



POLIANA BRITO NEJAIM

**USO DE APRENDIZADO DE MÁQUINA PARA A
PREDIÇÃO DO RENDIMENTO OPERACIONAL NA
COLHEITA DE EUCALIPTO**

LAVRAS – MG

2019

POLIANA BRITO NEJAIM

**USO DE APRENDIZADO DE MÁQUINA PARA A
PREDIÇÃO DO RENDIMENTO OPERACIONAL NA
COLHEITA DE EUCALIPTO**

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Engenharia Florestal, para a obtenção do título de Bacharel.

Prof. Dr. Lucas Rezende Gomide
Orientador

Msc. Talles Hudson Souza Lacerda
Coorientador

LAVRAS – MG

2019

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha
Catalográfica da Biblioteca Universitária da UFLA, com dados
informados pelo(a) próprio(a) autor(a).**

Nejaim, Poliana Brito.

Uso de aprendizado de máquina para predição do rendimento
operacional da colheita florestal / Poliana Brito Nejaim. - 2019.
35 p. : il.

Orientador(a): Lucas Rezende Gomide.

Coorientador(a): Talles Hudson Souza Lacerda.

TCC (graduação) - Universidade Federal de Lavras, 2019.

Bibliografia.

1. Planejamento florestal. 2. Colheita florestal. 3. Aprendizado
de máquina. I. Gomide, Lucas Rezende. II. Lacerda, Talles Hudson
Souza. III. Título.

POLIANA BRITO NEJAIM

**USO DE APRENDIZADO DE MÁQUINA PARA A
PREDIÇÃO DO RENDIMENTO OPERACIONAL NA
COLHEITA DE EUCALIPTO**

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Engenharia Florestal, para a obtenção do título de Bacharel.

APROVADA em (29/11/2019)

Prof. Dr. Lucas Rezende Gomide UFLA

Msc. Talles Hudson Souza Lacerda UFLA

Msc. Isáira Leite e Lopes UFLA

Prof. Dr. Lucas Rezende Gomide
Orientador

Msc. Talles Hudson Souza Lacerda
Coorientador

LAVRAS – MG

2019

*Ao meu avô, Vicente, por ser o primeiro engenheiro florestal que conheci.
Formado pela escola da vida, apaixonado pelas árvores e pela terra.
Dedico.*

AGRADECIMENTOS

Agradeço primeiramente a Deus, pela vida e força para enfrentar os dias difíceis e por se fazer presente nos pequenos detalhes.

Aos meus pais, Ana Elisa e Hércules, por não medirem esforços para que meu sonho se realizasse. Pelo amor, incentivo e compreensão de sempre.

À minha irmã, Paloma, pelo companheirismo e por sempre me fazer lembrar que a vida pode ser vista de uma maneira leve.

Ao meu namorado, Eduardo, pelo apoio incondicional. Pelo amor e cuidados diários, pela parceria e cumplicidade.

À minha prima, Carolina, por ser uma irmã mais velha. Pelos cuidados, atenção e paciência durante toda minha vida.

Ao vôlei feminino UFLA e amizades feitas através do esporte universitário, pelas histórias e superações vividas.

Aos amigos de curso, Ana Cláudia, Ana Luiza, Thaynara, Gabriela, Marcela, Matheus e Mayck, que dividiram angústias e conquistas. Pela amizade que deixa os dias mais alegres.

À minhas companheiras de casa, Aline, Danusa, Vanessa Viana, Vanessa Marques e Mariana, pela convivência e por ser minha família em Lavras.

Ao Prof. Lucas Gomide e a todos integrantes do laboratório GOPLAN, pelos conhecimentos adquiridos e pela oportunidade de trabalhar com pessoas tão generosas.

De modo geral, agradeço a todos que contribuíram com minha formação pessoal e acadêmica.

Muito obrigada!

RESUMO

A coleta e o processamento de variáveis para a modelagem de um dado atributo é um desafio constante na Engenharia Florestal. Independente do caminho metodológico seguido, os resultados gerados auxiliam na tomada de decisão. Atualmente, a inteligência artificial se mostra como uma alternativa promissora para gerar resultados confiáveis e com baixo erro. Assim, o presente trabalho teve como objetivo avaliar o desempenho das variáveis coletadas no boletim de colheita para a predição do rendimento operacional de frente de corte. Foram avaliadas variáveis como volume médio individual das árvores, área, turno, classe de experiência dos operadores e equipamentos. Para tal, a pesquisa utilizou a construção de Redes Neurais Artificiais (RNAs) na predição do rendimento operacional da colheita florestal. Buscando o êxito deste propósito, definiu-se a utilização da arquitetura *Multilayer Perceptron* com a separação da base de dados em treinamento (70%) e validação (30%) no pacote *Neuralnet*. Os resultados demonstraram um desempenho promissor no uso deste método. A partir das opções testadas foram selecionadas as 3 melhores configurações. Posteriormente, essas passaram por um refino para potencializar seu desempenho. A rede número 684 apresentou o melhor conjunto de análises estatísticas e gráficas, os valores apresentados foram: RMSE (teste: 17,1% e validação: 21,65%), BIAS (teste: -0,06% e validação: 0,25%) e r_s (teste: 0,45 e validação: 0,36). Apesar do bom desempenho do método, observou-se baixa correlação dos dados entre o estimado e o real pode ser vinculada à escassez de variáveis preditoras, o que poderia ser sanado com a coleta de mais informações edafoclimáticas, mecânicas e temporais. Concluiu-se que o estudo permitiu a ampliação do conhecimento técnico sobre o tema, obtendo resultados satisfatórios. As redes neurais artificiais são eficientes para prever o rendimento operacional, mas ainda faz-se necessária a coleta e estudos de mais variáveis no boletim de colheita para a melhoria da correlação dos dados.

Palavras-chave: Planejamento Florestal, Colheita Florestal, Aprendizado de Máquina.

ABSTRACT

The collection and processing of variables for modeling a given attribute is a constant challenge in Forest Engineering. Regardless of the methodological path followed, the results generated help in decision making. Today, artificial intelligence shows as a promising alternative to generate results with low errors. Thus, the present study aimed to evaluate the performance of the variables collected in the harvest report to predict the operational performance of the cutting front. Variables such as the individual average volume of trees, area, shift, operator experience and equipment were evaluated. For such, a research used the construction of Artificial Neural Networks (RNAs) in the prediction of the operational yield of the forest harvest. In pursuit or achievement of this goal, define the use of the *Multilayer Perceptron* architecture with training database selection (70%) and validation (30%) in the *Neuralnet* package. The results demonstrated promising performance in using this method. From the options tested, the 3 best settings were selected. Subsequently, these threats refine to enhance their performance. Number 684 presents the best set of statistics and statistics, the values presented were: RMSE (test: 17.1% and validation: 21.65%), BIAS (test: -0.06% and validation: 0.25%) and r_s (test: 0.45 and validation: 0.36). Despite the good performance of the method, the low correlation between estimated and actual data may be linked to predictor variable scores, or that could be remedied by collecting more edaphoclimatic, mechanical, and temporal information. It was concluded that the study allowed the expansion of technical knowledge on the subject, obtaining satisfactory results. Because artificial neural networks are effective in predicting operational performance, it is still necessary to collect and study more variables in the harvest report to improve data correlation.

Keywords: Forestry Planning, Forest Harvest, Machine Learning.

SUMÁRIO

1	INTRODUÇÃO	9
2	REVISÃO BIBLIOGRÁFICA	11
2.1	O eucalipto no Brasil	11
2.2	A colheita florestal no Brasil	12
2.2.1	Fatores que afetam o rendimento operacional da colheita florestal	13
2.3	Inteligência artificial.....	14
2.3.1	Redes neurais artificiais.....	16
3	MATERIAL E MÉTODOS	19
3.1	Descrição da área de estudo e base de dados.....	19
3.2	Treinamento da rede <i>Multilayer perceptron</i> (MLP).....	19
3.2.1	Etapa 1 – Parametrização da rede.....	21
3.2.2	Etapa 2 – Refino da rede.....	21
4	RESULTADOS E DISCUSSÃO	22
5	CONCLUSÃO	28
	REFERÊNCIAS BIBLIOGRÁFICAS	28

1 INTRODUÇÃO

O cenário florestal brasileiro possui grande importância na economia do país, movimentando diversos ramos que dependem da matéria prima madeireira. Segundo o IBÁ (2019), os setores representados pela celulose, pisos e painéis de madeira, madeira serrada e carvão vegetal cresceram 13,1% em relação a 2017, totalizando uma receita de R\$ 86,6 bilhões. Ainda segundo o relatório, em comparação à indústria e a agropecuária o desenvolvimento do setor florestal apresentou maior desenvolvimento, comprovando sua relevância no cenário econômico do país. Indo além da economia, a importância do reflorestamento pode ser observada em fatores como preservação da qualidade do solo, retenção de água, sequestro de carbono e minimização da supressão de florestas nativas (ROCHA et al., 2015).

Dentre as culturas florestais existentes a nível comercial no Brasil, o Eucalipto recebe o maior destaque quando se relaciona à produtividade e versatilidade. Sua adaptação está aliada as tecnologias silviculturais e de melhoramento genético, que permite ao gênero assumir uma vantagem competitiva excelente frente ao mercado nacional e internacional (VALVERDE et al., 2004). Sendo assim, as atividades florestais exigem um elevado nível de investimento em cada etapa de extração da matéria-prima para que a demanda seja atendida com qualidade.

