio. O conjunto de atividades, bem como a tomada de decisões, deve ser realizada em completa harmonia para que os índices de incerteza no processo decisório sejam reduzidos e que novas perspectivas e diretrizes conduzam a empresa a resultados desejáveis (MITCHELL, 2004).

Segundo Rocha (2000), as análises estruturais de empresas permitem avaliar que o foco das atividades está, permanentemente, direcionado à sustentabilidade dos recursos e de todo o empreendimento. Em um contexto mais particular, este mesmo prisma se encaixa sublimemente na área florestal, tendo em vista que as atividades são programadas para a geração de recursos financeiros/produtos finais no prazo pré-estabelecido pelo planejamento.

Em termos de gestão dos recursos florestais, Gomide (2009) sobreleva que a promoção da viabilidade de mudanças estruturais e a produção de recursos financeiros são fundamentadas nas intervenções florestais produzidas em cada unidade de manejo. Em outras palavras, este ponto de vista pode ser ilustrado a partir da execução de operações clássicas de desbastes, qualidade do produto, necessidades de mercado, operações logísticas de transporte e/ou roteamento de veículos.

Conduzido pelo prisma da tomada de decisão no planejamento, Mitchell (2004) considera que o monitoramento de desenvolvimento da floresta é um dos principais pilares. Para ele, monitorar representa uma contextualização, num nível informativo, a respeito da atual situação do povoamento de tal forma que seja possível subsidiar o gestor na determinação de medidas corretivas para a obtenção de melhores resultados.

Oliveira (1995) destaca a importância em conhecer o estoque de crescimento e da produção futura da floresta por meio de técnicas de modelagem, tanto para o planejamento (da produção) como da empresa florestal. Sendo assim, a saída produzida por esses recursos permite avaliações de intervenções silviculturais e a realização de análises em

diferentes configurações de cenários que podem respaldar a tomada de decisão.

Tendo como base essa mescla de informações, o planejamento florestal, em seu sentido amplo, pode ser observado como a sistematização de um conjunto de atividades desenvolvidas ao longo do horizonte de tempo, na qual a sua semântica está voltada em atender os objetivos estabelecidos. Todavia, devido à ação de considerar um elevado número de opções de manejos em suas unidades de povoamento (de modo a garantir a sustentabilidade da floresta), a estrutura original acaba compreendendo uma forma mais complexa e, portanto, deverá ser determinada em função de subproblemas modelados hierarquicamente (GOMIDE, 2009).

Ao abordar esta linha, Andersson (2005), traz como contribuição a ideia de que os modelos hierárquicos constituem uma gama de subsistemas interconectados que compõem uma estrutura composta por objetivos e metas a serem alcançadas. Invariavelmente, estes modelos são divididos em três classes: Planejamento em nível operacional, tático e estratégico (MITCHELL, 2004).

O nível estratégico trabalha com longos períodos de tempo e menor grau de detalhamento das informações. Normalmente procura abordar temas relativos à tomada de decisão e ao ambiente externo como os aspectos sociais, econômicos, demográficos, políticos, técnicos e ecológicos (MITCHELL, 2004).

Em um nível inferior, o planejamento tático tem como natureza integrar a estrutura da organização, desdobrando os objetivos institucionais em departamentais. Diferentemente do nível estratégico, este considera horizontes mais curtos de tempo, lidando, principalmente, com situações de mercado que envolve a demanda e oferta, produtos desejados pelos consumidores e o alcance das metas de produção a partir do agendamento da colheita (MITCHELL, 2004).

Por fim, o operacional corresponde a planos bem detalhados, e que retratam as operações que ocorrem diariamente ou semanalmente, tendo como

referência as ações e metas providas dos níveis mais altos, como as decisões de colheita e tipo de produto (MITCHELL, 2004).

2.4 MANEJO FLORESTAL

Historicamente, o manejo florestal esteve relacionado aos princípios silviculturais e biológicos das florestas. No entanto, com o advento do aprimoramento da área, tal prática passou a englobar diferentes assuntos e, por este motivo, pode ser definida como o estudo e a aplicação de técnicas analíticas orientadas em proporcionar melhor ajuste na escolha de alternativas que contribuam para o alcance dos objetivos estabelecidos por uma organização (LEUSCHNER, 1984).

Muitas definições a respeito do manejo têm sido construídas ao longo da ciência florestal. A sociedade Norte Americana de Engenheiros Florestais, por exemplo, apresentou em 1958, o conceito clássico que diz: “É a aplicação de métodos comerciais e princípios técnicos florestais na operação de uma propriedade florestal”.

Conjecturando seu sentido mais amplo, o manejo florestal alia todos os fatores biológicos, sociais e econômicos que impactam diretamente na tomada de decisões (que podem, eventualmente, envolver o futuro a longo prazo ou as atividades do dia-a-dia, lidando com sistemas dos mais simples aos mais complexos) sobre a floresta (LEUSCHNER, 1984).

Dentre todo o conjunto de questões que podem ser consideradas pelo manejo florestal, destacam-se: o planejamento da colheita; a previsão do efeito de diferentes tipos de regimes no valor de uma floresta; o planejamento da produção de uma indústria atendendo os objetivos estabelecidos de receita; a determinação do ciclo e a intensidade de cortes visando a maximização da produção de madeira e o delineamento de uma rede de estradas com o menor custo possível de modo a atender os projetos (BUONGIORNO e GILLESS, 1987).

Sob outra perspectiva, o aumento exponencial de consumo de produtos de madeira reforça a necessidade da produção de florestas de rápido

crescimento para que a demanda existente seja, de fato, atendida. Porém, em função dos avanços tecnológicos em todos os processos industriais, torna-se cada vez mais difícil prever quais serão os produtos madeireiros com maior rentabilidade e, como consequência, as decisões, sobre o tipo de floresta a ser produzida e quais regimes de manejo adotar, acabam sendo drasticamente afetadas (SANTOS, 2012).

Aliado a este contexto, juntamente com a atividade de planejamento, é possível implantar uma floresta que consiga o só atender as demandas atuais, como, também, que possibilite atender outros mercados (multiprodutos) através da alteração do tipo de manejo aplicado no momento dos primeiros desbastes (ARCE, 2000).

2.5 DESBASTE

Na medida em que as árvores de um povoamento florestal se desenvolvem, uma carência por maior espaço individual, para que possam crescer adequadamente, passa a existir. Em determinados momentos, a falta desta área acaba condicionando a competição das copas na tentativa de captar a luz na parte aérea e, do mesmo modo, as raízes na busca por água e ricos nutrientes no solo. Inevitavelmente, neste processo todos os indivíduos sofrem algum prejuízo em relação ao incremento ou qualidade que poderiam ter (CALDEIRA e OLIVEIRA, 2008).

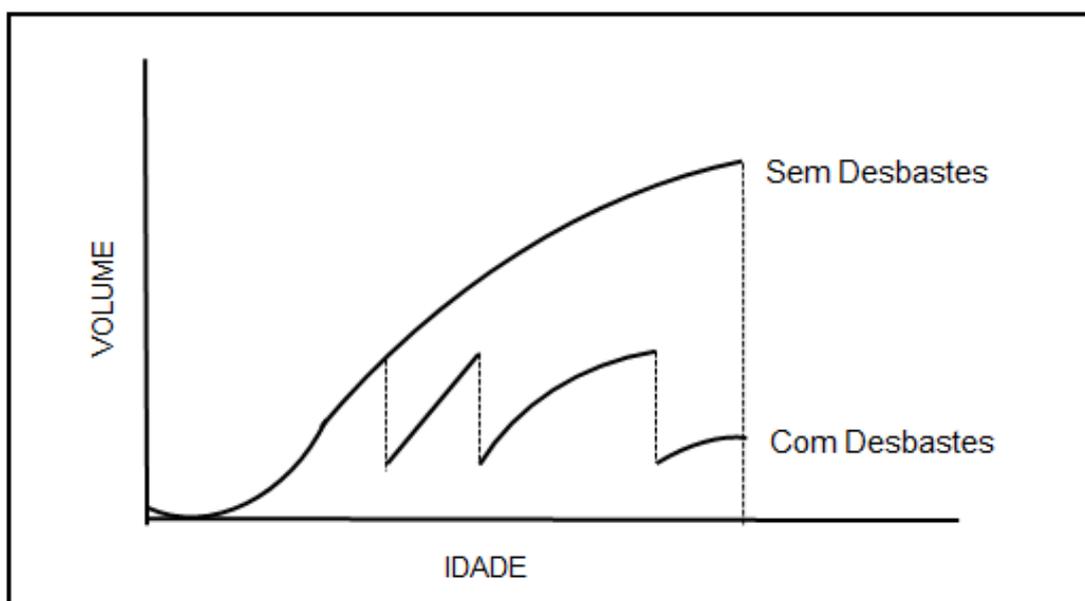
Nas suas condições naturais, o desbaste garante que as árvores não desenvolvidas sejam, efetivamente, suprimidas do povoamento ao longo do seu ciclo de vida, possibilitando, assim, a abertura de espaço para que as remanescentes retomem o seu crescimento. No entanto, em razão do tempo, manutenção e necessidade, um novo processo foi produzido, o desbaste com intervenção humana (CALDEIRA e OLIVEIRA, 2008).

Conforme apresentado por Kronka et al. (2015), o processo de desbaste é rotulado como uma das principais técnicas silviculturais e, portanto, pode ser definido como uma ação que integra um conjunto de operações capazes de viabilizar, no médio e longo prazo, a otimização da qualidade e o crescimento das árvores remanescentes.

A semântica encontrada por Ribeiro et al. (2002), para o termo, pode ser vista em função da classificação das árvores, na qual o foco é moderar a competição a partir do processo de seleção de indivíduos potenciais (remanescentes) e não potenciais (removidos). Para tanto, em tese, são vários os métodos instruídos para realizar esta classificação, desde que considerem as características das copas, dos fustes e a sua posição sociológica.

Schneider e Finger (1994) ilustraram, por meio da figura 2.2, o impacto proporcionado pela prática de desbastes e a real necessidade em se utilizar estratégias orientadas ao máximo rendimento do povoamento ao longo do tempo, uma vez que este comportamento garante o adiantamento de subsídios para o produtor, mas a sua retirada drástica pode prejudicar a qualidade e a produção futura.

Figura 2.2: Impacto dos desbastes ao longo do tempo



Fonte: Schneider e Finger (1994).

Nessas condições, considerando sua totalidade, pode-se dizer que a técnica conserva inúmeras vantagens como, por exemplo, a exclusão de árvores inferiores (pouco valor agregado), inibição da perda antecipada de volume devido à mortalidade motivada pela competição e a melhora da qualidade e rentabilidade do produto final. Em compensação, seu uso incorreto pode fomentar o aumento da vulnerabilidade, elevação nos custos de

investimento, geração de danos físicos, compactação do solo, riscos de incêndio e a diminuição da porcentagem de tronco aproveitável (RIBEIRO et al., 2002).

2.6 VARIAÇÃO DA FORMA DO FUSTE

Historicamente, o processo de definir a forma do fuste (tronco) tem sido o eixo de diferentes teorias dentro do contexto da mensuração florestal, principalmente, devido à sua elevada relação com o volume individual da árvore. Estudos nesta linha, como o de Schikowski (2016) e Souza et al. (2016), por exemplo, são unânimes em afirmar que não existe uma forma padrão que descreva o fuste, mas sim que cada espécie, em seus vários estágios de desenvolvimento, condições ambientais, arranjo espacial ou tratos silviculturais (poda e desbaste), pode assumir diferentes comportamentos.

Para Moura (1994), a forma do tronco de uma árvore é a sua própria configuração externa que, a rigor, não se identifica com a geometria de apenas um único sólido, mas sim, com vários outros, dependendo da porção do tronco considerada.

Devido à grande variação de forma inerente ao fuste, a determinação de seu volume acaba sendo uma tarefa de difícil execução, necessitando, assim, de métodos confiáveis e precisos, capazes de abranger as diferentes formas que uma mesma espécie pode apresentar. Como complemento, Kohler (2013) informou que, em geral, a avaliação vem sendo conduzida pela aplicação de fatores e quocientes de forma e funções de afilamento.

Conciliando todas essas informações, segundo Campos e Leite (2013), a forma do fuste, ou simplesmente, afilamento, pode ser definida como uma taxa relativa de diâmetro (d) que vem decrescendo com o aumento da altura (h) da árvore e, na maioria dos casos, é calculada pela intermediação de modelos matemáticos robustos.

Em tese, a construção de modelos generalizados de afilamento, conforme Souza et al. (2013), são expressos como relações funcionais e,

portanto, constituem um importante ferramental estatístico de uso corrente na determinação dos perfis dos fustes.

2.7 EQUAÇÕES DE VOLUME

A disseminação de pesquisas e metodologias direcionadas à prática de obtenção de estimativas precisas de produtividade, como o volume, vem ganhando destaque desde meados da década de 50 e, segundo Rezende (2006), ela continua sendo considerada um pré-requisito importante no estabelecimento de ações de manejo.

De acordo com Figueiredo Filho et al. (1996), o emprego de equações volumétricas ajustadas com base em variáveis de fácil mensuração como o DAP (Diâmetro a Altura do Peito) e altura total, por exemplo, tem facilitado o processo de predição de volume total, encontrando resultados com acurácias satisfatórias.

2.8 MODELAGEM DA FORMA DO FUSTE

Documentadamente, a primeira tentativa em utilizar formas matemáticas para descrever o comportamento do fuste deu-se apenas em 1903 pelo, até então, pesquisador sueco A.G. Hojer. A partir daí, concomitante ao avanço tecnológico da época, novos modelos foram construídos para atuar em diferentes naturezas.

De acordo com os estudos promovidos por Ahrens e Holbert (1981), a função de afilamento, ou “taper”, pode ser definida como uma descrição matemática do perfil longitudinal do fuste e, seu volume, pode ser obtido a partir da integração desta função, considerando o próprio tronco como sólido de revolução.

Para Andrade (2014), as equações do tipo “taper” são elaboradas por meio de análises de regressão em dados de cubagem rigorosa e contam com a implementação de modelos estatísticos adequados à caracterização da variação de diâmetros do tronco em toda a sua extensão no sentido base-topo.

Neste alinhamento, segundo Prodan *et al.* (1997), tais funções constituem uma importante ferramenta estatística na determinação dos perfis de troncos, tendo em vista que permitem ao usuário estimar três características básicas das árvores: o diâmetro e volume em qualquer ponto do fuste, e a altura total (ou altura na qual se encontra determinado diâmetro limite especificado).

Assim, uma das inúmeras possibilidades de expressar a forma média do tronco de uma determinada espécie florestal é através da construção ou ajuste de uma curva modelo do tronco considerando o perfil característico da espécie analisada (BONETE, 2018).

Embora os modelos de afilamento apresentem as mesmas diretrizes, Prodan *et al.* (1997) afirmam que eles podem ser classificados como completos ou segmentados, dependendo da situação. Em geral, além de apresentarem boa convergência na estimativa de volume, os modelos completos são considerados facilmente manipuláveis, uma vez que integram uma única função que representa a forma do fuste.

Por outro lado, os modelos segmentados são reconhecidos pelo uso de submodelos sobrepostos, nos quais cada um representa uma porção específica do tronco e, ao final, o processo de união de todas as repartições é realizada a partir da imposição de restrições ao modelo geral. Como principal vantagem, este modelo visa diminuir o viés encontrado pelas estimativas do diâmetro ao longo do fuste, mas acaba tornando-se mais complexo de ser trabalhado.

Supletivamente, Moura (1994) explica que os modelos matemáticos utilizados para descrever a forma do tronco devem atender alguns condicionantes, podendo citar:

- a) As variáveis independentes como o diâmetro à altura do peito (*DAP*) e altura total (*h*) devem ser de fácil obtenção;
- b) O diâmetro estimado na altura 1,3 m deverá ser igual ao *DAP*;
- c) No instante em que $h =$ altura total, o diâmetro deve ser igual a zero;

d) A integração da função deve permitir a obtenção do volume total ou de segmentos do tronco.

2.9 REDES NEURAIS ARTIFICIAIS (RNAs)

Em seu sentido amplo, as RNAs são consideradas modelos computacionais inspirados na estrutura e funcionamento do cérebro humano e, na maioria das vezes, são motivadas pela tentativa de mimetizarem o seu comportamento na realização de uma determinada atividade, seja ela de reconhecimento, associação, previsão ou generalização de padrões (Finocchio, 2014). Essa importante ferramenta estatística, não linear, conserva a capacidade de interagir e de se adaptar facilmente ao meio externo a partir de “interligações maciças de células computacionais”, denominadas neurônios ou unidades de processamento FLECK et al. (2016).

Selli e Selegim (2007), através de uma análise matemática, descrevem as RNAs como um mapeamento não linear de um vetor de entrada para um vetor de saída correspondente, pode ser realizado com a aplicação de funções de ativação ou pela presença de neurônios artificiais.

Como contribuição, Haykin (2001) além de defini-la como uma “máquina cujo papel é modelar uma tarefa particular ou função de interesse com base nas conexões entre os seus elementos”, destaca que a sua implementação depende do uso de componentes eletrônicos ou pela simulação por propagação em computadores digitais.

O sucesso das RNAs em diferentes áreas se deve, *a priori*, pelas características inerentes de sua metodologia na busca pela convergência ou solução de problemas. Nessas condições, de acordo com Bittencourt (2006), podem ser traçadas as seguintes propriedades:

- a. Ser capaz de aprender através de exemplos, generalizando o aprendizado para o reconhecimento de novas instâncias similares;
- b. Encontrar bom desempenho em tarefas onde o conhecimento explícito do especialista não está disponível;

- c. Tornar-se adequada a problemas na qual não há entendimento a respeito dos modelos matemáticos dos domínios de aplicação;
- d. Possuir elevada imunidade ao ruído, ou seja, mesmo em contato com informações falsas ou ausentes, o desempenho da rede não entra em colapso, mas acaba piorando de maneira gradativa;
- e. Possibilidade de simulação de raciocínio “a priori” e impreciso através da associação com a lógica nebulosa.

Por via de regra, conforme apresentado por Módolo (2016), a “inteligência” das RNAs não está baseada na representação simbólica do raciocínio humano, mas sim em função das sucessivas interações entre todos os neurônios conectados a ela.

2.10 Breve histórico sobre as RNAs

O cérebro humano conserva atributos desejáveis em qualquer sistema artificial. Suas competências em diferentes panoramas como lidar com informações probabilísticas e/ou inconsistentes, alta flexibilidade para se adaptar a situações aparentemente pouco definidas e tolerância a falhas, têm despertado a atenção de muitos especialistas que, na década de 80, intensificaram suas linhas de estudo na área da inteligência artificial (IA) com o uso da computação intensiva (VELLASCO, 2007).

No entanto, as primeiras pesquisas destinadas a neuro-computação datam de 1943, quando o fisiologista McCulloch e o matemático Pitts desenvolveram um trabalho pioneiro que consistia em assimilar o comportamento dos neurônios biológicos como um circuito binário para a criação de um modelo matemático correspondente (Aguar, 2010). Apesar da capacidade em separar duas entradas booleanas, este modelo não era capaz de realizar o processo de aprendizagem, uma vez que não possuía parâmetros livres.

Em 1949, com a autoria do neuro-psicologista Donald Hebb, houve a grande contribuição ao modelo de McCulloch e Pitts. Resumidamente, os projetos de Hebb portavam como orientação a criação de uma lei de aprendizagem específica para a sinapse dos neurônios, demonstrando que a

competência das RNAs é fruto da alteração da eficiência sináptica (ALMEIDA, 2001).

Anos mais tarde, em 1958, Frank Rosenblatt e Charles Wightman elaboraram o que parecia ser o primeiro neuro-computador bem sucedido. Seus estudos, em partes, eram fundamentados em um “modelo cognitivo de unidades sensoriais (entradas) conectadas a uma simples camada de neurônio com o acréscimo de sinapses ajustáveis” (AGUIAR, 2010). Com o auxílio da lei de aprendizado de Hebb, Rosenblatt e Wightman, os autores demonstraram que uma rede denominada “Perceptron” poderia ser treinada para a classificação de padrões de classes lineares.

Apesar das consideráveis reduções de pesquisas relacionadas, o grande ápice para as RNAs aconteceu em 1980, com o advento de computadores com maior capacidade de processamento de cálculos. Foi nesta época que Rumelhart, Hinton e Williams formalizaram o desenvolvimento do algoritmo de retropropagação (*backpropagation*) (Rumelhart et al., 1986). Essa nova abordagem proporcionou o treinamento de redes MLP com grande poder de generalização, abrindo novas áreas de implementação que até então eram apenas idealizadas (FREIMAN, 2004).

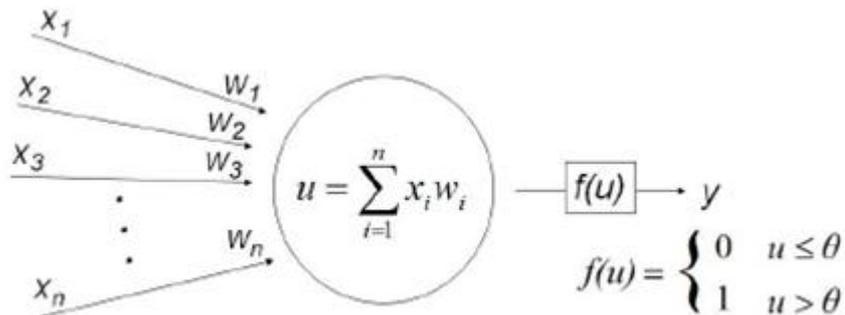
2.10.1 Modelo de um neurônio

Em geral, as representações arquitetônicas das RNAs assumem um comportamento clássico de sistemas baseados em neurônios interconectados, responsáveis pelo processamento básico de informações/conhecimentos adquiridos pela rede. Segundo Haykin (2001), este processo advém, sobretudo, em função dos procedimentos de aprendizagem e das forças de conexão entre os neurônios, denominados pesos sinápticos.

O primeiro neurônio artificial foi proposto pelos pesquisadores McCulloch e Pitts como uma simplificação do neurônio biológico cuja finalidade era simular o comportamento dos neurônios (BRAGA, CARVALHO e LUDEMIR, 2000). Alinhado com a Figura 2.3, este modelo é formado por diversas entradas (dendritos) ponderadas por pesos (análogos ao comportamento das sinapses)

e um único canal (axônio) responsável por conduzir a saída binária até as extremidades que a distribuem aos neurônios na qual estejam conectados.

Figura 2.3: Ilustração de um neurônio artificial



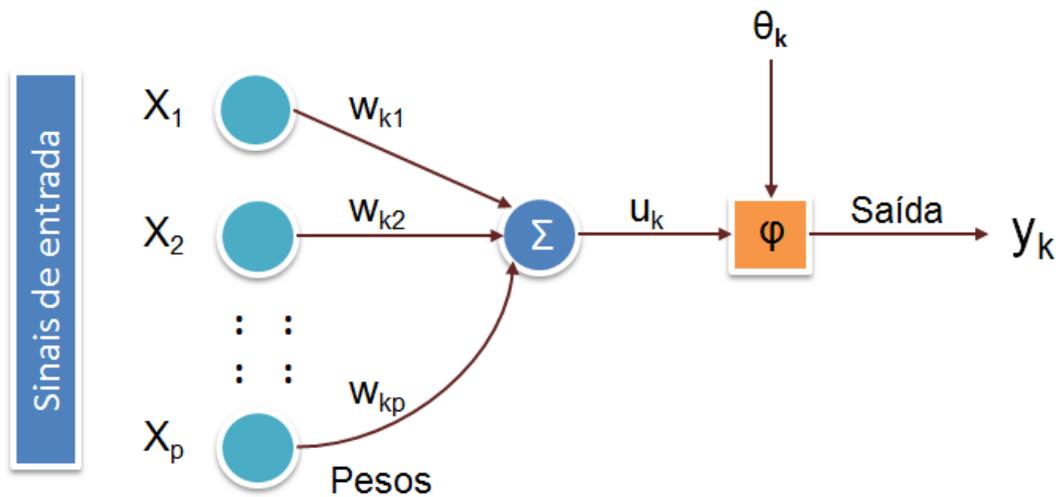
Fonte: Adaptado de Rezende (2003).

Onde: x_i (com $i = 1, \dots, n$) é a entrada da rede; w_1, w_2, \dots, w_n são os respectivos pesos; u é a saída do combinador linear; $f(u)$ é a função de ativação e, por fim, y é a saída do neurônio. Nestes moldes, considerando que a saída linear (u) é o resultado do combinador linear que calcula o produto escalar (ou produto interno) das entradas (x_i) e dos pesos (w_n) não são ajustáveis, ou seja, fixos, tem-se que a função de ativação $f(u)$ deverá ser, obrigatoriamente, linear (REZENDE, 2003).

Invariavelmente, diferentes autores começaram a utilizar o projeto de McCulloch e Pitts como referência para os seus e, a partir de algumas modificações, conseguiram criar modelos capazes de lidar com situações bem complexas, entre elas, a não linearidade.

Nessas condições, a Figura 2.4 traz uma representação abrangente a respeito deste neurônio, seguida pela descrição detalhada de todas as unidades básicas que o integram.

Figura 2.4: Descrição de um Neurônio não linear



Fonte: O autor (2019).

- Assumindo a sua forma mais simplificada, o funcionamento de um neurônio não linear é marcado pela inserção de um conjunto de nós entradas (ou *inputs*), geralmente representado por X_1, X_2, \dots, X_p , que recebe um vetor de padrões ou o sinal de entrada correspondente.
- Os pesos sinápticos ($W_{k1}, W_{k2}, \dots, W_{kp}$), associados a cada dado de entrada X , assumem a memória da rede em função da experiência adquirida como resultado das apresentações de cada padrão ou instância;
- O somador, por sua vez, é um elemento bem intuitivo que representa o processo de combinação linear dentro da RNA. Em outras palavras, ele é o responsável por produzir um potencial de ativação com base na soma dos sinais de entrada ponderados com seus respectivos pesos sinápticos;
- A função de ativação φ é observada como saturador de saídas dos neurônios (u_k) capaz de restringir sua amplitude para um valor finito, normalmente normalizado no intervalo fechado de $[0,1]$. Inerente ao fato de ser um neurônio não linear, suas características permitem, não só o uso de diferentes tipos de funções de ativação, como, também, a fácil adequação de sua saída ao tipo do problema analisado. Dentre todas as funções conhecidas, destacam-se a logística sigmoideal (retornam saídas

no intervalo $[0, 1]$), a hiperbólica (saídas no intervalo $[-1, 1]$) e a tangente sigmoïdal (saídas no intervalo $[-1, 1]$);

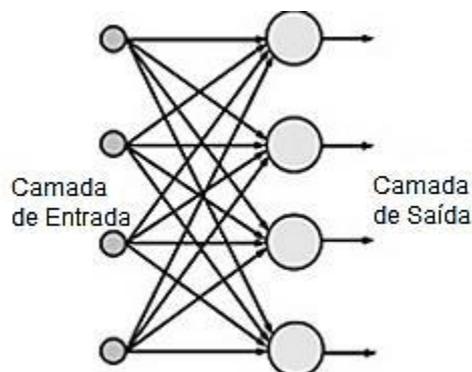
- Em resumo, o parâmetro θ , ou valor limite (*threshold*), tem como natureza auxiliar a RNA a se ajustar ao conhecimento fornecido. Apesar de desempenhar importante papel no funcionamento das redes, em alguns casos acaba sendo omitido, mas quando utilizado assume um valor análogo a um peso, com entrada sempre igual a “1” (Velasco, 2007). Haykin (2001) ressalta que sua grande contribuição está atrelada ao fato de permitir o deslocamento do hiperplano da origem no eixo das abscissas.

2.10.2 Arquiteturas de Redes Neurais Artificiais

A arquitetura de uma RNA, em grande parte dos casos, depende do tipo de problema a ser analisado. Tanto neurônios biológicos quanto os artificiais, pelo menos isoladamente, dispõem de baixa capacidade computacional, mas, quando conectados (formando uma rede) são capazes de resolver problemas de alta complexidade (BRAGA, CARVALHO e LUDEMIR, 2011).

A rede *feedforward* de camada única, em sua forma clássica, é considerada uma das arquiteturas mais simples de RNA, uma vez que é composta apenas por uma camada de entradas de nós de origem que se projeta diretamente para a camada de saída de neurônios (alimentação para frente) (Figura 2.5).

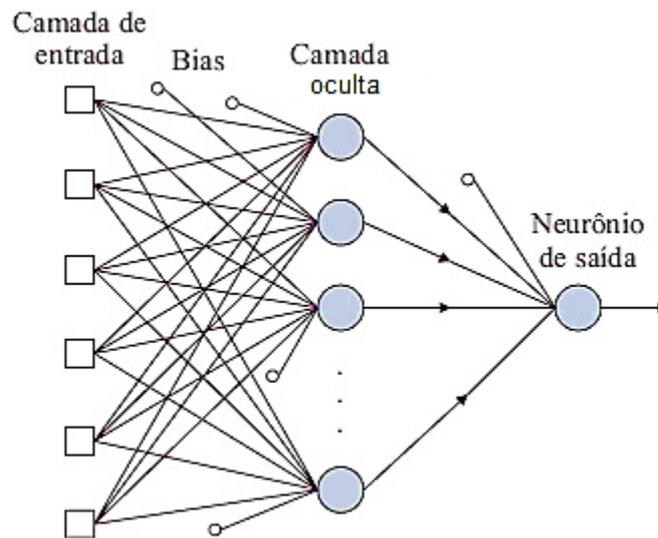
Figura 2.5: Exemplo de uma rede feedforward de camada única.



Fonte: Adaptado de Rezende (2003).

A rigor, a segunda classe de rede do tipo *feedforward* congrega uma arquitetura análoga ao primeiro caso, exceto pela presença de uma ou mais camadas denominadas ocultas ou intermediárias que operam de forma paralela a partir de nós de computação, comumente chamados de neurônios ocultos (Figura 2.6). Em síntese, de acordo com Haykin (2001), a função destes neurônios é intervir entre a camada de entrada e a saída de maneira útil, tornando a rede capaz de extrair estatísticas de ordem elevada.

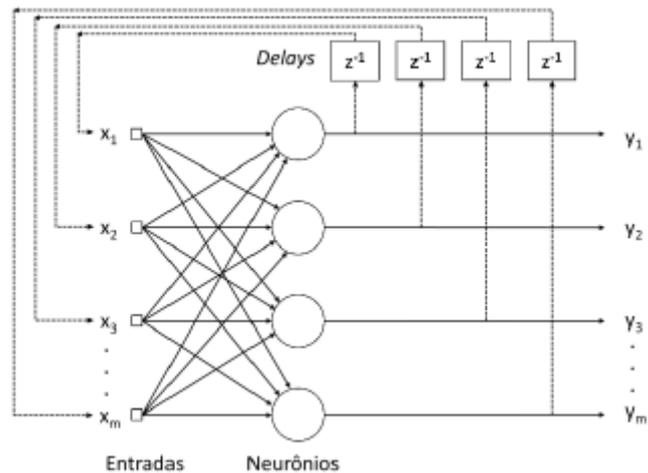
Figura 2.6: Exemplo de uma rede *feedforward* de camada única



Fonte: Adaptado de Assef (2018).

Diferentemente das abordagens progressivas, as Redes Neurais Recorrentes (RNR), em sua essência, constituem um classe de sistemas dinâmicos capazes de acessar o histórico de sinais a partir da inclusão de laços ou conexões de canais de realimentação (Figura 2.7). Apesar de apresentar características eminentes, seu uso pode fazer com que a RNR tenha um comportamento dinâmico não linear bastante complexo, sugerindo que pequenas alterações nos parâmetros podem desestabilizar a dinâmica da rede.

Figura 2.7: Exemplo de uma rede recorrente



Fonte: Adaptado de Assef (2018).

2.10.3 Fundamentos da aprendizagem das RNAs

Uma das prioridades mais significativas de uma RNA é a habilidade em entender o comportamento de um determinado padrão para que possa melhorar, de forma contínua, o seu desempenho. Este processo, popularmente chamado de aprendizagem, está formalmente associado à maneira de como se dá a modificação dos parâmetros livres (pesos), ocasionada pela ação dos estímulos provenientes do ambiente onde a rede está inserida (HAYKIN, 2001).

Segundo Braga, Carvalho e Ludemir (2000), uma RNA pode apresentar dois paradigmas de aprendizagem, os quais se diferenciam em função das características presentes no conjunto de exemplos usados no treinamento. Quando o exemplo contém uma saída esperada, a aprendizagem é dita supervisionada, ao passo que sua ausência (da resposta) implica na caracterização de um aprendizado não supervisionado.

Em síntese, o escopo da aprendizagem supervisionada é ajustar os parâmetros da rede de tal forma que, para cada uma das entradas, a saída da rede seja o mais próxima possível àquela fornecida. Ao final de cada iteração, o valor encontrado para o erro, correspondente de cada saída, denota o desempenho (acurácia) adquirido pela rede e, junto com os pesos, são atualizados e realimentados com a aplicação do algoritmo (*backpropagation*, por exemplo) para que sejam minimizados.

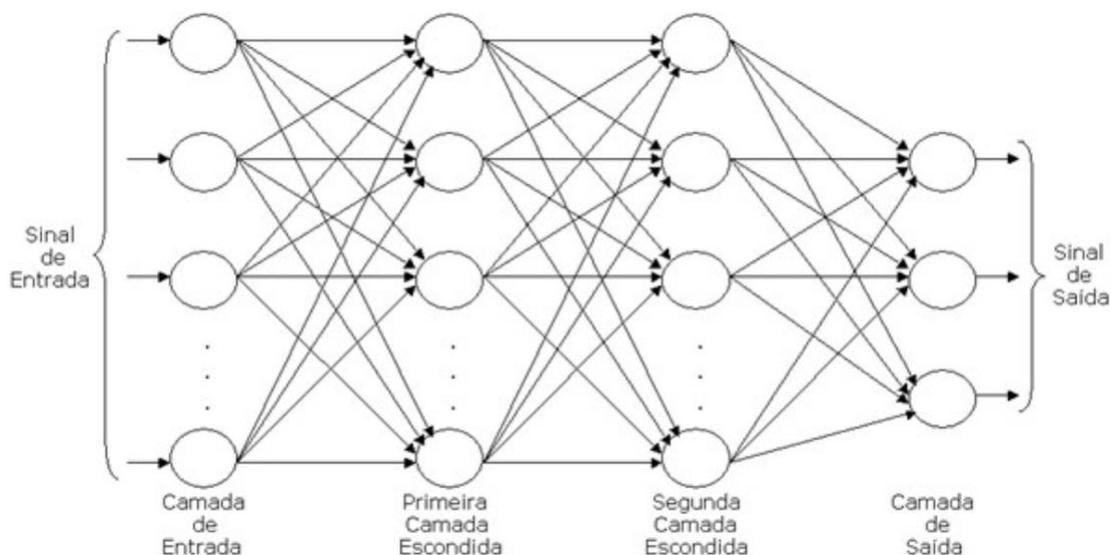
Já na aprendizagem não supervisionada, o algoritmo de treinamento busca criar novos grupos para estabelecer uma harmonia com as regularidades estatísticas das entradas e, conseqüentemente, formando novas representações internas.

2.10.4 Redes *MultiLayer Perceptron (MLP)*

As redes neurais MLP ou Perceptron de Múltiplas Camadas, constituem, segundo Silva (2009), os modelos neurais mais utilizados e conhecidos da atualidade, principalmente pela boa convergência em problemas voltados à classificação, reconhecimento de padrões e no controle/processamento de sinais.

Assim como as redes de única camada, a MLP apresenta uma arquitetura sólida, porém particular. Além de possuir o conjunto de nós que formam a camada de entrada, essa rede contempla uma ou mais camadas denominadas escondidas ou intermediárias, compostas por neurônios computacionais (Figura 2.8).

Figura 2.8: Arquitetura de uma rede do tipo MLP



Fonte: Castro e Castro (2008).