De todas as etapas existentes em um ciclo de florestas plantadas a colheita é a última atividade realizada em campo. Segundo Nascimento et al. (2015), a colheita florestal mecanizada é a mais aplicada atualmente e pode ser dividida em 3 etapas: corte, extração e transporte. A participação da colheita no custo final do produto é de aproximadamente 50%, visto que esta etapa engloba os maiores riscos e investimentos dado ao alto nível de mecanização (MACHADO; LOPES, 2000). Portanto, os fatores que possam vir a interferir negativamente na operação devem ser mitigados, e para isso o planejamento e a otimização florestal devem estar alinhados para colocarem em prática as melhores soluções.

Nesse sentido, o conhecimento e controle sobre as variáveis que influenciam no rendimento operacional da colheita tem despertado crescente interesse florestal. A predição dos dados de rendimento ainda configura um desafio visto que sua variabilidade pode ocorrer conforme inúmeros fatores, sendo os mais relevantes as condições edafoclimáticas, operacionais e humanas (BRAMUCCI; SEIXAS, 2002). Suas condições podem acarretar o sucesso ou o fracasso da operação. Visto sua

importância e complexidade, o investimento em técnicas e metodologias que facilitem a organização e processamento dos dados vem crescendo exponencialmente. Entretanto, é observado que existe uma carência no quesito de tecnologias da informação, para a gestão dos recursos madeireiros, que consigam lidar eficientemente com o nível de dados e variáveis existentes nesse setor.

As técnicas computacionais, como a inteligência artificial, já tem sido aplicadas em diversas áreas da agricultura com êxito (HONDA; JORGE, 2013). Os principais métodos aplicados atualmente são *Random forest*, *Support Vector Machine* e Redes Neurais Artificiais (RNAs), sendo considerados capazes de atender em alto nível um grande volume de dados com baixos erros (HAN et al., 2018). No setor florestal, destaca-se a utilização das RNAs para redução de custos e alta precisão (BINOTI; BINOTI; LEITE et al., 2014).

As RNAs são um ramo da neurociência, inspiradas no funcionamento dos neurônios humanos e são constituídas elementarmente por sua arquitetura e algoritmo de aprendizagem (RAUBER, 2005). A capacidade de resolver problemas complexos, modelar diversas variáveis e suas relações não lineares faz com que as RNAs superem os modelos de regressão (BINOTI et al., 2015). Das arquiteturas e algoritmos de treinamento existentes, destacam-se pelo ótimo desempenho a *Multilayer Perceptron* e o *Resilient Propagation*, respectivamente (NAOUM; ABID; AL-SULTANI, 2012). Buscando ainda o melhor entendimento das RNAs, alguns algoritmos foram propostos para auxiliar a interpretação deste tipo de processamento, como é o caso do Algoritmo de Garson (VALENÇA; LUDERMIR, 2007).

Sabe-se que há uma infinidade de variáveis qualitativas disponíveis que podem auxiliar a predição do rendimento operacional da colheita. Estas, na maioria das vezes, possuem comportamentos que não são conhecidos, tornando difícil sua modelagem. Aliado a isto, nos deparamos com a incipiência de estudos que possam alinhar estes dois fatores de forma confiável. Sendo assim, o uso das RNAs se faz uma alternativa promissora para sanar essa questão e aperfeiçoar o processamento. Diante do exposto, o objetivo deste trabalho foi modelar o rendimento operacional na colheita, bem como avaliar a influência das variáveis proveniente do apontamento da operação de colheita. Além disso, testar diferentes combinações e parametrizações das melhores RNAs nas suas predições.

2 REVISÃO BIBLIOGRÁFICA

2.1 O eucalipto no Brasil

O gênero *Eucalyptus* é originário da Austrália, possuindo aproximadamente 600 espécies, sua introdução no Brasil com fins técnicos ocorreu em 1904 por Edmundo Navarro de Andrade. (SOARES et al., 2010). A princípio, sua utilização era voltada para suprir principalmente as demandas mais rústicas, e atualmente é fonte de matéria prima para diversos pilares industriais tecnológicos (GALZERANO; MORGADO, 2008). Esta evolução da importância do eucalipto se dá por suas excelentes características de produtividade, crescimento, adaptabilidade e versatilidade (PEREIRA et al., 2011). Além disso, com todas essas características, essas espécies permitem um retorno financeiro em um tempo relativamente curto (DIAS et al., 2005).

De acordo com o relatório da Indústria Brasileira de Árvores – IBÁ (2019), em 2018, a área de florestas plantadas para fins industriais no Brasil totalizou cerca de 7,83 milhões de hectares, sendo que, deste total, as plantações de eucalipto ocupam 5,7 milhões de hectares. Ainda segundo o relatório, os estados que apresentam a maior intensidade de plantio do eucalipto são Minas Gerais (24%), São Paulo (17%) e Mato Grosso do Sul (16%).

A grande variedade de espécies de eucalipto permite sua utilização em diversos setores industriais, como movelaria, produção de celulose e papel, energia e construção civil (JÚNIOR; COLODETTE, 2013). A utilização dos produtos florestais não madeireiros também tem grande importância, sendo o eucalipto viável para extração de óleos das folhas, produção de mel, plantio de quebra ventos, entre outras utilizações. (WILCKEN, 2008). Dentre as espécies mais cultivadas no Brasil, destacam-se o *E. grandis*, *E. urophylla*, *E. saligna*, *E. citriodora*, *E. globulus*, *E. viminalis* e *E. tereticornis*. Além disso, também são utilizados em plantios florestais, os híbridos de eucalipto, resultantes do cruzamento de diferentes espécies (LERAYER, 2008). A produção de clones e híbridos visa melhorar as propriedades físicas e mecânicas da madeira para a obtenção produto de melhor qualidade, além de atender as demandas do mercado (MENDES et al., 2014).

A crescente evolução tecnológica nas áreas de silvicultura, melhoramento genético e manejo florestal, em áreas plantadas no Brasil atualmente possuem níveis de alta produtividade (HAKAMADA et al., 2015). Conseqüentemente, para acompanhar

esse alto nível produtivo, a colheita florestal também obteve grandes avanços (FREITAS et al, 2015).

2.2 A colheita florestal no Brasil

O setor florestal brasileiro é mundialmente reconhecido pelo seu desempenho e produtividade. É caracterizado por ser uma atividade econômica consolidada e que enfrenta de forma relativamente estável as nuances do mercado (CARVALHO; SOARES; VALVERDE, 2005). Ainda segundo esses autores, o setor é reconhecido por ser uma atividade engajada nos aspectos sociais e ambientais, quando comparados à outros ramos industriais. Para atender e garantir a responsabilidade social e ambiental exigidas pela sociedade, o setor florestal utiliza-se do mecanismo da certificação florestal (JACOVINE et al., 2006). Ainda segundo esse autor, a utilização da certificação contribui para reduzir atividades do setor que ainda atuam na ilegalidade e com premissas sociais e ambientais inadmissíveis.

Moreira, Simione e Oliveira (2017), relatam que a década de 90 foi um divisor de águas para a economia brasileira, sendo caracterizada por uma expansão que acarretou uma elevada demanda por produtos florestais. No Brasil, o aumento da fronteira florestal está ligada à expansão das indústrias de papel e celulose, juntamente com a produção de energia. Para que as metas de produtividade fossem atendidas, os níveis de industrialização se aprimoraram e as atividades mecanizadas para corte, extração e baldeio se tornaram cada vez mais estudadas (MINETTE et al., 2008).

De acordo com Machado, Silva e Pereira, (2002) mais da metade do custo final da madeira é proveniente da colheita e transporte florestal. Estes autores afirmam que a escolha de máquinas e equipamentos junto com o desenvolvimento de sistemas operacionais constitui o grande desafio para a redução dos custos desta atividade. O aumento do patamar técnico traz consigo uma relação direta entre custos e produtividade. Assim como qualquer ciclo produtivo, os custos de produção de plantios florestais também são dependentes de diversas situações, tais como objetivo da produção; nível tecnológico; controle de pragas; técnicas de manejo; densidade do plantio por hectare; escala de produção e nível de mecanização (MOREIRA; OLIVEIRA, 2017).

Atualmente, os sistemas de colheita praticados por empresas que detém alto nível de mecanização são: toras curtas, toras longas, árvores inteiras e árvores completas (LINHARES et al., 2012). Cada um contendo características específicas que conferem

vantagens e desvantagens para o rendimento e produtividade decorrentes (LINHARES et al., 2012). Acompanhando estes sistemas e as atividades que os englobam, as máquinas mais utilizadas são o *Harvester* que é um trator derrubador, desgalhador, traçador e empilhador, e a *Forwarder*, que é um trator florestal, cuja função é realizar o transporte primário por autocarregamento/descarregamento (LINHARES et al., 2012). Desta forma, as convergências das variáveis que interferem na colheita podem refletir positiva ou negativamente nos resultados finais.

2.2.1 Fatores que afetam o rendimento operacional da colheita florestal

Atualmente, as maiores empresas brasileiras produtoras de madeira dispõem do mais alto nível tecnológico para as operações de colheita florestal (COSTA et al., 2017). Desta forma, para atender as demandas do mercado e realizar atividades com qualidade e seguranças, as corporações tem visado diversas alternativas para minimizar as influências negativas de alguns fatores inerentes à colheita florestal. Bramucci e Seixas (2002) consideram relevantes as influências de variáveis edafoclimáticas, operacionais e humanas. Sendo estas determinantes para a viabilidade econômica e ambiental das atividades.