Imediatamente, observa-se que os modelos de redes MLP, ao mesmo tempo em que contemplam uma das configurações mais completas, conservam

o comportamento progressivo (*feedforward*) que possibilita a propagação do sinal de entrada (camada por camada) sem a presença de qualquer tipo de laço ou canal de realimentação entre as saídas dos neurônios (conectam-se unicamente às entradas do neurônio da camada seguinte) (CASTRO e CASTRO, 2008).

Segundo Braga, Carvalho e Ludemir (2000), as redes MLP são conhecidas por terem um poder computacional muito maior do que as redes sem camadas intermediárias. De fato, em um número finito de iterações, uma rede com duas ou mais camadas ocultas pode aproximar qualquer função não linear, mesmo que seja descontínua.

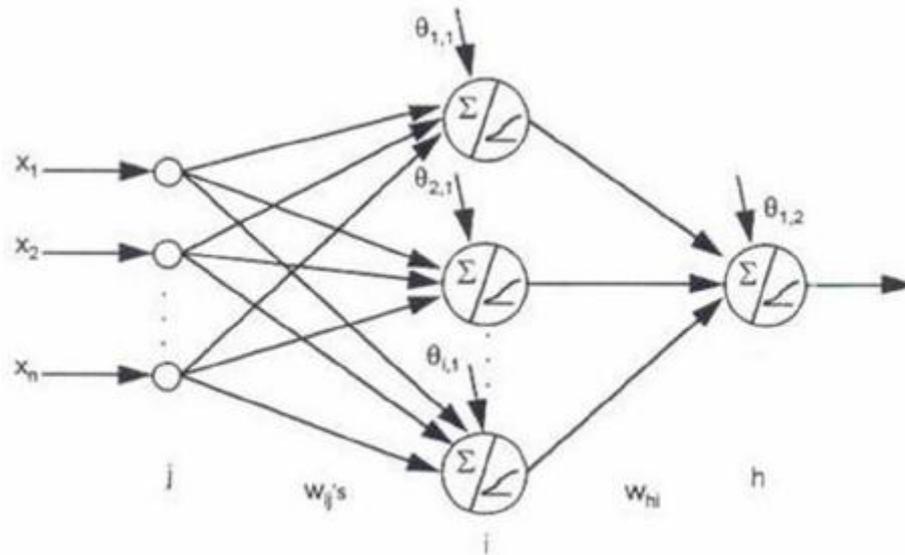
Ao abordar o número de camadas que uma MLP deve conter, Braga, Carvalho e Ludemir (2000) assumem que não há, de fato, uma regra que defina a situação ideal. Segundo os autores, uma possível constatação diz que o uso elevado de camadas intermediárias, *a priori*, não é recomendado, dado que o erro no processo assume o treinamento de retropropagação, tornando-se menos útil e impreciso. Sob outro ponto de vista, uma rede com uma quantidade reduzida de camadas, com número suficiente de neurônios, pode apresentar desempenhos satisfatórios.

Fausett (1994), por sua vez, defende a existência de três etapas cruciais para o sucesso de uma MLP: inicialmente, a rede é alimentada com a passagem de um padrão (instância), cujo valor de saída (desejado) é conhecido (fase *feedforward*). Na sequência, é realizado o cálculo de retropropagação (fase *backpropagation*) do erro e finaliza-se a passagem da instâncias com o ajuste dos pesos. Repete-se o procedimento para todas as instâncias e ao final tem-se completada uma iteração. Em geral são necessárias algumas dezenas de iterações até que haja a convergência da rede.

Segundo Steiner (2017), o comportamento das redes pode ser formulado com base em funções matemáticas. Em casos dicotômicos de classificação, reconhecimento de padrões e previsões, por exemplo, a equação abordada pelo algoritmo faz com que cada um dos neurônios receba os sinais

de entrada e os agregue em uma função generalizada ilustrada pela Figura 2.9 e descrita por (1).

Figura 2.9: Exemplo de uma Rede de Múltiplas Camadas



Fonte: Steiner (2017).

$$i_i^p = \sum_j w_{ij} x_j^p + \theta_i \quad (1)$$

Onde: i_i^p é o sinal de entrada de cada um dos neurônios ocultos (i) para cada um dos padrões (p); w_{ij} é o peso associado entre o nó de entrada (j) da rede e a camada oculta; x_j^p são as coordenadas ou atributos do padrão p no neurônio de entrada j e θ_i é a bias que interage em cada um dos neurônios na camada oculta.

Posteriormente, cada função de entrada acaba gerando um sinal de saída a_i^p (com valores entre “0” e “1” para as entradas variando de $(-\infty, +\infty)$) para o padrão p , utilizando a transferência sigmoideal contínua, como apresentado em (2).

$$a_i^p = \frac{1}{(1+e^{-i_i^p})} \quad (2)$$

Definidas as saídas, o fluxo da rede passa a percorrer o caminho inverso (voltando ao início), dando origem à fase *backward*. Neste passo, a partir da camada de saída até a camada de entrada, os pesos dos neurônios começam

a ser ajustados de tal forma que seus erros sejam reduzidos até que algum critério de parada seja atingido.

Apesar de considerar que o ajuste dos pesos deve ser realizado por toda a rede, optou-se, aqui, pela apresentação dos cálculos que envolvem apenas a camada de saída, conforme o alinhamento das equações (3) e (4) a seguir.

$$\delta_h^p = (d^p - a_h^p) a_h^p (1 - a_h^p) \quad (3)$$

$$\Delta_{wi}^p(t) = \gamma a_i^p \delta_h^p + \alpha \Delta_{wi}^p(t-1) \quad (4)$$

Onde: δ_h^p denota o erro calculado de cada um dos h neurônios da camada de saída para o padrão p em função do seu valor de saída, ou seja, tanto o desejado (d^p) quanto o obtido pela rede (a_h^p); $\Delta_{wi}^p(t)$ representa a variação dos pesos de cada neurônio i da camada oculta na iteração t ; γ condiz com a taxa de aprendizagem e α é a constante que determina o efeito na troca dos pesos na iteração anterior ($t - 1$).

Tendo armazenado estes valores, o próximo passo consiste no emprego da equação (5), responsável por definir a atualização dos pesos $w_{hi}(t)$ que formam a conexão entre o neurônio h da camada de saída com o neurônio i da camada oculta.

$$w_{hi}(t) = w_{hi}(t-1) + \Delta_{wi}^p(t) \quad (5)$$

Como fechamento, partindo da premissa de que todos os pesos foram devidamente atualizados, a rede conclui a apresentação da primeira instância e este processo é repetido para todas as instâncias, finalizando então uma iteração. Todo o processo de aprendizagem (treinamento) acontece até que um critério de parada (número de iterações, por exemplo) seja atingido..

2.10.5 Redes do tipo *Radial Basis Functions (RBF)*

As RBFs são consideradas estruturas de neurônios, assim como as redes MLP treinadas pelo algoritmo do *backpropagation*, supervisionadas com capacidade de aproximação universal, compondo uma classe de RNA

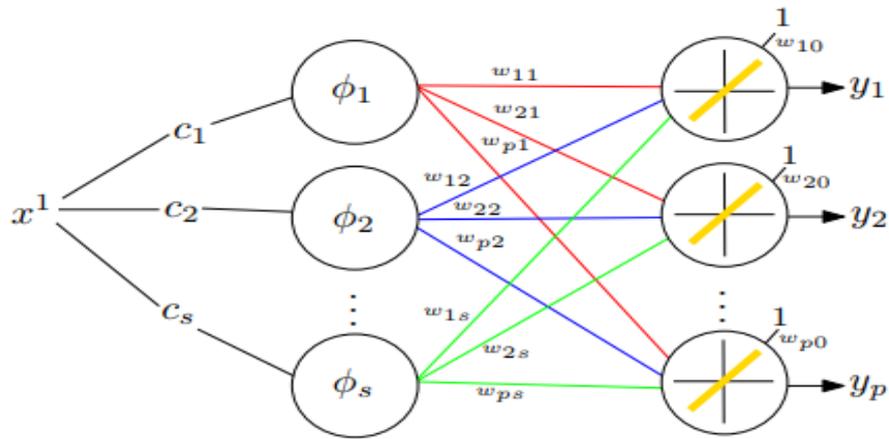
particularmente adequada à aproximação de funções, porém, com modelos ou padrões diferentes (ZUBEN e CASTRO, 2003).

Quanto à sua caracterização, Castro e Castro (2008) descrevem as RBFs como sendo uma metodologia extremamente útil e versátil para a atuação em ambientes dinâmicos. Sua capacidade em aprender e se adaptar às mudanças com facilidade, principalmente em padrões e tendências complexas presentes em dados, fazem dela uma boa solução para a predição, por exemplo, de séries temporais regidas por processos não lineares e/ou não estacionários.

Attux (2016), por sua vez, menciona que uma das principais características dessas redes é a aplicação de funções de base radial em todos os nós presentes na camada oculta que, ao invés de abordarem como argumento da função o produto escalar entre os valores de entrada e dos pesos sinápticos entre os neurônios, utilizam a distância entre os padrões de entrada e seus respectivos centros.

Assumindo sua representação mais simplificada, a rede RBF é constituída por uma camada com n nós de entrada (x^l , com $l = 1, 2, \dots, n$) que conectam a rede com o ambiente; uma camada de saída y_r (sendo $r = 1, 2, \dots, p$); uma camada intermediária, baseada em funções radiais (ϕ_i , com $i = 1, 2, \dots, s$); e as coordenadas c_i (com $i = 1, 2, \dots, s$), que não correspondem ao vetor de pesos w_{ij} ($i = 1, 2, \dots, p$ e $j = 1, 2, \dots, s$), mas sim aos centros das funções (Mota et al., 2013). Essa arquitetura pode ser observada com o auxílio da figura 2.10.

Figura 2.10: Representação de uma rede do tipo RBF



Fonte: Mota et al. (2013).

Franco e Steiner (2014) exteriorizam que cada camada da rede RBF desempenha um papel singular. De forma sintetizada, a primeira camada agrupa os dados em grupos (ou *clusters*) por meio de hiper-elipsóides no espaço de padrões de entrada, tendo como resultado a transformação de um conjunto de padrões não linearmente separáveis em um conjunto de saídas linearmente separáveis. Já a camada de saída tem como meta a classificação dos padrões recebidos da camada anterior.

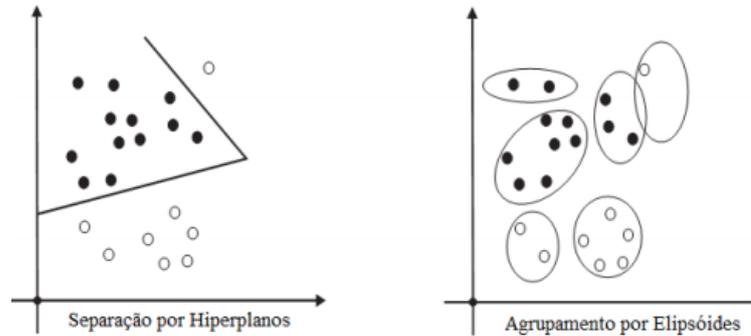
A justificativa para a transformação não linear seguida por uma linear pode ser encontrada no teorema de Cover (1965), quando o mesmo retratou a separabilidade de padrões, afirmando que “um problema complexo de classificação de padrões não lineares em um espaço altamente complexo, tem maior probabilidade de ser linearmente separável do que em um espaço de baixa dimensionalidade”.

Um ponto de vista interessante é apontado por Franco e Steiner (2014) quando afirmam que, frequentemente, as arquiteturas das redes RBFs tendem a ter muito mais neurônios na camada oculta do que as redes MLP, uma vez que os neurônios com a função de ativação sigmoideal produzem saídas para vastas regiões do espaço de entrada, ao passo que os neurônios radiais correspondem a uma região moderadamente pequena deste mesmo espaço.

Partindo para uma abordagem comparativa, Oliveira et al. (2015) enumeram que a principal diferença entre as operações exercidas nas RBFs e

MLPs está na forma de como os dados são manipulados. Isto é, enquanto as RBFs agrupam os dados em um número finito de regiões elipsoides, as MLP divergem pelo fato de que particionam este mesmo espaço em função de hiperplanos (Figura 2.11).

Figura 2.11: Classificação por Rede MLP (esquerda) e RBF (direita)



Fonte: Adaptado de Oliveira et al. (2015)

Em referência ao algoritmo de treinamento empregado, López et al. (2016) demonstram, matematicamente, que: numa série de m elementos pertencentes a um conjunto de treinamento $\vec{E}_{m \times n} = \{e_1, e_2, \dots, e_m\}$ e, onde $\vec{W} = \{w_1, w_2, \dots, w_n\}$ são os pesos dos neurônios que compõem a rede, a expressão na qual a rede RBF está associada é descrita em (6):

$$rbf(\vec{x}) = \sum_{i=1}^m w_i \cdot \varphi(|\vec{e}_i - \vec{x}|) \quad (6)$$

Onde: $\varphi_i(\cdot)$ é observado como sendo uma função de base radial; $(|\vec{e}_i - \vec{x}|)$ representa a distância euclidiana entre os vetores de pontos arbitrários $\in a \vec{E}$ e valores correspondentes às saídas desejadas \vec{x} . Segundo Haykin (1994), colocando $\varphi(|\vec{e}_i - \vec{x}|)$ em formato matricial, tem-se (7):

$$\begin{pmatrix} \varphi_1(\vec{e}_1) & \cdots & \varphi_1(\vec{e}_m) \\ \vdots & \ddots & \vdots \\ \varphi_m(\vec{e}_1) & \cdots & \varphi_m(\vec{e}_m) \end{pmatrix} X \begin{pmatrix} w_1 \\ \vdots \\ w_m \end{pmatrix} = \begin{pmatrix} y_1 \\ \vdots \\ y_m \end{pmatrix} \quad (7)$$

E depois, para a obtenção dos pesos (\vec{W}) desconhecidos (função do estágio de treinamento), basta isolá-los conforme a condição descrita em (8):

$$\begin{pmatrix} w_1 \\ \vdots \\ w_m \end{pmatrix} = \begin{pmatrix} y_1 \\ \vdots \\ y_m \end{pmatrix} X \begin{pmatrix} \varphi_1(\vec{e}_1) & \cdots & \varphi_1(\vec{e}_m) \\ \vdots & \ddots & \vdots \\ \varphi_m(\vec{e}_1) & \cdots & \varphi_m(\vec{e}_m) \end{pmatrix}^{-1} \quad (8)$$

Em termos de representação, a camada de entrada das redes RBF não transforma o padrão fornecido, mas encaminha uma imagem de variáveis para cada nó que constitui a camada de função. Estes nós, por sua vez, são especificados por uma função de transferência, $\Phi(x)$, comumente utilizada a guassiana, que radialmente modifica a informação recebida, conforme descrito por (9):

$$\Phi(x) = e^{-\left(\frac{\sum_{j=1}^n \|x_j - c_i\|^2}{2\sigma^2}\right)} \quad (9)$$

onde: x_j representa as coordenadas do padrão j ; c_i é o valor do centro escolhido; σ está associado a medida de espalhamento (*spread*) e $\| \cdot \|$ é a distância euclidiana entre os dados de entrada e seus respectivos centros.

Segundo Kasiviswanathan e Agarwal (2012), o desempenho da rede depende criticamente do centro escolhido, na qual o valor da função é maior e o *spread* é o indicativo da distância radial do centro (normalmente assumindo um valor diferente de zero). Nos casos em que o *spread* for alto, os pontos de dados serão espalhados a uma grande distância do centro e, portanto, a resposta máxima da função será reduzida. Dessa forma, visando o melhor desempenho da rede, o valor do *spread* deverá ser determinado adequadamente.

3 REVISÃO DA LITERATURA

A revisão sistemática da leitura proposta neste trabalho está coadunada em três segmentos de abordagem. Em primeiro plano é apresentado, brevemente, o conceito de revisão Bibliométrica e Sistemática da Literatura, seguido pelo desenvolvimento metodológico utilizado para o encontro dos principais trabalhos que se enquadram ao contexto analisado e, por fim, são evidenciados vários aspectos considerados pertinentes e que podem ser construtivos para a área florestal.

3.1 CONTEXTUALIZAÇÃO DAS RNAs NO CENÁRIO FLORESTAL

A disseminação das metodologias encontradas neste campo tem alcançado resultados interessantes em diferentes áreas do conhecimento. Na área florestal, por exemplo, a técnica de Redes Neurais Artificiais (RNAs) é considerada uma alternativa promissora e muito eficiente para definir, por exemplo, o melhor manejo dos recursos florestais, quando comparados com os tradicionais modelos de regressão linear ou não linear (Menzies et al. [2007]; Bhering et al. [2015]; Miguel et al. [2015]; Ribeiro et al. [2016] e Çatal & Saplioglu [2018]).

A necessidade em desenvolver estudos e análises direcionadas à parametrização e adaptação de diferentes cenários, como a predição de volume final, área basal, altura dominante ou crescimento e produção dos plantios florestais (Binoti, 2014), tem atribuído elevado potencial às RNAs, principalmente no que se refere à modelagem de variáveis e fenômenos considerados complexos. Estudos nesta linha, como os desenvolvidos por Diamantopoulou et al. (2009); Özçelik et al. (2010); Soares et al. (2011) e Binoti et al. (2017), têm sido considerados relevantes para as aplicações que ocorrem na ciência florestal.

O significativo aumento de conteúdos científicos não só na área florestal, mas também, em várias outras, tem apontado para a premência em desenvolver sínteses que facilitem o acesso a essas informações. Em outras

palavras, sua idealização tem viabilizado a formação de conclusões baseadas em combinações de resultados provenientes de inúmeras fontes.

3.2 REVISÃO SISTEMÁTICA DA LITERATURA

A revisão sistemática é um processo secundário que tem como natureza a compilação e o agrupamento de uma série de trabalhos (ou pesquisas) relacionados a um ou mais temas com base na aplicação investigativa, focada e bem definida, que caracteriza a identificação, seleção, avaliação e a sintetização das evidências relevantes.

Galvão e Pereira (2015) citam que as revisões sistemáticas devem ser disponibilizadas de forma que outros pesquisadores possam repetir o procedimento metodológico aplicado e que seus critérios de busca careçam da existência de um cunho abrangente e ausente de tendências em sua preparação, sendo estes delineados em oito passos: (1) elaboração da pergunta de pesquisa; (2) busca na literatura; (3) seleção dos artigos; (4) extração dos dados; (5) avaliação da qualidade metodológica; (6) meta-análise; (7) avaliação da qualidade das evidências; e (8) redação e publicação dos resultados.

Normalmente, o desenvolvimento deste tipo de revisão estabelece o encontro de um padrão relativamente sólido na busca por trabalhos e que acaba sendo modificado de acordo com a necessidade do pesquisador ou da área estudada. Apesar de existir um passo a passo a ser seguido, não há, de fato, uma regra única para a definição dos critérios de busca e, tão pouco, na maneira de como a pesquisa será direcionada.

Conforme apontado por Medeiros et al. (2015), a Revisão Bibliométrica de Literatura pode ser assimilada como uma ação puramente investigativa que incide sobre assuntos congêneres com aquele que está sendo tratado e, por este motivo, é considerada uma das etapas iniciais do método científico (aplicado para evitar qualquer eventualidade de duplicidade em trabalhos).

Como contribuição, Gil (2002) realça que essa abordagem clássica de analisar (ou avaliar) uma revisão reside em viabilizar ao pesquisador, uma

cobertura/aferição muito maior dos índices orientados à produção e disseminação de assuntos relevantes do que as pesquisas consideradas de cunho pragmático, isto é, diretas.

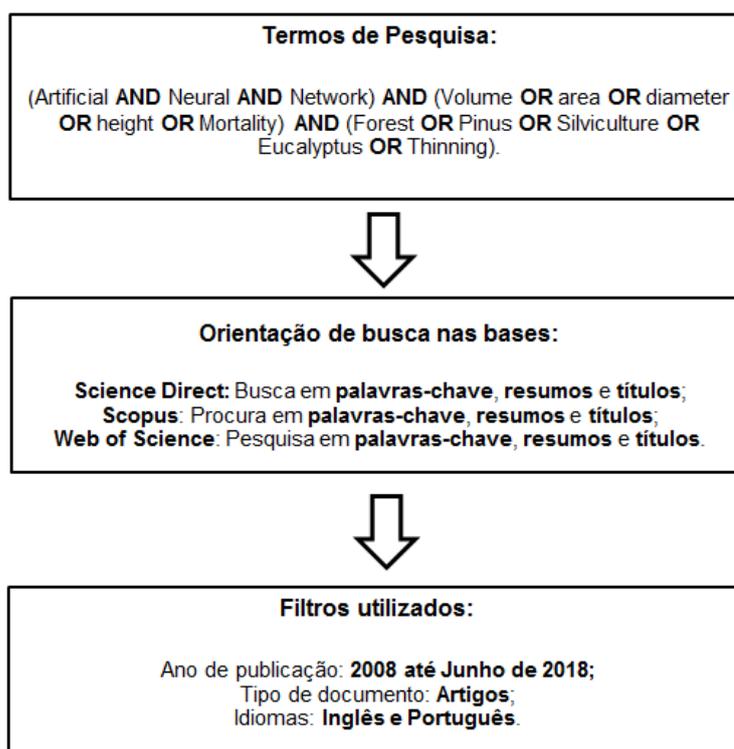
Nessas condições, buscando formalizar todas as condições importantes para uma revisão de sucesso, o presente trabalho adotou, *a priori*, a interpretação dos assuntos que são considerados relevantes e que poderiam servir de base para o desenvolvimento da seguinte questão associada à pesquisa: Quais foram os avanços tomados pela área florestal no que diz respeito ao emprego da metodologia de RNAs para a predição, prognose ou previsão de variáveis para o manejo?

Para responder esta questão, um estudo piloto foi conduzido com diferentes termos seguido de um operador lógico AND ou OR para averiguar qual formato de busca seria a mais conveniente nas seguintes bases de procura: *Science Direct*, *Scopus* e *Web Of Science*. A análise preliminar permitiu identificar que grande parte dos autores refuta a manipulação de derivações ou terminologias muito específicas da área florestal, em particular nos títulos, resumos ou palavras-chave, uma vez que o espaço de procura e, conseqüentemente, o índice de artigos encontrados, foram relativamente baixos.

Já os filtros de busca foram ajustados para compactar a pesquisa, sobretudo no que está relacionado à data de submissão, tipo de documento e idioma (para verificar como está o avanço na área em cenário nacional e internacional).

Assim, as prerrogativas obtidas pelas diversas experimentações ficaram descritas em função da identificação a respeito da melhor configuração dos termos de busca que delimita, ao máximo, a seleção dos artigos, conforme mostra a Figura 3.1.

Figura 3.1: Metodologia aplicada para as Revisões Sistemática e Bibliométrica



Fonte: O autor (2018)

A partir da busca preliminar, como mostrado na Figura 3.1, a pesquisa assegurou o levantamento de 1.140 artigos nas três bases utilizadas, sendo que deste total: 465 provenientes da *Scopus*, 557 da *Web Of Science* e 118 pela *Science Direct* até o final de Julho de 2018. Não obstante, o passo subsequente foi orientado à elaboração de uma atividade que pudesse oferecer uma solução para a separação dos artigos com base em sua relevância. Para isso, promoveu-se uma garimpagem destes trabalhos a partir da aplicação de um critério de seleção processado na etapa 1 e 2 (definidas a seguir) e na exclusão dos artigos duplicados.

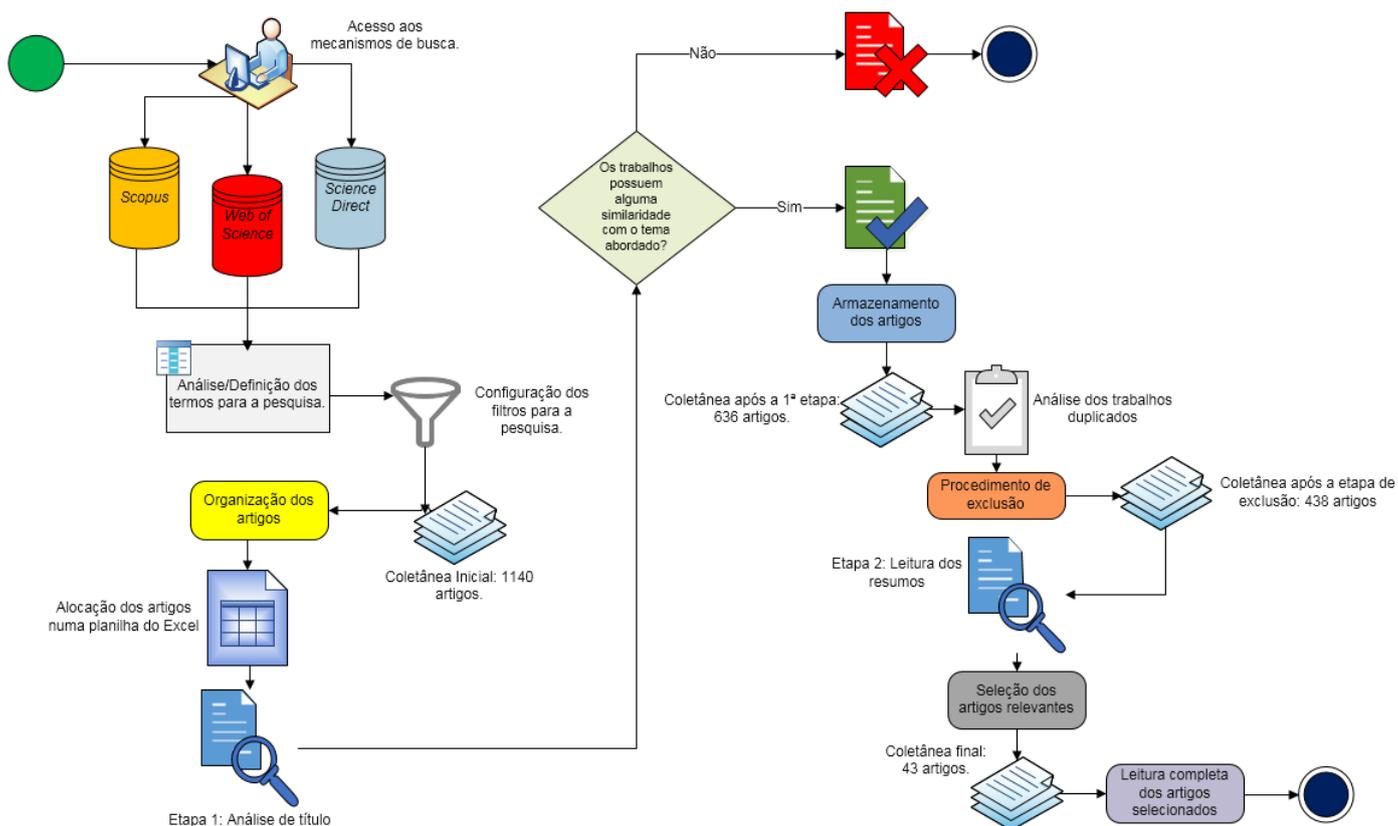
Teoricamente, embora sejam consideradas etapas diferentes, suas naturezas, por assim dizer, englobam o mesmo objetivo, isto é, são encarregadas por ponderar, mediante título (etapa 1) ou resumo (etapa 2 - analisado quando só o título não permite definir se é assunto de interesse) os trabalhos de interesse (ou não) para a pesquisa em questão.

Apesar de contar com essas premissas, torna-se importante ressaltar que em vários momentos a de leitura dos resumos (etapa 2) foi desnecessária,

uma vez que o título do trabalho não apresentava nenhum tipo de analogia ou relação com o tema de estudo como, por exemplo: contexto forense, crescimento populacional, deslizamento de terras urbanas, eletrocardiogramas, exames de raios-X, fraturas em membros, inovações no setor de energia limpa, mudanças climáticas, padrões de densidade, possibilidade de radiação, problemas hemorrágicos, previsão de furacões, entre outras abordagens.

Em tese, com a execução da primeira etapa, o levantamento passou a ser conduzido por 636 artigos e, com a exclusão dos duplicados – via ferramenta Excel 2010 -, o conjunto final contou com 438 para uma análise mais detalhada (etapa 2) para a identificação daqueles que realmente podem contribuir para o estudo, resultando em 43 trabalhos. Essas e outras informações são facilmente encontradas com o auxílio da Figura 3.2.

Figura 3.2: Critérios para a filtragem dos 43 artigos correlatos



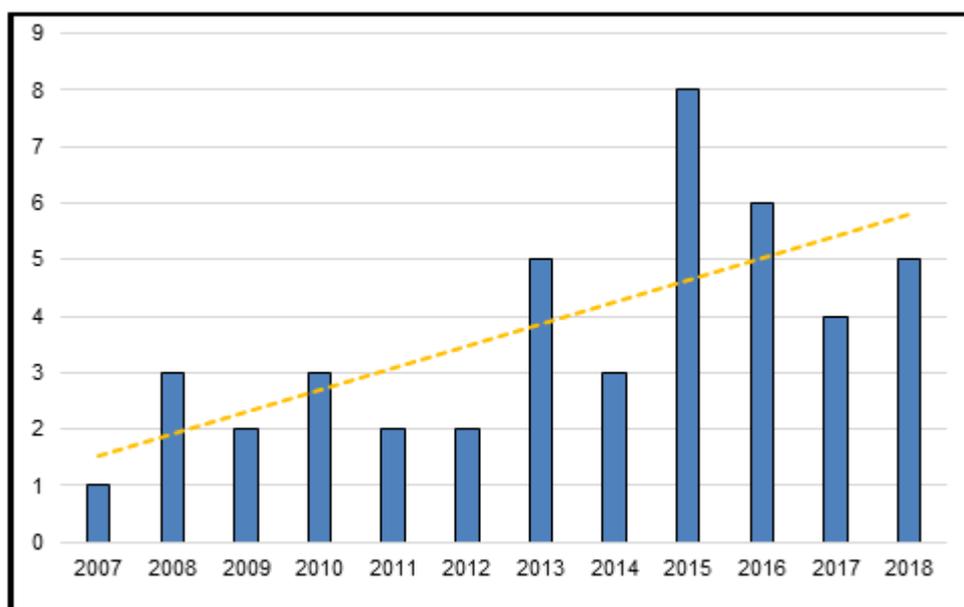
Fonte: O autor (2018)

Conforme delineado pela figura 3.2, os 43 artigos selecionados/filtrados serviram de base para a realização da análise dos seguintes levantamentos:

número de artigos publicados ao longo dos anos (2007 – Julho/2018), definição de seus escopos, *softwares* utilizados, classificação das RNAs, funções de ativação, métodos de validação, autores por países, técnicas complementares (caso aplicadas), filiações, principais periódicos e os resultados obtidos.

Inicialmente, o processo de análise incidiu a respeito da produção de artigos publicados com ênfase na aplicação das RNAs no contexto florestal. Como pode ser observado na Figura 3.3, houve uma leve ascensão nos primeiros anos (até 2012), com alguns períodos estacionários (2009, 2011 e 2012 com apenas duas publicações) e um comportamento mais acentuado nos últimos 6 anos, realçando as 8 publicações em 2015 e até Julho de 2018, 5 novos trabalhos até o momento desta pesquisa. Este crescimento está associado ao interesse na área, disponibilidade de bases de dados, novos *softwares* e pacotes atualizados com diferentes técnicas funcionais, muitas vezes distribuídos gratuitamente.

Figura 3.3: As 43 publicações florestais analisadas e seus anos de publicação



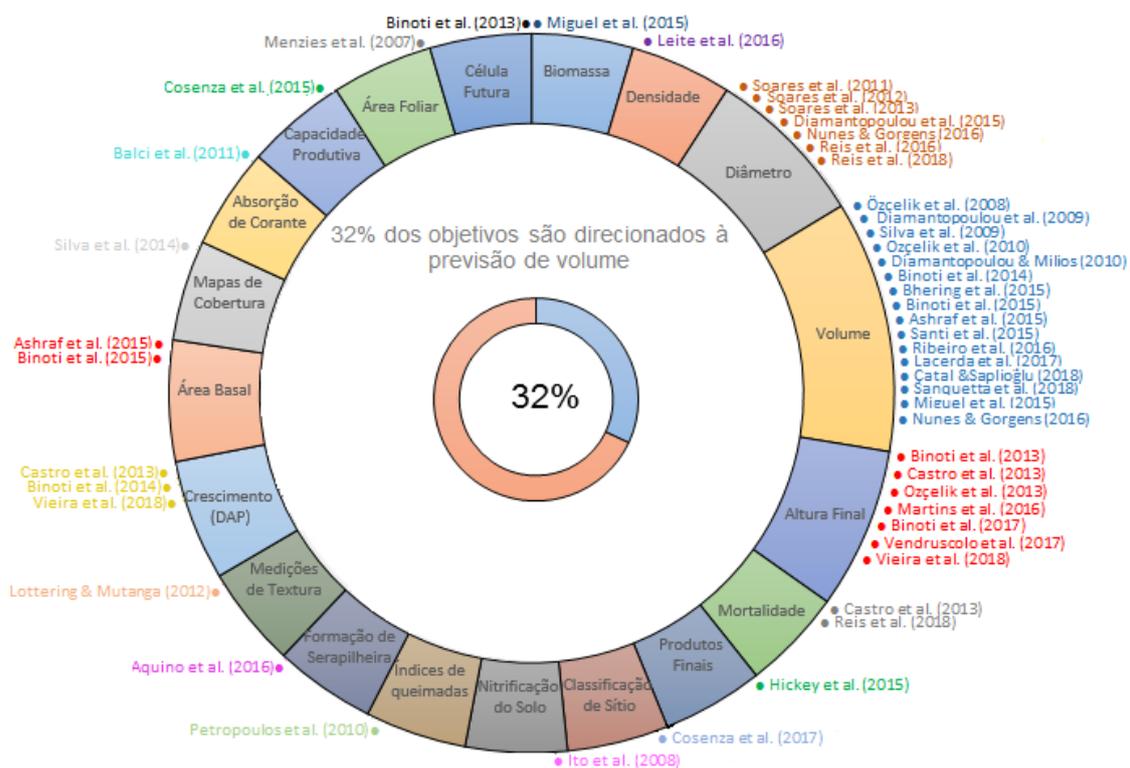
Fonte: O autor (2018)

Considerando a interpretação dos objetivos propostos por cada autor, foi possível investigar que alguns optaram em aprofundar seu estudo em mais de um objetivo, muitas vezes em função da possibilidade de encontrar um ferramental alternativo às tradicionais técnicas ou modelos que frequentemente são utilizadas no cenário florestal, dentre os quais pode-se citar: Castro et al.

(2013), cujos objetivos abordaram a questão da Mortalidade, DAP (Diâmetro da Altura do Peito) e Altura Total; Ashraf et al. (2015) e Binoti et al. (2015), trabalharam com o Incremento de Volume e Área Basal; Miguel et al. (2015), com o Volume e Altura Final; Nunes & Gorgens (2016), desenvolveram um estudo referente ao Volume e Diâmetro e Vieira et al. (2018), lidaram com o Crescimento e Altura Futura.

Nas mesmas circunstâncias, destaca-se que o escopo mais abordado de toda a amostra foi a predição (prognose) do volume total final de madeira comercializável (32% dos trabalhos). A Figura 3.4 apresenta de maneira intuitiva a integração de todas as informações em um formato de relacionamento (Autor – Objetivos).