As variáveis edafoclimáticas refere-se ao âmbito externo da operação (característica do sítio), como exemplo, tem a declividade do terreno, época do ano, pluviosidade, umidade do solo e qualidade da operação anterior como influentes diretos na operação de colheita de madeira (SIMÕES; FENNER, 2010). Autores como She, Chung e Kim (2018) reafirmam, por exemplo, a interferência do declive no desempenho das máquinas e que conseqüentemente afetam a produtividade final. A umidade do solo se mostra um fator muito relevante, pois pode gerar problemas como a compactação e comprometer produções futuras (SZYMCZAK et al., 2014). Por outro lado, as variáveis operacionais, segundo Malinowski et al. (2006), são aquelas que possuem ligação direta com a máquina, ao implemento utilizado e ao sistema escolhido e que devem ser controladas. Nesse sentido, Diniz et al., (2018) reforça a importância da análise dos dados para a escolha do maquinário e implementos ideais. Sendo assim, o sistema escolhido refletirá diretamente na qualidade e custo do produto (FIEDLER; ROCHA; LOPES, 2008).

Estudos trouxeram à tona a importância do fator humano no desempenho do trabalho mecânico. Purfürst e Erlar (2011) relatam que a oscilação entre o desempenho

dos operadores pode ser alta, bem como avaliado individualmente ao longo do tempo. Estes autores afirmam que uma das principais diferenças observadas entre os operadores é relacionada ao número de decisões que precisam ser tomadas de forma rápida e contínua durante o manuseio da máquina. O conhecimento refinado da máquina alinhado ao raciocínio rápido e eficiente refletirá no resultado final da operação, e a exclusão desse fator pelos cálculos do planejamento pode introduzir erros na tomada de decisão (PURFÜRT; ERLER, 2011).

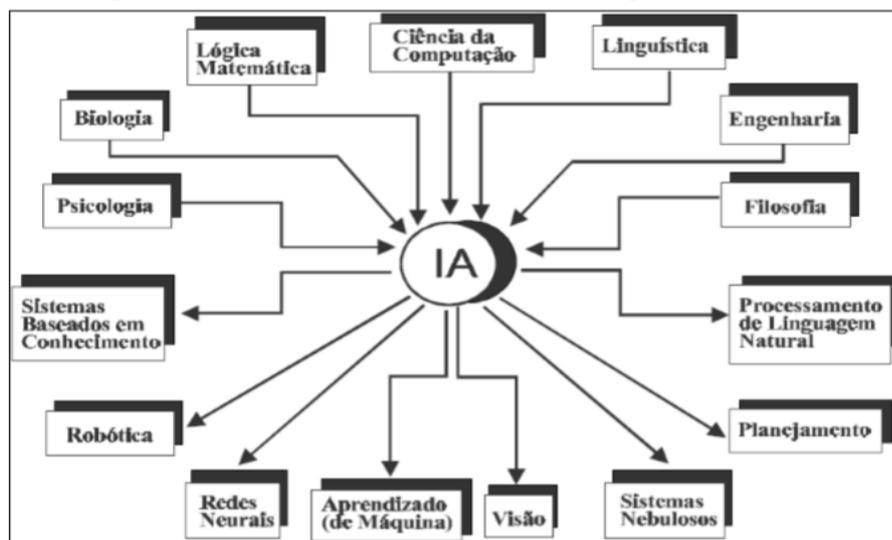
De posse do conhecimento sobre a ação dessas variáveis no processo da colheita de madeira, o planejamento terá o papel crucial de considerá-las e buscar as melhores alternativas para viabilizar as operações nos mais diversos cenários existentes. Segundo Silva et al. (2006), além da experiência e habilidade, os manejadores florestais necessitam de ferramentas computacionais de que possam respaldar e orientar a tomada de decisão e prever informações. Entretanto, é observado que existe uma carência no quesito de tecnologias da informação para a gestão dos recursos madeiros que consigam lidar eficientemente com o nível de dados e variáveis existentes nesse setor (ANGELO et al., 2018). Soares et al. (2015) relata que na área agrícola a inserção de instrumentos como a inteligência artificial já são amplamente aplicados e garantem excelentes resultados, visando antecipar os valores de produtividade para deliberar sobre necessidades futuras de logística e armazenamento.

2.3 Inteligência artificial

A inteligência artificial (IA) surgiu pela necessidade de buscar soluções para problemas complexos e que cada vez mais possuem grandes volumes de dados a serem manipulados (SILVA; NATHANSOHN, 2018). Segundo esses autores, o conceito de IA surgiu por volta 1956, a partir do Simpósio sobre Teoria da Informação realizado no MIT (Massachusetts Institute of Technology). Madsen e Adamatti (2011) referem-se à IA como um segmento da ciência da computação que abrange a construção de sistemas computacionais baseados na inteligência humana. A interdisciplinaridade e versatilidade das ferramentas de IA mostram o quão importante elas são nos dias atuais (MADSEN; ADAMATTI, 2011). A sua utilização transita em áreas como psicologia (PAIVA, 2007), lógica matemática (MARRO et al., 2010), ecologia (REIS et al., 2018), entre outras áreas científicas conforme exemplifica a Figura 1. Diante do exposto, a aplicação da IA trouxe consigo o conceito de *machine learning* (Aprendizado de Máquina), que

consiste no desenvolvimento de métodos de aprendizagem de máquina para abranger um conjunto de dados coletados em diversos ambientes (CARVALHO; CRUZ; GOUVEIA, 2017). Os métodos permitem que haja uma análise de dados e automatiza a construção de modelos estatísticos.

Figura 1 – Áreas relacionadas com a inteligência artificial.



Fonte: Monard e Baranaukas (2000).

Dentre os mais estudados, temos o *Random Forest* (Floresta Aleatória) que é um método que pode ser caracterizado pela construção de inúmeras árvores de decisão decorrelacionadas para o refinamento da predição desejada, que é obtida pela média dos valores preditos por todas as árvores (REDDY; GEBRESLASIE; ISMAIL, 2017). Para Moreira, Nery e Fernandes (2014), o *Support Vector Machine* (Máquina Vetor de Suporte) que é proveniente da teoria de aprendizagem por análise estatística, além de ser considerado um classificador de alto padrão não paramétrico. E por fim, as redes neurais artificiais, que consiste em uma ferramenta baseada na organização cerebral humana com capacidade de aprendizado e determinado por sua arquitetura (SOARES et al., 2014).

Das diversas áreas abrangidas pela inovação das técnicas computacionais, a agricultura tem conseguido grandes avanços na gestão dos dados coletados (HONDA; JORGE, 2013). Para Ramírez (2017) a inteligência artificial aplicada à agricultura de precisão permite vislumbrar novas linhas de trabalho, de forma otimizada e com redução de custos. Esse advento tecnológico, considerado a quarta revolução industrial, atualmente é denominado Indústria 4.0 (VINICIUS et al., 2019).

Seguindo o desenvolvimento da agricultura de precisão, o setor florestal tem apostado na tecnologia da informação para diminuir as falhas e aumentar o controle das atividades (MELO et al., 2016). A utilização e domínio das ferramentas disponíveis permitem ao setor que haja uma base confiável para a tomada de decisões e definição de estratégias.

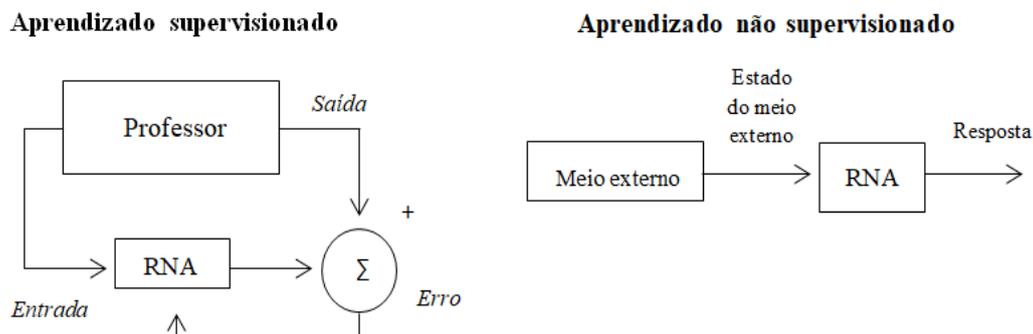
2.3.1 Redes neurais artificiais

As redes neurais artificiais (RNAs) são um dos processamentos existentes no ramo da inteligência artificial que são baseadas no processamento neural do cérebro humano. As RNAs são organizações compactas e dispersas simultaneamente, são compostas por elementos de processamento simples e que possuem a tendência em acumular o conhecimento experimental e disponibilizá-lo para uso posterior (HAYKIN, 2007). Sua comparação ao funcionamento cerebral humano se deve a dois quesitos: a necessidade de um processo de aprendizagem para assimilar o conhecimento e a potência de conexão entre os neurônios (HAYKIN, 2007). Por meio dos fatores anteriormente citados por este autor, as RNAs conseguem ajustar saídas para entradas que não estavam presentes no “aprendizado” e esta característica confere a capacidade do método de obter respostas para problemas complexos.

A conexão entre os neurônios é conhecida como arquitetura da rede, esse arranjo permitirá a definição de qual algoritmo será utilizado para o processo de treinamento da RNA possibilitando a classificação de acordo com a dinâmica dessas conexões (HAYKIN, 2007). Estas podem ser classificadas em camada única, múltiplas camadas e cíclicas (BRAGA; CARVALHO; LUDERMIR, 2000).