Figura 3.4: Relação (Autor-Objetivos) dos 43 artigos selecionados

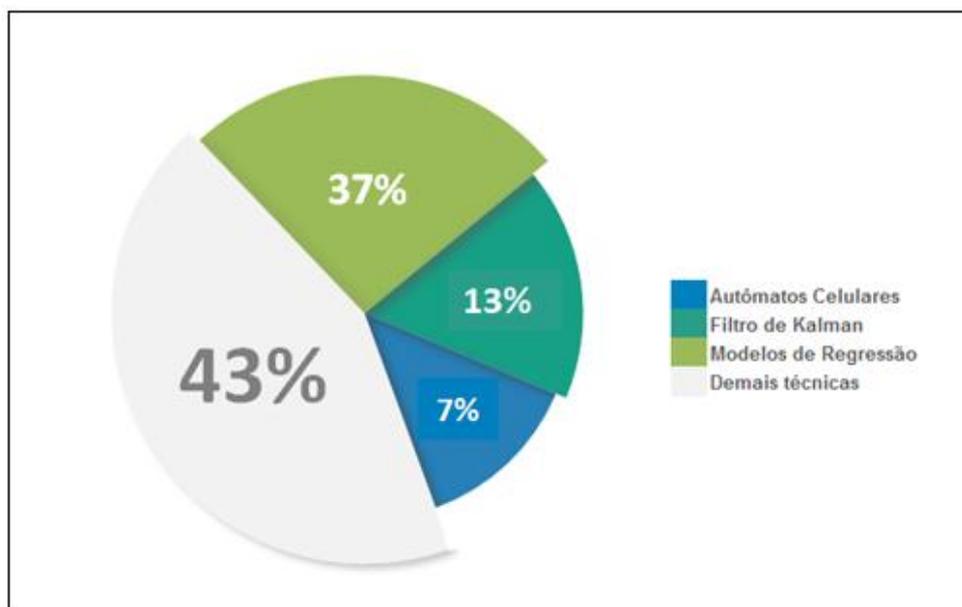


Fonte: O autor (2018).

Apesar de todo direcionamento voltado às RNAs, 31 artigos contemplaram a aplicação de uma técnica complementar, seja ela de modelos de Regressão Linear (37%), Autômatos Celulares (7%) ou filtro de Kalman (13%) (procedimento incorporado às redes), conforme conteúdo informado pela Figura 3.5. Outras

abordagens como as Equações Volumétricas, *Random Forest* (Floresta Randômica), *Support Vector Machine* (SVM; Máquina de Vetor de Suporte), Mínimos Quadrados, Modelos de Árvores Individuais e técnica de Segmentação de Imagens, por exemplo, também foram aplicadas, porém uma única vez e, por isso, foram agregadas em “demais técnicas”, somando 43% do total.

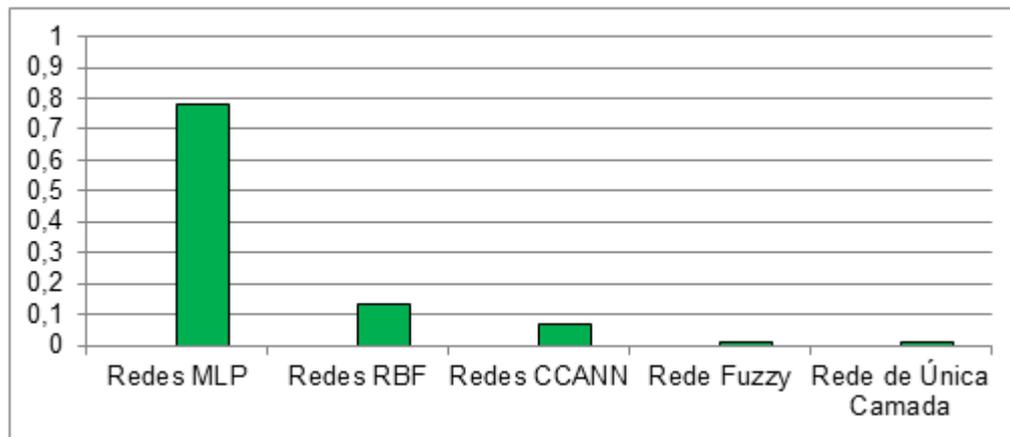
Figura 3.5: Técnicas complementares abordadas pelos 31 (dos 43) artigos



Fonte: O autor (2018).

Outra premissa deste estudo envolveu a identificação dos tipos de RNAs mais aplicados para a resolução dos problemas detectados. Contando com cinco classificações diferentes ao final da pesquisa, a preferência dos autores (Figura 3.6) foi restringida ao modelo clássico de Perceptron Multicamadas (MLP; *Multilayer Perceptron*) com 78% do total, seguido pelas redes de Base Radial (RBF; *Radial Basis Function*) com 13%, as redes Correlação em Cascata (CCANN; *Cascade Correlation Artificial Neural Network*), um modelo considerado promissor para o encontro de resultados satisfatórios na prognose do volume total, segundo Diamantopoulou & Milios (2010), com 7% e somando 1% cada, as redes com a lógica *Fuzzy* e a Perceptron de Camada Única.

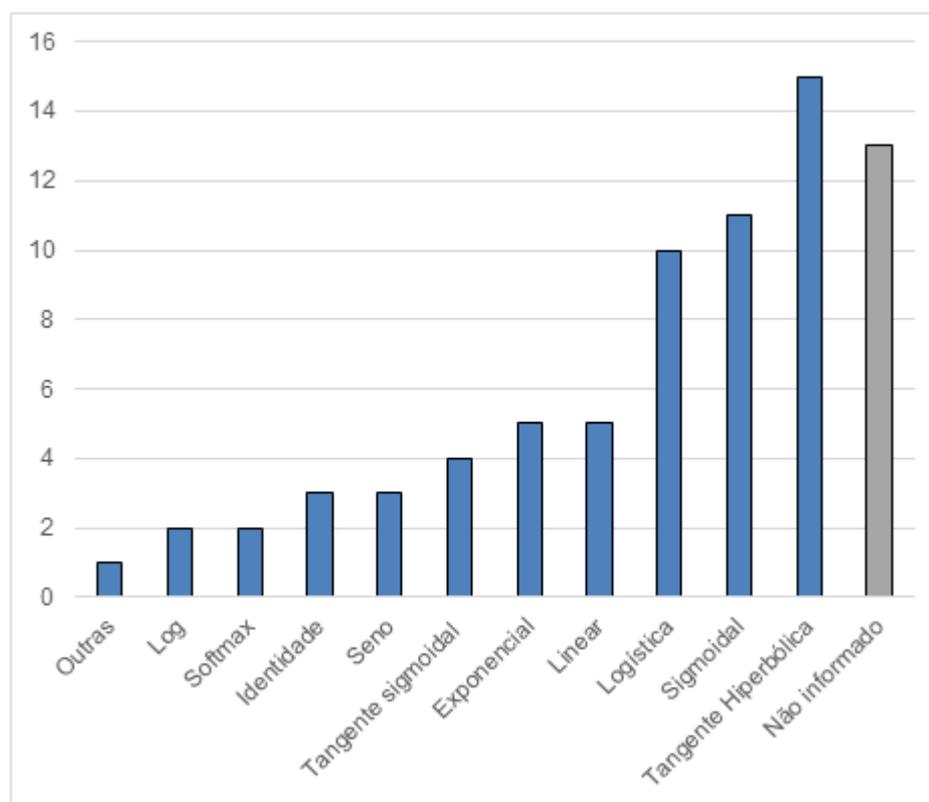
Figura 3.6: Modelos de RNAs mais utilizados pelos 43 trabalhos



Fonte: O autor (2018)

Concomitante ao panorama encontrado, outra informação que pode ser extraída a respeito do uso das RNAs é o tipo de função de ativação empregada em suas respectivas camadas de entrada e saída (Figura 3.7). Apesar de existirem diferentes tipos (ou componentes matemáticos), a maioria dos autores (15, no total) optou pela utilização da Tangente Hiperbólica, seguido pela função Sigmoide ou Sigmoidal (11), Logística (10), Linear e Exponencial (5), Tangente Sigmoidal (4), Seno e Identidade (3), Softmax e Log (2), outras (1) e o número de trabalhos sem a especificação (não informado) foi equivalente a 13.

Figura 3.7: Principais funções de ativação empregadas nos 43 artigos



Fonte: O autor (2018)

No que tange a aplicação dos métodos de validação (ou verificação) da capacidade das RNAs em prever com sucesso os resultados esperados, a Figura 3.8 mostra que o coeficiente de correlação foi o principal critério adotado pelos autores (21 vezes), acompanhado pela Raiz do Erro Quadrático Médio (RMSE; Root Mean Square Error) com 20, a %RMSE (9), Bias (9), Erro Absoluto Médio (7), Histogramas e Análise Gráfica de Resíduos (6), Erro Médio e o Erro Quadrático médio (5), Erro Padrão (4), Erro Relativo, Erro Absoluto Máximo e o Coeficiente de Determinação (3), Teste Estatístico (L&O), Modelos de Eficiência, Matriz de Erros, Critério de Informação de Akaike, Coeficiente Kappa e a % do Desvio Absoluto somaram (2) e a classe outros contou com apenas uma única aplicação.

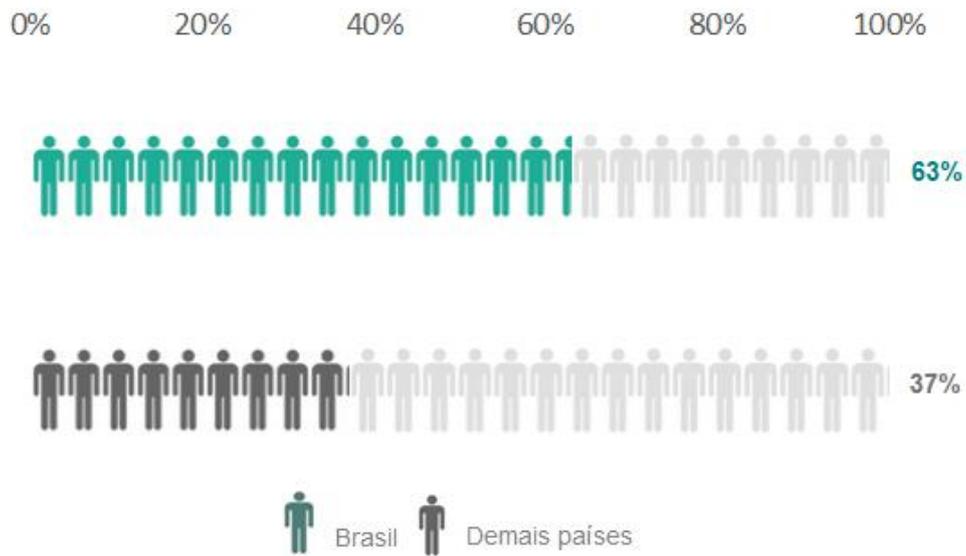
Figura 3.8: Métodos utilizados para a avaliação das RNAs nos 43 artigos



Fonte: O autor (2018)

Ao abordar a nacionalidade dos pesquisadores (Figura 3.9), pode-se dizer que o grande motivador para o desenvolvimento de artigos nesta linha é o Brasil, responsável por 63% do total, enquanto que a Turquia aparece logo depois com 12%, Grécia 10% e com 3% encontram-se: África do Sul, EUA, Inglaterra, Irlanda e Japão. Como complemento, a Universidade Federal de Viçosa, no Brasil, foi a instituição com o maior número de publicações, em um total de oito.

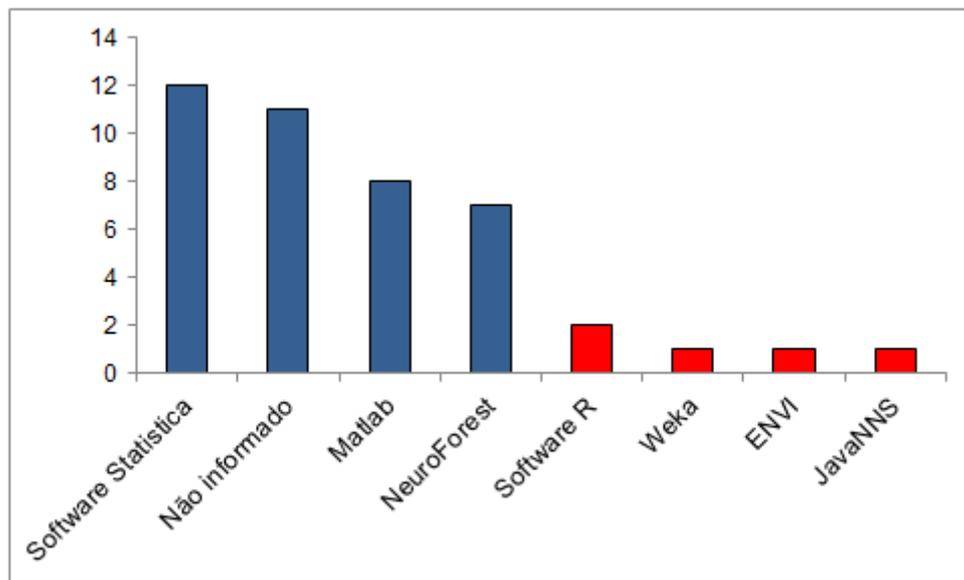
Figura 3.9: Distribuição geográfica dos 43 trabalhos, envolvendo diversos autores



Fonte: O autor (2018)

Por outro lado, a análise dos procedimentos computacionais, para a implementação e execução das RNAs, garantiu que a interface mais utilizada foi o *software Statistica* em 12 trabalhos, acompanhado, *Matlab* (8), *NeuroForest* (7), *Software R* (2), *WEKA - Waikato Environment for Knowledge Analysis* - (1), *ENVI - Environment for Visualizing Images* - (1), *JavaNNS - Java Neural Network Simulator* - (1) e pelos não informados (11). No entanto, cabe ressaltar que as diferentes versões ou derivações pertencentes ao mesmo pacote/programa, não foram considerados sistemas operacionais diferentes, como é o caso do *Statistica* (7,10 e 12) ou o *Matlab* (r2010a, r2013a e r2016b), por exemplo. Estes dados são facilmente encontrados na figura 3.10. .

Figura 3.10: Softwares utilizados para a implementação da linguagem empregada nos 43 trabalhos analisados



Fonte: O autor (2018)

Em relação aos principais periódicos encontrados, a Tabela 1 retrata que a “Revista Árvore” e a “Cerne” são considerados os principais periódicos, contendo, respectivamente, 6 e 5 artigos publicados. Em compensação, a classe denominada como “outras” congrega uma vasta lista com apenas um único artigo, dentre os quais: *Applied Ecology and Environmental Research*, *Applied Soft Computing Journal*, *Computers and Electronics in Agriculture*, *Communicata Scientiae*, *Crop Breeding and Applied Biotechnology*, *Ecological Engineering*, *Ecological Modelling*, *European Journal of Remote Sensing*, *Expert Systems with Applications*, *Floresta*, *Forest Products Journal*, *Forest Science*, *GIScience & Remote Sensing*, *Journal of Environmental Management*, *Journal of Spatial Science*, *Nativa*, *Natural Resource Modeling*, *Neural Computing and Applications*, *Revista Brasileira de Ciências Agrárias*, *Science of the Total Environment*, *Sensors* e *Southern Forests*.

Tabela 3.1: Levantamento dos periódicos em que os 43 trabalhos foram publicados

Revista	Quantidade
Revista Árvore	6
Cerne	5
Biosystems Engineering, Forest Ecology and Management, Pesquisa Agropecuária Brasileira, PlosOne e Scientia Forestalis/Forest Sciences	2
Outras	1

Fonte: O autor (2018)

Como complemento às informações apresentadas pela Tabela 1, a Tabela 2 traz, em perspectiva, as instituições que mais participaram do levantamento realizado pela pesquisa. Resumidamente, a Universidade Federal de Viçosa, localizada no estado de Minas Gerais, é a principal contribuinte, compreendendo o total de 8 artigos aceitos, seguido pela Süleyman Demirel *University* e pela Universidade Federal dos Vales do Jequitinhonha e Mucuri, ambas com 4 publicações. Já a classe “outras” é composta por: *Arid Agriculture University, Cukurova University, Forestry and Forest Products Research Institute, Indiana University, Institute of Applied Physics, Universidade Federal de Jequitinhonha e Mucuri, Universidade Federal de Lavras, Universidade Federal de Mato Grosso, Universidade Federal do Espírito Santo, Universidade Federal do Oeste do Pará, Universidade Federal do Paraná, University College Dublin, University of Bristol, University of Cambridge, University of KwaZulu-Natal e University of Lisbon.*

Sob a ótica das conclusões levantadas nos estudos, pode-se dizer que todas as informações serviram de subsídio para o desenvolvimento e execução de experimentos direcionados em avaliar a capacidade das RNAs em diferentes contextos (cenários e objetivos). De modo geral, todas as 43 pesquisas destacaram que as RNAs obtiveram resultados satisfatórios (em função dos erros relativamente baixos) e, portanto, pode ser considerada uma alternativa muito eficiente e precisa na prognose de variáveis intrínsecas presentes no inventário florestal.

Tabela 3.2: Principais afiliações encontradas na amostra de 43 artigos

Afiliação	Frequência
Universidade Federal de Viçosa	8
Süleyman Demirel University e Universidade Federal dos Vales do Jequitinhonha e Mucuri	4
Aristotle University of Thessaloniki, Universidade de Brasília e Universidade Federal de Goiás	3
Instituto de Desenvolvimento Sustentável Mamirauá	2
Outras	1

Fonte: O autor (2018)

Partindo da hipótese de que há muitos outros dados e/ou informações elementares a respeito dos artigos analisados neste estudo, a Tabela 3 corrobora com a condensação desses conteúdos de uma forma bem clara e organizada.

Tabela 3.3: Descrição detalhada de dados/informações relevantes referente ao levantamento dos 43 artigos selecionados pela amostra

Publicação	Objetivo(s) proposto(s)	Identificação das entradas (Inputs) e saídas (Outputs) da rede	Resultados obtidos pelas RNAs
Menzies et al. (2007)	A ideia central do artigo consistiu em prever a degradação ambiental a partir da medição dos valores do índice de área foliar (LAI) utilizando as técnicas de Regressão Múltipla e RNAs, criando, posteriormente, uma análise comparativa para a identificação do melhor método.	As entradas , da rede consideraram parâmetros distintos para cada classe desenvolvida: Classe 1: Tipos de cobertura, terra urbana, pastagem, campos cultivados, água e vegetação. Classe 2: Sucessão secundária inicial e intermediária. Classe 3: Florestas adultas e sucessão avançada. Classe 4: Florestas adultas. Saída : Área Foliar.	A comparação do erro encontrado na duas técnicas implicaram que as RNAs obtiveram melhores resultados (erros mais baixos).
Ito et al. (2008)	A proposta consistiu em desenvolver modelos de RNAs para a previsão do potencial de nitrificação do solo (com o menor número de propriedades físico-químicas como dados de entrada) e, posteriormente, comparar seus resultados com os modelos de Regressão Linear Multipla.	Entradas : Relação carbono-nitrogênio, capacidade máxima de retenção de água e a relação de saturação de água. Saída : Potencial de nitrificação do solo.	A abordagem de RNA modelou com precisão a relação de potencial de nitrificação do solo com o carbono-nitrogênio (Principal controlador hierárquico). Portanto, além do modelo sugerido ser relativamente simples, fato que aumenta muito o seu valor prático, ele poderá ser empregado em novas escalas para a predição espacial do potencial de nitrificação.
Özpelik et al. (2008)	O objetivo deste estudo foi testar o desempenho de uma fórmula de volume padrão (utilizando o método de Huber e tabelas de volumes locais), além de várias outras técnicas, incluindo a modelagem da rede CCANN, para prever o volume do fuste de árvores, de três espécies, na região mediterrânea da Turquia.	Entradas : Diâmetro do toco e o comprimento do fuste para a rede CCANN I e a Rede CCANN II contou com o diâmetro do toco, diâmetro no topo do tronco da árvore e o comprimento do fuste. Saída : Volume.	Todos os métodos abordados foram observados como eficientes para estimar o volume do fuste das três diferentes espécies analisadas neste estudo e, portanto, devem ser seriamente considerados para a estimativa do volume do fuste.
Diamantopoulou et al. (2009)	O prisma deste trabalho foi voltado, não só com o desenvolvimento de equações de volume para os fustes da espécie <i>Pinus brutia</i> , abordando as técnicas de RNAs, como, também, no sentido de demonstrar a aplicação de uma metodologia alternativa no campo do projeto de reflorestamento, responsável por permitir a estimativa e otimização do volume dos fustes de árvores dominantes em reflorestamentos (usando fatores facilmente mensuráveis no local e na competição).	Entradas : Idade (anos); Área Basal (m ² /ha); Incremento médio anual (m ³ /ha/ano) na idade da medição; Altura Total (m); Diâmetro a 1,3m da superfície do solo (DAP); Número de fustes por hectare (n/ha) e a razão entre o DAP e a altura total. Saída : Densidade.	O uso das MLPs pode ser observado como uma ferramenta útil na prática florestal, especialmente quando as características dos locais são facilmente mensuráveis e a densidade das árvores plantadas são usadas como variáveis de entrada neste modelo. Já a modelagem CCANN, introduzida neste estudo, tem a capacidade de superar problemas em dados florestais, como relacionamentos não-lineares ou distribuições não-gaussianas, além de parecer uma alternativa promissora frente aos modelos tradicionais de regressão, uma vez que a rede determina seu tamanho e topologia.
Silva et al. (2009)	O primeiro objetivo foi direcionado à avaliação do ajuste do modelo volumétrico de Schumacher e Hall com a utilização de diferentes algoritmos. Além disso, foi empregada a metodologia de RNAs para a estimativa de volume para a espécie de eucalipto em função do DAP.	Entradas : 9 Redes considerando o DAP (4,5 a 28,3 centímetros) e Altura Total (6,6 a 33,8 metros) e outras 9 Redes contando com o DAP (4,5 a 28,3 centímetros, Altura Total (6,6 a 33,8 metros) e Clone. Saída : Volume.	A tecnologia das RNAs apresentou boa adequação ao problema, tornando-se altamente recomendada para previsão volumétrica da produção de plantios florestais.
Diamantopoulou & Milios (2010)	Os autores propuseram a descrição de uma modelagem RNAs para estimar o volume total de <i>Pinus</i> dominantes (<i>Pinus brutia</i>) no interior/exterior do tronco de árvore em reflorestamentos.	Entradas : Diâmetro médio dentro da casca (máximo e mínimo), tomados a dois intervalos [(0,3), (1,3), (3,3) e (5,3)], e a altura total. Em contrapartida, a rede 2 (para o volume de fora da casca) também contou com essas variáveis, porém, com modificações no tipo do diâmetro (calculado fora da casca). Saída : Volume total (dentro e fora da casca).	A técnica de RNA introduzida no estudo, com base em dados de medidas reduzidas através de análise multivariada, comprovou ser promissora para a estimativa.

Özçelik et al. (2010)	Objetivou-se testar o desempenho de diferentes modelos de RNAs na estimativa do volume de fuste de quatro espécies de árvore. Para tanto, foi avaliada a performance de dois tipos de RNA: 1) a arquitetura perceptron multicamada usando o algoritmo de propagação de retorno e 2) a arquitetura CCANN.	Entradas: Diâmetro do toco, altura do fuste e o diâmetro no topo do fuste. Saída: Volume do fuste.	Os resultados, incluindo a análise comparativa entre as RNAs e os métodos adicionais, mostraram que a CCANN e BPANN foram úteis para a previsão de volume de fuste. Em especial, destaca-se que os modelos CCANN, onde a regra de aprendizado de Kalman está incorporada, pareceu ser uma excelente alternativa (fornecendo resultados precisos e imparciais, reduzindo a dendrometria necessária e economizando tempo no campo).
Petropoulos et al. (2010)	O escopo foi destinado na avaliação da capacidade das RNAs e de um SAM, ambos combinados com imagens de satélite Landsat TM em uma região do Mediterrâneo, no mapeamento de área queimada.	Entradas: Embora não especificado, assume-se que os <i>inputs</i> estão relacionados com os pontos de queimada apontados nas imagens do satélite Landsat TM. Saída: Área total queimada. Cada rede tem sua previsão de queimada associada a uma classe apresentada. Logo, o somatório de todas as áreas de queimada, de todas as classes, irão informar o total de queimadas ocorridas na região.	Em termos comparativos, a RNA foi quem apresentou o melhor desempenho, diferindo em 0,5% e 142% de área queimada total nos índices disponíveis no site da Risk-EOS (imagens SPOT XS) e Greece (imagens IKONOS), respectivamente, ao passo que o SAM teve estimativas com discrepância de 8,8% e 5%. As análises (das estatísticas de classificação, coeficiente Kappa e Acurácia) relataram aprox. 84% de precisão para o método SAM e 90% para as RNAs. Sendo assim, os resultados demonstraram claramente o potencial da RNA em delinear áreas queimadas em condições topográficas e ecossistêmicas complexas.
Balci et al. (2011)	A proposição encontrada buscou aplicar o modelo de Bohart e Adams para exibir o processo de absorção de corantes têxteis em pilares de vidros utilizando cascas de Eucalipto. Além disso, optou-se por fazer uso das RNAs para determinar a capacidade de absorção de corante do sistema de leito.	Entradas: Volume de água, altura do material filtrante e a concentração de corantes por litro de água. Saídas: Concentração de corante da água tratada.	Os resultados previstos apontaram que as RNAs se aproximaram muito dos valores experimentais encontrados, apresentando erro quadrático médio na ordem de 10^{-3} . Não obstante, os autores relataram que a RNA pode ser empregada como um excelente complemento para o convencional e complicado modelo matemático abordado na predição dos parâmetros de bioprocessos.
Soares et al. (2011)	O escopo foi direcionado em apresentar uma abordagem para a predição de diâmetro para as espécies de Eucalipto com o uso das RNAs.	Entradas: Medidas de diâmetros em três alturas diferentes na base de cada árvore (0,30m; 0,70m e 1,30m). Observação: O próximo passo considerou a saída do primeiro caso como um novo input, gerando: (0,7m, 1,3m e 2m). Estes passos são repetidos em intervalos de um metro ao longo do caule até atingir a altura total da árvore. Sendo assim, pode-se descrever as entradas de uma forma generalizada: $d = \text{Diâmetro}(di-2, di-1 \text{ e } di)$. Saída: Diâmetro futuro seguindo a série temporal $di+1$.	Os resultados finais evidenciaram que as RNAs conseguiram convergir para o propósito do trabalho (previsão de diâmetro da árvore), mesmo contando com apenas 3 variações de diâmetro. Esse panorama permite a automatização do processo de inventário florestal, uma vez que reduz significativamente o custo e tempo para sua conclusão.
Lottering & Mutanga (2012)	O objetivo deste trabalho foi determinar o potencial de medidas de textura integradas com um modelo de RNA e de Regressão Linear Múltipla na estimativa do efeito de borda das estradas em florestas adjacentes de <i>Eucalyptus grandis</i> . Além disso, buscou-se investigar o uso de medidas de textura, calculadas mediante imagens do SPOT-5 multispectral e pancromáticas, na previsão do DAP, altura total, área basal, volume e área foliar.	Entradas: DAP, altura das árvores, área basal, volume e os índices de área foliar. Vale ressaltar, também, que cada variável foi associada a uma medida de textura: DAP: 3 Medidas; Volume: 2 Medidas; Altura: 3 Medidas; Área Basal: 3 Medidas; Índice de Área Foliar: 4 Medidas. Saídas: Atributos estruturais da floresta e a medição de textura (efeito de borda das estradas).	As RNAs se mostraram mais eficientes do que qualquer método de Regressão Linear Múltipla no que diz respeito à estimativa de atributos estruturais da floresta para ambas as imagens multiespectrais e pancromáticas da ferramenta SPOT-5. O desempenho desses modelos foi baseado em altos valores de determinação e baixo RMSE em um conjunto de dados de teste independente. Além disso, a abordagem integrada que envolve as medidas de textura de imagens do SPOT-5 e as RNAs previram com sucesso o efeito de borda da estrada em florestas adjacentes de <i>Eucalyptus grandis</i> .
Soares et al. (2012)	Delineou-se a modelagem de dois tipos de RNAs, as MLPs e RBFs, para a previsão de diâmetro (aplicado apenas três medidas reais tomadas na base da árvore). Diferentemente dos outros dois trabalhos promovidos pelos autores (Soares et al. [2011 e 2013]), este inseriu uma nova restrição: a previsão foi realizada até que o diâmetro mínimo comercializável tivesse sido atingindo, isto é, o topo com 4 cm fora da casca. Ademais, houve a realização de algumas comparações entre as duas redes, debatendo sobre qual apresentou os melhores resultados.	Entradas: Medidas de diâmetros em três alturas diferentes na base de cada árvore (0,30m; 0,70m e 1,30m). Observação: O próximo passo considerou a saída do primeiro caso como um novo input, gerando: (0,7m, 1,3m e 2m). Estes passos são repetidos em intervalos de um metro ao longo do caule até atingir a altura total da árvore. Sendo assim, pode-se descrever as entradas de uma forma generalizada: $d = \text{Diâmetro}(di-2, di-1 \text{ e } di)$. Saída: Diâmetro futuro seguindo a série temporal $di+1$.	Pôde-se observar que em todos os testes, independente da variação do diâmetro ser regular ou não, os valores de diâmetro preditos pelas MLPs e RBFs foram bastante satisfatórios. Já no comparativo das redes, os modelos de estimação apresentaram um pequeno <i>spread</i> , sendo que a RBF teve um ligeiramente maior que o modelo MLP e uma inclinação considerada uma tendência pequena.
Binoti et al. (2013a)	Este estudo teve como escopo a construção e avaliação de um modelo de autômatos celulares, com sua regra de evolução baseada em redes neurais artificiais, para a projeção da distribuição de diâmetros em povoamentos de eucalipto.	Entradas: Estado atual da célula, estado das células contidas na extensão a sua vizinhança e as idades (atual e futura). Saída: Estado Futuro da Célula.	O modelo proposto neste estudo, baseado em autômatos celulares e em RNAs, pode ser utilizado para a projeção da distribuição diamétrica de povoamentos equiâneos.

Binoti et al. (2013b)	<p>A essência deste estudo estava direcionada em aumentar a precisão das estimativas de altura de árvores e, ao mesmo tempo, diminuir a necessidade de aferição da altura em campo, para reduzir os custos no inventário florestal (a partir da construção e validação de um modelo de RNAs).</p>	<p>Entradas: Variáveis quantitativas: Altura Dominante média da parcela, diâmetro com casca a 1,30m de altura (DAP) e idade. Variáveis qualitativas: Apenas o Solo. Saída: Altura Final de eucalipto.</p>	<p>O modelo desenvolvido foi considerado eficiente para estimativa da altura de árvores em povoamentos de eucalipto. Além disso, a aplicação da metodologia permitiu a redução significativa de medições em clones recém-introduzidos no povoamento.</p>
Castro et al. (2013)	<p>Este artigo objetivou a avaliação e comparação de duas categorias de modelos de crescimento e produção em plantios comerciais de Eucalipto por meio de equações simultâneas e RNAs.</p>	<p>Entradas: Cada uma das 15 redes sofreram variações no número e no tipo de variáveis, podendo ser: Idade atual e futura (Ie I2), índice de local (S), classe de DAP, índice de competição independente da distância (IID1, IID2, IID3, IID4, IID5), o DAP na idade atual (DAP 1) e a altura total na idade atual (h1). Saída: Cada RNA teve associado à sua saída, uma possibilidade: Probabilidade de Mortalidade, DAP na idade futura ou altura total na idade futura.</p>	<p>Ambos os modelos conduziram estimativas adequadas para o volume de madeira por hectare em todas as idades, principalmente nas idades finais. Sendo assim, constatou-se que o uso das RNAs pode servir como alternativa às funções que compõem o MAI, auxiliando na identificação das variáveis mais importantes para a prognose do crescimento em diâmetro, altura, probabilidade de mortalidade em árvores individuais e a produção volumétrica de um povoamento.</p>
Özçelik et al. (2013)	<p>O propósito foi realizar um estudo comparativo (entre vários métodos) no sentido de obter previsões de altura em parcelas de amostra de <i>Crimerian juniper</i>, localizada na região sul da Turquia. Para isso, várias funções de crescimento não-lineares, ajustadas com o emprego das técnicas de modelos de efeitos mistos não lineares, foram utilizadas, além de modelos generalizados do tipo h-d (medidas de diâmetro altura) e das RNAs.</p>	<p>Entradas: A Rede I foi alimentada com dados de DAP; e a Rede II com o mesmo DAP, mas levando em consideração a variação encontrada para cada parcela analisada. Saída: Altura final.</p>	<p>A análise comparativa entre os modelos conduzidos neste estudo mostraram que quando a variabilidade da relação h-d de <i>stand to stand</i> pode ser incorporada ao modelo, tanto a abordagem de efeitos mistos não-lineares quanto as RNAs são consideradas ferramentas úteis para a predição de altura de fuste arbóreo no manejo de recursos florestais. No tocante aos resultados, o modelo BPANN_V (Rede 2) foi considerado superior aos demais, graças a sua capacidade de generalização.</p>
Soares et al. (2013)	<p>Desenvolveu-se uma abordagem para o uso de redes MLP para a previsão recursiva de diâmetros de árvores, com o uso de apenas três medidas reais tomadas na base da árvore, sem o conhecimento prévio da altura total. Em seguida, os diâmetros previstos foram usados com o método Smalian para calcular o volume de árvores em um local plantado.</p>	<p>Entradas: Medidas de diâmetros em três alturas diferentes na base de cada árvore (0,30m; 0,70m e 1,30m). Observação: O próximo passo considerou a saída do primeiro caso como um novo <i>input</i>, gerando: (0,7m, 1,3m e 2m). Estes passos são repetidos em intervalos de um metro ao longo do caule até atingir a altura total da árvore. Sendo assim, pode-se descrever as entradas de uma forma generalizada: d= Diâmetro (di-2, di-1 e di). Saída: Diâmetro futuro seguindo a série temporal di +1.</p>	<p>No geral, foram observados que todos os testes, independentemente de a variação do diâmetro ser regular ou não, encontraram valores previstos de diâmetros com muita eficiência, quando comparados aos valores dos diâmetros reais. No entanto, foi difícil para as MLPs preverem o diâmetro mais próximo das copas das árvores, algo que já era esperado, especialmente pelo fato de que o modelo desenvolvido executa previsões recursivas e o erro em um dado diâmetro previsto será repassado para os próximos. Por outro lado, os testes realizados com o aproximador polinomial de mínimos quadrados, apesar de baixo custo operacional, não mostraram resultados satisfatórios.</p>
Binoti et al. (2014a)	<p>Tendo em vista o elevado custo para a cubagem de árvores nas empresas florestais, o desígnio deste estudo foi propor uma metodologia com o emprego das RNAs para reduzir o número de árvores a serem cubadas durante o processo de geração de equações volumétricas.</p>	<p>Entradas: DAP, altura e os diâmetros nas posições 0,0; 0,5; 1,0; 1,5; 2,0; e 4,0m do solo, além dos volumes obtidos de 2 até 4m e da variável categórica definida como clone, na qual apresenta 15 subdivisões (C1 a C15). Saída: Volume.</p>	<p>A RNA mostrou-se eficiente para a estimação do volume de árvores e, por isso, é indicada para a obtenção do volume total (com e sem casca) de povoamentos de eucalipto, possibilitando a construção de equações volumétricas com baixo custo.</p>
Binoti et al. (2014b)	<p>Foi proposto o desenvolvimento e avaliação das RNAs na projeção de parâmetros da distribuição Weibull e na comparação deste método com alguns modelos de distribuição diamétrica comumente utilizados na área florestal.</p>	<p>Entradas: Parâmetro β da função Weibull, idade inicial, idade futura, parâmetro γ da função Weibull, diâmetro médio, altura mínima, altura dominante, altura média, altura máxima, DAP mínimo, média do DAP, DAP máximo e número de árvores plantadas. Saída: As quatro primeiras redes trabalharam com o parâmetro β da função de Weibull na idade futura; As redes de 5 a 8 preveram o parâmetro γ da função de Weibull na idade futura; As redes 9 a 12 fizeram a prognose do DAP mínimo na idade futura e as últimas 4 redes estimaram o DAP máximo na idade futura.</p>	<p>A modelagem de distribuição diamétrica feita pelas RNAs foi avaliada como "mais eficiente" quando confrontados com os modelos usuais desenvolvidos por regressão.</p>