Os tipos de aprendizados podem ser divididos em supervisionado, onde há a necessidade de um professor que forneça os dados de entrada-saída, e o não supervisionado onde há somente a entrada. (BRAGA; CARVALHO; LUDERMIR, 2000). Na Figura 2 podemos observar o esquema caracterizando os métodos de aprendizado.

Figura 2 – Métodos de aprendizagem.



Fonte: Adaptada de BRAGA; CARVALHO; LUDERMIR (2000).

As RNAs mais utilizadas atualmente são do tipo *Multilayer perceptron* (MLP), devido à sua alta flexibilidade, como os exemplos dos trabalhos de Clesio e Sassi (2014), Valente et al. (2014) e Soares, Quintella e Campos (2017). As MLP possuem camadas ocultas que se encontram entre as variáveis de entrada e saída, que podem ser organizadas de inúmeras maneiras conforme a complexidade do problema (RAMCHOUN et al., 2016). Braga, Carvalho e Ludermir (2000) afirmam que existem diversos algoritmos utilizados para treinamento de redes neurais supervisionadas. Entre eles, destaca-se o *resilient back-propagation* (Rprop), proveniente de uma evolução do *backpropagation*. Ele permite uma robustez maior para a solução de problemas mais complexos e visa minimizar o erro no ajuste dos pesos entre as conexões (BRAGA; CARVALHO; LUDERMIR, 2000).

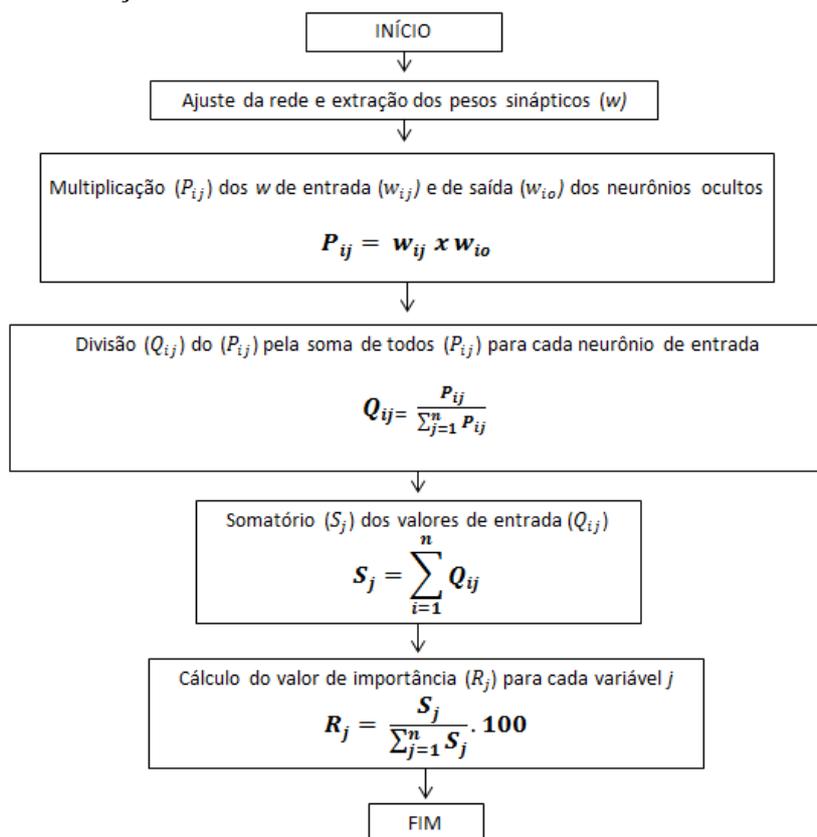
Para qualquer método de predição é importante conhecer de forma confiável a estimação do erro. Rodríguez, Pérez e Lozano (2009) consideram que existem vários estimadores do erro de classificação, sendo o mais utilizado o método de validação cruzada, conhecido como *k-fold*. Ainda segundo esses autores, o método consiste na subdivisão dos dados em *k* subconjuntos do mesmo tamanho, realiza-se o teste (obtenção do erro) para um subconjunto e obtêm-se os pesos (treinamento) com os conjuntos *k-1*.

Existem técnicas que auxiliam a validação dos dados e ainda permitem uma análise de sensibilidade das RNAs facilitando e ajudando a compreender os processamentos mais robustos (LIMA; LACERDA; NETO, 2017). Esses autores apontam métodos como Algoritmo de Garson, método Perturb, método PaD, como os

mais relevantes para o entendimento da importância de cada variável no processamento e podendo inferir até mesmo se esta é relevante ou não.

Destacando o Algoritmo de Garson, ele permite a avaliação da contribuição de cada variável associando os pesos entre as conexões de entrada e saída conforme o fluxograma da Figura 3 (LIMA; LACERDA; NETO, 2017).

Figura 3 - Fluxograma do funcionamento do Algoritmo de Garson para avaliar a contribuição relativa de cada variável de entrada testada.



Fonte: Adaptado de Lima, Lacerda e Neto (2017).

Na engenharia florestal, as redes neurais artificiais já são difundidas em diversas áreas como, por exemplo, mapeamento de biomassa e carbono (SCHOENINGER et al., 2008), estimação de volume de florestas plantadas (BINOTI; BINOTI; LEITE, 2014) e nativas (LACERDA et al., 2017), tecnologia da madeira (VAN NGUYEN et al., 2018), se mostrando uma ferramenta aplicável e precisa. Contudo, os estudos aplicados à predição do rendimento operacional da colheita florestal ainda são incipientes, revelando-se uma lacuna para desenvolvimento de pesquisa e inserção de tecnologias.

3 MATERIAL E MÉTODOS

3.1 Descrição da área de estudo e base de dados

A área de estudo está situada no estado do Mato Grosso do Sul, no qual apresenta uma área produtiva de 1.002,13ha. Segundo Andrella e Neto (2017), essa região possui o clima estacional, com período chuvoso de outubro a março e período seco de abril a setembro. As temperaturas médias oscilam entre 22°C a 27°C, a precipitação média anual é de 1.500 mm e o clima Tropical *Aw* segundo Köppen (1948).

Os dados foram provenientes de uma área que abrange 26 talhões com diferentes clones de *Eucalyptus spp.* direcionados para a produção de celulose. O período de coleta de dados ocorreu entre fevereiro a maio de 2019, considerando 2 turnos de 8,8 horas divididos em manhã/tarde, totalizando 1895 observações. As variáveis coletadas foram divididas em contínuas e categóricas. Dentre as contínuas (TABELA 1), tem-se o volume médio individual (VMI) em m³, a área do talhão em hectare e o rendimento em m³.h⁻¹. As categóricas são as máquinas utilizadas para cada operação (*Harvesters*), os turnos e a classe de experiência do operador sendo esta dividida em 6 classes com intervalo de 1 ano entre elas. Desta forma, a classe 1 abrange os operadores com menos experiência, enquanto a classe 6 caracteriza os operadores com 6 anos ou mais de experiência.

Tabela 1 – Informações descritivas das variáveis quantitativas na área de estudo.

Variáveis	Mínimo	Média	Máximo	CV (%)
Rendimento (m ³ .h ⁻¹)	10,75	27,06	47,88	17,68
Área (ha)	19	48,16	81,71	37,67
VMI (m ³)	0,21	0,27	0,32	7,98

Em que: VMI = volume médio individual (m³) e CV = coeficiente de variação (%).

Fonte: Do autor (2019).

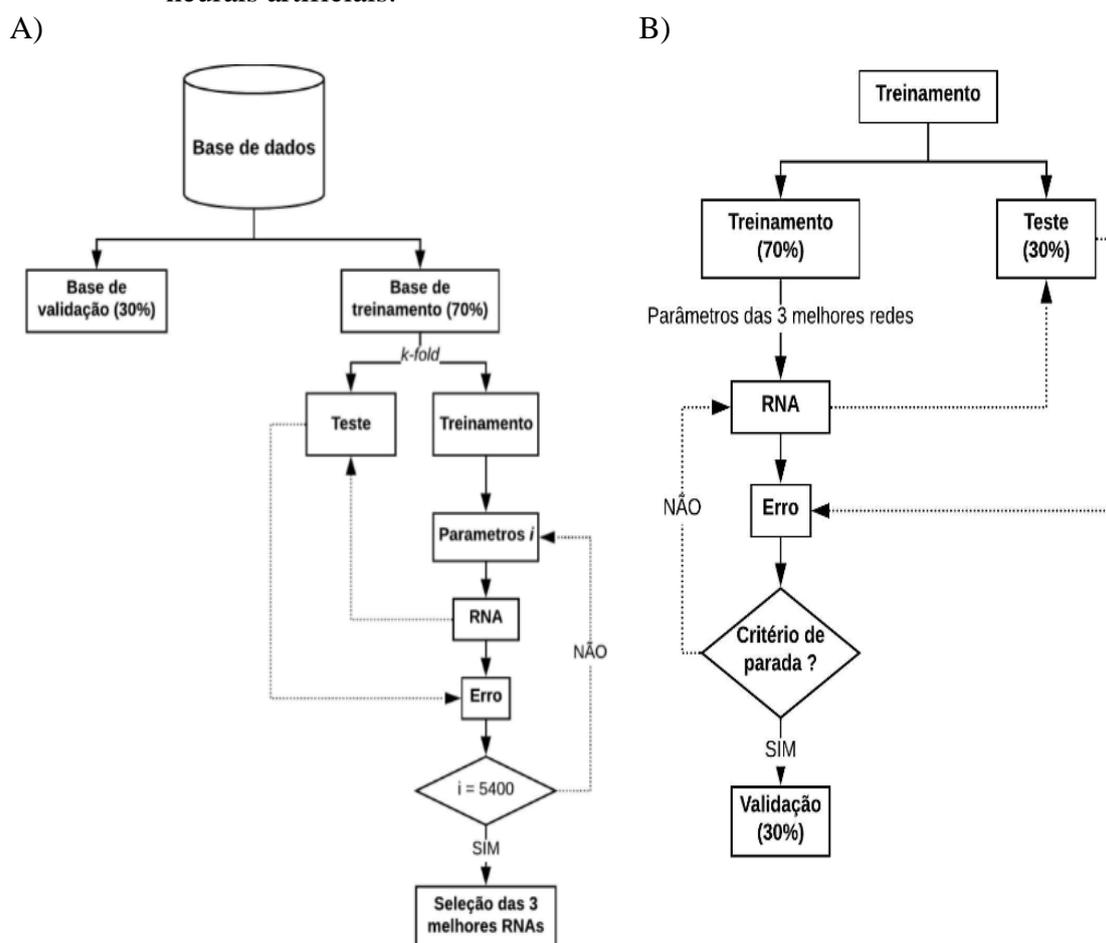
3.2 Treinamento da rede *Multilayer perceptron* (MLP)