Silva et al. (2014)	<p>O prisma deste trabalho foi orientado em modelar uma metodologia para a criação de um mapa de uso e cobertura do solo na região norte do estado de Minas Gerais. Para isso, traçou-se três objetivos específicos: Testar o uso de técnicas de segmentação de imagens para uma classificação baseada em objetos, contemplando informações espectrais, espaciais e temporais; Testar o uso de imagens de alta resolução espacial (Rapideye) combinadas a séries temporais Landsat-TM, visando a captar os efeitos da sazonalidade, e a classificação dos dados por meio das RNAs.</p>	<p>Entradas: Valores dos 4 NDVI provenientes de imagens do Landsat TM, refletância média dos objetos em cada uma das 5 bandas, brilho total, taxa de contribuição de uma determinada banda para o brilho geral (bandas 4 e 5), diferença máxima entre as intensidades médias de cada banda, diferença média entre os valores de pixel dos objetos (bandas 4 e 5) e o desvio padrão (bandas 4 e 5).</p> <p>Saídas: Cada neurônio representa um tipo de classe nativa, podendo ser: Terras agrícolas (1), água (2), cerrado (3), floresta decídua (4), eucalipto (5), outros (6), pastagens (7) e vereda (8).</p>	<p>A proposta mostrou-se altamente eficaz no mapeamento da cobertura e uso da terra em uma região com alta diversidade de classes de flora e ocupação. Ao integrar as informações espaciais e espectrais das imagens RapidEye com as imagens Landsat TM, a técnica de segmentação de imagens permitiu combinar o melhor de ambos sem qualquer perda ou comprometimento de dados. No que diz respeito as RNAs, o número de camadas ocultas, assim como o número de neurônios em cada camada, não parece ter correlação direta com a precisão do mapeamento, provando ser capaz de classificar dados com grande precisão e diferindo apenas pelo número de iterações requeridas para cada camada.</p>
Ashraf et al. (2015)	<p>O direcionamento deste estudo foi voltado na construção de um modelo de crescimento e rendimento simples que tenha a capacidade de prever o crescimento de árvores individuais sob diferentes cenários de mudanças climáticas. Estes dados são provenientes da integração de registros históricos, processos ecológicos, o JABOWA-3 (responsável por projetar o crescimento de árvores em diferentes cenários de mudanças climáticas), e das RNAs.</p>	<p>Entradas: Área Basal, soma dos stands totais de área basal de madeiras macias (SW) no PSP, stands totais de área basal de madeiras nobres ou folhosas no PSP, soma da área basal de árvores grandes (com base no diâmetro) em um PSP, soma da área basal de árvores grandes do tipo HW (com base no diâmetro) em um PSP, altura dominante, umidade do solo, nutrientes do solo, identificação de classe de espécie, fator de estoque, dias de grau crescente, radiação solar e cenários climáticos.</p> <p>Saídas: Incremento de volume e área basal.</p>	<p>O modelo baseado em RNAs teve a capacidade de prever o crescimento (em função do incremento da área basal e do volume) nas condições climáticas atuais, bem como nos três diferentes cenários projetados.</p>
Bhering et al. (2015)	<p>O objetivo central englobou avaliar a metodologia de RNAs para a predição do volume de madeira nos programas de melhoramento de eucalipto e na seleção das famílias, comparando seus resultados com os encontrados pelo modelo de regressão.</p>	<p>Entradas: Situação A: Diâmetro e altura total; Situação B: Diâmetro e altura comercial; Situação C: Tipos de espécies, diâmetro e altura total (ambas para o volume total) e diâmetro e altura comercial (usadas para o cálculo do volume comercial).</p> <p>Saída: Volume.</p>	<p>As conclusões inferem que as RNAs podem ajudar a melhorar a precisão para medir o volume de eucalipto e automatizar o processo de inventário florestal. Quando comparada com os modelos de regressão, observou-se que ela conseguiu ser superior à quase todos.</p>
Binoti et al. (2015)	<p>O principal foco do artigo foi modelar não só a produção volumétrica de povoamentos de clones de Eucalipto em função de variáveis categóricas e numéricas, como, também, avaliar a exatidão da prognose das RNAs.</p>	<p>Entradas: Categóricas (para a área basal): Projeto, tipo de solo, relevo, textura, clone e espaçamento. Numéricas (para a área basal): Idade atual, idade futura e área basal atual. Categóricas (para o volume): Projeto, tipo de solo, relevo, textura, clone e espaçamento. Numéricas (para o volume): Idade atual, idade futura, área basal atual, volume inicial e área basal futura.</p> <p>Saídas: Um <i>output</i> para o primeiro conjunto de redes: área basal. Uma saída para o segundo conjunto de redes: Volume futuro. Isso acontece porque a área basal futura é tratada como <i>input</i> para a previsão do volume.</p>	<p>Observou-se que as RNAs do tipo Linear, MLP e RBF foram aptas ao desempenhar a tarefa de aproximação de funções para a projeção da área basal e do volume em povoamentos de clones de eucalipto, comprovando o grande potencial da técnica para diferentes aplicações no manejo florestal.</p>
Cosenza et al. (2015)	<p>O objetivo foi centrado na comparação dos resultados obtidos pelo processamento de dados florestais com a Máquina de Vetor de Suporte e RNAs, visando à classificação da capacidade produtiva de povoamentos de eucalipto.</p>	<p>Entradas: O tipo de solo e de preparo antes do plantio; O espaçamento utilizado; A idade do povoamento; Altura dominante; Área basal; Volume com casca; Diâmetro à 1,3 m de altura (dap) mínimo, médio e máximo do povoamento e o número de indivíduos por hectare. Dentro destas variáveis categóricas, estavam descritos dez tipos de solos, dois tipos de preparo do solo e cinco tipos de espaçamento.</p> <p>Saída: O valor emitido por cada um dos três neurônios da camada de saída representará a probabilidade de um dado talhão pertencer à sua respectiva classe.</p>	<p>As técnicas de Inteligência Computacional obtiveram uma boa capacidade em classificar a capacidade produtiva do local. Como complemento, o comparativo das abordagens garantiu que as RNAs conseguiram maior precisão do que a Máquina de Vetor de Suporte.</p>

Diamantopoulou et al. (2015)	Investigou-se o potencial de melhoria na modelagem de distribuição de diâmetro no momento em que os modelos de RNA (com aprendizado Levenberg-Marquardt) foram utilizados como um procedimento interno para a estimativa precisa dos parâmetros necessários na modelagem de distribuição Weibull de dois parâmetros, usando o método dos momentos (MOM) e a estimação por máxima verossimilhança (MLE).	Entradas: Idade das árvores, diâmetro médio quadrático e área basal. Saída: Distribuição de diâmetro.	Os modelos de RNAs conseguiram fornecer uma estimativa precisa para o crescimento e modelos de produção da floresta, ambos de vital importância para o planejamento do manejo florestal. Sendo assim, conforme sugere a pesquisa, a RNA configura um cenário de melhoria na previsão da distribuição de diâmetro.
Hickey et al. (2015)	A proposta consistiu na construção de modelos alternativos de previsão para a proporção de produtos finais planejados que podem ser extraídos de um compartimento florestal. Para isso, foi desenvolvido um modelo de regressão de Dirichlet e uma RNA para comparar seus respectivos resultados com um modelo multivariado de benchmark de regressão múltipla.	Entradas: Diâmetro médio a altura do peito, colheita do primeiro desbaste, colheita do segundo desbaste, espécies SS/NS e espécies LP/LPS/OC (ambas não informadas o que significam) e a elevação. Saídas: Proporção de <i>Sawlog</i> (tamanho adequado para serrar madeira. Processado em serrarias); Proporção de Pallets de madeira; Proporção de Estacas de madeira; Proporção de Polpa de madeira.	Os resultados apontaram que tanto o modelo de regressão de Dirichlet quanto as RNAs obtiveram resultados eficientes e confiáveis na previsão das 4 proporções. Embora o modelo de Dirichlet seja mais simplificado, foi a RNA que apresentou melhor acurácia, de acordo com a análise quantitativa realizada na comparação. Segundo os autores, um dos motivos centrais para a boa previsão das RNAs foi o uso de três heurísticas para encontrar a topologia ideal, fato que não desmerece o potencial das RNAs.
Miguel et al. (2015)	Buscou-se avaliar a eficácia da aplicação de modelos de análise de regressão e RNAs na predição do volume de madeira e da biomassa, acima do solo, da vegetação arbórea em área constituída pelo bioma de cerrado, o cerrado.	Entradas: Área basal (G); EVI (2); NDVI; SAVI; e o SRVI. Saída: Volume total, volume do fuste, biomassa total ou biomassa do fuste.	Tanto os modelos de regressão quanto as RNAs conseguiram gerar estimativas precisas de volume de madeira e biomassa para a vegetação lenhosa, juntamente com ajustes em função da área basal e de índices de vegetação gerados por sensoriamento remoto. Contudo, os resultados apontaram maior acurácia por parte das RNAs.
Santi et al. (2015)	Os autores buscaram investigar o potencial de imagens SAR de banda L (ALOS/PALSAR) e banda C (ENVISAT/ASAR) no monitoramento de biomassa florestal e, simultaneamente, desenvolver um algoritmo de recuperação, baseado em RNAs, para estimar o volume de madeira das aquisições combinadas das imagens de satélite.	Entradas: Aquisições de frequências disponíveis e polarizações, intermediadas pelo RAS, além dos ângulos de incidência e uma base de dados auxiliares. Saída: Volume.	Apesar das diferentes características apresentadas nas duas áreas, em termos de vegetação, nuances de relevo e outras paisagens, as RNAs conseguiram proporcionar resultados animadores com erros relativamente baixos e, conseqüentemente, induzindo ao baixo índice dos riscos.
Aquino et al. (2016)	A proposição embasou-se em analisar variáveis ambientais que atuam na formação da serapilheira em uma mata de galeria através da aplicação da metodologia de RNAs.	Entradas: Elevação, posição espacial (coordenada x e y), dados mensais de chuva acumulada, quantidade de dias com chuva, temperaturas máxima e mínima, temperatura média, umidade relativa do ar média, pressão atmosférica média, precipitação média, velocidade média do vento, número de indivíduos e espécies por parcela, índice de diversidade de <i>ShannonWeaver</i> e o número de indivíduos das famílias mais representativas. Saídas: Frações de folhas; Frações de ramos (galhos e cascas); Estruturas reprodutivas e o total de Serapilheira em gramas.	Segundo a conclusão dos autores, as RNAs se apresentaram como uma ferramenta muito interessante na análise de variáveis ambientais associadas à deposição de serapilheira. Além disso, foi considerado que os valores obtidos para o erro de validação das redes podem ser relevantes, uma vez que a serapilheira possui alta variabilidade devido aos diversos fatores que a afetam.
Leite et al. (2016)	O estudo envolveu a modelagem da densidade básica de madeira para povoamentos de clones de Eucalipto em função de variáveis numéricas, obtidas pelo IFC, com o emprego das RNAs sob diferentes óticas de treinamento: <i>Error backpropagation</i> , <i>RP</i> , <i>MUR</i> , <i>SCG</i> , <i>LM</i> , <i>quick propagation</i> e as meta-heurísticas do <i>SA</i> e <i>AG</i> .	Entradas: Idade (anos); Área Basal (m ² /ha); Incremento médio anual (m ³ /ha/ano) na idade da medição; Altura Total (m); Diâmetro a 1,3m da superfície do solo (DAP); Número de fustes por hectare (n/ha) e a razão entre o DAP e a altura total. Saída: Densidade.	Embora tenham sido abordadas diferentes combinações, os resultados apontaram que não houve diferenças significativas entre os tipos de funções de ativação e, tão pouco, boas soluções com o uso dos algoritmos do <i>SCG</i> , <i>MUR</i> , <i>LM</i> , <i>SA</i> e <i>AG</i> . No entanto, em síntese, concluiu-se que as demais RNAs obtiveram convergência e, por isso, são capazes de estimar a densidade básica em função de valores obtidos no inventário florestal.
Martins et al. (2016)	O escopo do artigo consistiu em definir configurações adequadas de RNAs para a obtenção da altura total de árvores de eucalipto, levando em conta diferentes métodos de treinamento, podendo citar: o <i>MUR</i> , <i>SCG</i> , <i>LM</i> e duas meta-heurísticas, o <i>GA</i> e o <i>SA</i> .	As entradas contaram com o uso de Variáveis quantitativas (diâmetro a altura do peito, altura dominante e idade) e categóricas (Projeto, clone, tipo do solo, espaçamento e relevo contendo, respectivamente, 4, 6, 15 e 6 classes). Saída: Altura total de árvores de Eucalipto.	As RNAs foram eficazes para a estimativa da altura das árvores por meio de diversas configurações, sendo elas: O algoritmo de aprendizagem <i>RP</i> , <i>Quick Propagation</i> e <i>SCG</i> . Além do mais, configurações simples de RNAs com apenas três neurônios ocultos são eficientes para prever a altura e árvores e devem ser preferidas em detrimento de configurações complexas.

Nunes & Gorgens (2016)	O alinhamento deste trabalho abarcou a avaliação das habilidades dos modelos de RNAs e da técnica RF na prognose do diâmetro de árvores em qualquer altura e volume acumulado ao longo do comprimento do caule (em função da medição da conicidade da árvore) em três regiões diferentes: O cerrado, uma floresta tropical e uma floresta semidecídua. Ao final, estes resultados foram comparados com um modelo específico de equação <i>taper</i> .	Entradas: Diâmetro a altura do peito, altura total e três variáveis categóricas "dummy" que representam o tipo de floresta de cada um dos cenários estudados (cerrado, floresta tropical e semidecídua). Saídas: Volume e diâmetro.	A RNA lidou bem com os dados provenientes de três diferentes tipos de florestas dentro de um mosaico de vegetação. Não obstante, este procedimento forneceu uma compreensão dos padrões que surgem de fenômenos complexos, na medida em que treinam corretamente o modelo e realizam previsões. Devido a esses fatores, os autores recomendaram a aplicação das redes MLP nas previsões, especialmente quando a forma do caule e a variação na arquitetura da árvore são complexas.
Reis et al. (2016)	A proposição do trabalho consistiu em modelar a projeção do diâmetro futuro de árvores individuais, em uma floresta manejada na Amazônia, utilizando as RNAs como fonte de subsídio para a tomada de decisões.	Entradas: Índice de competição semi-independente da distância, diâmetro medido a 1,30m do solo, classe florestal, grupo de crescimento, classe de identificação de troncos, intensidade de infestação por Liana e iluminação da coroa. Saída: Incremento periódico anual de diâmetro.	Comprovou-se que todas as RNAs podem ser utilizadas no prognóstico do crescimento individual e, conseqüentemente, no diâmetro futuro de árvores após a fase de colheita, uma vez que apresentaram RMSE abaixo de 1%, correlação acima de 99% e eficiência do modelo acima de 0,97. Além disso, a RNA que não utilizou o índice de competição (como variável de entrada) foi avaliada como a mais simples e com o menor RMSE durante o teste.
Ribeiro et al. (2016)	As diretrizes deste estudo foram voltadas à aplicação e avaliação dos métodos de regressão, baseado na expansão do modelo de Schumacher, e de RNAs para a estimativa de volume de fuste e de galhos na Floresta Nacional do Tapajós.	Entradas: A unidade de trabalho, o tipo de espécie, DAP, a altura comercial e uma variável <i>dummy</i> (0 para o volume do fuste e 1 para o volume dos galhos). Saída: Volume dos fustes e galhos.	Embora o modelo único para múltiplos volumes tenha encontrado bons resultados, foi a RNA que apresentou melhor acurácia.
Binoti et al. (2017)	Este estudo foi conduzido em avaliar o método <i>Neuroevolution of Augmenting Topologies</i> (NEAT), para o ajuste dos pesos e da topologia de RNAs, na estimação da altura de árvores em povoamento clonais de eucalipto, bem como comparar suas previsões com as estimativas encontradas por um modelo hipsométrico de regressão.	Entradas: Diâmetro ajustado para 1,3m de altura (DAP) e altura dominante (Hd). Saída: Altura total.	A metodologia NEAT gerou estimativas precisas, sem viés, para o estudo proposto. Isso prova que ele é viável para a parametrização de RNAs, não só para a previsão de altura total como, também, para aplicações operacionais de medição e de manejo. No que tange o comparativo entre as técnicas, várias configurações de RNAs apresentam estatísticas superiores ao modelo hipsométrico de regressão.
Cosenza et al. (2017)	O objetivo deste trabalho foi conduzido pela avaliação das RNAs para a realização da classificação de sítios de plantios de Eucalipto (com base em informações silviculturais e ambientais) para poder responder duas questões: Encontrar a melhor configuração de rede para a classificação de sítio e; A abordagem de RNA, sem recurso de suporte (<i>stand</i>) como entrada, foi mais precisa do que o método de curva-guia?	Entradas: Material Genético, espaçamento, rotação, tipo de solo e informações climáticas. Segundo os autores, foram considerados 17 tipos de solo, 49 genótipos, 8 espaçamentos e 11 condições diferentes de clima. Saídas: A rede com 3 classes apresentou 3 neurônios na saída. Para este caso, a classificação de mapeamento da área teve amplitudes de 5,5m (32-37,5m; 26,5-31,9m e 21-26,4m). Já a rede com 4 classes teve 4 neurônios na saída. Semelhante ao primeiro caso, a classificação de mapeamento da área teve amplitudes, porém, com valores equivalentes a 4,0m: (33-37m; 29-32,9m; 25-28,9m e 21-24,9m). Em outras palavras, a saída se refere a classificação do sítio baseada no índice de sítio observado nas diferentes classes com variação de amplitude.	Em geral, a RNA, utilizando apenas insumos ambientais e silviculturais, proporcionou melhor acurácia de classificação do que o método CG, o que permite dizer que a técnica pode ser aplicada na ausência de dados de altura dominante ou histórico de povoamento (desde que haja uma RNA previamente treinada para ela). No entanto, no caso de estandes estabelecidos com idade próxima ao ano de referência, o CG deve ser priorizado para classificação do sítio devido a sua melhor precisão.
Lacerda et al. (2017)	A essência do artigo consistiu em retratar que o uso das RNAs pode ser visto como uma ferramenta altamente viável para estimar o volume de árvores, considerando diferentes espécies da savana brasileira. Como complemento, criou-se comparações entre as estimativas das Redes com algumas equações volumétricas.	Entradas: Situação A: Diâmetro e altura total; Situação B: Diâmetro e altura comercial; Situação C: Tipos de espécies, o diâmetro comercial e total, além da altura total e comercial. Saídas: Situação A: Volume total; Situação B: Volume comercial e Situação C: Volume total (comercial+total).	O estudo descobriu que tanto as RNAs quanto os modelos de regressão podem ser utilizados como ferramentas eficientes para estimar os volumes de árvores totais e comerciais da savana brasileira.
Vendruscolo et al. (2017)	Propôs-se avaliar e comparar a modelagem de RNAs, com a técnica de regressão, no que diz respeito à estimativa da altura total de árvores de <i>Tectona grandis</i> em diferentes espaçamentos no município de Cáceres, MT, Brasil.	Entradas: diâmetro a altura do peito (DAP), além do diâmetro máximo e dos espaçamentos. Saída: Altural total.	Ambas as técnicas avaliadas são observadas como eficientes para estimativa da altura de árvores de <i>Tectona grandis</i> . No entanto, a RNA apresentou indicadores estatísticos superiores em relação à regressão, com erro de estimativa abaixo de 10%.

Çatal & Saplıoğlu (2018)	Foi analisado qual método poderia determinar corretamente a quantidade de casca em <i>Pinus brutia ten.</i> numa região da Turquia. A ideia foi focar na construção de modelos de RNAs e um sistema de inferência adaptativo NeuroFuzzy, como alternativa ao modelo de regressão não linear.	Entradas: Diâmetro a altura do peito com casca, diâmetro a altura do peito sem casca e volume da árvore com casca. Saída: Volume de casca.	Apesar da rede MLP apresentar resultados superiores à técnica de regressão não linear, foi a rede Neuro Fuzzy que obteve maior precisão na estimativa do volume de casca da espécie <i>Pinus brutia ten.</i>
Reis et al. (2018a)	A finalidade incidiu em estimar a sobrevivência e a mortalidade de árvores individuais, em uma floresta colhida seletivamente, a partir do uso de RNAs (como fonte de subsídio) para as decisões silviculturais sobre o manejo florestal na Amazônia.	Entradas: Diâmetro a altura do peito, classe da floresta, classe de identificação de tronco, índice de competição, grupos de crescimento, intensidade de infestação de liana, iluminação da coroa, lesões (ou não) em árvores e podridão de árvores. Saídas: Mortalidade e Sobrevivência.	As RNAs foram consideradas eficazes em oferecer um prognóstico sobre a mortalidade e sobrevivência de árvores na região da Amazônia.
Reis et al. (2018b)	O trabalho teve como proposta o emprego dos Autômatos celulares, como regra de evolução em RNAs, para projetar a distribuição dos diâmetros em floresta colhida, podendo servir como tomada de decisão para o Manejo Florestal Sustentável na Amazônia brasileira.	Entradas: Densidade atual, densidade futura e o período de medições (em anos). Saída: Distribuição diamétrica.	Com base nas experimentações, o uso das duas técnicas produziu bons resultados na tarefa de prever a distribuição diamétrica, ao longo do ciclo de corte, para as árvores de Eucalipto, especialmente por manter a forma da distribuição observada ao longo do tempo.
Sanquetta et al. (2018)	Procurou-se examinar o desempenho de alguns modelos de AI (Variante do k-vizinhos, um e três vizinhos mais próximos e RNAs) na estimativa do volume comercializável de toras de <i>Cryptomeria japonica</i> , em um plantio experimental no sul do Brasil.	Entradas: Não foram informadas. Saída: Volume total.	Os resultados apontaram que as RNAs conseguiram melhorar a estimativa do volume de árvores comercializáveis de <i>Cryptomeria japonica</i> .
Vieira et al. (2018)	Considerando o potencial da Inteligência Artificial na mensuração florestal, o artigo propôs a aplicação das RNAs e de um sistema ANFIS para a prever o crescimento em DAP e altura de Eucaliptos.	Entradas: Diâmetro atual a 1,30m (DAP), idade futura, idade atual, índice de competição (independente da distância), material genético, índice de sítio e altura total atual. Uma saída por rede, podendo ser direcionada para o crescimento futuro em DAP ou a altura futura.	As redes MLP e ANFIS apresentaram maior acurácia do que os modelos de regressão, na necessidade de projetar o DAP e Altura, ambos futuros, para a espécie de Eucalipto.

Legenda: RNAs (Redes Neurais Artificiais); DAP (Diâmetro a altura do Peito); LAI (Leaf Area Index); SAR (Synthetic Aperture Radar); ENVISAT (Environmental Satellite); ASAR (Advanced Synthetic Aperture Radar); ALOS (Advanced Land Observing Satellite); PALSAR (Phased Array type L-band Synthetic Aperture Radar); MLP (Multilayer Perceptron); RBF (Radial Basis Function); IFC (Inventário Florestal Contínuo); CCANN (Cascade Correlation Artificial Neural Network); RAS (Radar de Abertura Sintética); SA (Simulated Annealing); GA (Algorithm Genetic); RF (Random Forest); NVDI (Normalized Difference Vegetation Index); EVI (Enhanced Vegetation Index); SAVI (Soil-adjusted vegetation index); SRVI (Simple Ratio Vegetation Index); MOM (Method of Moments); MLE (Maximum Likelihood Estimation); LMANN (Levenberg- Marquardt Artificial Neural Network); NEAT (Neuroevolution of Augmenting Topologies); LM (Levenberg - Marquardt); SCG (scaled conjugate gradient); MUR (Manhattan update rule); RP (resilient propagation); ANFIS (Adaptative Network based Fuzzy Inference Systems); RMSE (Root Mean Square Error); GC (Guide curve); AI (Artificial Intelligence); MAI (Modelo de Árvores Individuais); SAM (Spectral Angle Mapper); Landsat (Land Remote Sensing Satellite); PSP (Permanent Sample Plots).

3.3 TRABALHOS CORRELATOS EM DIFERENTES ÁREAS

A acirrada competição nos diversos setores da indústria tem exigido das empresas esforços direcionados ao alinhamento de seus produtos e/ou serviços com a necessidade do cliente final. Por esta razão, o processo de segmentação de mercado, uma das áreas abordadas na teoria do marketing, tem como premissa a clusterização (agrupamento) de clientes finais em subconjuntos de acordo com a similaridade de suas características e necessidades. Aliando essa nova perspectiva com a atual situação de uma companhia de celulares na Grécia, Petroulakis et al. (2007) aplicaram as redes neurais como fonte mediadora na escolha de qual seria o celular mais adequado para que a empresa possa mapear suas diretrizes estratégicas rumo à construção e promoção (campanhas de marketing) do produto. Para este fim, os autores estabeleceram que o preenchimento de formulários, distribuídos uniformemente em diversos meios de comunicação, seria a melhor opção para encontrar respostas mais realísticas. No entanto, o uso dessas informações (texto) foi considerado impróprio para a implementação na rede neural. Como solução, houve a padronização de cada um dos formulários em formato de matriz numérica, sendo assim utilizados como vetor de entrada. No que tange ao desenvolvimento dos modelos, as duas redes desenvolvidas pelos autores contaram com o algoritmo de retropropagação para a classificação, sendo que o treinamento foi conduzido pela otimização de *Levenberg-Marquardt* na rede 1 e pelo método de gradiente conjugado escalado (*Scaled Conjugate Gradient – SCG*) para a rede 2. A caracterização deste problema como sendo um sistema não linear, facilitou a escolha da função de ativação tangente hiperbólica (*Tansig*) na camada escondida e a sigmoide logarítmica (*Logsig*) para a saída. Para a avaliação, os autores fixaram, para ambos os modelos, *inputs* de 40 dados (instâncias) com variação no número de neurônios. Como resultado, ambas as redes conseguiram proporcionar resultados satisfatórios, levando em consideração a complexidade do problema. Em outras palavras, a rede 1 obteve como melhor solução a configuração com 35 neurônios na camada escondida, apresentando uma taxa de sucesso (comparativo do obtido com o

real) igual a 50%, ao passo que a rede 2 mostrou-se mais eficiente, atingindo 70% de sucesso com 37 neurônios.

Expressa como uma das mais importantes decisões na área econômico-financeira, a concessão de crédito não tem sido uma tarefa fácil. Se não bastasse isso, os altos níveis de inadimplência, juntamente com a falta de garantia de retorno, são considerados os principais responsáveis pelo aumento gradativo no índice de incerteza a respeito do repasse de verbas. No entanto, diversas técnicas têm sido desenvolvidas para lidar com este cenário negativo, dentre as quais o reconhecimento de padrões. Nessas condições, *a priori* do estudo realizado por Adamowicz et al. (2002) contou com a comparação entre o desempenho promovido pela RNA e pela rede da lógica *fuzzy*. A definição dos parâmetros e a coleta de informações foram intermediadas por uma instituição financeira, disponibilizando o total de 136 dados de clientes (instâncias). Para cada cliente foram associadas nove características influentes na decisão de crédito, sendo posteriormente convertidas na representação de vetor para facilitar a entrada nas redes. Além disso, os autores realçaram a criação de duas lógicas aplicadas à rede *fuzzy* para indicar o grau de pertinência no conjunto “bom” (mais próximo de zero) e no “ruim” (acima de 0,5 até 1,0). Diferentemente da arquitetura da RNA, na qual se usou o algoritmo de retropropagação com uma única camada de saída, a rede *fuzzy* teve como característica a existência de neurônios lógicos do tipo *and* e *or* com duas camadas escondidas e um algoritmo de treinamento competitivo para o ajuste de pesos. A análise dos testes permitiu assegurar que a rede neural atingiu com maior precisão os resultados esperados (erro médio abaixo de 0% para treinamento e teste), ao passo que a rede *fuzzy* obteve erro igual a 3,7% no treinamento e 7,1% para os testes.

No Brasil, as refinarias adotam misturas criteriosas e, por força da legislação, podem incorporar o álcool etílico como fonte de aumento do poder antidetonante em motores de combustão interna. No entanto, o controle de qualidade exigido pela Agência Nacional do Petróleo (ANP) tem identificado diversas adulterações nas especificações do combustível para a comercialização como, por exemplo, a adição de solventes. Neste contexto, Borsato et al. (2009) estruturaram as RNAs com foco direcionado na classificação de instâncias de três tipos de gasolina (A, C e C adulterada) na

região de Londrina, Paraná. Para isso, o experimento contabilizou o total de 531 amostras (30 amostras do tipo A, 480 do tipo C e 21 adulteradas). O modelo de RNA utilizado é do tipo *perceptron* de múltiplas camadas com uma camada oculta de neurônios com a função de ativação tangente hiperbólica e três neurônios na saída (um para cada tipo de gasolina) com a função logística. Além disso, a rede foi treinada com o algoritmo de retropropagação. Contrariamente ao cenário atual da ANP, uma vez que seus parâmetros não permitem a detecção de algumas gasolinas adulteradas, a RNA conseguiu classificar com precisão todas as amostras (100% de acurácia). Ademais, de acordo com o gráfico de superfície gerado pelo *software* Statistica 7.1, em conjunto com a análise de sensibilidade, os autores descobriram que, dentre todas as variáveis computadas, a temperatura dos primeiros 50ml e a primeira gota provocaram grandes variações na resposta, sendo determinantes na classificação de gasolina pela rede.

O futebol é considerado a modalidade esportiva mais popular do mundo, na qual sua torcida não possui limites, seja ela por idade, sexo ou classe social. A valorização dessa prática “quebrou” a margem dos bilhões de dólares nos últimos anos com a movimentação do mercado de transferência de jogadores e na publicidade promovida por empresas privadas e estatais (em menor número). O efeito produzido por esse crescente interesse acabou despertando a motivação das pessoas em participar de jogos em casas de apostas. Nessas condições, Fernandes et al. (2015) desenvolveram um trabalho inovador que contou com a possibilidade de obter a maior probabilidade em ganhar apostas a partir da predição de partidas com no mínimo 2 gols (uma das diversas estatísticas em que o apostador pode participar) com o uso das RNAs. A preparação de dados ocorreu com o levantamento dos jogos disputados em duas temporadas (2013 - 2014 e 2014 - 2015) da primeira divisão inglesa (*Premier League*). No entanto, devido a questões de adaptação e falta de ritmo por parte dos atletas, houve a desconsideração das seis primeiras rodadas em ambas as temporadas. No montante, 640 jogos serviram de base para o funcionamento de uma RNA do tipo *Multilayer Perceptron* com função de ativação *Logsig* treinada pelo algoritmo *Feedforward*, uma vez que as saídas se conectam apenas com os neurônios da camada seguinte. Seguindo a lógica de que um bom meio-campo e ataque tende a fazer muitos gols e uma sólida

defesa propende a tomar poucos gols, os autores descobriram que os indicadores de qualidade dos três setores (defesa, meio-campo e ataque) seriam as principais variáveis de entrada na rede com a complementação da taxa de vitórias, derrotas, empates, gols sofridos e marcados. Sendo a premissa do projeto voltada à predição da quantidade de gols em uma determinada partida, a rede necessitava, por vez, a inserção dos dados referentes a dois times quaisquer, A e B. Os testes apontaram baixa dispersão entre as 1.000 redes treinadas (comprovado pelo comportamento do histograma), resultando numa taxa de acerto equivalente a 57,85% para partidas com mais de 2 gols ou não. Embora a comparação com outros trabalhos passe a ser uma medida inviável, pelo fato deste trabalho ser inovador, a RNA se mostrou uma boa ferramenta para a predição de resultados, uma vez que o apostador passaria a ter mais de 50% de chances em ganhar.

Constituída por um conjunto de aclives, as bacias hidrográficas são sistemas complexos de suma importância para a efetivação de atividades que representam a sustentação integral de qualquer ecossistema. A dificuldade de prever as precipitações, em função de fatores como, por exemplo, a proximidade do mar, tem proporcionado grande variabilidade de seu espaço temporal, desencadeando não só a dificuldade no gerenciamento de recursos hídricos como também na ocorrência de eventos extremos. Nesta vertente, Sousa et al. (2010) propuseram o alinhamento deste cenário com a aplicação da RNA cuja finalidade foi simular a previsão de vazões médias (responsáveis pela minimização do impacto das incertezas do clima sobre a gestão de recursos) na estação fluviométrica de Piancó, na Paraíba. De acordo com os autores, as 120 amostras obtidas junto a 5 postos pluviométricos durante o ano de 1964 até 2003. Visando a convergência da solução, a proposta de RNA é trabalhada com o modelo *Multilayer Perceptron* (MLP) com três camadas, sendo a função de ativação sigmoideal foi utilizada para a camada oculta e linear para a saída. Além disso, os autores propuseram a criação de 15 redes distintas, variando as funções de ativação e o número de neurônios na camada intermediária. Adicionalmente, o treinamento foi motivado pelo uso do algoritmo *Levenberg-Marquardt* (LM), método responsável por gerar bons resultados em trabalhos com caráter não linear. Para o estudo, o desempenho das diferentes

redes neurais foi informado pelo valor obtido a partir de três estatísticas: coeficiente de variação, coeficiente de eficiência e erro padrão de estimativa. De maneira geral, os resultados foram considerados satisfatórios para a variação e eficiência de todas as arquiteturas de RNA, ressaltando-se, porém, que os índices apresentados pelos erros médios foram consideráveis (acima de 10% na maioria dos casos).

A predição da demanda de energia elétrica, conforme Oliveira et al. (2015), pode ser considerada uma vantagem competitiva para qualquer planejamento empresarial. À medida que o grau de incerteza vai aumentando, a necessidade em utilizar técnicas científicas com habilidades em gerar boas previsões passa a ser uma função intrínseca desse sistema. Dessa forma, aspirando por bons resultados, os autores decidiram abordar as redes RBF e a *General Regression Neural Network* (GRNN) como métodos de previsão de energia para os 7 anos seguintes na região sudeste do Brasil, com estimativas. A implementação da matriz de amostras a partir do algoritmo *k-means*, originou uma nova matriz de distâncias euclidianas entre os centros dos agrupamentos para o cálculo da largura da rede (*spread*). O valor resultante serviu como entrada para a primeira camada da rede RBF treinada por uma rede *Adalaine*. Já a rede GRNN adotou o procedimento de passagem dos parâmetros de período a ser aproximado com dois meses de espaçamento. Como resultado, a rede RBF garante a aproximação dos dados de saída de forma categórica com os reais, atingindo 99,68%, ao passo que a GRNN alcançou 97,21% para os 7 anos seguintes.

Embasado no princípio de ajustar o planejamento e gestão das ações públicas e, também, na complexidade promovida pelo dinamismo de variáveis não controladas, Neves e Bristot (2004), resolveram avaliar a possibilidade de implementação da rede RBF para prever as condições climáticas que correlacionam a quantidade de manchas solares e o seu reflexo na quantidade de chuva, além de categorizar os anos em normal, chuvoso ou seco para o município de Caicó, na região semiárida e em todo estado do Rio Grande do Norte entre os anos 1997 e 2003. Basicamente, as considerações iniciais apontadas pelos autores inferem na modelagem do problema e na escolha das manchas solares como principal fonte de informação. Visando obter bons

resultados, a rede RBF contou com uma função de ativação gaussiana com um algoritmo composto de duas partes: uma seleção auto-organizada de centros a partir do *k-means* e uma seleção supervisionada com aprendizado e ajustes de parâmetros livres com o uso do gradiente estocástico (*Linear Mean Square-LMS*). Antecedendo os testes, a experimentação garantiu a variação dos pesos sinápticos e dos centros de funções de base radial. De maneira geral, os resultados apresentados pelos modelos de rede foram considerados potenciais tanto para a região semiárida quanto ao estado, conseguindo prever o comportamento da chuva com diferenças pouco significativas. Em contrapartida, o modelo para o município mostrou-se pouco eficiente, acertando duas previsões.