Para que haja uma boa análise do valor de importância das variáveis, elas precisam ser bem definidas previamente, pois são elas que irão explicar o comportamento da variável saída. A seleção de boas entradas é o grande desafio para justificar fidedignamente o rendimento operacional em questão. A utilização das Redes Neurais Artificiais tem se mostrado uma excelente alternativa, devido à sua capacidade

de fornecer resultados satisfatórios para problemas complexos (CHIARELLO et al., 2018).

Logo, para o desenvolvimento do trabalho, a base passou por uma Clusterização onde foi dividida em 5 grupos para que houvesse uma representação global dos dados (JÚNIOR; JÚNIOR; BASTOS FILHO, 2018). Em seguida foi dividida aleatoriamente em 2 conjuntos: a) treinamento (70%) e validação (30%). Inicialmente, foi realizado um pré-processamento, denominado normatização dos dados, buscando a homogeneização da amplitude dos dados, para que haja maior velocidade e confiabilidade no treinamento (GÖRGENS et al., 2009). A base de dados teve sua normatização entre 0 e 1, sendo o mínimo e máximo, respectivamente. O processamento foi realizado no software R versão 3.5.2 (R Core Team, 2018) utilizando o pacote *Neuralnet* (GÜNTHER; FRITSCH, 2010). A Figura 4 descreve a metodologia do trabalho.

Figura 4 – Esquema ilustrativo do processo metodológico de modelagem via redes neurais artificiais.



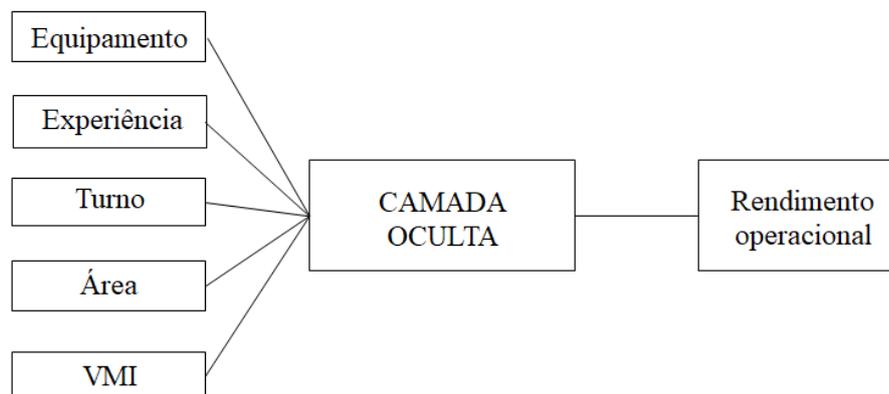
Em que: A) Parametrização da rede (Etapa 1) e B) Refino da rede (Etapa 2).

Fonte: Do autor (2019).

3.2.1 Etapa 1 – Parametrização da rede

A arquitetura utilizada foi a *Multilayer perceptron* (MLP) com uma camada oculta, cujo número de neurônios foi definido pela validação cruzada, usando a técnica *k-fold*, a qual variou de 1 a 15 neurônios. Esta técnica consiste na subdivisão aleatória da base de dados em k subgrupos (RODRÍGUEZ; PÉREZ; LOZANO, 2009), e o processamento em questão utilizou $k=5$. A base utilizada para essa parametrização foi a de treinamento. A MLP foi construída com 5 variáveis de entrada (turno, equipamento, classe de experiência do operador, volume médio individual e área), e uma variável de saída (rendimento), conforme a Figura 5. O algoritmo de aprendizado utilizado foi o *Resilient Propagation* (Rprop) (MOSCA; MAGOULAS, 2015), com taxa mínima variando de 0,4 a 0,6 e máxima de 1,1 a 1,3. As funções de ativação de entrada foram logísticas e tangenciais, e na saída foram linear ou similar a de entrada. O critério de parada foi o erro médio quadrático de 0,01.

Figura 5 – Esquema simplificado da MLP construída.



Fonte: Do autor (2019).

3.2.2 Etapa 2 – Refino da rede

Após geradas as 1.080 RNAs, os dados de treinamento foram utilizados, no qual foram subdivididos em treinamento e teste, com 70% e 30%, respectivamente. Com as parametrizações já definidas na Etapa 1, as três melhores foram recrutadas pela análise da média dos erros do teste de *fold*s. Com isso, após as redes ajustadas, fez-se necessário o refino dessas RNAs para sua validação para a base de dados. Feito isso a predição da produtividade dos dados de validação foi avaliada por meio das estatísticas (Tabela 2): correlação não linear de Spearman entre os valores observados e estimados

(r_s), BIAS (%) e raiz do erro quadrado médio (Root Mean Square Error – RMSE %), que foram calculados pelo software R versão 3.5.2 (R Core Team, 2018). Uma avaliação gráfica também foi realizada a fim de observar a assertividade das predições (ÖZÇELİK; BAL, 2013). Essa avaliação permite observar a dispersão dos valores, sendo que quanto mais próximo os pontos estiverem da linha de 45°, melhores as predições.

Tabela 2 – Estatísticas de avaliação das Redes Neurais.

Estatística	Fórmula
Correlação não linear de Spearman (r_s)	$r_s = 1 - \frac{6 \cdot \sum_{i=1}^n d_i^2}{n \cdot (n^2 - 1)}$
BIAS (%)	$B(\%) = \frac{100}{\bar{Y}} \cdot \frac{\sum_{i=1}^n Y_i - \sum_{i=1}^n \hat{Y}_i}{n}$
Raiz do erro quadrado médio (%)	$RMSE(\%) = \frac{100}{\bar{Y}} \cdot \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}$

Em que: Y_i = observado; \hat{Y}_i = estimado; \bar{Y} = média observada; d = diferença entre Y_i e \hat{Y}_i e n = número de observações.

Fonte: Do autor (2019).

4 RESULTADOS E DISCUSSÃO

Na Tabela 3 estão apresentadas as parametrizações das 3 melhores RNAs juntamente com suas avaliações estatísticas. Observou-se que a função logística, também chamada de sigmoïdal, foi unanimidade em todas as redes, representando um forte comportamento não linear dos dados. A utilização desta função pode ser observada em trabalhos como Binoti, Binoti e Leite (2014), Oliveira et al. (2015) e Neto et al. (2019), de modo a justificar que o comportamento não linear pode ser bem captado por esta função de ativação.

Tabela 3 – Parametrização das RNAs selecionadas e suas métricas de avaliação.

Parâmetros	RNAs		
	528	684	886
Nº de neurônios da camada oculta	8	10	13
Função de entrada	<i>Logistic</i>	<i>Logistic</i>	<i>Logistic</i>
Função de saída	<i>Logistic</i>	<i>Logistic</i>	<i>Logistic</i>
Algoritmo de treinamento	rprop+	rprop-	rprop+
Taxa mínima de treinamento	0,5	0,6	0,5
Taxa máxima de treinamento	1,3	1,3	1,1
Estadísticas	Teste		
RMSE (%)	17,42	17,1	19,03
BIAS (%)	-0,13	-0,06	-0,12
r_s	0,46	0,45	0,43
Estadísticas	Validação		
RMSE (%)	21,19	21,65	23,72
BIAS (%)	0,20	0,25	0,33
r_s	0,38	0,36	0,37

Em que: RMSE (%) = raiz do erro quadrado médio; BIAS (%) = erro sistemático; r_s = correlação não linear de Spearman.

Fonte: Do autor (2019).