Affonso et al. (2010) desenvolveram uma abordagem um pouco diferente do que foi visto até agora, aliando aos modelos de RNA *multilayer Perceptron* e RBF, a lógica *fuzzy*. Diferentemente de alguns métodos tradicionais, a lógica *fuzzy* fornece todo o ferramental matemático para o tratamento das incertezas e ambiguidades, criando um modelo de inferência. A semântica da combinação de metodologias permitiu não só a capacidade de aprendizado, como também a aptidão em transformar variáveis linguísticas em regras à rede *NeuroFuzzy*. Nessas condições, o direcionamento deste trabalho está em prever o tempo de ciclo do processo de injeção de polímeros em uma indústria automobilística a partir da criação de duas redes *NeuroFuzzy* (RNF): uma com a RNA e a outra com a RBF. As principais noções paramétricas para a rede RBF podem ser descritas sendo o número de neurônios de entrada, função de base radial, taxa de aprendizado (em forma de constante) e o critério de parada (erro médio absoluto ou no máximo 50 iterações). Já a premissa da RNA *multilayer perceptron* conta com o mesmo mecanismo de inferência, sofrendo alterações apenas no aprendizado, na arquitetura básica e nos parâmetros (máximo de 500 iterações). De acordo com os autores, a rede RNF do tipo RBF apresentou bom desempenho à medida que o número de iterações foi aumentando. Além disso, ressalta-se a rápida convergência deste modelo, atingindo o ponto de corte com apenas 46 iterações. O gráfico do erro médio absoluto, semelhante à exponencial negativa, comprova o potencial da rede. De maneira análoga ao estudo anterior, a RNF do tipo MLP também apresentou bons resultados,

analisando o valor obtido pelo erro médio absoluto. No entanto, a título de comparação, as redes do tipo MLP necessitaram de um número maior de iterações para alcançar resultados satisfatórios (valor não informado), evidenciando o aprendizado mais rápido da rede do tipo RBF. Como consequência, os autores concluem destacando a aderência de ambos os modelos, tanto na lógica *fuzzy* quanto na predição do ciclo do processo de polímeros.

Steiner et al. (2005) propuseram a utilização de duas técnicas da metodologia de *Data Mining*, as RNAs e as Árvores de Decisão, no reconhecimento de padrões, como auxílio na classificação de novos casos de clientes (pessoa jurídica) de uma agência bancária do município de Guarapuava, Paraná. A “alimentação” de dados para os referidos modelos ocorreu com a coleta de 339 registros históricos (instâncias). Neste contexto, seu escopo é orientado não só para a classificação de empresas em adimplentes ou inadimplentes, como também no comparativo entre os dois métodos, verificando qual deles promove melhores resultados (acurácia). Para o treinamento da RNA, os autores optaram pelo algoritmo de retropropagação do erro (*back-propagation*), no qual os resultados desejados são conhecidos preliminarmente além de a rede ter como função aprender a obter esses valores. Como efeito, novas instâncias poderão ser classificadas sem grandes dificuldades. Embora a árvore de decisão permita melhor compreensão do problema, a partir da derivação em problemas menores, foi a RNA que apresentou menor erro médio, resultando no melhor desempenho na classificação de clientes.

Destacando o amplo “leque” de situações nas quais as redes neurais podem ser aplicadas, Guingo et al. (2002) mostraram estabelecer uma solução no reconhecimento automático de placas de veículos automotores. Suas principais diretrizes apontam na criação de duas RNAs, considerando que as placas apresentam em sua essência, letras e números. Em conjunto com o Departamento de Estrada e Rodagem do Rio de Janeiro (DER-RJ), os autores conseguiram “capturar” 9.079 fotografias digitais. Todavia, apenas 5.233 deste total puderam ser identificadas, evidenciando a existência de problemas corriqueiros como, por exemplo, a falta de placas e a baixa resolução de

imagem. Infelizmente, os resultados obtidos não foram considerados satisfatórios, sendo que apenas 72% das letras e 79% dos dígitos puderam ser reconhecidos. Segundo os autores, a baixa qualidade das fotos, associada às dificuldades de iluminação e falta de foco, foram determinantes para o encontro de soluções consideradas regulares.

Diferentemente dos modelos voltados à classificação, Carneiro (2014) trabalhou a metodologia de RNA como meio de previsão da velocidade de vento no município de Maracanaú, Ceará. Teoricamente, sua complexidade do problema estava na dificuldade de prever o horizonte de tempo (subsequente). Apesar de existirem diversas ferramentas clássicas, como os modelos físicos ou de regressão linear, a proposta foi avaliar o desempenho da RNA para esta tarefa. O modelo foi alimentado com 8.784 valores horários (obtidos a cada 10 minutos) com a ajuda das estações anemométricas. Duas arquiteturas foram desenvolvidas para o estudo. A primeira é aplicada aos dados da própria série de velocidade do vento, ao passo que na segunda são acrescentadas às entradas, informações a respeito da temperatura do ar, rugosidade e direção. Para a implementação computacional, os autores utilizaram (nos dois modelos) o algoritmo *back-propagation* combinado com a técnica *Focused Time Delay Neural Network* (FTDNN), responsável por lidar com os atrasos de tempo. As previsões encontradas pela RNA foram avaliadas por meio do índice de correlação e da raiz do erro quadrático médio. Como resultado, a correlação apontou índice superior a 90% tanto no treinamento quanto no teste para ambos os modelos. No que diz respeito à raiz do erro quadrático médio, seus valores foram considerados extremamente baixos (treinamento e teste) para os modelos 1 e 2 (0,0000076994 e 0,0000017090; 0,0010 e 0,0014 respectivamente), indicando a boa qualidade para a previsão de ventos.

Já Oliveira e Vasconcelos (2006) investigaram a viabilidade das redes neurais para a previsão da produção de álcool no Brasil com um propósito um pouco diferente. Sua peculiaridade está voltada ao comparativo de soluções encontradas entre a metodologia de RNA com as tradicionais séries temporais. Estruturalmente, este modelo ficou compreendido por 12 neurônios na camada de entrada, 48 na camada oculta e um na saída. Seus principais parâmetros envolveram a aplicação da função de ativação sigmoideal em todos os

neurônios: treinamento a partir do algoritmo de retropropagação com taxa de aprendizagem e momentum equivalentes a 0,01. Em resumo, os resultados apontaram que as RNAs proporcionaram melhores resultados (menor erro quadrático) do que as séries temporais em padrões não lineares.

Orientado pela disseminação/difusão ocorrida nos últimos anos, Teixeira (2011) propôs um estudo aplicado às bolsas de valores, um mercado amplamente complexo com constantes flutuações ao longo da escala de tempo, por meio do emprego da rede neural como instrumento elementar na previsão do índice da bolsa do Estado de São Paulo, a Bovespa. *A priori* deste estudo pôde ser entendida como a procura por um padrão futuro a partir do comportamento de cotações anteriores. A rede foi conduzida pelo algoritmo de retropropagação com função de ativação sigmoideal em todos os neurônios. Os dados foram inseridos de maneira normalizada (intervalo de zero a um) desde o mês de janeiro de 1998 até dezembro de 2011. Destaca-se, também, que 92,83% (3.215 valores) destinaram-se ao treinamento e 7,16% (248 dados) para o teste. Após exaustivas mudanças nos parâmetros da rede como, por exemplo, no número de neurônios na camada oculta e nas de entrada, o autor conseguiu obter resultados satisfatórios por meio da metodologia de RNA. Seu erro quadrático médio ficou abaixo de 0,0095 em todos os casos.

A dinâmica da rede neural também contribuiu na resolução de problemas envolvendo adulteração no processo de fabricação de leite, adicionando grandes proporções de soro em sua composição. Conforme apontado por Valente et al. (2014), os índices envolvendo essa infração atingiram altos patamares pelo simples fato do soro ter baixo valor comercial. A partir de análises rotineiras, os autores conseguiram coletar 167 amostras sem adulteração em dias alternados. Deste total, 72 tiveram suas propriedades modificadas em diferentes dosagens de soro, enquanto 95 permaneceram normais. O grande objetivo com essa ação foi criar um padrão no qual a rede neural possa identificar o momento em que uma amostra com fraude passe pelo controle de qualidade. A configuração da rede neural conta com o modelo RBF (*Radial Basis Function*) na qual foi empregado o algoritmo *k-means* para a definição da largura dos campos receptivos, o *k-nearest* e os pesos da camada de saída agiram de acordo com o método da pseudo-inversa. Já para as redes

do tipo MLP (*Multilayer Perceptron*), o treinamento foi baseado na retropropagação com os dados sendo distribuídos de maneira randômica em três subgrupos: 60% para o treinamento; 20% teste e 20% validação. Em síntese, foi possível de verificar o grande potencial de aplicação da RNA na identificação de fraude em leite a partir da análise de rotina. No comparativo com outro estudo que apresentou erro médio superior a 30% em função da metodologia da estatística multivariada (MANOVA), a rede neural conseguiu valores inferiores a 5%.

Alicerçada na importância que a cafeicultura possui, juntamente com as intensas pesquisas direcionadas à área, Andrade (2011) investigou o potencial de ação da RNA na classificação automática de dados de sensoriamento remoto, de forma a identificar áreas de café na região de Machado, Minas Gerais. As imagens multiespectrais, disponibilizadas pelo Instituto Nacional de Pesquisas Espaciais (IMPE), além de submetidas ao processo de restauração (cuja finalidade é melhorar a qualidade espacial dos dados), serviram de base na criação de uma “máscara” para evitar a seleção de matas não correspondentes ao café e, posteriormente, transformadas em formato poligonal para atuarem como fonte de “alimentação” para a rede. Um mapa temático da região estudada serviu de auxílio na definição de 45 a 50 amostras de treinamento para cada atributo. A arquitetura da rede pode ser definida como sendo do tipo MLP com o algoritmo de retropropagação com alterações não só no número de camadas para o treinamento e teste, como também no fator de momentum e na taxa de aprendizado. Categoricamente, a autora creditou que a RNA potencializou os resultados na classificação automática de áreas cafeeiras, sendo considerada melhor do que os métodos abordados na literatura. A inclusão da máscara e as restaurações de imagem possibilitaram a redução da variabilidade e, conseqüentemente, a obtenção de resultados mais realísticos.

A notoriedade alcançada nos diversos segmentos de pesquisa fez com que Rocha et al. (2015) abordassem a técnica de redes neurais na definição de viagens por zona de tráfego na região metropolitana de São Paulo. A holística deste trabalho conta com o uso da própria metodologia de RNA e da usual ferramenta de Regressão Linear Múltipla (como fonte comparativa de

resultados). O levantamento das 460 amostras finais (zonas e tráfegos) ocorreu com a ajuda da companhia do Metropolitano de São Paulo no ano de 2007. Foram criadas 80 variáveis agregadas altamente correlacionadas como, por exemplo, a população, número de automóveis, empregos, matrículas escolares, renda familiar e serviços. Para a previsão de viagens pela rede neural, os autores utilizaram uma arquitetura personalizada com uma camada oculta, sendo que 70% dos dados serviram de base para o treinamento e 30% para teste e validação. A função de erro a ser minimizada é a da soma dos erros quadráticos. Em contrapartida, para a técnica de regressão os autores optaram pelo modelo de *Stepwise*. Sua empregabilidade contribuiu na construção iterativa de uma sequência de modelos a serem submetidos à avaliação de uma estatística “F” parcial, por meio da inserção ou exclusão de variáveis ao longo de cada etapa, detectando redundâncias e relacionamentos. A avaliação partiu da escolha do melhor modelo de regressão, em conjunto com a saída da rede neural, onde foi possível identificar similaridade e compatibilidade no planejamento do transporte. Quantitativamente, o erro quadrático médio encontrado no treinamento da rede teve valor igual a 0,029 e 0,048 nos testes. Já as medidas de desempenho da técnica de regressão apontam 0,061 nos primeiros 70% das amostras e 0,045 para os 30% restante.

Incentivado pela crescente competitividade entre as empresas do setor de produção têxtil, Antoneli e Neitzel (2015) propuseram um estudo voltado à análise dos fios de algodão, atentando-se para os principais fatores responsáveis pela qualidade do fio, a matéria prima e suas características. Na prática, a cultura do algodão pode apresentar diversas derivações, observando a forma de como a safra é produzida, armazenada e transportada. Neste contexto, grande parte das empresas acaba optando pela mistura de diferentes tipos de matéria prima (algodão), na qual o objetivo é direcionado para a redução de custos operacionais, desfocando da propriedade do produto acabado. Deste modo, a contribuição do trabalho está na agregação de complexidade, isto é, na dificuldade em determinar a qualidade do fio de algodão a partir das características das fibras processadas. Visando estabelecer uma solução viável para este problema, os autores avaliaram as habilidades da RNA como fonte de informação. Para isto, a rede foi modelada

como sendo do tipo *multilayer perceptron* com 11 neurônios na camada de entrada e sete na camada de saída. Seu treinamento é baseado em dois algoritmos distintos, o de retropropagação e o *conjugate gradient descent*. Definida como técnica avançada para as redes *multilayer*, o *conjugate* é amplamente recomendado para arquiteturas com elevado número de pesos. Em sua essência, trabalha com a saída média do gradiente da superfície de erro, intermediando nas atualizações automáticas de todos os pesos de uma só vez ao final de cada iteração. O procedimento para a coleta de dados parte de três princípios, a qualidade da fibra, fio e processo. De acordo com o banco de dados da empresa Cocamar, Maringá-PR, os autores obtiveram 100.551, 44.097 e 779 registros, respectivamente, que foram organizados de maneira uniforme ao longo do tempo para a aplicação da RNA, isto é, compatibilizados com o espaço tempo. Em função da baixa oscilação apresentada pelas variáveis de ajuste do processo ao longo do conjunto de dados, o treinamento acabou se tornando inviável, exigindo além de novos recursos para a seleção, a redução de valores de entrada da rede. Dessa forma, as novas restrições fizeram com que o número de registros baixasse para 1.207. Deste total, 807 repassados ao treinamento, 200 no subconjunto da seleção e 200 no teste. Com a aplicação da RNA, provou-se que é possível determinar a qualidade do fio produzido por uma mistura de algodão, a partir dos valores encontrados pelo coeficiente de correlação inferior a um (para todas as qualidades apresentadas).

4 DESCRIÇÃO DOS ESTUDOS DE CASO (A E B)

Coligado ao avanço tecnológico, o segmento florestal tem disseminado cada vez mais o seu núcleo de empresas e produtores com enfoque na produção e uso de madeira vendável para os diferentes consumidores finais, sejam eles comerciais ou industriais.

Este horizonte crescente, apesar de ser considerado positivo para a área, tem ocasionado um efeito adverso quase que imediato: a necessidade em encontrar soluções que possibilitem a definição das configurações mais adequadas para que o uso das técnicas de manejo sejam, de fato, otimizadas.

Infelizmente, o processo de construção de modelos ou ferramentas computacionais que sejam capazes de simular uma situação real complexa, com precisão, não é uma tarefa simples, ainda mais se existir um número relativamente alto de variáveis de decisão que podem impactar fortemente no resultado desejado.

Como solução, a Embrapa Florestas desenvolveu o *software* da família Sis, para as espécies ou gêneros mais cultivados no Brasil, que traz uma interface clara e objetiva que viabiliza, ao usuário, configurações de cenários que podem ser aplicados em simulações de volume, DAP e altura final, por exemplo, para várias espécies de árvores com um baixo tempo de processamento.

Neste sentido, a premissa que envolve o estudo de caso A consiste em analisar o comportamento e a acurácia da RNA do tipo RBF como uma possível alternativa viável para a predição/prognose do volume final comercializável da espécie de *Pinus taeda* L., a partir de um conjunto de dados fornecidos pelo *software* SisPinus.

Por outro lado, apesar do estudo de caso B possuir algumas similaridades, sua essência está centrada em determinar o volume parcial de 302 cubagens rigorosas de *Pinus taeda* L. a partir da construção de cinco redes RBF associadas às seguintes classes de diâmetro: 0-8 cm, 8-18 cm, 18-25 cm, 25-35 cm e >35 cm.

4.1 COLETA DE DADOS PARA O ESTUDO DE CASO A

A base de dados adotada para conduzir o experimento contou, *a priori*, com a configuração de um estudo piloto abstrato, canalizado em identificar/avaliar, as principais variáveis que, de alguma forma, pudessem impactar fortemente na quantidade de madeira colhida (m^3) ao final do ciclo de vida do povoamento de *Pinus taeda* L.

A investigação teve como principal intermediador e propulsor, o *software* SisPinus que, ao longo de várias simulações, permitiu o encontro dos seguintes 21 atributos relevantes: o índice de sítio (dado pela altura média das árvores dominantes aos 15 anos); número de árvores plantadas por hectare; % de sobrevivência após o primeiro ano; níveis de homogeneidade da plantação; idade da colheita final do povoamento; altura dominante no ato do desbaste; altura dominante no corte final; número de árvores remanescentes no desbaste e na colheita final; diâmetro médio no desbaste e na colheita final; altura média no desbaste e na colheita final; altura média no desbaste; área basal no desbaste e na colheita final; idade do desbaste; desbaste seletivo sendo determinado pelo número de árvores remanescentes; volume total no desbaste; volume colhido no desbaste e como resposta a estes 21 atributos, o volume total na colheita final.

Dessa maneira, concomitante as diferentes óticas abordadas, foram obtidas, ao todo, 144 instâncias/padrões (algumas delas apresentadas pela Tabela 4.1) definidas pelas seguintes combinações possíveis: dois talhões contendo 1.667 ou 2.000 árvores plantadas por hectare, níveis de homogeneidade equivalente a 5, índice de sítio podendo ser 18m, 21m ou 24m, um único desbaste seletivo aos 8 ou 12 anos de idade com a premissa de que o número de remanescente seja de 400, 600, 800 ou 1000 árvores por hectare e idade final de 16, 19 ou 22 anos.

Tabela 4.1: Geração de algumas das 144 instâncias para a determinação do volume final para o *Pinus taeda L.*

Índice de Sítio	Árvores plantadas/Hectare	% de sobrevivência (Primeiro ano)	Idade Final	Altura Dominante (m) Até o desbaste 1	Altura Dominante (m) Até o corte final	Nº Árvores remanescentes/Hectare (Até o ano do desbaste 1)	Nº Árvores no corte final	Diâmetro Médio até o desbaste 1	Diâmetro Médio (Pós desbaste) - Corte final -	Altura Média (até o desbaste 1)	Altura média (até o corte final)	Altura Média (sortimento do desbaste 1)	Área Basal (até o desbaste 1)	Área Basal (até o corte final)	Ano do desbaste 1	Tipo de desbaste (1) 1.	Fixando o número de árvores 1.2	Volume total até o ano do desbaste 1	Resultado Volume (m³) Desbaste 1	Resultado Volume (m³) Corte final	Volume TOTAL (soma do D1 + corte final).
18	1667	100	16	11,5	18,9	1666	400	14,3	27,1	9,9	17,4	10,3	26,8	23	8	Seletivo	400	106,2	68,6	159,9	228,5
18	1667	100	16	11,5	19	1666	599	14,3	24,9	9,9	17,1	10	26,8	29,3	8	Seletivo	600	106,2	53,5	200	253,5
18	1667	100	16	11,5	19,2	1666	797	14,3	23,9	9,9	16,9	9,7	26,8	35,7	8	Seletivo	800	106,2	40	241,8	281,8
18	1667	100	16	11,5	19,3	1666	990	14,3	23,1	9,9	16,8	9,4	26,8	41,6	8	Seletivo	1000	106,2	28	279,7	307,7
18	1667	100	16	15,6	19,3	1654	400	18,2	25,2	13,3	17,9	13,9	43,2	19,9	12	Seletivo	400	230,3	148,1	142,5	290,6
18	1667	100	16	15,6	19,3	1654	599	18,2	23,9	13,3	17,6	13,4	43,2	26,9	12	Seletivo	600	230,3	115,3	188,8	304,1
18	1667	100	16	15,6	19,4	1654	797	18,2	23,3	13,3	17,3	13	43,2	33,9	12	Seletivo	800	230,3	86	235,3	321,3
18	1667	100	16	15,6	19,5	1654	989	18,2	22,8	13,3	17,2	12,5	43,2	40,3	12	Seletivo	1000	230,3	59,7	276,9	336,6
18	1667	100	19	11,5	20,9	1666	400	14,3	29,5	9,9	19,1	10,3	26,8	27,4	8	Seletivo	400	106,2	68,6	209,2	277,8
18	1667	100	19	11,5	21	1666	598	14,3	27	9,9	18,8	10	26,8	34,2	8	Seletivo	600	106,2	53,5	257	310,5
18	1667	100	19	11,5	21,2	1666	793	14,3	25,7	9,9	18,6	9,7	26,8	41,2	8	Seletivo	800	106,2	40	306,7	346,7
18	1667	100	19	11,5	21,3	1666	977	14,3	24,8	9,9	18,5	9,4	26,8	47,2	8	Seletivo	1000	106,2	28	349,3	377,3
18	1667	100	19	15,6	21,3	1654	400	18,2	27,9	13,3	19,7	13,9	43,2	24,4	12	Seletivo	400	230,3	148,1	192,6	340,7
18	1667	100	19	15,6	21,4	1654	598	18,2	26,1	13,3	19,3	13,4	43,2	32	12	Seletivo	600	230,3	115,3	247,3	362,6
18	1667	100	19	15,6	21,5	1654	793	18,2	25,2	13,3	19,1	13	43,2	39,5	12	Seletivo	800	230,3	86	301,5	387,5
18	1667	100	19	15,6	21,5	1654	972	18,2	24,5	13,3	18,9	12,5	43,2	45,7	12	Seletivo	1000	230,3	59,7	345,4	405,1
18	1667	100	22	11,5	22,7	1666	399	14,3	31,6	9,9	20,6	10,3	26,8	31,2	8	Seletivo	400	106,2	68,6	258	326,6

Fonte: O autor (2019).

4.2 COLETA DE DADOS PARA O ESTUDO DE CASO B

O banco de dados aplicado neste estudo foi disponibilizado pela empresa Klabin S.A., localizada na região de Telêmaco Borba no estado do Paraná. Geograficamente, o relevo da área é levemente ondulado com uma altitude média de 850 metros acima do nível do mar. Em termos de clima, a temperatura e a precipitação média anual correspondem a 23,0°C e 1.470 mm, respectivamente, o que sugere uma região temperada úmida, sem estação de seca e com geadas periódicas (BONETE, 2018).

Quantitativamente, foram colhidas informações a respeito de 302 árvores provenientes de parcelas permanentes de *Pinus taeda L.* (idade, altura, DAP (com ou sem casca), volume total (com ou sem casca) e fator de forma (com ou sem casca)), distribuídas em povoamentos não desbastados com espaçamento inicial de plantio equivalente a 2,5 x 2,5m, com variações nos parâmetros de idade (4 a 19 anos), DAP (5 até 45 cm) e altura (4,3 e 31,95 metros). Como complemento, na tabela 4.2 está a quantidade de árvores de acordo com a idade e classe de diâmetro.

Tabela 4.2: Estratificação dos dados em classes de diâmetro e idade

Conjunto de Dados	Ci (Anos)	Classe de Diâmetro (cm)				Total de Árvores	
		<8	8 [-] 18	18 [-] 25	25 [-] 35		>35
Base de Dados (Treinamento e Teste)	4 [-] 5	17	15	3			
	5 [-] 6	30	26	7	1		
	6 [-] 7	9	7	2	1		
	7 [-] 8	27	25	14	8	1	
	8 [-] 9	21	21	16	11	5	
	9 [-] 10	9	9	7	5		
	10 [-] 11	11	11	7	4	1	
	11 [-] 12	30	30	27	23	11	
	12 [-] 13	4	4	3	2		
	13 [-] 14	17	17	15	14	7	
	14 [-] 15	14	14	11	7	4	
	15 [-] 16	26	26	23	21	16	
	16 [-] 17	13	13	13	13	11	
	17 [-] 18	37	37	37	37	32	
	18 [-] 19	23	23	23	21	16	
	19 [-] 20	14	14	14	14	14	
	Total		302	292	222	182	118

Fonte: O autor (2019)

onde: C_i = classe de idade (anos) e [-] indicam, respectivamente, a inclusão do limite inferior e exclusão do limite superior.

Paralelamente ao processo de estratificação, houve a execução de um plano detalhado que incidiu a respeito do conjunto de variáveis consideradas intrínsecas para o cálculo do volume parcial com casca para a espécie de *Pinus taeda* L. (DAP e fator de forma com casca, altura e idade das árvores e volume total) e que, posteriormente, foram utilizadas como atributos na camada de entrada para a implementação computacional das redes RBF durante a fase de aprendizado e validação.

4.3 DEFINIÇÃO DOS PRINCIPAIS ATRIBUTOS

Como complemento às informações reproduzidas no segmento da coleta de dados (4.1 e 4.2), esta seção tem como foco a exteriorização das principais definições (organizados em formato de item) a respeito dos atributos que serviram de suporte para o desenvolvimento das instâncias/padrões utilizadas no decurso do processo de simulação de ambos os estudos, A e B.

- O Índice de sítio é classificado como sendo uma medida que infere no potencial de produtividade de um local, isto é, a capacidade de uma área

em assegurar o crescimento de determinada espécie a partir das características típicas de solo e clima;

➤ O número de árvores plantadas por hectare assume que os dados concebidos correspondem a uma floresta recém-plantada (que ainda não sofreu o processo de crescimento) e, ao mesmo tempo, prognostica a quantidade de mudas que serão efetivamente plantadas, respeitando um conjunto de condições elementares.

➤ O nível de homogeneidade trata-se de um parâmetro que permite flexibilidade no método a ser usado para a descrição da homogeneidade e, comumente, é baseado em medidas estatísticas ou empíricas com notas de 1 a 10 associadas não só à variabilidade genotípica como, também, às questões fenotípicas.

➤ A idade final consiste no término do ciclo do povoamento, período no qual haverá a colheita final das árvores;

➤ Dentre todas as designações presentes para a altura dominante, a mais usual é a que considera como altura média das 100 árvores de maior diâmetro em um hectare;

➤ O diâmetro é uma variável que representa as dimensões de uma árvore com medição, na maioria dos casos, à altura do peito (1,30m). Dele, é possível definir outro parâmetro intrínseco: o diâmetro médio que pode ser retratado como o resultado do somatório do diâmetro de todas as árvores, dividido pelo número total de árvores medidas;

➤ A altura média da árvore contempla o somatório da altura de todas as árvores medidas dividido pelo respectivo número total de árvores. Este parâmetro é muito importante para a classificação da qualidade do sítio, estimativas volumétricas e para ajustes de modelos de hipsométricos;

➤ A área basal é compreendida como a soma das áreas seccionais transversal das árvores de um povoamento por hectare e que é geralmente medida a altura do peito;

➤ Em sua essência, a técnica de desbaste é uma atividade silvicultural que tem como objetivo a remoção de algumas árvores de forma a favorecer o crescimento das árvores remanescentes;

➤ Os tipos de desbaste podem assumir três campos distintos: Os sistemáticos, seletivos e mistos. O primeiro consiste na utilização de um

esquema fixo de escolha, em função da disposição do povoamento. O seletivo pratica a remoção das menores árvores do povoamento, enquanto o misto congrega os conceitos de ambos, processando-se com o sistemático num primeiro momento e, em seguida, nas linhas remanescentes, o seletivo;

- O fator de forma, em tese, assume valores entre 0 e 1 e expressa o quão cilíndrica a árvore é.
- O volume é delineado como sendo uma das variáveis de maior interesse para qualquer empresa (ou produtor) quando se trata do manejo florestal.

5 METODOLOGIAS PROPOSTAS

Preliminarmente, o estudo A foi embasado em uma abordagem puramente investigativa que serviu de auxílio para a identificação da questão problema “como aplicar as RNAs para a predição/prognose do volume total de *Pinus taeda L.*, considerando diferentes práticas impostas ao manejo florestal?” e, paralelamente, das principais limitações/restrições que norteiam o escopo estabelecido.

Em conjunto com a fase de identificação, houve o desenvolvimento de um planejamento orientado em avaliar, num nível macro, a disponibilidade de recursos e métodos que possam contribuir para que estes objetivos fossem, de fato, alcançados.

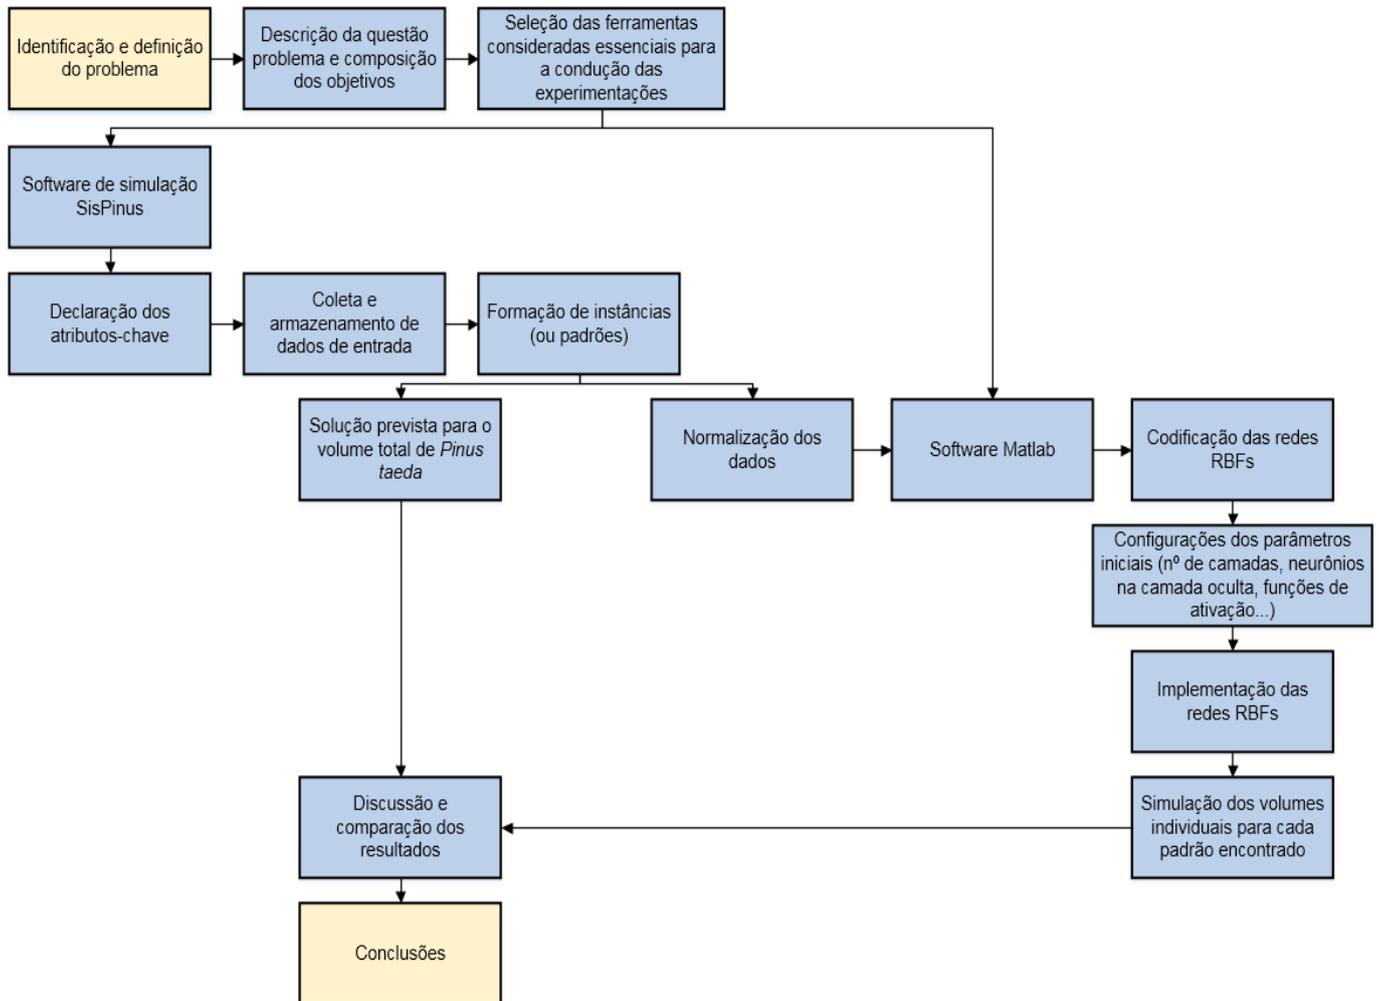
Dando continuidade ao fluxo, a tarefa seguinte propôs a análise e composição das ferramentas consideradas vitais para a construção do projeto, dando destaque ao *software* SisPinus e a implementação das redes do tipo RBF no Matlab R2016b. Em termos práticos, o simulador será encarregado por intermediar, não só a identificação dos atributos que impactam no volume final (21 ao todo), como, também, em conduzir experimentações em diferentes cenários (144 padrões ou instâncias).

Para facilitar a alimentação das entradas nas redes RBFs e, ao mesmo tempo, procurando evitar qualquer tipo de problema, uma vez que muitos atributos são expressos qualitativamente, cada instância (ou padrão) passou pelo processo de normalização (intervalo de [0,1]).

Depois de configurada (número de camadas, quantidade de neurônios, ajuste de pesos e funções de ativação) e alimentada com o banco de dados já existente, a missão da rede RBF incumbiu a predição do volume total comercializável de *Pinus taeda* L. Para tanto, das 144 instâncias produzidas, 98 foram destinadas para o aprendizado/treinamento e as demais, 48, para a validação (teste) do comportamento proporcionado pela rede já treinada. Complementarmente, a construção destes conjuntos sucedeu-se de forma estratificada, evitando-se assim, possíveis tendências.

Concomitante ao encontro dos volumes obtidos pela rede RBF, a ação seguinte consistiu na elaboração de uma abordagem comparativa com os valores assumidos pelas simulações do *software* SisPinus. Ou seja, a ideia é calcular a diferença individual entre os padrões e, ao final, determinar o erro quadrático médio (EQM) que expressa a acurácia da RNA. Essas e outras informações podem ser observadas com o respaldo da Figura 5.1

Figura 5.1: Definição da metodologia para o caso A



Fonte: O autor (2019).

Ao abordar o procedimento metodológico que envolve a concepção do estudo de caso B, poderão ser observadas, a priori, algumas características análogas ao promovido por A, principalmente na forma em como foi conduzida a fase de identificação e análise da questão problema a ser resolvida. Como resultado, a semântica deste cenário está norteadada na aplicação das redes RBFs como fonte alternativa na predição de volumes parciais de *Pinus taeda* L. tomados em cinco classes de diâmetro (0-8; 8-18; 18-25; 25-35 e >35 cm).

No que corresponde aos dados empregados, a base contou com a cubagem rigorosa de 302 árvores em condições diversas (alturas, idades, DAP e fatores de forma) para que pudessem expressar o volume total individual com casca. Porém, como a dinâmica do experimento conduz caminhos opostos às

informações apresentadas, uma vez que seus resultados assumem uma variável diferente, algumas implementações e adaptações foram imprescindíveis:

Devido à necessidade de seu escopo (volume parcial), foi proposta, inicialmente, a modelagem de uma função, genérica, de afilamento de 4ª ordem capaz de descrever o perfil longitudinal do fuste das 302 árvores amostrais, isto é, o comportamento assumido pelo diâmetro em qualquer altura (h_i), conforme corroborado por (10):

$$\frac{d_i}{dap} = \beta_0 + \beta_1 \left(\frac{h_i}{ht}\right)^{p1} + \beta_2 \left(\frac{h_i}{ht}\right)^{p2} + \beta_3 \left(\frac{h_i}{ht}\right)^{p3} + \beta_4 \left(\frac{h_i}{ht}\right)^{p4} \quad (10)$$

em que: d_i é o diâmetro i ao longo do fuste (cm); dap é o diâmetro a 1,30m do solo (cm); h_i representa a altura i ao longo do fuste (m); ht é a altura total da árvore (m); β está associado aos coeficientes e p informa o grau (ou potência) do modelo.

Paralelamente, partindo da premissa que o perfil do fuste tende a afinar conforme o aumento da altura, as árvores foram “fatiadas” em 100 partes cada uma delas, na qual cada parcela representa o diâmetro previsto associado a 1% de sua altura relativa $\left(\frac{h_i}{ht}\right)$. Em tese, essa sucessão de análises permitirá um melhor detalhamento e precisão a respeito das informações a serem coletadas.