As análises estatísticas foram realizadas para cada rede selecionada. Observa-se, *a priori*, que os erros relacionados aos testes foram menores do que os da validação, comportamento que era esperado, caracterizando confiabilidade no processamento dos dados. Para os valores de RMSE (%), a rede 886 apresentou desempenho inferior. Enquanto para as redes 528 e 684, os valores foram próximos, em que a rede 528 apresentou o menor valor entre todas para a validação. Em relação ao BIAS (%), os valores foram próximos entre as redes e o menor valor foi para a rede 528. O RMSE (%) e o BIAS (%) são consideradas as principais estatísticas analisadas na utilização de redes neurais como se pode observar em trabalhos com prognose de plantadas (CHIARELLO et al., 2018), modelagem da densidade básica de nativas (SILVA et al., 2018) e modelagem meteorológica (CHOU et al., 2007). Seu resultado indica que

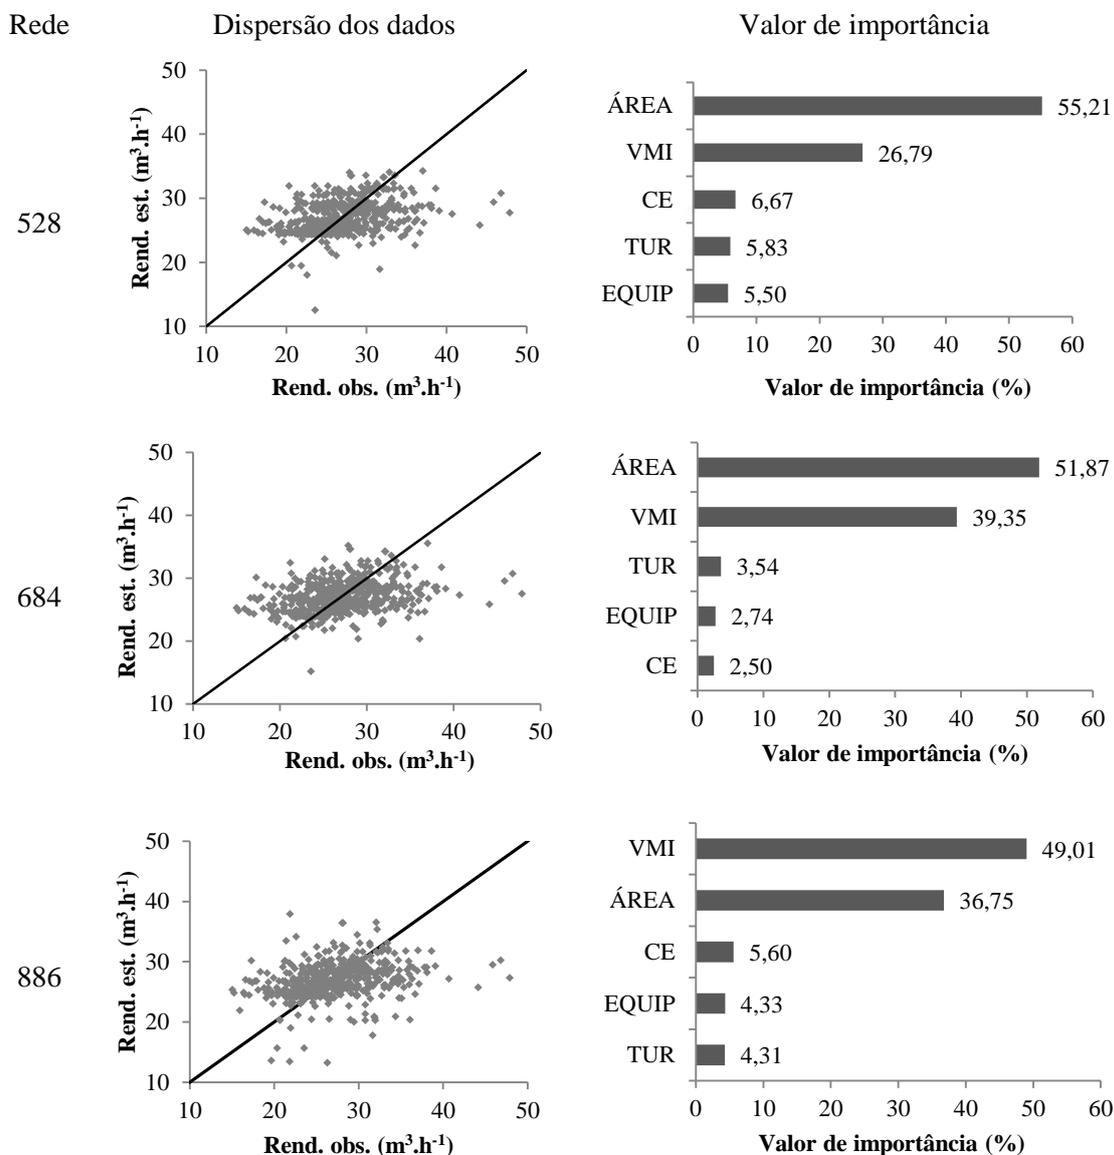
quanto menor seus valores, melhor. O presente trabalho obteve valores satisfatórios assim como os estudos expostos anteriormente, em que o menor RMSE (%) e menor BIAS (%) são correspondentes à rede 528 com valores de 21,19% e 0,20, respectivamente, para os dados do conjunto de validação.

Correlação de Spearman (r_s) foi utilizada para buscar descrever como os dados observados e estimados se correlacionariam, visto que o estudo proposto não possui precedentes. Em geral, observou-se que mesmo apostando na não linearidade dos dados, a correlação foi baixa para todas as redes sendo o melhor desempenho para a rede 528 com o valor de 0,38. Portanto, entende-se que a busca por mais variáveis que possam justificar de forma mais abrangente os dados é um desafio para a estimação do rendimento.

De modo a complementar a estatística das redes, é importante que haja uma abordagem gráfica para que se compreenda melhor o comportamento das predições. Foi utilizado o gráfico de dispersão com a linha de 45° para toda a base de validação representada pela Figura 6. Observou-se que a rede 684 teve maior adesão dos dados à linha, mesmo obtendo a maioria das estatísticas numéricas inferiores à rede 528. Este fato corrobora com a necessidade da comparação gráfica aos dados numéricos estatísticos.

Ressalta-se que o comportamento dos dados ao longo do gráfico (FIGURA 6) permite inferir que as variáveis apresentam dificuldade em aderir a variável resposta, mesmo estes sendo eficientes. Isso mostra a necessidade de coletar informações mais detalhadas a partir das variáveis convencionalmente obtidas pelo boletim da colheita, bem como para todas as atividades do ciclo florestal. Um exemplo que corrobora com essa afirmação é o estudo sobre o tempo de parada dos picadores florestais, que apresentou relevância na produtividade final da operação e que é uma variável derivada da utilização do maquinário (DINIZ et al., 2018).

Figura 6 – Dispersão dos dados para cada RNA e valor de importância das variáveis pelo método Garson para as 3 melhores redes.



Em que: VMI = volume médio individual; TUR = turno; CE = classe de experiência e EQUIP = equipamento; Rend. Est. = rendimento estimado e Rend. Obs. = rendimento observado.

Fonte: Do autor (2019).

Visto a parametrização e estatísticas das RNAs, as abordagens relacionadas às variáveis inseridas são de fundamental importância para o resultado do trabalho proposto. Para este fim, foi utilizada a metodologia de Garson, que indica o valor de importância (VI) de cada variável inserida na rede. Foram disponibilizados para as RNAs fatores contínuos de área (ha) e volume VMI (m^3), e categóricos como classe de experiência do operador (dias), turno (manhã/tarde) e equipamentos. A Figura 6

também representa graficamente o valor de importância (VI) de cada variável de entrada da rede. As variáveis contínuas foram as que obtiveram maiores VI em todas as redes, o maior valor de área foi dado pela rede 528 e o maior VMI pela rede 886, sendo 55,21% e 49,01%, respectivamente. Estudos como o de Schettino, Minette e Souza (2015) corroboram com os resultados encontrados para a área e VMI, pois esses fatores são considerados como principais na influência da operação de corte florestal.