Considerando que a equação de melhor ajuste e o método de corte condicionem baixas margens de erros, quando comparados com os reais, a prioridade voltou-se para o cálculo do diâmetro, em cm, a cada 1% da altura total das árvores a partir da isolação do termo d_i em (9), assim como sugerido por (11):

$$d_i = dap \left(\beta_0 + \beta_1 \left(\frac{h_i}{ht}\right)^{p1} + \beta_2 \left(\frac{h_i}{ht}\right)^{p2} + \beta_3 \left(\frac{h_i}{ht}\right)^{p3} + \beta_4 \left(\frac{h_i}{ht}\right)^{p4} \right) \quad (11)$$

Buscando formalizar o alinhamento dos resultados encontrados com o propósito do estudo, foi necessária uma análise individual para identificar as classes que cada árvore contempla e, concomitantemente, o seu respectivo

comprimento (intervalo da altura relativa). Em outras palavras, dispõem-se do seguinte exemplo para ilustrar o que foi, de fato, realizado: escolhendo arbitrariamente uma árvore i , verificou-se que ela possui uma porção de fuste com diâmetro maior do que 35 cm que perdura até 20% de sua altura total (isso significa dizer que 20% da árvore possui um volume com tora superior a 35 cm de diâmetro).

Este processo de seleção e separação é fundamental para que, com o auxílio de integrações parciais da função de afilamento elevada ao quadrado, seja possível estimar o volume dos segmentos (a cada 1% da altura) e, também, o total da árvore conjecturando o próprio tronco como sólido de revolução.

Para transformar a sua grandeza em m^3 , inicialmente, o volume das árvores obtido, até então, para as cinco classes, foi dividido pelo fator de forma (FF) que, neste caso, corresponde a 100% (uma vez que, quando $\frac{h_i}{ht} = 1$, a soma dos coeficientes da integral é o próprio FF) e será o responsável por informar o volume proporcional de cada um dos segmentos.

Ininterruptamente, o ajuste final contou com a aplicação da equação (12), cujo objetivo é expressar o volume calculado, em m^3 , das parcelas de árvores que são atribuídas a cada um dos cinco intervalos de diâmetro, e (13), responsável por validar os dados a partir da soma dos valores parciais com os totais.

$$V = \frac{(FF * \pi * D^2 * HT)}{40000} \quad (12)$$

$$\sum_{i=1}^5 vp_{ai} = VT_a \quad \forall a \in S \quad (13)$$

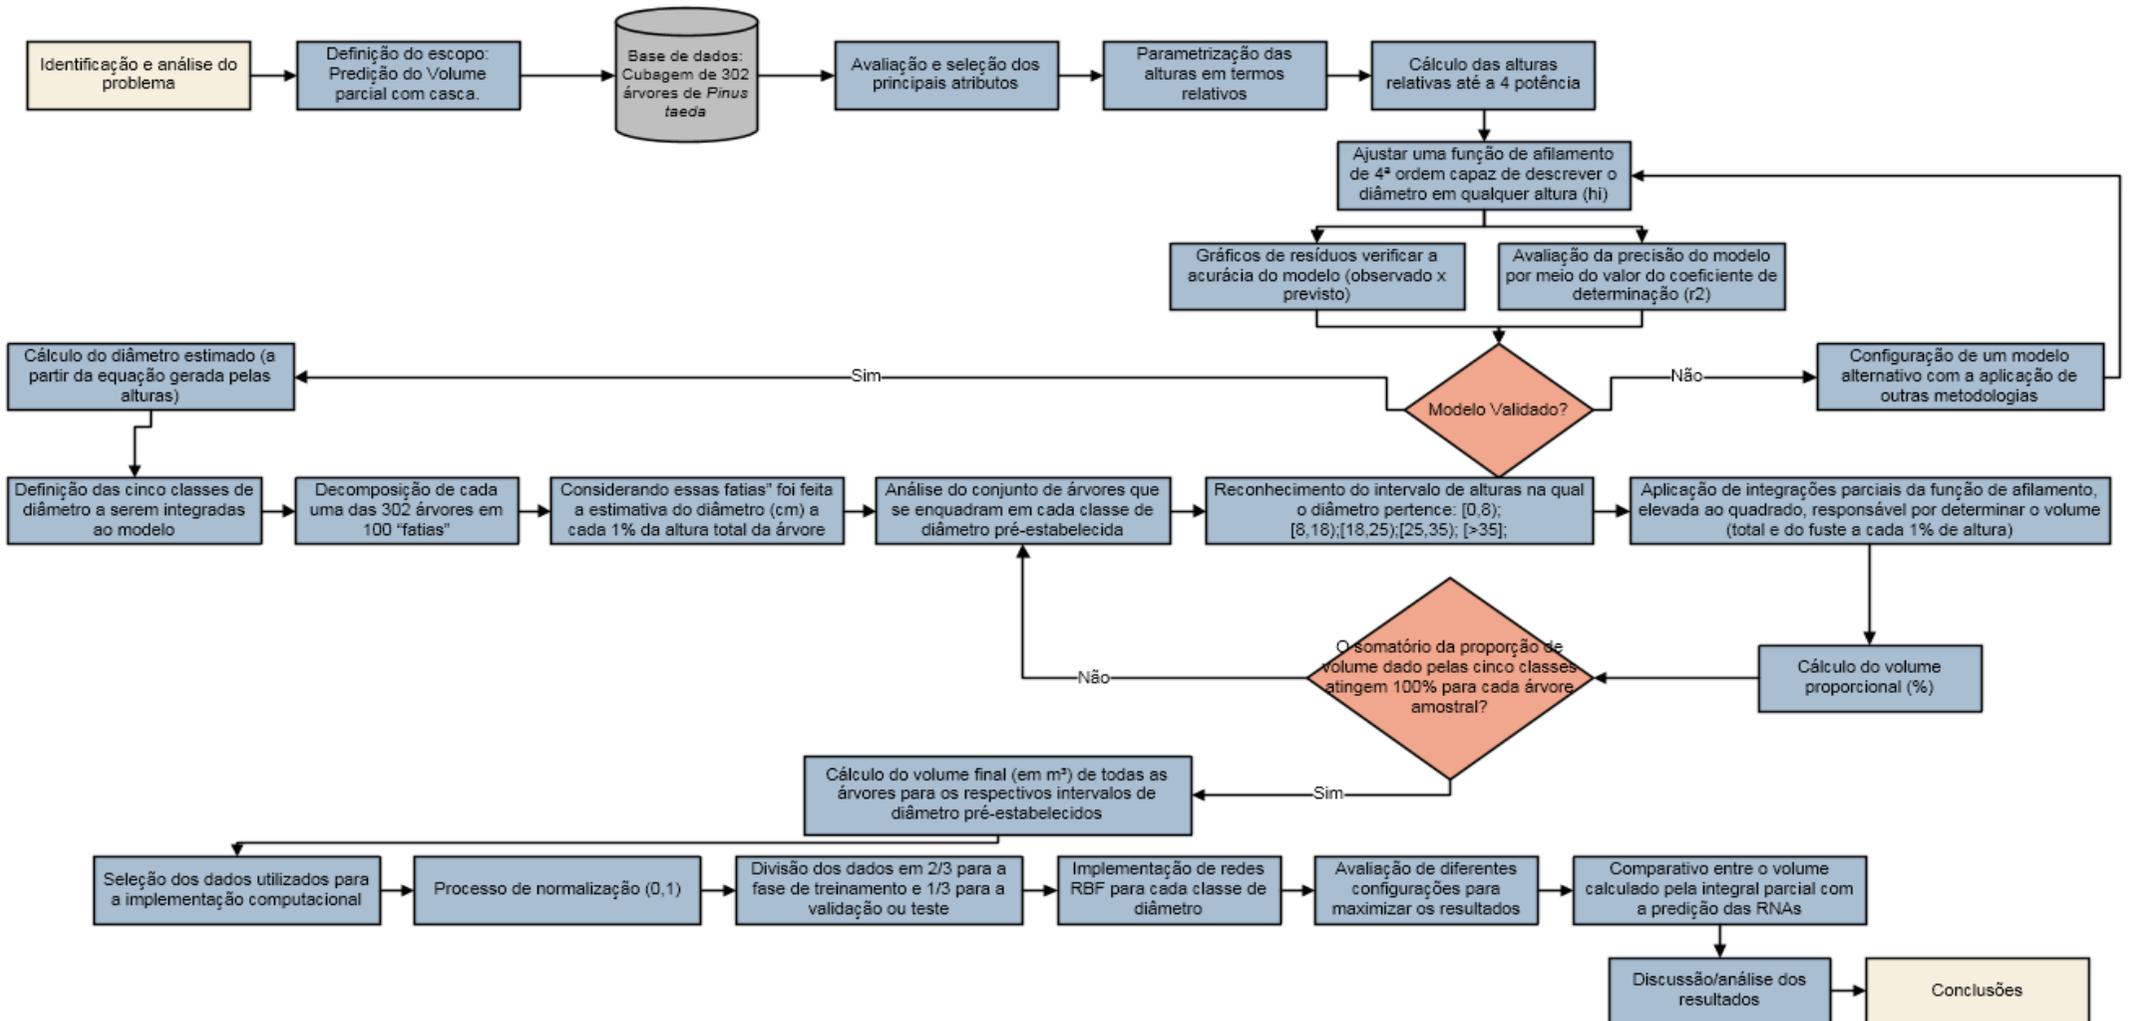
onde: i representa as classes de diâmetro; a é o número da árvore; S contempla o conjunto de 302 árvores; VT_a é o volume total da árvore a e vp_{ai} refere-se ao volume parcial da árvore a na classe i .

Computacionalmente, a implementação das redes RBFs foi motivada pela elaboração de cenários com diferentes configurações em termos de atributos e número de neurônios na camada oculta. Para tanto, os dados

introduzidos nestas experimentações também passaram pelo processo de normalização (intervalo de 0 a 1) e sua estratificação contou com a mesma abordagem do estudo A, isto é, 2/3 para as fases de treinamento e 1/3 para o treino (validação) das redes.

Tendo obtida a predição de volumes parciais, pelas redes RBFs, correspondente a cada classe de diâmetro, foi feita a confrontação com os valores calculados pela integração parcial a partir da utilização do teste EQM e de análises individuais entre as instâncias (padrões). Todas essas informações podem ser encontradas na Figura 5.2.

Figura 5.2: Definição da metodologia para o caso B



Fonte: O autor (2019).

6 RESULTADOS

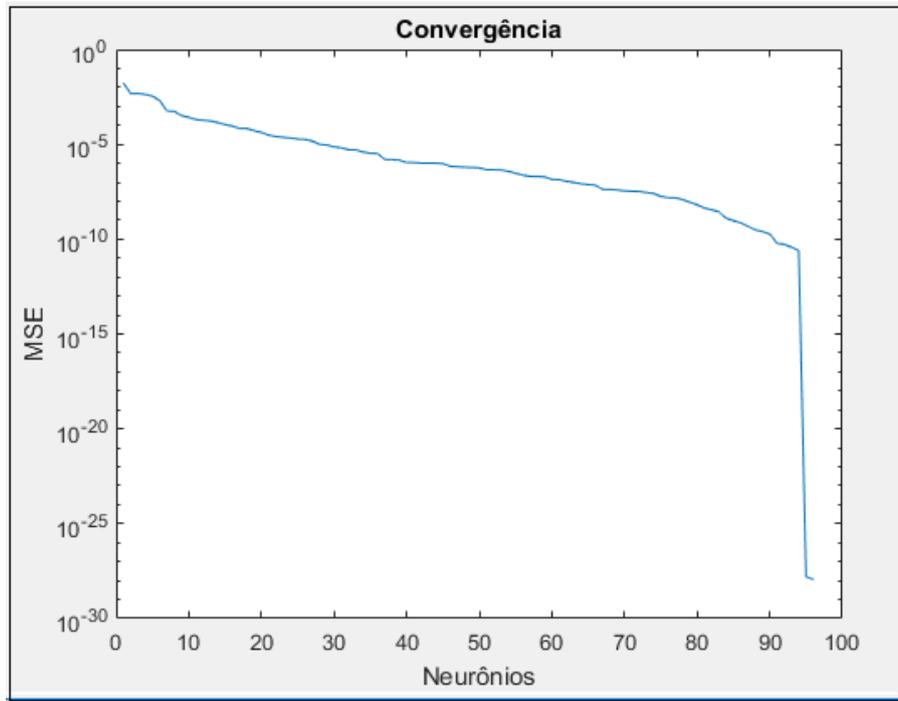
Este capítulo disserta a respeito dos resultados encontrados, por meio da construção e simulação de RNAs no *software* Matlab r2016b, para o volume total e volume parcial de *Pinus taeda L.* sob a ótica de diferentes condições de manejo ou pela segmentação em termos de classes de diâmetro (estudos A e B, respectivamente).

6.1 ESTIMATIVAS DO VOLUME TOTAL (ESTUDO A)

A partir das características intrínsecas do *software* SisPinus, juntamente com o processo de análise e seleção dos principais atributos que influenciam diretamente no processo de previsão de volume, foi possível construir 144 instâncias (ou padrões) que, depois de normalizadas, serviram de entrada para as fases de treinamento e testes (validação) das redes RBFs.

O estudo macro do processo de implementação computacional permitiu verificar que a rede RBF, de melhor arquitetura, foi capaz de assimilar muito bem as 96 instâncias destinadas à fase de treinamento. Estatisticamente, o erro de aprendizado chegou a ser de 1.14402×10^{-28} , ao final da última iteração, conforme corroborado pela Figura 6.1.

Figura 6.1: Gráfico sobre o desempenho da RBF para o seu conjunto de treinamento



Fonte: O autor (2019)

No entanto, apesar de contar com um valor extremamente baixo, muitos problemas podem acontecer nesta fase inicial, principalmente na definição do número de neurônios necessários. Nestes casos, Diamantopoulou et al. (2009) garantem que uma das decisões mais complicadas é justamente definir o número de neurônios que a camada oculta deverá receber. Além disso, ainda com os autores, não há, de fato, uma configuração que seja considerada a melhor opção para o processo de predição do volume.

Dependendo da complexidade do modelo, uma rede com poucos neurônios pode, eventualmente, não vir a ter sucesso pelo fato de tender para uma baixa capacidade de generalização (*underfitting*). Em compensação, na hipótese de se empregar elevado número, a RNA trabalha com a possibilidade de que seu treinamento seja excessivamente longo e, portanto, gere problemas de sobreajuste (*overfitting*). Ou seja, a perda de capacidade preditiva [pequenos desvios de previsão para os dados de treinamento e grandes desvios para a entrada de novos dados (fase de testes)].

Dando prosseguimento às considerações, no que diz respeito aos testes (ou validação) promovidos na rede RBF já treinada, foram apresentadas a ela

as demais 48 instâncias. Com o respaldo da Tabela 6.1, a análise dos resultados experimentais expressa que a rede conseguiu predizer com boa precisão os volumes desconhecidos em termos do Erro Quadrático Médio ($2,1631 \times 10^{-9}$) e, também, pelas diferenças individuais entre os valores finais e simulados (com variações a partir da quarta casa decimal).

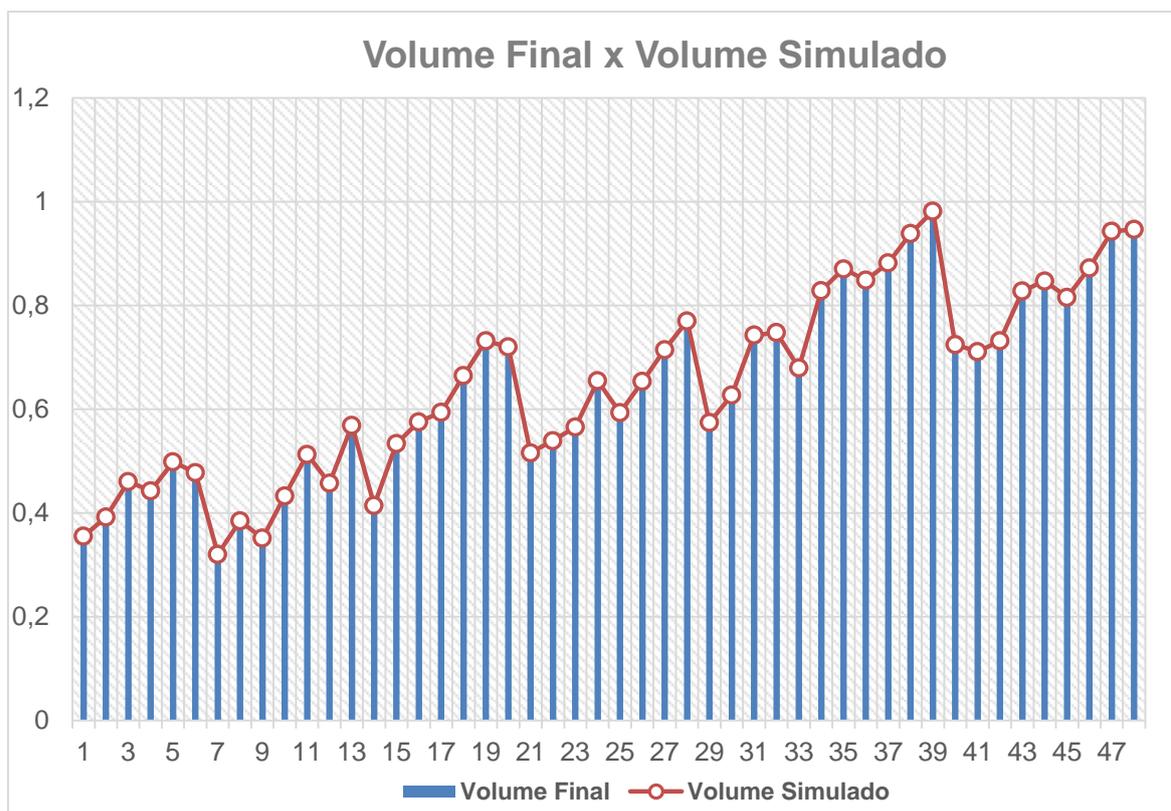
Tabela 6.1: Erros quadráticos e diferenças para as 48 instâncias utilizadas para testar a RBF

Valor Final	Valor Simulado	Erro quadrático	Diferença entre o final e o simulado (em módulo)	Erro quadrático médio global
0,355039707	0,355361934	1,0383E-07	0,000322227	2,16313E-09
0,392547343	0,392211257	1,12953E-07	0,000336085	
0,46096518	0,460775829	3,58538E-08	0,000189351	
0,443005498	0,442669431	1,12941E-07	0,000336066	
0,498594991	0,498720804	1,5829E-08	0,000125814	
0,477458766	0,477899018	1,93822E-07	0,000440252	
0,320952963	0,320557356	1,56505E-07	0,000395607	
0,385094685	0,384825275	7,25822E-08	0,000269411	
0,35149664	0,351371564	1,56441E-08	0,000125076	
0,43347587	0,433217461	6,67753E-08	0,000258409	
0,512889432	0,51302701	1,89278E-08	0,000137578	
0,457544288	0,457369313	3,06163E-08	0,000174975	
0,569578497	0,569077106	2,51393E-07	0,000501391	
0,415638363	0,4146304	1,01599E-06	0,001007962	
0,533414783	0,533713378	8,91587E-08	0,000298594	
0,575565058	0,575812347	6,11518E-08	0,000247289	
0,594379963	0,594139555	5,77962E-08	0,000240408	
0,664996946	0,665023592	7,10011E-10	2,6646E-05	
0,732315211	0,731964523	1,22982E-07	0,000350688	
0,719242517	0,720240499	9,95968E-07	0,000997982	
0,516065974	0,516193103	1,61618E-08	0,000127129	
0,539279169	0,539542945	6,95776E-08	0,000263776	
0,565791081	0,565795307	1,78549E-11	4,2255E-06	
0,654245571	0,654839383	3,52613E-07	0,000593812	
0,594013439	0,593480827	2,83676E-07	0,000532612	
0,654245571	0,653835403	1,68238E-07	0,000410168	
0,716065974	0,715076653	9,78757E-07	0,000989321	
0,770311546	0,770215281	9,26689E-09	9,62647E-05	
0,57275504	0,574271029	2,29822E-06	0,001515989	
0,626145388	0,627606655	2,1353E-06	0,001461267	
0,740378742	0,742880926	6,26093E-06	0,002502185	
0,745387905	0,747973056	6,68301E-06	0,002585151	
0,678558338	0,679529476	9,43107E-07	0,000971137	
0,828100183	0,828812162	5,06914E-07	0,000711979	
0,868295663	0,870658503	5,58301E-06	0,00236284	
0,847525962	0,84873454	1,46066E-06	0,001208578	
0,884178375	0,882151327	4,10893E-06	0,002027049	
0,938179597	0,938737739	3,11523E-07	0,000558142	
0,980818571	0,982124638	1,70581E-06	0,001306068	
0,724496029	0,724935549	1,93178E-07	0,00043952	
0,707513745	0,711006344	1,21983E-05	0,003492599	
0,731704337	0,731958202	6,44475E-08	0,000253865	
0,827000611	0,827938425	8,79494E-07	0,000937814	
0,844960293	0,847343222	5,67835E-06	0,002382929	
0,812095296	0,815887129	1,4378E-05	0,003791833	
0,871838729	0,872560517	5,20977E-07	0,000721788	
0,942333537	0,943050827	5,14505E-07	0,00071729	
0,944532682	0,94682757	5,26651E-06	0,002294888	

Fonte: O autor (2019).

Corroborando com o que foi dito anteriormente, a Figura 6.2 exterioriza que o comportamento adquirido por ambas as simulações durante o estágio de testes (para as 48 instâncias) é praticamente o mesmo, uma vez que é possível afirmar que a reta coincide com o gráfico em barras ao longo do processo.

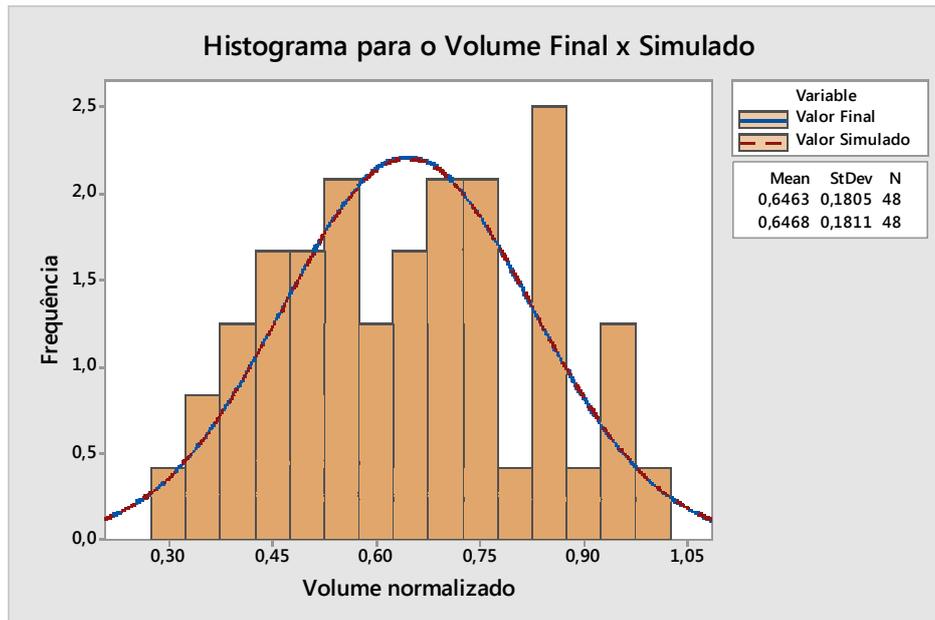
Figura 6.2: Comparação entre os volumes finais de *Pinus taeda* L. obtidos pelo software SisPinus e pela utilização da rede RBF



Fonte: O autor (2019)

Já a Figura 6.3 viabiliza uma abordagem estatística, com o objetivo de comparar ambos os cenários a partir dos valores de média e do desvio padrão (DP). Visualmente, percebe-se que a distribuição de frequências e a própria curva normal são muito semelhantes, ficando difícil de observar as duas linhas e os dois histogramas. Para comprovar isso, basta verificar que os valores obtidos de média (0,1811 e 0,1805) e DP (0,6468 e 0,6463) para o SisPinus e RBF, respectivamente, são equivalentes.

Figura 6.3: Histograma da média e desvio padrão para os dois resultados obtidos na fase de testes



Fonte: O autor (2019)

Como contribuição, uma das grandes vantagens de uma RNA é, após ser treinada adequadamente, antever o volume de qualquer instância nova (desconhecida) sem a necessidade da introdução de novos dados, ao passo que o simulador terá que ser, obrigatoriamente, alimentado com essas informações para efetuar a previsão. Não obstante, as análises ratificam que, em termos comparativos, a RBF pode ser utilizada como fonte alternativa muito promissora para este tipo de previsão, tendo em vista que sua acurácia foi extremamente alta.

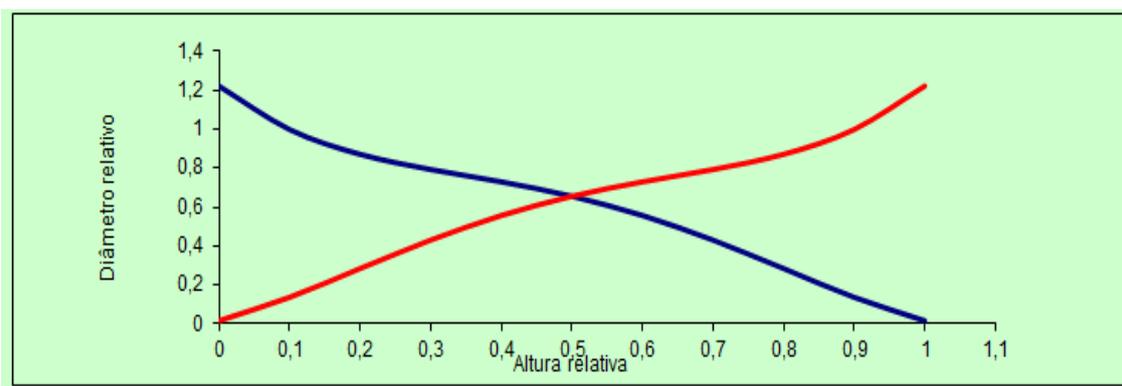
6.2 ESTIMATIVAS DO VOLUME PARCIAL (ESTUDO DE CASO B)

Conforme delineado no capítulo 5, a respeito das metodologias abordadas, o escopo deste estudo é direcionado em prever o volume parcial com casca de 302 árvores de *Pinus taeda* L., distribuído em cinco classes de diâmetros pré-definidos (0-8; 8-18; 18-25; 25-35 e >35 cm). Partindo da premissa de que a base de dados utilizada é desprovida de informações importantes, uma vez que contém apenas o DAP e volume total de cada árvore (e a necessidade é o diâmetro em qualquer altura e o volume parcial) algumas implementações e adaptações foram realizadas.

Inicialmente, a premência consistiu em encontrar o ajuste de uma função de afilamento genérica capaz de descrever o perfil longitudinal do fuste, isto é, o comportamento do diâmetro em qualquer altura (h_i/H). Para isso, contando com o suporte do *software* Minitab 2017 e do cálculo das alturas relativas até a 4ª ordem, a equação que melhor se adequa ao experimento é descrita por (14) e sua forma padrão pode ser visualizada com o auxílio da Figura 6.4:

$$D_i = DAP * \left[1,22134 - 2,8889 * \left(\frac{h_i}{ht}\right)^1 + 7,584 * \left(\frac{h_i}{ht}\right)^2 - 10,377 * \left(\frac{h_i}{ht}\right)^3 + 4,478 * \left(\frac{h_i}{ht}\right)^4 \right] \quad (14)$$

Figura 6.4: Comportamento do Diâmetro (d_i) em função da Altura (h_i/ht)

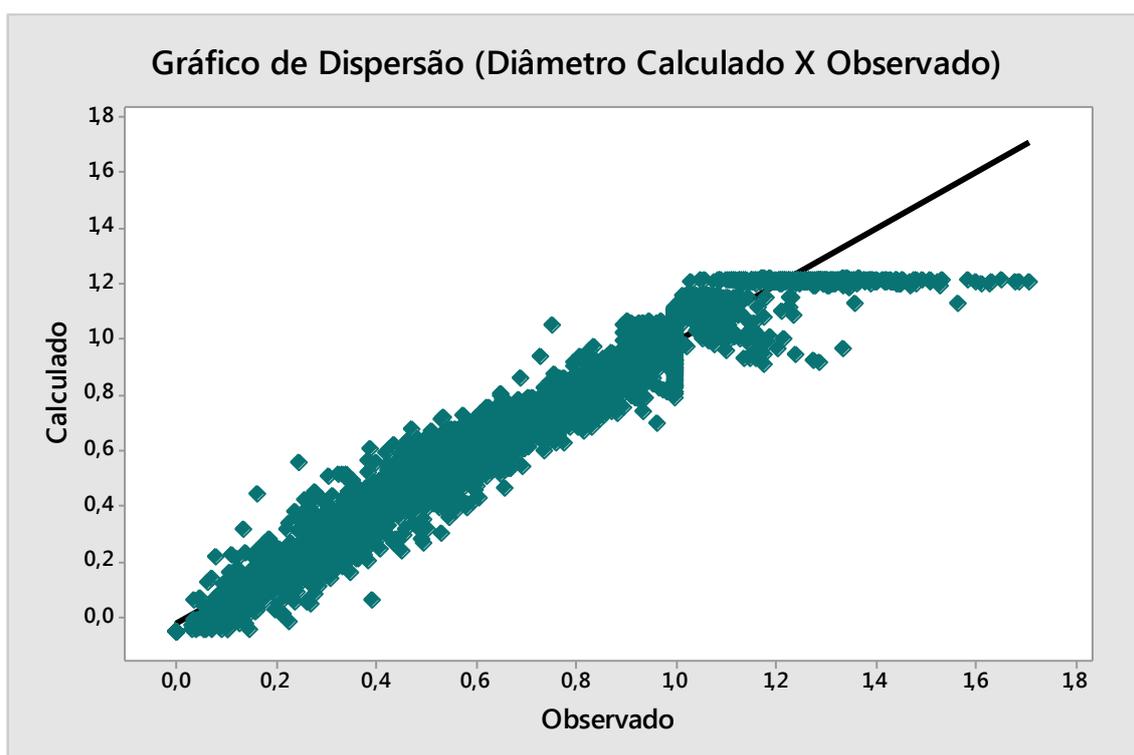


Fonte: O autor (2019)

onde: a linha crescente (vermelho) representa a função utilizada pelos *softwares*: $x = (1-h_i/H)$ e a linha decrescente (azul) está associada à equação $x = (h_i/H)$.

Em termos de validação, o modelo escolhido passou por duas abordagens distintas: uma representação gráfica dos diâmetros estimados e observados (Figura 6.5) onde se percebe uma baixa variação (desvio) dos dados frente à linha de regressão e da distribuição de alguns *outliers* aceitáveis na porção da base, considerando que, em muitos casos, a “saia” se alonga para dar sustentação à árvore; e o cálculo do Coeficiente de Determinação (R^2), compreendendo 96,87%, uma medida descritiva responsável por avaliar a qualidade do ajuste.

Figura 6.5: Gráfico de dispersão entre o diâmetro observado e calculado



Fonte: O autor (2019)

Tendo armazenado os valores previstos de diâmetro para cada 1% da altura das árvores, concomitante ao uso integrações parciais ($\int f(x) d(x)$) de afilamento elevada ao quadrado, foi possível estimar tanto o volume dos segmentos quanto o total da árvore, conjecturando o próprio tronco como sólido de revolução.

Para tanto, admitindo os coeficientes associados à equação de afilamento já ajustada (demonstrada em 14), desenvolveu-se (15) e, conseqüentemente, (16):

$$\int_{h_1}^{h_2} (1,22134 - 2,8889x + 7,584x^2 - 10,377x^3 + 4,478x^4)^2 dx \quad (15)$$

em que: h_1 e h_2 denotam os limites da função.

Resolvendo a integral por partes, obteve-se a seguinte expressão:

$$1,491671x - 3,52833x^2 + 8,957009x^3 - 17,2916x^4 + 25,68232x^5 - 30,5452x^6 + 25,08635x^7 - 11,6171x^8 + 2,228054x^9 \quad (16)$$

onde: x representa a altura relativa (h_i/H).

Deste modo, apenas reforçando o que foi dito anteriormente, esses coeficientes são capazes de descrever o volume correspondente de cada segmento (1% da altura) ou total, e, juntamente com a análise e identificação dos intervalos de altura na qual o diâmetro de cada uma das 302 árvores permanece na mesma classe, tornou-se viável a proposta de obter o volume proporcional referente às cinco classes pré-estabelecidas (0-8; 8-18; 18-25; 25-35 e >35 cm). Em outras palavras, para exemplificar, supondo que durante a altura de 1% até 4%, o diâmetro da árvore continua sendo > 35 cm, basta utilizar o valor calculado pela integral, nesta mesma altura, dividido pelo fator de forma (que neste caso coincide com 100% da árvore), para encontrar a % do volume com casca desta tora associado à respectiva classe.

Ao abordar o prisma da implementação computacional, o estudo contou, *a priori*, com a mesma distribuição de dados encontrados em A, onde 2/3 foram destinados à fase de treinamento da rede e o restante, 1/3, para a realização de testes. Para a validação dos resultados, três métricas conduziram as análises: coeficiente de correlação, erro quadrático médio e a maior diferença, em módulo, dentre todas as instâncias desconhecidas.

Preliminarmente, objetivando estabelecer maior dinâmica nos resultados, optou-se por desenvolver oito tipos de cenários, baseados nas combinações das principais variáveis de entrada e de diferentes números de neurônios na camada oculta, para determinar o volume parcial das cinco classes.

Os tipos de funções de ativação nas camadas intermediárias e de saída (gaussiana e linear, respectivamente), foram mantidas em todas as situações porque, segundo Franco e Steiner (2014), além de serem as mais usuais, geralmente conseguem obter melhores resultados. Com relação ao parâmetro *spread*, ou raio da função de base radial, as adaptações aconteceram no intervalo de (0 a 2) de forma a verificar o desempenho alcançado pela rede.

Considerando os resultados encontrados pelas oito arquiteturas de melhor desempenho (Tabela 6.2) para a classe de diâmetro < 8 cm e entre 8 a 18 cm, pode-se afirmar com segurança que, em termos do coeficiente de correlação e EQM, todas as redes obtiveram resultados satisfatórios (acima de 90% e um erro abaixo de $2,53 \times 10^{-3}$, respectivamente) para as 201 novas instâncias aplicadas à

rede. Apesar disso, a melhor configuração foi selecionada a partir do reconhecimento, em módulo, da maior diferença entre o volume calculado e previsto, entendendo que denota a minimização das variações de cada um dos padrões. Neste sentido, a rede 5 A com duas entradas (DAPcc e h), 50 neurônios na camada oculta e com *spread* de 2, foi selecionada como sendo a melhor de todas, assimilando uma desigualdade de apenas 0,05991 m³ que pode ser vista com o auxílio da Figura 6.6.