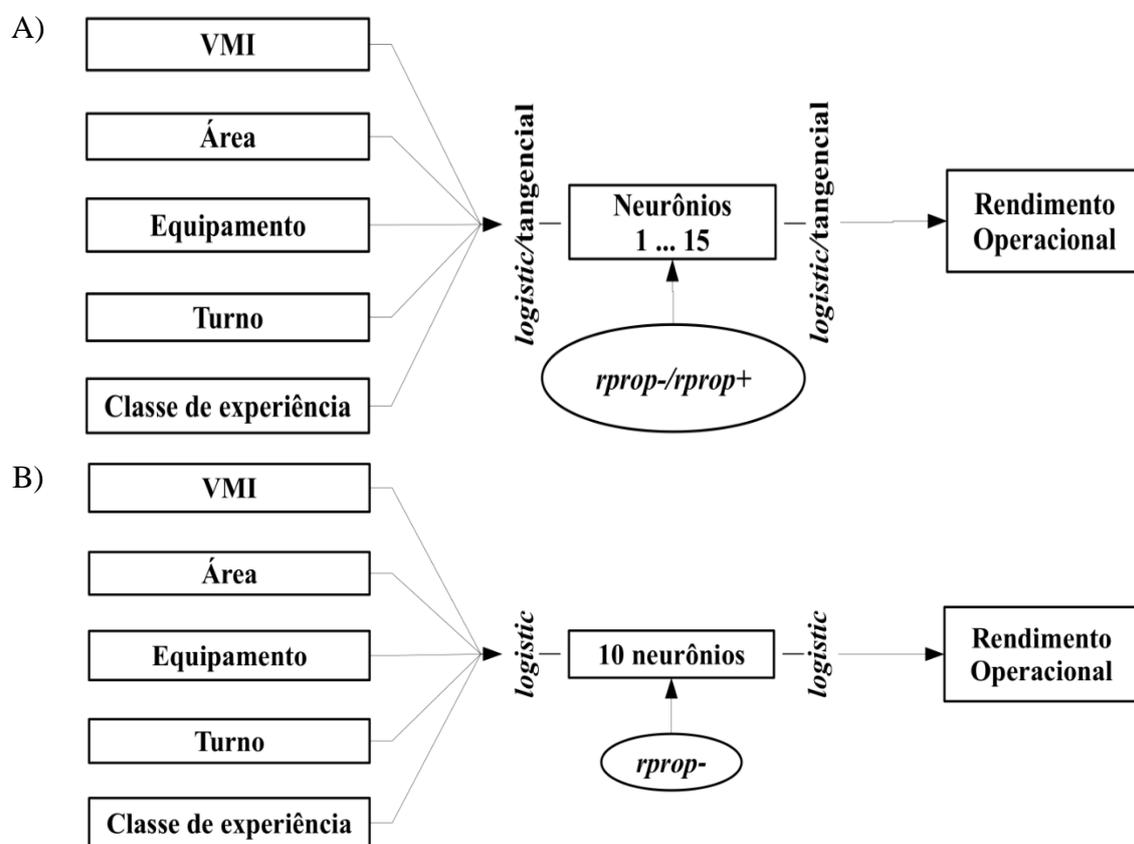
Observou-se que houve oscilação no VI para as variáveis categóricas de rede para rede. A classe de experiência (CE) obteve o maior valor VI dentre as variáveis categóricas nas redes 528 e 886, com valores de 6,67% e 5,60%, respectivamente. De fato, é esperado que houvesse uma relevância na variável humana. A influência dessa variável é evidenciada no trabalho de Leonello, Gonçalves e Fenner (2012), em que as classes iniciais apresentavam produtividade crescente, se estabilizavam durante certo tempo e posteriormente decrescia. Esta pesquisa vai de encontro com a importância dessa variável destacada pelo gráfico de Garson. Isso nos mostra um comportamento heterogêneo ao longo do tempo e a necessidade de manter os operadores em constante treinamento e da aplicação de programas motivacionais.

O maior VI relacionado ao turno foi de 5,83% na rede 528. Os turnos trabalhados refletem na disponibilidade das máquinas para a operação, e consequentemente no rendimento operacional, conforme abordado por Carmo et al. (2015), sendo compatível com nossos resultados. Desta forma, conseguimos compreender que há uma relação muito forte entre turno e equipamentos usados na colheita florestal. Estes, por sua vez, apresentam significância para a produtividade da operação, afetando a relação com tempo, custo e qualidade, conforme apresenta Pereira, Lopes e Dias (2015). Além disso, deve-se atentar a depreciação dos equipamentos, que segundo Alves et al. (2015), a manutenção dos equipamentos é fundamental para aumentar a hora efetiva trabalhada. Monteiro, Brown e Robert (2018), propuseram a aplicação de um sistema similar a um *pit-stop* para abastecimento e lubrificação dos equipamentos, visando redução de tempo e insumos utilizados. Estudos como este fomentam a busca pela excelência operacional e futuramente podem servir como banco de dados para modelagem do rendimento da operação.

Aprofundando um pouco mais sobre a coleta de variáveis, é fundamental que os fatores edafoclimáticos sejam considerados inclusive nos apontamentos da colheita florestal. Sua influência é comprovada em alguns estudos como Szymczak et al. (2014) e She, Chung e Kim (2018), e pode subsidiar a construção de muitos modelos. Diante

do exposto, a abordagem para a predição da produtividade do corte utilizando redes neurais artificiais com entradas coletadas nos boletins de colheita apresentou caráter inovador. Visto ainda que além das variáveis tradicionais contínuas como área e VMI, as variáveis categóricas foram modeladas com sucesso. Mas cabe ressaltar a necessidade de utilização de outras variáveis que influenciem no rendimento operacional, proporcionando um melhor desempenho para RNA. A Figura 7 representa um esquema simplificado das possíveis parametrizações e da rede 684 selecionada como a melhor entre todas.

Figura 7 – Esquema simplificado das possíveis parametrizações para a construção da rede e da RNA 684.



Em que: A) = Composição da rede com todas as suas possíveis parametrizações e B) Parametrização da RNA selecionada (684).

Fonte: Do autor (2019).

5 CONCLUSÃO

A RNA 684 mostrou-se eficiente na predição do rendimento operacional e avaliação das variáveis disponíveis no apontamento da operação de corte florestal. Deste modo, foi possível observar os fatores que mais influenciaram, sendo: volume médio individual das árvores e área.

Apesar dos resultados favoráveis, ainda faz-se necessário mais estudos relacionados às coletas de variáveis categóricas e suas modelagens para a predição da produtividade. Estas análises permitem inferir que apesar das variáveis categóricas utilizadas apresentarem valor de importância relativamente baixo, elas podem auxiliar como complementação da base de dados. Além disso, reforça a interferência do fator humano, como é o caso da classe de experiência, na predição dos dados.

AGRADECIMENTOS

À Universidade Federal de Lavras e ao Laboratório de Planejamento e otimização florestal pelo auxílio na execução do trabalho e à empresa de celulose por ter cedido os dados necessários.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALVES, E. G. et al. Efeito do turno de trabalho na produção e produtividade de máquinas de colheita de madeira. **Nativa**, v. 3, n. 3, p. 201-204, 2015.
- ANDRELLA, G. C.; NETO, M. J. Levantamento florístico dos arredores do parque das capivaras, três lagoas-ms. **Revista Saúde e Meio Ambiente**, v. 5, n. 2, p. 70-77, 2017.
- ANGELO, H. et al. Determinantes para um sistema de informação florestal. **Floresta e Ambiente**, v. 24, p. 0-0, 2018.
- BINOTI, D. H. B.; BINOTI, M. L. M. da S.; LEITE, H. G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Revista Ciência da Madeira (Brazilian Journal of Wood Science)**, v. 5, n. 1, p. 10-12953/2177-6830. v05n01a06, 2014.
- BINOTI, M. L. M. da S. et al. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Cerne**, v. 21, n. 1, p. 97-105, 2015.
- BRAGA, A.P; CARVALHO, A.P.L.F; LUDERMIR, T.B. Redes neurais artificiais: teoria e aplicações. Rio de Janeiro: **Livros técnicos e científicos**. Editora S.A, 2000. 262p.

BRAMUCCI, M.; SEIXAS, F. Determinação e quantificação de fatores de influência sobre a produtividade de harvesters na colheita de madeira. **Scientia Florestalis**, n. 62, p. 62-74, 2002.

CARMO, F. C. de A. et al. Otimização do uso do trator florestal forwarder em função da produtividade, custos e capacidade de carga. **Revista Árvore**, v. 39, n. 3, p. 561-566, 2015.

CARVALHO, J.; CRUZ, L.; GOUVEIA, R. Descoberta de conhecimento com aprendizado de máquina supervisionado em dados abertos dos censos da educação básica e superior. **In: Anais dos Workshops do Congresso Brasileiro de Informática na Educação**. 2017. p. 674.

CARVALHO, R. M. M. A.; SOARES, T. S.; VALVERDE, S. R. Caracterização do setor florestal: uma abordagem comparativa com outros setores da economia. **Ciência Florestal**, [S.l.], v. 15, n. 1, p. 105-118, mar. 2005. ISSN 1980-5098, 2005.

CHIARELLO, F. et al. Redes de Bases Radiais na prognose de volume de plantações de *Pinus taeda*. **In: Embrapa Florestas-Artigo em anais de congresso (ALICE)**. In: ENCONTRO BRASILEIRO DE SILVICULTURA, 4., 2018, Ribeirão Preto. Anais. Brasília, DF: Embrapa; Colombo: Embrapa Florestas, 2018.

CHOU, S. C. et al. Refinamento estatístico das previsões horárias de temperatura a 2 m do modelo Eta em estações do Nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 22, n. 3, p. 287-296, 2007.

CLESIO, F.; SASSI, R. J. Classificação de portfólio de créditos não-performados utilizando redes neurais artificiais Multilayer Perceptron. **Revista GEPROS**, v. 9, n. 1, p. 27, 2014.

COSTA, E. M. et al. Desempenho e custos operacionais de um harvester em floresta de baixa produtividade. **Revista Engenharia Na Agricultura-Reveng**, v. 25, n. 2, p. 124-131, 2017.

DIAS, A. N. et al. Emprego de um modelo de crescimento e produção em povoamentos desbastados de eucalipto. **Revista Árvore**, v. 29, n. 5, p. 731-739, 2005.

DINIZ, C. C. C. et al. Desempenho de um Feller Buncher em extrema variação da declividade do terreno. **Advances in Forestry Science**, v. 5, n. 3, p. 381-384, 2018.

DINIZ, C. C. C. et al. Influência das interrupções sobre o grau de utilização de picadores florestais. **BIOFIX Scientific Journal**, v. 3, n. 2, p. 267-272, 2018.

FIEDLER, N. J.; DA ROCHA, E. B.; DA SILVA LOPES, E. Análise da produtividade de um sistema de colheita de árvores inteiras no norte do Estado de Goiás. **Floresta**, v. 38, n. 4, 2008.

FREITAS, L. C. de. et al. Avaliação quantitativa de impactos ambientais da colheita florestal em dois módulos. **Ceres**, v. 54, n. 313, 2015.