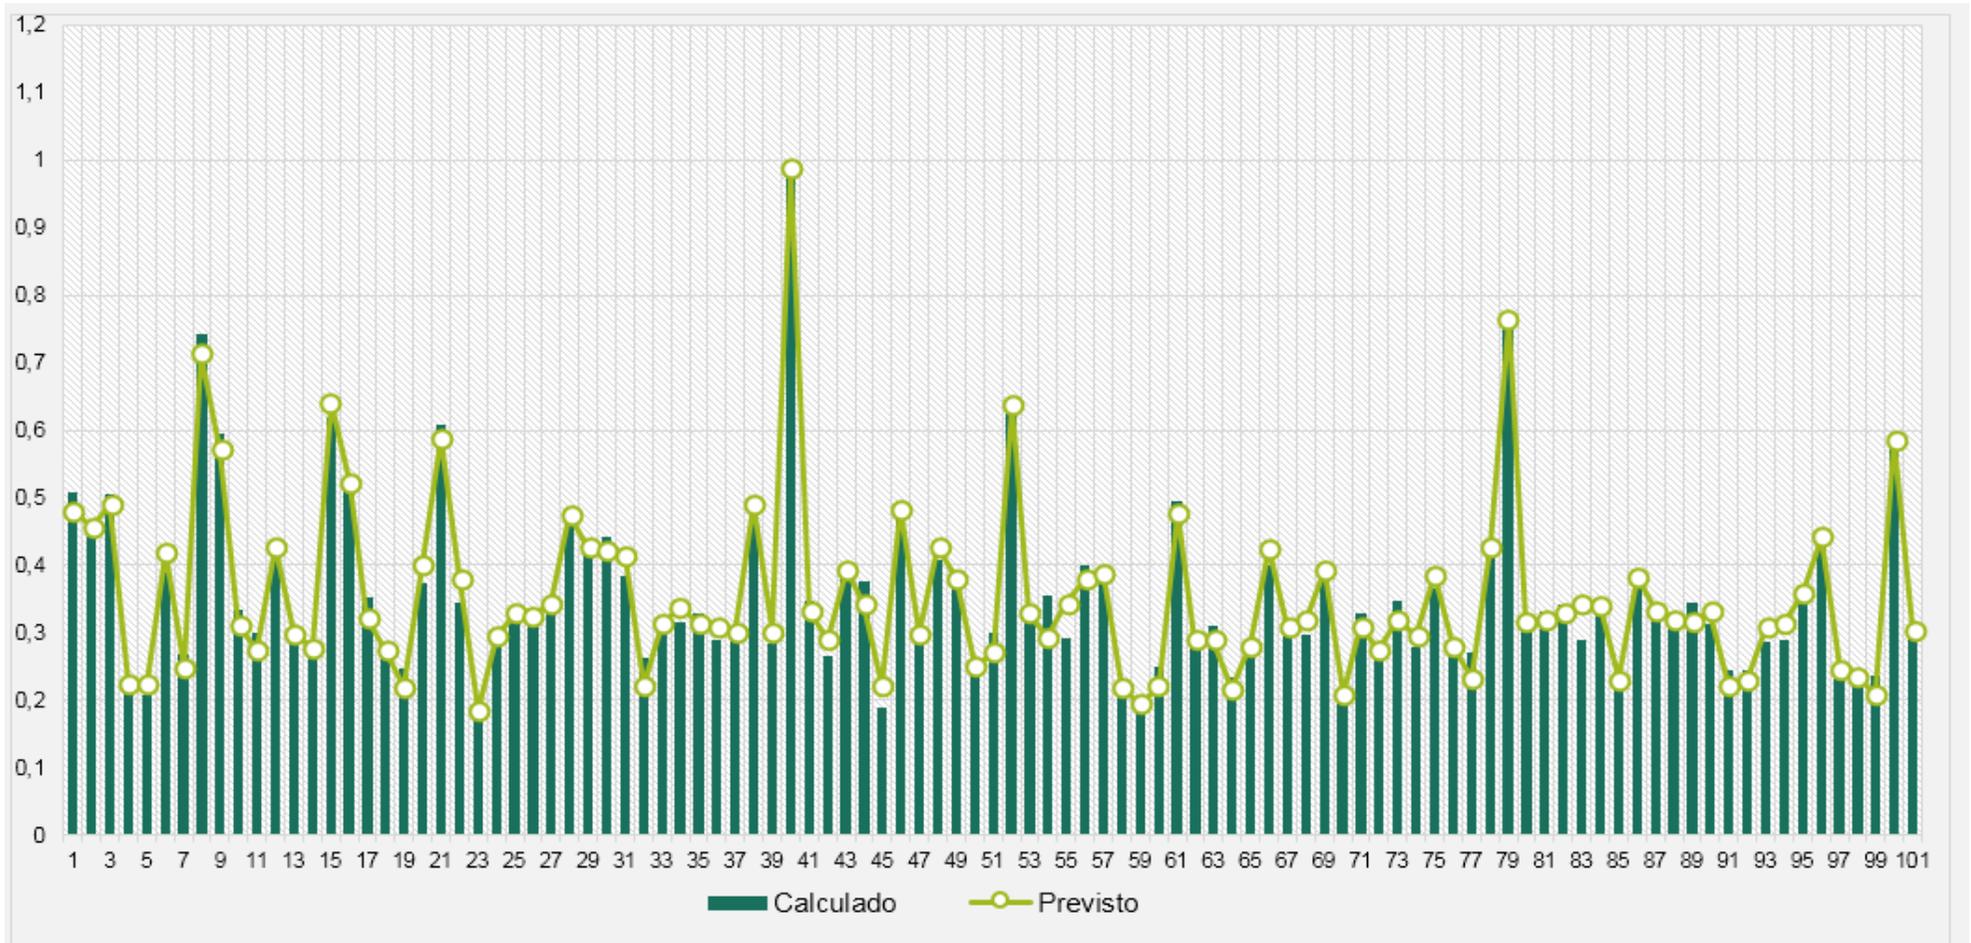
Tabela 6.2: Características das RNAs selecionadas para as estimativas de volume parcial com casca de *Pinus taeda* L considerando a classe de diâmetro < 8 cm

RNAs	Arquitetura de melhor desempenho*	Variáveis de Entrada	Spread (Raio da Função)	Função de Ativação		Variável de Saída	Teste (Validação)		
				CO	CS		$r_{y\hat{y}}$	EQM	Maior diferença individual (módulo)
1A	5-90-1	<i>I, DAPcc, h, VT e FFcc</i>	1	Gaussiana	Linear		0,96384	0,001565839	0,18768
2A	3-67-1	<i>I, DAPcc e h</i>	1	Gaussiana	Linear		0,97236	0,000997757	0,09517
3A	3-75-1	<i>DAPcc, h e VTcc</i>	1	Gaussiana	Linear	Volume Parcial	0,97132	0,001145504	0,12279
4A	3-100-1	<i>DAPcc, VTcc e FFcc</i>	0.98	Gaussiana	Linear	com casca para a	0,94464	0,002299365	0,19582
5A	2-50-1	<i>DAPcc e h</i>	1	Gaussiana	Linear	classe com	0,98697	0,000431146	0,05991
6A	4-50-1	<i>DAPcc, h, VTcc e FFcc</i>	1	Gaussiana	Linear	diâmetro < 8cm	0,97222	0,000947577	0,09711
7A	2-80-1	<i>I e DAPcc</i>	1.10	Gaussiana	Linear		0,95223	0,001639103	0,13448
8A	2-90-1	<i>DAPcc e VTcc</i>	1	Gaussiana	Linear		0,92049	0,002531858	0,24108

Fonte: O autor (2019).

em que: *Número de neurônios em cada uma das camadas (entrada, oculta e saída); CO = camada oculta; CS = camada de saída; EQM = Erro Quadrático Médio e $r_{y\hat{y}}$ = coeficiente de correlação entre valores observados e estimados.

Figura 6.6: Comparação entre os volumes parciais calculados e previstos para a classe de diâmetro <8 cm



Fonte: O autor (2019).

Procedendo-se de forma análoga, a rede que apresentou o melhor desempenho para a classe de diâmetro entre 8 a 18 cm foi a 5 A, configurada com duas entradas (DAPCC e h), 60 neurônios na camada oculta, *spread* de 0,9, coeficiente de correlação superior a 99%, EQM de $1,26 \times 10^{-04}$ e a maior diferença, análise determinante para a escolha da melhor rede, sendo de $0,02930 \text{m}^3$ (Tabela 6.3) e conforme corroborado pela Figura 6.7.

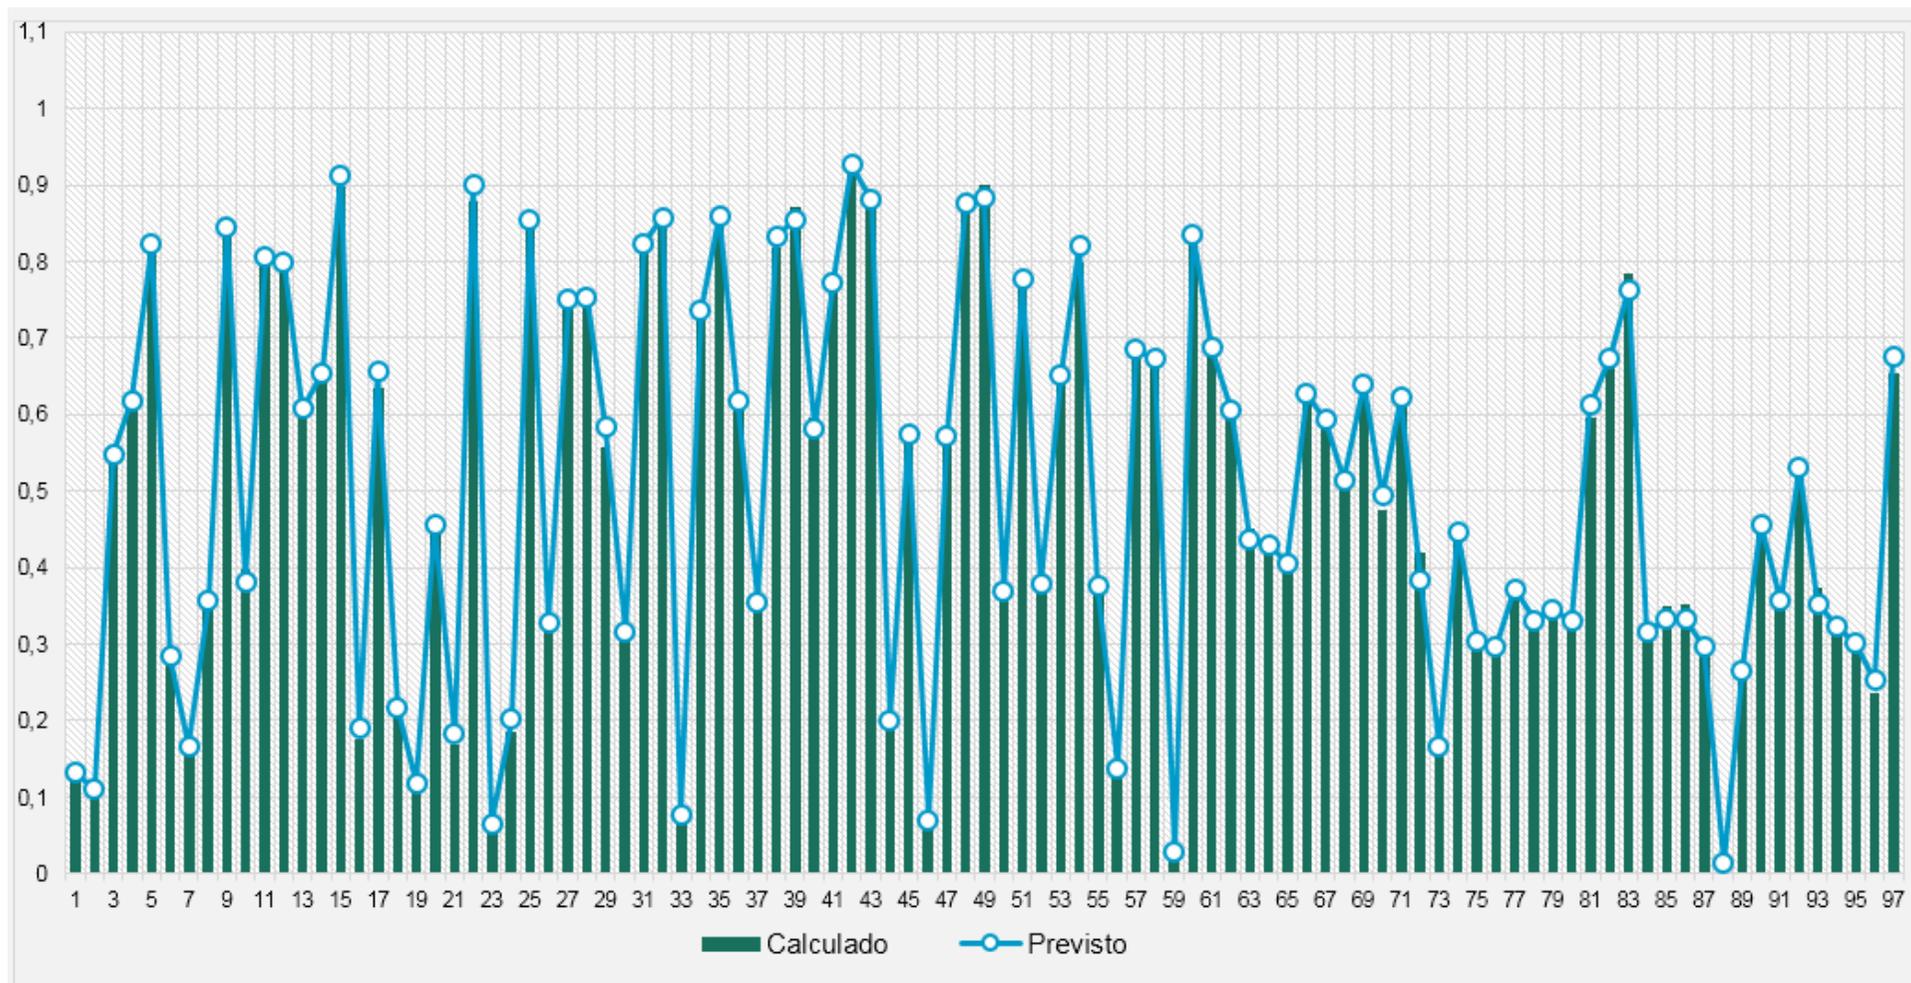
Tabela 6.3: Características das RNAs selecionadas para as estimativas de volume parcial com casca de *Pinus taeda* L considerando a classe de diâmetro entre 8 e 18 cm

RNAs	Arquitetura de melhor desempenho*	Variáveis de Entrada	Spread (Raio da Função)	Função de Ativação		Variável de Saída	Teste (Validação)		
				CO	CS		$r_{y\hat{y}}$	EQM	Maior diferença individual (módulo)
1A	5-95-1	<i>I, DAPcc, h, VT e FFcc</i>	1.1	Gaussiana	Linear	Volume Parcial com casca para a classe com diâmetro entre 8 e 18 cm	0,99612	0,000328290	0,06724
2A	3-79-1	<i>I, DAPcc e h</i>	1.25	Gaussiana	Linear		0,99572	0,000295088	0,06116
3A	3-55-1	<i>DAPcc, h e VTcc</i>	0.75	Gaussiana	Linear		0,99803	0,000169781	0,04166
4A	3-42-1	<i>DAPcc, VTcc e FFcc</i>	0.84	Gaussiana	Linear		0,99838	0,000140104	0,03872
5A	2-60-1	<i>DAPcc e h</i>	0.90	Gaussiana	Linear		0,99852	0,000125602	0,02930
6A	4-64-1	<i>DAPcc, h, VTcc e FFcc</i>	0.89	Gaussiana	Linear		0,99581	0,000360542	0,08268
7A	2-68-1	<i>I e DAPcc</i>	0.99	Gaussiana	Linear		0,96990	0,002745739	0,19890
8A	2-20-1	<i>DAPcc e VTcc</i>	0.88	Gaussiana	Linear		0,98688	0,001143439	0,12620

Fonte: O autor (2019).

em que: *Número de neurônios em cada uma das camadas (entrada, oculta e saída); CO = camada oculta; CS = camada de saída; EQM = Erro Quadrático Médio e $r_{y\hat{y}}$ = coeficiente de correlação entre valores observados e estimados.

Figura 6.7: Comparação entre os volumes parciais calculados e previstos para a classe de diâmetro entre 8 e 18 cm



Fonte: O autor (2019).

Em síntese, para as classes com diâmetro entre 18 a 25 cm e de 25 a 35 cm, os modelos mais adequados, compreendendo todas as possibilidades, foram as redes 3 A (DAPcc, h e VTcc) e 5 A (DAP e h), com 25 ou 15 neurônios na camada intermediária e *spread* podendo ser de 0,52 ou 1,84 (Tabela 6.4). No que tange a qualidade da predição, os resultados para ambos os cenários se mostraram promissores, tendo em vista a alta correlação (0,99824; 0,99947), baixo EQM ($1,87 \times 10^{-04}$; $1,00 \times 10^{-04}$) e a maior diferença sendo de 0,03615 e 0,02674 m³ para a classe 3 (18 a 25 cm) e 4 (25 a 35 cm), respectivamente. Em termos gráficos, as Figuras 6.8 e 6.9 possibilitam um melhor entendimento a respeito do comportamento adquirido por ambas as redes na confrontação dos volumes obtidos pela previsão e o calculado pelas funções matemáticas.

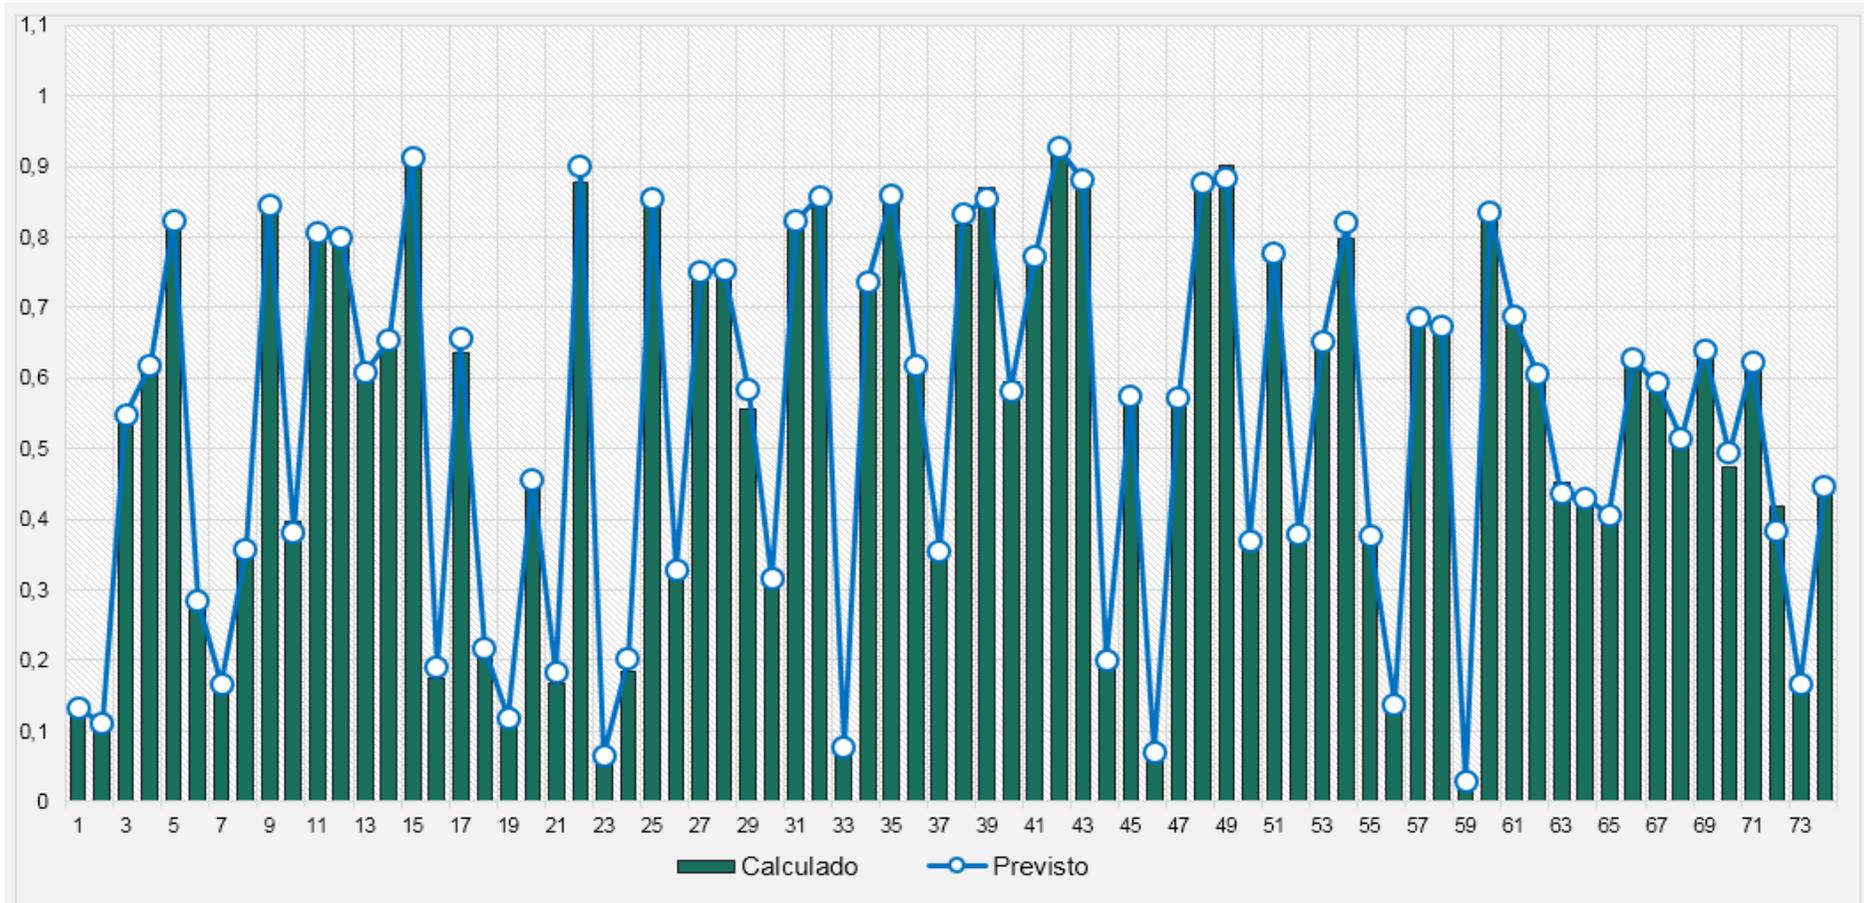
Tabela 6.4: Características das RNAs selecionadas para as estimativas de volume parcial com casca de *Pinus taeda* L considerando a classe de diâmetro entre 18 e 25 cm e de 25 a 35 cm, respectivamente

RNAs	Arquitetura de melhor desempenho*	Variáveis de Entrada	Spread (Raio da Função)	Função de Ativação		Variável de Saída	Teste (Validação)		
				CO	CS		$r_{y\hat{y}}$	EQM	Maior diferença individual (módulo)
1A	5-33-1	<i>I, DAPcc, h, VT e FFcc</i>	0.87	Gaussiana	Linear	Volume Parcial com casca para a classe com diâmetro entre 18 e 25 cm	0,99517	0,000466443	0,08436
2A	3-33-1	<i>I, DAPcc e h</i>	1.12	Gaussiana	Linear		0,99399	0,000567611	0,09614
3A	3-25-1	<i>DAPcc, h e VTcc</i>	0.52	Gaussiana	Linear		0,99824	0,000187282	0,03615
4A	3-40-1	<i>DAPcc, VTcc e FFcc</i>	0.52	Gaussiana	Linear		0,99810	0,000185192	0,04313
5A	2-45-1	<i>DAPcc e h</i>	1.27	Gaussiana	Linear		0,99724	0,000265548	0,05610
6A	4-65-1	<i>DAPcc, h, VTcc e FFcc</i>	0.55	Gaussiana	Linear		0,99605	0,000373260	0,08513
7A	2-20-1	<i>I e DAPcc</i>	0.45	Gaussiana	Linear		0,98055	0,001812126	0,10087
8A	2-27-1	<i>DAPcc e VTcc</i>	1	Gaussiana	Linear		0,97647	0,002170210	0,16950
RNAs	Arquitetura de melhor desempenho*	Variáveis de Entrada	Spread (Raio da Função)	Função de Ativação		Variável de Saída	Teste (Validação)		
				CO	CS		$r_{y\hat{y}}$	EQM	Maior diferença individual (módulo)
1A	5-24-1	<i>I, DAPcc, h, VT e FFcc</i>	1.30	Gaussiana	Linear	Volume Parcial com casca para a classe com diâmetro entre 25 e 35 cm	0,99893	0,000198580	0,03444
2A	3-22-1	<i>I, DAPcc e h</i>	1.35	Gaussiana	Linear		0,99927	0,000134669	0,03154
3A	3-26-1	<i>DAPcc, h e VTcc</i>	1.44	Gaussiana	Linear		0,99938	0,000114835	0,02967
4A	3-10-1	<i>DAPcc, VTcc e FFcc</i>	1.84	Gaussiana	Linear		0,99908	0,000154378	0,03081
5A	2-15-1	<i>DAPcc e h</i>	1.84	Gaussiana	Linear		0,99947	0,000100736	0,02674
6A	4-18-1	<i>DAPcc, h, VTcc e FFcc</i>	1.39	Gaussiana	Linear		0,99915	0,000152966	0,03120
7A	2-29-1	<i>I e DAPcc</i>	0.99	Gaussiana	Linear		0,99053	0,001393580	0,13821
8A	2-60-1	<i>DAPcc e VTcc</i>	1.09	Gaussiana	Linear		0,98531	0,005986440	0,15581

Fonte: O autor (2019).

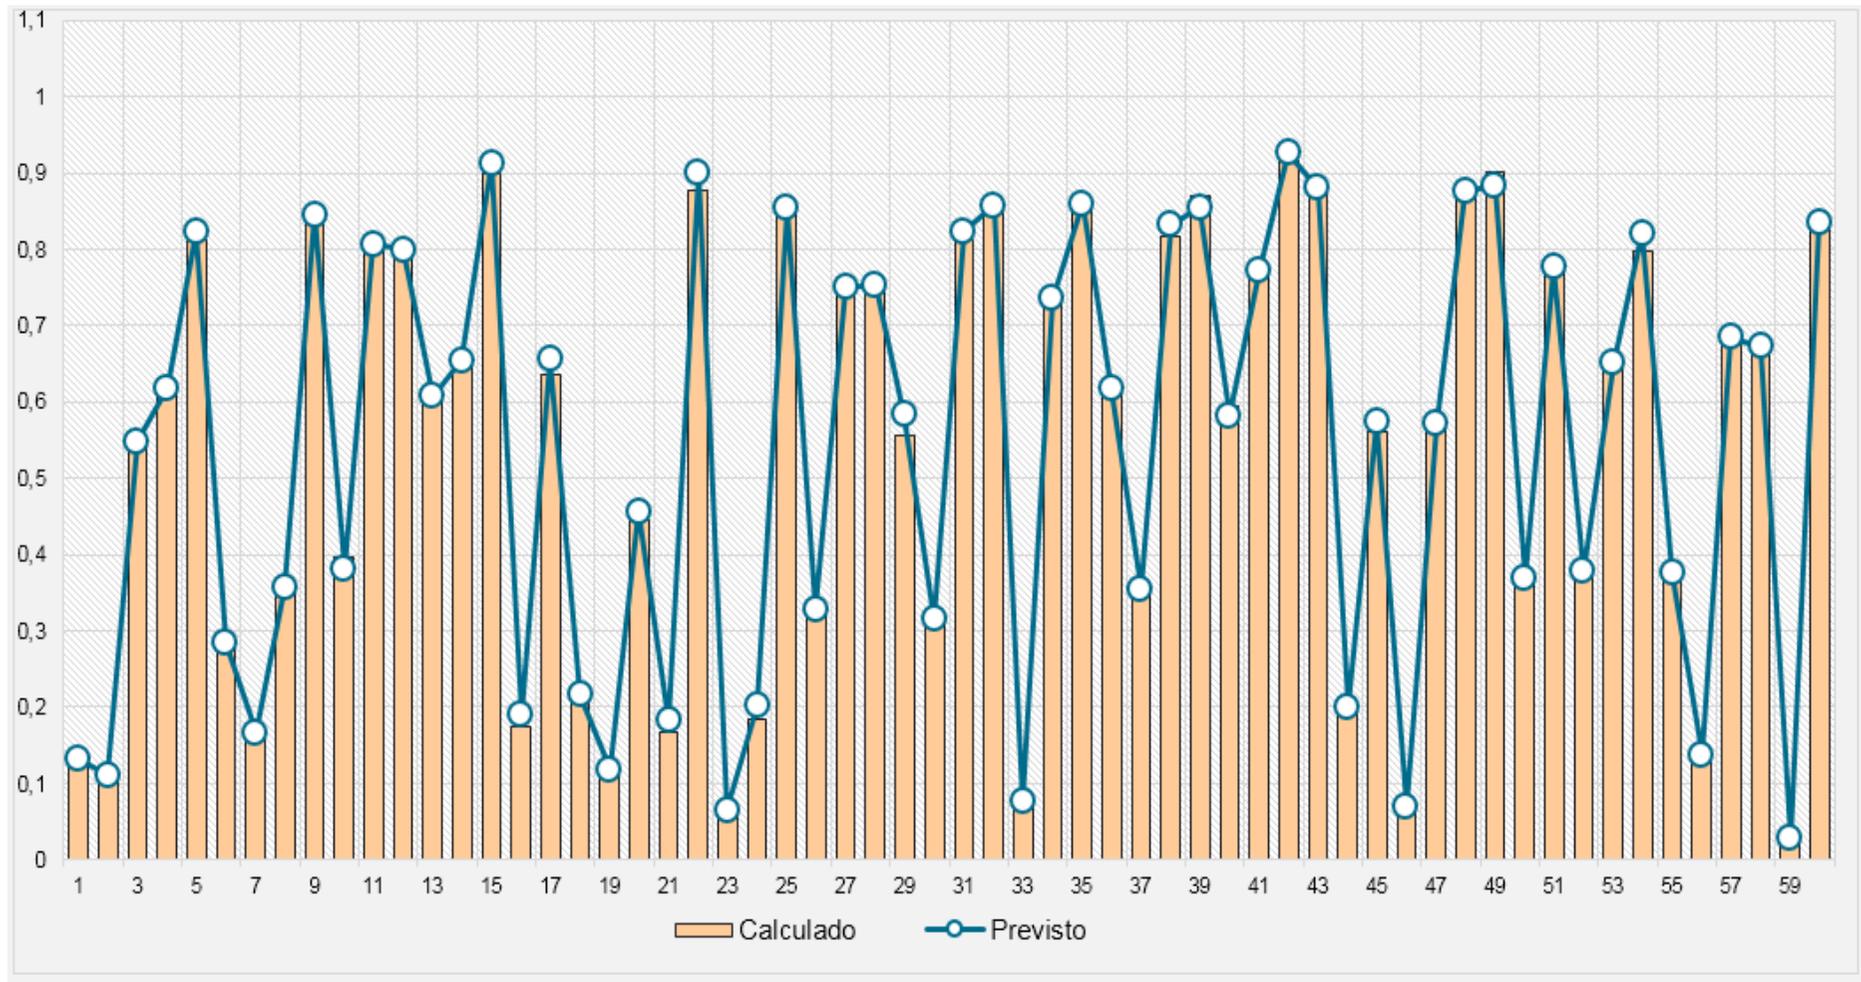
em que: * Número de neurônios em cada uma das camadas (entrada, oculta e saída); CO = camada oculta; CS = camada de saída; EQM = Erro Quadrático Médio e $r_{y\hat{y}}$ = coeficiente de correlação entre valores observados e estimados.

Figura 6.8: Comparação entre os volumes parciais calculados e previstos para a classe de diâmetro entre 18 e 25 cm



Fonte: O autor (2019).

Figura 6.9: Comparação entre os volumes parciais calculados e previstos para a classe de diâmetro entre 25 e 35 cm



Fonte: O autor (2019).

Por fim, na sua totalidade, a Tabela 6.6 elucida que os menores índices de EQM ($3,01 \times 10^{-05}$), correlação (0,99980) e diferença em módulo (0,01186m³) pertence à rede 4 A. Para este caso, a arquitetura contém três neurônios associados à camada de entrada, 15 na camada oculta e um spread de 0.75. Novamente, visando exteriorizar o desempenho da predição para os 39 padrões desconhecidos, gerou-se a Figura 6.10.

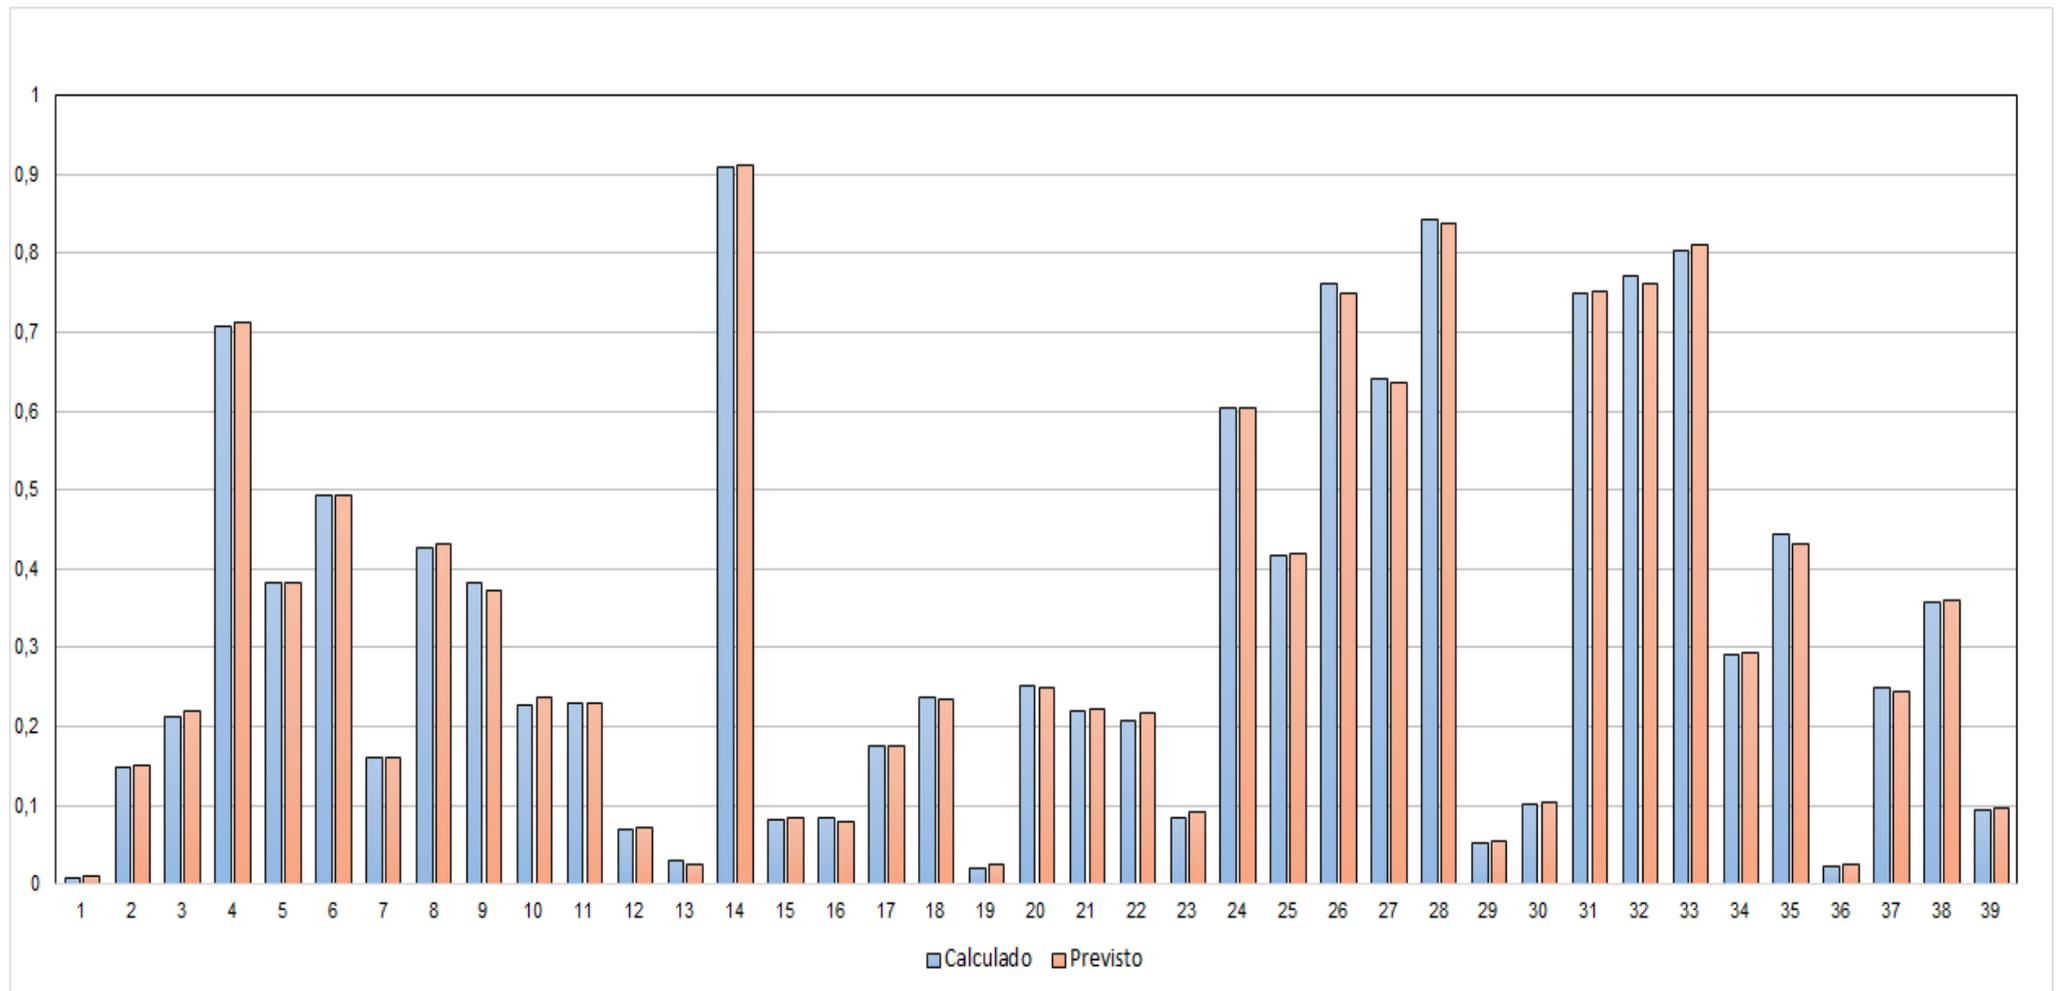
Tabela 6.5 Características das RNAs selecionadas para as estimativas de volume parcial com casca de Pinus taeda L considerando a classe de diâmetro acima de 35 cm, respectivamente

RNAs	Arquitetura de melhor desempenho*	Variáveis de Entrada	Spread (Raio da Função)	Função de Ativação		Variável de Saída	Teste (Validação)		
				CO	CS		$r_{y\hat{y}}$	EQM	Maior diferença individual (módulo)
1A	5-30-1	<i>l, DAPcc, h, VT e FFcc</i>	0.55	Gaussiana	Linear		0,99963	6,92144E-05	0,02910
2A	3-25-1	<i>l, DAPcc e h</i>	0.75	Gaussiana	Linear		0,99981	3,13718E-05	0,01304
3A	3-20-1	<i>DAPcc, h e VTcc</i>	0.75	Gaussiana	Linear	Volume Parcial	0,99980	3,19096E-05	0,01234
4A	3-15-1	<i>DAPcc, VTcc e FFcc</i>	0.75	Gaussiana	Linear	com casca para a	0,99980	3,01740E-05	0,01186
5A	2-14-1	<i>DAPcc e h</i>	0.75	Gaussiana	Linear	classe com	0,99982	2,94142E-05	0,01244
6A	4-20-1	<i>DAPcc, h, VTcc e FFcc</i>	0.90	Gaussiana	Linear	diâmetro > 35 cm	0,99964	2,87387E-05	0,02329
7A	2-10-1	<i>l e DAPcc</i>	1.15	Gaussiana	Linear		0,99459	0,000798086	0,10496
8A	2-14-1	<i>DAPcc e VTcc</i>	1.10	Gaussiana	Linear		0,99472	0,000831814	0,09001

Fonte: O autor (2019).

em que: * Número de neurônios em cada uma das camadas (entrada, oculta e saída); CO = camada oculta; CS = camada de saída; EQM = Erro Quadrático Médio e $r_{y\hat{y}}$ = coeficiente de correlação entre valores observados e estimados.

Figura 6.10: Comparação entre os volumes parciais calculados e previstos para a classe de diâmetro acima de 35 cm



Fonte: O autor (2019).

7 CONCLUSÃO

A mudança de cultura do produtor, bem como os avanços tecnológicos, tem permitido que todas as áreas, independentemente da esfera de atuação, possam se atualizar e buscar por sistemas integrados que auxiliem na tomada de decisão. Essa nova perspectiva tem se tornado uma das principais vantagens competitivas.

Neste contexto, este trabalho apresenta a aplicação da metodologia de RNAs, mais especificamente, das RBFs, em dois problemas florestais. O primeiro se resume em determinar o volume final dos povoamentos da espécie de *Pinus taeda L.* com a intermediação do *software* SisPinus para a definição dos atributos e instâncias aplicadas ao longo do processo. Já o segundo considera um banco de dados reais que foi modificado, a partir do ajuste de uma equação de afilamento que descreve o perfil longitudinal do fuste e de sucessivas integrações parciais, para o encontro do volume parcial com casca contemplado para cada um dos cinco segmentos pré-definidos.

Em termos computacionais, a utilização do *software* Matlab permitiu a construção e implementação de diferentes configurações de redes RBFs (com eventuais variações no número de neurônios na camada de entrada (atributos e intermediária) para a definição da melhor rede, contando com a estratificação de 2/3 para a fase de treinamento e 1/3 para a realização de testes (validações) da rede já treinada. No que diz respeito à acurácia dos modelos, as principais avaliações consideraram como parâmetros elementares o EQM, diferenças individuais entre os valores previstos pela RNA com o calculado (equações matemáticas) ou previsto (simulador SisPinus) e o coeficiente de determinação, sendo este último apenas para o caso B.

Ao abordar o aspecto da confrontação dos dados, ficou evidente que as redes RBFs, para ambos os estudos, convergiram potencialmente para o objetivo do trabalho, alcançando valores de EQM extremamente baixos, para os conjuntos de testes e, por este motivo, podem ser consolidadas como uma

excelente ferramenta alternativa para a prognose do volume total e parcial (com casca) de *Pinus taeda* L.

Para futuros trabalhos, há um campo de oportunidades muito crescente para se aplicar a metodologia de RNAs, seja para a predição do volume (considerando esses e outros atributos de entrada), reconhecimento de padrões (terrenos, solos) ou de qualquer outra variável caracterizada como sendo importante para a prática do manejo florestal.

REFERÊNCIAS

ADAMOWICZ, E. C.; SAMPAIO, M. E. C. S.; BARBOZA, A. O. **Reconhecimento de Padrões na Análise Econômico-Financeira de Empresas**. Trabalho apresentado no XXII Encontro Nacional de Engenharia de Produção. Curitiba 2002.

AFFONSO, E. T. F. SILVA, A. M. RODRIGUES, T. M. D. MOITA, G. F. **Uso de Redes Neurais Multilayer Perceptron (MLP) em sistema de bloqueio de websites baseado em conteúdo**. Asociación Argentina de Mecânica Computacional. Buenos Aires, 2010.

AGUIAR, F. G. **Utilização de Redes Neurais Artificiais para detecção de padrões de vazamento em dutos**. Dissertação (Mestrado em Engenharia Mecânica) – Universidade de São Carlos. São Carlos, 2010.

AHRENS, S.; HOLBERT, D. Uma função para forma de tronco e volume de *Pinus taeda L.* **Boletim de Pesquisa Florestal**, Colombo, n. 3, p. 37-68, 1981

ALMEIDA, A. D. **Comparação entre métodos para roteamento de redes de dados usando Redes Neurais Artificiais**. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Santa Catarina. Florianópolis, 2001.

ANDERSSON, D. **Approaches to integrated strategic/ tactical forest planning**. Umea. 29f. Swedish University of Agricultural Sciences. 2005.

ANDRADE, S. F. **Sensoriamento remoto e algumas aplicações**. CADEGEO, 2011.

ANDRADE, V. C. L. Modelos de *taper* do tipo expoente-forma para descrever o perfil do fuste de árvores. **Pesquisa Florestal Brasileira**, Colombo, v.34, n.80, p.1-13, 2014.

ANTONELI, G.C.; NEITZEL, I. **Aplicação de redes neurais artificiais na indústria de fios de algodão**. Bauru, São Paulo. 2015.

AQUINO, P.S.R.; RODRIGUES, M.S.; CASTRO, R.V.O., NAPPO, M.E. Use of artificial neural network in the analysis of environmental variables associated to litterfall. **Comunicata Scientiae**, 7(3): 394-405, 2016.

ARCE, J.E. **Um sistema de análise, simulação e otimização do sortimento florestal em função da demanda por multiprodutos e dos custos de transporte**. Tese (Doutorado em Engenharia Florestal) – Universidade Federal do Paraná, Curitiba, 2000.

ASSEF, F.M. **Algoritmos de classificação em aplicação financeira: Avaliação de risco de crédito para pessoa jurídica**. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal do Paraná, UFPR. Curitiba, 2018.

ASHRAF, M.I.; MENG, F.R.; BOURQUE, C.P.A.; MACLEAN, D.A.; BOND-LAMBERTY, B. A novel modelling approach for predicting forest growth and yield under climate change. **PLoS ONE** 10(7), 2015.

ATTUX, R. **Redes Neurais II**. Unicamp. Campinas, 2016. (Material de aula).

BALCI, B.; KESKINKAN, O.; AVCI, M. Use of BDST and an ANN model for prediction of dye adsorption efficiency of Eucalyptus camaldulensis barks in fixed-bed system. **Expert Systems with Applications**, 38(1):949-956, 2011.

BELLOTE, A. F. J. SILVA, H. D. **Sistemas de desbaste**. Agência Embrapa de informação Tecnológica. 2011.

BHERING, L.L.; CRUZ, C.D.; PEIXOTO, L.A.; ROSADO, A.M.; LAVIOLA, B.G.; Nascimento, M. Application of neural networks to predict volume in eucalyptus. **Crop Breeding and Applied Biotechnology**, 15(3):125-131, 2015.

BINOTI, M.L.M.S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54p. Dissertação (Mestrado) - Universidade Federal de Viçosa, Viçosa.

BINOTI, M.L.M.S.; BINOTI, D.H.B.; LEITE, H.G. Application of artificial neural networks to estimate the height of even-aged stands of eucalyptus. **Revista Árvore**, 37(4):639-645, 2013.

BINOTI, D.H.B.; BINOTI, M.L.M.S.; LEITE, H.G.; DA SILVA, A.A.L.; ALBUQUERQUE, A.C. An approach to diameter distribution modeling using Cellular Automata and Artificial Neural. **Cerne**, 19(4):677-685, 2013.

BINOTI, M.L.M.S.; BINOTI, D.H.B.; LEITE, H.G.; GARCIA, S.L.R.; FERREIRA, M.Z.; RODE, R.; DA SILVA, A.A.L. Neural networks for estimating of the volume of trees. **Revista Árvore**, 38(2):283-288, 2014.

BINOTI, M.L.M.S.; BINOTI, D.H.B.; LEITE, H.G.; DA SILVA, A.A.L.; PONTES, C. Use of artificial neural network for diameter distribution modelling for even-aged population. **Revista Árvore**, 38(4):747-754, 2014.

BINOTI, M.L.M.S.; LEITE, H.G.; BINOTI, D.H.B.; GLERIANI, J.M. Stand-level prognosis of eucalyptus clones using artificial neural networks. **Cerne**, 21(1):97-105, 2015.

BINOTI, D.H.B.; DUARTE, P.J.; BINOTI, M.L.M.S.; DA SILVA, G.F.; LEITE, H.G.; MENDONÇA, A.R.; DE ANDRADE, V.C.L.; VEGA, A.E.D. Estimation of height of Eucalyptus trees with neuroevolution of Augmenting Topologies (NEAT). **Revista Árvore**, 41(3), 2017.

BITTENCOURT, G. **Inteligência Artificial: Ferramentas e Teorias**. 3. ed. Florianópolis: Editora da UFSC, 2006.

BONETE, I.P. **Redes Neurais Artificiais e modelagem de efeitos mistos na descrição do perfil do fuste de *Pinus taeda* L.** Tese (Doutorado em Ciências

Florestais) – Universidade Estadual do Centro-Oeste, Unicentro. Iraty, PR, 2018.

BORSATO, D. MOREIRA, I. NOBREGA, M. M. MOREIRA, M. B. DIAS, G. H. **Aplicação de Redes Neurais Artificiais na identificação de gasolinas adulteradas comercializadas na região de Londrina – Paraná.** 31a Reunião Anual da Sociedade Brasileira de Química, 2009.

BRAGA, A. P. CARVALHO, A. C. P. L. F. LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações.** Rio de Janeiro: LTC, 2000.

BRENA, D. A. BOM, R. P. **Modelos de crescimento e produção florestal.** Tese (Doutorado em Engenharia Florestal) – Universidade Federal do Paraná. Curitiba, 1991.

BUONGIORNO, J.; GILLES, K. J. **Forest management and economics: a primer in quantitative methods.** New York: Collin Macmillan, 1987.

CALDEIRA, S. F.; OLIVEIRA, D. L. C. **Desbaste seletivo em povoamentos de *Tectona grandis* com diferentes idades.** Revista Acta Amazônica. Mato Grosso do Sul, 2008.

CARNEIRO, T. C. SANTOS, H. A. BRAGA, A. P. S. CARVALHO, P. C. M. **Redes neurais artificiais para previsão de velocidade do vento: estudo de caso para Maracanaú–CE.** In: CONGRESSO BRASILEIRO DE AUTOMÁTICA. Belo Horizonte, p. 1011- 1018. 2014

CASTRO, F. C. C.; CASTRO, M. C. **Radial Basis Function.** Apostila do curso de Mestrado em Engenharia Elétrica na Pontifícia Universidade Católica do Rio Grande do Sul. Porto Alegre, 2008.

CASTRO, R.V.O.; SOARES, C.P.B.; MARTINS, F.B.; LEITE, E.H.G. Growth and yield of commercial plantations of eucalyptus estimated by two categories of models. **Pesquisa Agropecuária Brasileira**, 48(3):287-295, 2013.

COSENZA, D.N.; LEITE, H.G.; MARCATTI, G.E.; BINOTI, D.H.B.; DE ALCÂNTARA, A.E.M.; RODE, R. Site classification with support vector machine and artificial neural network. **Scientia Forestalis**, 43(108):955-963, 2015.

COSENZA, D.N.; SOARES, A.A.V.; DE ALCÂNTARA, A.E.M.; DA SILVA, A.A.L.; RODE, R.; SOARES, V.P.; LEITE, H.G. Site classification for eucalypt stands using artificial neural network based on environmental and management features. **Cerne**, 23(3):310-320, 2017.

ÇATAL, Y.; SAPLIOGLU, K. Comparison of adaptive neuro-fuzzy inference system, artificial neural networks and non-linear regression for bark volume estimation in brutian pine (*Pinus brutia* ten.). **Applied Ecology and Environmental Research**, 16(2):2015-2027, 2018.

DIAMANTOPOULOU, M.J.; MILIOS, E.; DOGANOS, D.; BISTINAS, I. Artificial neural network modeling for reforestation design through the dominant trees bole-volume estimation. **Natural Resource Modeling**, 22(4):511-543, 2009.

DIAMANTOPOULOU, M.J.; MILIOS, E. Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural network models. **Biosystems Engineering**, 105:306-315, 2010.

DIAMANTOPOULOU, M.J.; ÖZÇELİK, R.; CRECENTE-CAMPO, F.; ELER, T. Estimation of Weibull function parameters for modelling tree diameter distribution using least squares and artificial neural networks methods. **Biosystems Engineering**, 133:33-45, 2015.

FAUSETT, L. **Fundamentals of Neural Networks**, Prentice-Hall, Englewood Cliffs, NJ, 1994.

FERNANDES, F. A. P. WANNER, E. F. MARTINS, V. C. **Um Modelo de Redes Neurais Artificiais para Predição do Limite Mínimo de Gols em uma Partida de Futebol**. Associação Brasileira de Inteligência Computacional, 2015.

FERRARI, L.S.; SFEIR, T. A. **Pesquisa Operacional aplicada à Engenharia Florestal**. SEAFLORE – Semana de Aperfeiçoamento em Engenharia Florestal. Curitiba, 2017.

FIGUEIREDO FILHO, A.; BORDERS, B.E.; HITCH, K.L. Taper equations for *Pinus taeda* plantations in southern Brazil. **Forest Ecology and Management**, Amsterdam, v. 83, p.36-46, 1996.

FINOCCHIO, M. A. F. **Noções de Redes Neurais Artificiais**. Apostila do curso de Engenharia Elétrica pela Universidade Tecnológica Federal do Paraná. Campus Cornélio Procopio, 2014.

FLECK, L. TAVARES, M. H. F. EYNG, E. HELMANN, A. C. ANDRADE, M. A. M. **Redes Neurais Artificiais: Princípios Básicos**. Revista Eletrônica Científica Inovação e Tecnologia, v. 1, n. 13, p. 47-57, 2016.

FOEKEL, C. **Espécies de Pinus taeda úteis ao Brasil – Pinus taeda**. Disponível em: < http://www.celso-foelkel.com.br/pinus_03.html > Acesso em: 19 de outubro de 2017.

FRANCO, D. G. B. STEINER, M. T. A. **Estudo comparativo de Redes Neurais Artificiais para previsão de séries temporais financeiras**. Revista Blucher Marine Engineering Proceedings. Curitiba, 2014.

FREIMAN, J. P. **Utilização de Redes Neurais Artificiais na previsão de indicadores financeiros para avaliação econômica de negócios em situação de risco**. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Itajubá. Itajubá, 2004.

GOMIDE, L. R. **Planejamento Florestal Espacial**. Tese (Doutorado em Engenharia Florestal) – Universidade Federal do Paraná, Curitiba, 2009.

GUINGO, B. C. PONTES, T. S. STIEBLER, G. M. THOMÉ, A. C. G. **Um sistema de reconhecimento automático de placas de veículos e suas**

aplicações potenciais. Anais do XVIII Congresso de Pesquisa e Ensino em Transportes. Florianópolis, 2004.

HAYKIN, S.. **Neural Networks, A comprehensive Foundation.** IEEE Press. 1994.

HAYKIN, S. **Redes neurais: princípios e prática.** Porto Alegre: Bookman, 2001.

ITO, E.; ONO, K.; ITO, Y.M.; ARAKI, M. A neural network approach to simple prediction of soil nitrification potential: A case study in Japanese temperate forests. **Ecological Modelling**, 219(1-2):200-211, 2008.

JUVENAL, T. L.; MATTOS, R. L. G. **O setor florestal no Brasil e a importância do reflorestamento.** BNDES Setorial, Rio de Janeiro, n. 16, p. 3-29, 2002.

KASIVISWANATHAN, K. S.; AGARWAL, A. Radial Basis Function Artificial Neural Network: Spread Selection. **International Journal of Advanced Computer Science**, 2(11), 2012.

KERR, G. e HAUFE, J. **Thinning Practice a Silvicultural Guide**, 2011.

KOHLER, S. V. **Evolução do afilamento do tronco e do sortimento em plantios de *Pinus taeda* nos estados do Paraná e Santa Catarina.** 84f. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal do Paraná, Curitiba, PR, 2013.

KRONKA, F. J. N. NALON, M. A. MATSUKUMA, C. K. KANASHIRO, M. M. SHIN-IKE, M. S. PAVÃO, M. DURIGAN, G. LIMA, L. M. P. R. **Inventário florestal da vegetação natural do Estado de São Paulo.** São Paulo: Secretaria do Meio Ambiente/Instituto Florestal, 2005. 200p.

LACERDA, T.H.S.; CABACINHA, C.D.; ARAÚJO JÚNIOR, C.A.; MAIA, R.D.; LACERDA, K.W.S. Artificial neural networks for estimating tree volume in the Brazilian savanna. **Cerne**, 23(4):483-491, 2017.

LEITE, H.G.; BINOTI, D.H.B.; OLIVEIRA NETO, R.R.; LOPES, P.F.; DE CASTRO, R.R.; PAULINO, E.J.; BINOTI, M.L.M.S.; COLODETTE, J.L. Artificial neural networks for basic wood density estimation. **Scientia Forestalis**, 44(109):149-154, 2016.

LEUSCHNER, W. A. **Introduction to forest resource management**. New York: John Wiley & Sons, 1984.

LÓPEZ, M. F. J.; ARRIAZA, J. A. T.; PUERTAS, S. M.; LÓPEZ, M. M. P. Multilevel neuronal architecture to resolve classification problems with large training sets: Parallelization of the training process. **Journal of Computational Science**. vol. 16, p. 59 – 64, 2016.

LOTTERING, R.; MUTANGA, O. Estimating the road edge effect on adjacent Eucalyptus grandis forests in KwaZulu-Natal South Africa using texture measures and an artificial neural network. **Journal Spatial Science** 57:153-173, 2012.

LOUREIRO, A. M. **Condução dos Povoamentos. Apontamentos de Silvicultura**. Universidade de Trás-os-Montes e Alto Douro. 2 a Edição, Série Didática. Vila Real-Portugal, 1991.

LOUREIRO, S. T. **Desenvolvimento da área florestal no Brasil**. Campinas, 2015. (Material de aula).

MANTEL, W. **Forsteinrichtung**. Frankfurt: Sauerland's Verlag, 1959.

MARTINS, E.R.; BINOTI, M.L.M.S.; LEITE, H.G.; BINOTI, D.H.B.; DUTRA, G.C. Configuration of artificial neural networks for estimation of total height of eucalyptus trees. **Revista Brasileira de Ciências Agrárias**, 11(2):117-123, 2016.

MEDEIROS, I.L.; VIEIRA, A.; BRAVIANO, G.; GONÇALVES, B.S. Revisão Sistemática e Bibliometria facilitadas por um Canvas para visualização de

informação. **Revista Brasileira de Design da Informação**, São Paulo, v. 12, n. 1, p. 93 - 100, 2015.

MENZIES, J.; JENSEN, R.; BRONDIZIO, E.; MORAN, E.; MAUSEL, P. Accuracy of neural network and regression leaf area estimators for the Amazon Basin. **GIScience and Remote Sensing**, 44(1):82-92, 2007.

MIGUEL, E.P.; REZENDE, A.V.; LEAL, F.A.; MATRICARDI, E. A. T.; VALE, A.T.; PEREIRA, R.S. Artificial neural networks for modeling wood volume and aboveground biomass of tall Cerrado using satellite data. **Pesquisa Agropecuária Brasileira**, 50(9):829-839, 2015.

MITCHELL, S. A. Operational Forest Harvest Scheduling Optimization – **A mathematical model and solution strategy**. Auckland, 2004.

MÓDOLO, M.. **Classificação automática de supernovas usando redes neurais artificiais**. Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais. São José dos Campos. 2016.

MOTA, J. F.; SIQUEIRA, P. H.; DE SOUZA, L. V.; VITOR, A. **Uma rede neural de base radial baseada em computação evolucionária**. XXXII CILAMCE, 2013.

MOURA, J. B. **Estudo da forma do fuste e comparação de métodos de estimativa volumétrica de espécies florestais da Amazônia brasileira**. 132f. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal do Paraná, Curitiba, 1994.

NEVES, J. A. BRISTOT, G. **Modelo de previsão Climática baseado em Rede Neural com funções de Base Radial para o semiárido brasileiro**. XXXVI Simpósio SBPO, 2004.

NUNES, M. H.; GORGENS, E. B. Artificial intelligence procedures for tree taper estimation within a complex vegetation mosaic in Brazil. **PLoS ONE** 11(5):1-16, 2016.

OLIVEIRA, E.B. **Um sistema computadorizado de prognose de crescimento e produção de Pinus taeda L. com critérios quantitativos para a avaliação técnica e econômica de regimes de manejo.** Tese (Doutorado em Engenharia Florestal) - Universidade Federal do Paraná. Curitiba, 1995.

OLIVEIRA, M.; VASCONCELOS, Y. **Revolução no canavial.** Pesquisa FAPESP, v. 122, p. 62-70, 2006.

OLIVEIRA, V. P. L. **Redes Neurais Artificiais e K-médias em um modelo híbrido alternativo para a classificação de clientes em aprovação de crédito.** Universidade Federal de Goiás. Goiânia, 2015.

OLIVEIRA, E.L.; CASTRO, C.L.; COELHO, F.; SALDANHA, R.R. Uso de redes neurais RBF e GRNN para comparação de previsões de carga de longo prazo de energia elétrica. **Congresso Brasileiro de Inteligência Computacional.** 2015.

ÖZÇELİK, R.; DIAMANTOPOULOU, M.J.; WIANT Jr., H.V.; BROOKS, J.R. Comparative study of standard and modern methods for estimating tree bole volume of three species in Turkey. **Forest Products Journal**, 58(6):73-81, 2008.

ÖZÇELİK, R.; DIAMANTOPOULOU, M.J.; BROOKS, J.R.; WIANT Jr., H.V. Estimating tree bole volume using artificial neural network models for four species in Turkey. **Journal of Environmental Management**, 91(3):742-753, 2010.

ÖZÇELİK, R.; DIAMANTOPOULOU, M.J.; CRESCENTE-CAMPO, F.; ELER, U. Estimating Crimean juniper tree height using nonlinear regression and artificial neural network models. **Forest Ecology and Management**, 306(15):52-60, 2013.

PETROPOULOS, G.P.; VADREVU, K.P.; XANTHOPOULOS, G.; Karantounias, G.; SCHOLZE, M. A comparison of spectral angle mapper and artificial neural network classifiers combined with landsat TM imagery analysis for obtaining burnt area mapping. **Sensors**, 10(3):1967-1985, 2010.

PRODAN, M.; PETERS, R. COX, F.; REAL, P. **Mensura forestal**. San José, Costa Rica: IICA, 1997. 586p.

PETROULAKIS, N. MIAOUDAKIS, A. **An application of Neural Networks in Market Segmentation**. Journal: PanHellenic Conference in New Technologies and Marketing. 185-190. (2007).

REIS, L.P.; SOUZA, A.L.; MAZZEI, L.; REIS, P.C.M.; LEITE, H.G.; SOARES, C.P.B.; TORRES, C.M.M.E.; DA SILVA, L.F. Prognosis on the diameter of individual trees on the eastern region of the amazon using artificial neural networks. **Forest Ecology and Management**, 382:161-167, 2016.

REIS, L.P.; SOUZA, A.L.; REIS, P.C.M.; MAZZEI, L.; BINOTI, D.H.B.; LEITE, H.G. Prognosis of the diameter distribution in the Amazon by using artificial neural networks and cellular automata. **Floresta**, 48(1):93-102, 2018.

REIS, L.P.; Souza, A.L.; Reis, P.C.M.; Mazzei, L.; Soares, C.P.B.; Torres, C.M.M.E.; da Silva, L.F.; Ruschel, A.R., Rêgo, L.J.S.; Leite, H.G. **Ecological Engineering**, 112:140-147, 2018.

REZENDE, S. O. **Sistemas Inteligentes: Fundamentos e Aplicações**. 1. ed. Barueri: Manole, 2003.

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

RIBEIRO, N.; SITO, A. A.; GUEDES, B. S.; STAISS, C. **Manual de Silvicultura Tropical**. Publicação produzida com apoio da FAO (Universidade Eduardo Mondlane). Maputo, 2002. 130 p.

RIBEIRO, R.B. da S.; Gama, J.R.V.; de Souza, A.L.; Leite, H.G.; Soares, C.P.B.; da Silva, G.F. Methods to estimate the volume of stems and branches in the Tapajós national forest. **Revista Árvore**, 40(1):81-88, 2016.

ROCHA, M. P. ***Eucalyptus grandis* Hill ex Maiden e *Eucalyptus dunnii* Maiden como fontes de Matéria Prima para Serrarias**. Tese (Doutorado em Engenharia Florestal) – Universidade Federal do Paraná. Curitiba, 2000.

ROCHA, S. S. PIANUCCI, M. N. PITOMBO, C. S. CUNHA, A. L. B. N. **Uso de redes neurais para previsão de produção de viagens: uma análise agregada**. In: XXIX Anpet - Congresso de Pesquisa e Ensino em Transportes, 2015, Ouro Preto. Congresso de Pesquisa e Ensino em Transportes (2015).

RUMELHART, D. E. HINTON, G. E. WILLIAMS, R. J. **Learning internal representations by error propagation**. In James L. McClelland & David E. Rumelhart (Eds.), *Parallel Distributed Processing*, 1, 318–362, MIT Press. 1987.

SANQUETTA, C.R.; Piva, L.R.O.; Wojciechowski, J.; Corte, A.P.D.; Schikowski, A.B. Volume estimation of *Cryptomeria japonica* logs in southern Brazil using artificial intelligence models. **Southern Forests**, 80(1):29-36, 2018.

SANTI, E.; Paloscia, S.; Pettinato, S.; Chirici, G.; Mura, M.; Maselli, F. Application of neural networks for the retrieval of forest woody volume from SAR multifrequency data at L and C bands. **European Journal of Remote Sensing**, 48:673-687, 2015.

SANTOS, A.L. Estratégia ótima de regulação florestal considerando mix de consumo através da programação linear. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Paraná. Curitiba, 2012.

SCOLFORO, J. R. S. **Manejo florestal**. Textos acadêmicos. Curso de especialização – UFLA. Lavras, 2010.

SCHIKOWSKI, A. B. **Estimativa do volume e da forma do fuste utilizando técnicas de aprendizado de máquina**. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal do Paraná. Curitiba, 2016.

SCHNEIDER, P. R.; FINGER, C. A. G. **Determinação de regimes de desbaste para povoamentos de Pinus elliottii E. do planalto ocidental no estado de Santa Catarina**. Ciência Florestal. Santa Maria, v. 4, n. 1, p. 43-59. 1994.

SCHRÖDER, T.; PEREIRA, L. D.; HOFIÇO, N. S. A. Comparação de Métodos de Estimativa de Volume Total para *Eucalyptus grandis* W. Hill ex Maiden. **Floresta e Ambiente**, Rio de Janeiro. v. 20, n.4, p. 480-486, 2013.

SELLI, M.F.; SELEGHIM JR, P. **Online identification of horizontal two-phase flow regimes through Gabor transform and neural network processing**. HEAT TRANSFER ENGINEERING, v. 28, n. 6, p. 541-548, 2007.

SILVA, J.N.M; CARVALHO, J.O.P; LOPES, J. C. A; CARVALHO, M.S.P. Equações de volume para a Floresta Nacional do Tapajós. Boletim de Pesquisa Florestal, 8:50-63, 1984.

SILVA, M.L.M.; Binoti, D.H.B.; Gleriani, J.M.; Leite, H.G. Adjustment of the Schumacher and Hall model and application of artificial neural networks to estimate volume of eucalypt trees. **Revista Árvore**, 33(6):1141-1147, 2009.

SILVA A. M. **Utilização de Redes Neurais Artificiais para Classificação de SPAM**. Dissertação (Mestrado em Modelagem Matemática e Computacional) - Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte, BH, 2009.

SILVA, P.R.; Acerbi Júnior, F.W.; de Carvalho, L.M.T.; Scolforo, J.R.S. Use of artificial neural networks and geographic objects for classifying remote sensing imagery. **Cerne**, 20(2):267-276, 2014.

SIQUEIRA, J.D.P. **Tabelas de volume para povoamentos nativos de Araucária angustifolia** (Bert.) O. Ktze, no sul do Brasil. *Floresta*, 8 (1) : 7 - 12 p. 1977.

SHIMIZU, J. Y. **Pinus na silvicultura brasileira**. Colombo: Embrapa Florestas, p. 17-47, 2008.

SOARES, F.A.A.M.N.; Flôres, E.L.; Cabacinha, C.D.; Carrijo, G.A.; Veiga, A.C.P. Recursive diameter prediction and volume calculation of eucalyptus trees using Multilayer Perceptron Networks. **Computers and Electronics in Agriculture**, 78(1):19-27, 2011.

SOARES, F.A.A.M.N.; Flôres, E.L.; Cabacinha, C.D.; Carrijo, G.A.; Veiga, A.C.P. Recursive diameter prediction for calculating merchantable volume of Eucalyptus clones without previous knowledge of total tree height using artificial neural networks. **Applied Soft Computing Journal**, 12(8): 2030-2039, 2012.

SOARES, F.A.A.M.N.; Flôres, E.L.; Cabacinha, C.D.; Carrijo, G.A.; Veiga, A.C.P. Recursive diameter prediction for calculating merchantable volume of eucalyptus clones using Multilayer Perceptron. **Neural Computing and Applications**, 22(7-8):1407-1418, 2013.

SOUSA, W. S.; SOUSA, F. A. **Rede Neural Artificial aplicada à previsão de vazão da Bacia Hidrográfica do Rio Piancó**. Revista Brasileira de Engenharia Agrícola e Ambiental. Universidade Federal de Campina Grande. Campina Grande, 2010.

SOUZA, C. A. M. de; FINGER, C. A. G.; SCHNEIDER, I. M. Modelos de afilamento para *Pinus taeda* L. baseados em pontos de mudança de forma. **Ciência Florestal**, Santa Maria, v. 26, n. 4, p. 1239-1246, 2016.

STEINER M.T.A.; Soma, N.Y.; SHIMIZU, T.; NIEVOLA, J.C. & STEINER NETO, P.J. **Using Neural Network Extraction for Credit-risk Evaluation**. *IFORS (17th Triennial Conference of the International Federation of Operational Research Societies hosted by INFORMS)*, 2005.

STEINER, M. T. A. **Redes neurais artificiais**. Notas de Aula. Curso de Engenharia de Produção pela Pontifícia Universidade Católica do Paraná. Curitiba, 2017.

TEIXEIRA, J. V. S. **Previsão do Índice da Bolsa de Valores do Estado de São Paulo utilizando Redes Neurais Artificiais**. Universidade Federal de Lavras. Lavras, 2012.

VALENTE, G. F. S.; GUIMARÃES, D. C.; GASPARDI, A. L. A.; OLIVEIRA, L. A. **Aplicação de redes neurais artificiais como teste de detecção de fraude de leite por adição de soro de queijo**. *Revista do Instituto de Laticínios Cândido Tostes*, v. 69, n. 6, p. 425-432, 2014.

VELLASCO, M. M. B. R. **Redes Neurais Artificiais**. Rio de Janeiro, 2007. (Apostila).

VENDRUSCOLO, D.G.S.; Chaves, A.G.S.; Medeiros, R.A.; da Silva, R.S.; Souza, H.S.; Drescher, R.; Leite, H.G. Height estimative of *Tectona grandis* L. f. trees using regression and artificial neural networks. **Nativa: Pesquisas Agrárias e Ambientais**, 5(1):52-58, 2017.

VIEIRA, G.C.; de Mendonça, A.R.; da Silva, G.F.; Zanetti, S.; da Silva, M.M., dos Santos, A.R. Prognoses of diameter and height of trees of eucalyptus using artificial intelligence. **Science of the Total Environment**, 619-620:1473-1481, 2018.

YOSHITANI JUNIOR, M.; NAKAJIMA, N. Y.; ARCE, J. E.; MACHADO, S. A.; DRUSZCZ, J. P.; HOSOKAWA, R. T.; MELLO, A. A. Funções de afilamento para plantios desbastados de *Pinus taeda*. **Floresta**, Curitiba, v. 42, n. 1, p. 169-176, 2012.

ZEIDE, B. **Evolution of silvicultural thinning: from rejection to transcendence.** In Proceedings of the 13th. Biennial Southern Silvicultural Research Conference. Department of Agriculture, Forest Service, Southern, U.S. Research Station, pp. 322–327. 2006.

ZUBEN, F. CASTRO, L. N. **Redes Neurais Artificiais.** DCA/FEEC/Unicamp. 2003.