GALZERANO, L.; MORGADO, E. Eucalipto em sistemas agrossilvipastoris. **REDVET. Revista electrónica de Veterinária**, v. 9, n. 3, p. 1-6, 2008.

GARSON, G. D. Interpreting neuralnetwork connection weights. **Artificial Intell. Expert.** v.6, p.47-51, 1991.

GÖRGENS, E.B. et al. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, v.33, n.6, p. 1141-1147, 2009.

GÜNTHER, F.; FRITSCH, S. Neuralnet: Training of neural networks. **The R journal**, v.2, n.1, p.30-38, 2010.

HAKAMADA, R. E. et al. Uso do inventário florestal e da uniformidade entre árvores como ferramenta de monitoramento da qualidade silvicultural em plantios clonais de eucalipto. **Scientia Forestalis**, v. 43, n. 105, p. 27-39, 2015.

HAN, T. et al. Comparison of random forest, artificial neural networks and support vector machine for intelligent diagnosis of rotating machinery. **Transactions of the Institute of Measurement and Control**, v. 40, n. 8, p. 2681-2693, 2018.

HAYKIN, S. *Redes neurais: princípios e prática*. Bookman Editora, 2007.

HONDA, B.; JORGE, L. A. de C. Computação aplicada à agricultura de precisão. **Embrapa Instrumentação-Artigo em periódico indexado (ALICE)**, 2013.

HONG, H. et al. Applying genetic algorithms to set the optimal combination of forest fire related variables and model forest fire susceptibility based on data mining models. The case of Dayu County, China. **Science of the total environment**. Amsterdam, v. 630, p.1044-1056, July 2018.

INDÚSTRIA BRASILEIRA DE ÁRVORES. **Relatório Ibá 2019**. São Paulo: IBÁ, 2019. 80 p.

JACOVINE, L. A. G. et al. Certificação florestal na visão gerencial e estratégica da indústria moveleira nacional. **Semina: Ciências Agrárias**, v. 27, n. 3, p. 367-378, 2006.

JÚNIOR, A. P. P.; JÚNIOR, C. J. S.; BASTOS FILHO, C. J. A. Uso de técnicas de clusterização em uma base de dados financeira. **Revista de Engenharia e Pesquisa Aplicada**, v. 3, n. 3, 2018.

JÚNIOR, D. L.; COLODETTE, J. L. Importância e versatilidade da madeira de eucalipto para a indústria de base florestal. **Pesquisa Florestal Brasileira**, v. 33, n. 76, p. 429-438, 2013.

LACERDA, T. H. S. et al. Artificial neural networks for estimating tree volume in the brazilian savanna. **Cerne**, v. 23, n. 4, p. 483-491, 2017.

LEONELLO, E. C.; GONÇALVES, S. P.; FENNER, P. T. Efeito do tempo de experiência de operadores de Harvester no rendimento operacional. **Revista Árvore**, v. 36, n. 6, p. 1129-1133, 2012.

LERAYER, A. *Guia do Eucalipto: oportunidades para um desenvolvimento sustentável*. São Paulo: **Conselho de Informações sobre Biotecnologia**, 2008.

LIMA, Á.; LACERDA, W.; NETO, H. Seleção de características de dados utilizando Redes Neurais Artificiais. **In: Anais do XIII Simpósio Brasileiro de Sistemas de Informação**. SBC, 2017. p. 135-142.

- LINHARES, M. et al. Eficiência e desempenho operacional de máquinas harvester e forwarder na colheita florestal. **Pesquisa Agropecuária Tropical**, v. 42, n. 2, p. 212-219, 2012.
- MACHADO, C. C.; LOPES, E da S. Análise da influência do comprimento de toras de eucalipto na produtividade e custo da colheita e transporte florestal. **Cerne**, v. 6, n. 2, p. 124-129, 2000.
- MACHADO, C. C.; SILVA, E. N. da; PEREIRA, R. S. O setor florestal brasileiro. **Colheita florestal**, v. 2, p. 15-42, 2002.
- MADSEN, C. A.; ADAMATTI, D. F. NeuroFURG: uma ferramenta de apoio ao ensino de Redes Neurais Artificiais. **Brazilian Journal of Computers in Education**, v. 19, n. 02, p. 14, 2011.
- MALINOVSKI, R. A. et al. Análise das variáveis de influência na produtividade das máquinas de colheita de madeira em função das características físicas do terreno, do povoamento e do planejamento operacional florestal. **Floresta**, v. 36, n. 2, 2006.
- MARRO, A. A. et al. Lógica fuzzy: conceitos e aplicações. Natal: **Universidade Federal do Rio Grande do Norte (UFRN)**, 2010.
- MELO, E. A. S. C de. et al. Considerações finais Controle de qualidade das atividades silviculturais e silvicultura de precisão: ferramentas para gestão eficiente e aumento da produtividade madeireira. **Série Técnica IPEF**, v. 24, n. 45, 2016.
- MENDES, R. F. et al. Qualidade de painéis aglomerados homogêneos produzidos com a madeira de clones de *Eucalyptus urophylla*. **Cerne**, v. 20, n. 2, p. 329-336, 2014.
- MINETTE, L. J. et al. Análise técnica e econômica da colheita florestal mecanizada em Niquelândia, Goiás. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 12, n. 6, p. 659-665, 2008.
- MONARD, M. C.; BARANAUKAS, J. A. Aplicações de Inteligência Artificial: Uma Visão Geral. São Carlos: **Instituto de Ciências Matemáticas e de Computação de São Carlos**, 2000.
- MONTEIRO, H. M.; BROWN, R. O.; ROBERT, R. C. G. Lean Manufacturing na atividade de colheita florestal. **Conhecimento Interativo**, v. 10, n. 2, p. 27-37, 2018.
- MOREIRA, A. A.; NERY, C. V. M.; FERNANDES, F. H. S. Aplicação do algoritmo support vector machine na análise espaço-temporal do uso e ocupação do solo na bacia do rio vieira. **Caminhos de Geografia**, v. 15, n. 50, 2014.
- MOREIRA, J. M. M. A. P.; DE OLIVEIRA, E. B. Importância do setor florestal brasileiro com ênfase nas plantações florestais comerciais. **Embrapa Florestas- Capítulo em livro científico (ALICE)**, 2017.
- MOREIRA, J. M. M. Á. P.; SIMIONI, F. J.; DE OLIVEIRA, E. B. Importância e desempenho das florestas plantadas no contexto do agronegócio brasileiro. **Floresta**, v. 47, n. 1, p. 85-94, 2017.
- MOSCA, A.; MAGOULAS, G. D. Adapting resilient propagation for deep learning. **arXiv preprint arXiv:1509.04612**, 2015.

- NAOUM, R. S.; ABID, N. A.; AL-SULTANI, Z. N. An enhanced resilient backpropagation artificial neural network for intrusion detection system. **International Journal of Computer Science and Network Security (IJCSNS)**, v. 12, n. 3, p. 11, 2012.
- NASCIMENTO, A. C. N. et al. Avaliação técnica e econômica da colheita florestal com feller-buncher. **Cerne**, v. 17, n. 1, p. 9-15, 2015.
- NETO, E. M. da C. et al. Estimativa do afilamento do fuste de indivíduos de eucalipto por meio de técnicas de inteligência artificial. **BIOFIX Scientific Journal**, v. 4, n. 2, p. 166-171, 2019.
- OLIVEIRA, A. A. et al. Identificação de madeiras utilizando a espectrometria no infravermelho próximo e redes neurais artificiais. **TEMA (São Carlos)**, v. 16, n. 2, p. 81-95, 2015.
- ÖZÇELİK, R.; BAL, C. Effects of adding crown variables in stem taper and volume predictions for black pine. **Turkish Journal of Agriculture and Forestry**, v.37, n.2, p.231-242, 2013.
- PAIVA, G. J de. Psicologia cognitiva e religião. **Revista de estudos da Religião**, p. 183-191, 2007.
- PEREIRA, A. L. N.; LOPES, E. da S.; DIAS, A. N. Análise técnica e de custo do Feller Buncher e Skidder na colheita de madeira em diferentes produtividades do povoamento. **Ciência Florestal**, v. 25, n. 4, p. 981-989, 2015.
- PEREIRA, T. et al. Análise de viabilidade econômica de uma plantação de eucalipto no Pará-Amazônia-Brasil. **Observatorio de la Economía Latinoamericana**, v. 159, 2011.
- PURFÜRST, F. T.; ERLER, J. The human influence on productivity in harvester operations. **International Journal of Forest Engineering**, v. 22, n. 2, p. 15-22, 2011.
- RAMCHOUN, H. et al. Multilayer Perceptron: architecture, optimization and training. **IJIMAI**, v. 4, n. 1, p. 26-30, 2016.
- RAMÍREZ, N. M. La inteligencia artificial. Nuevo enfoque en la evaluación de las máquinas en el complejo cosecha-transporte-recepción de la caña de azúcar. **Revista Ingeniería Agrícola**, v. 4, n. 2, p. 60-64, 2017.
- RAUBER, T. W. Redes neurais artificiais. **Universidade Federal do Espírito Santo**, 2005.
- REDDY, N.; GEBRESLASIE, M.; ISMAIL, R. A hybrid partial least squares and random forest approach to modelling forest structural attributes using multispectral remote sensing data. **South African Journal of Geomatics**, v. 6, n. 3, p. 377-394, 2017.
- REIS, L. P. et al. Prognose da distribuição diamétrica na Amazônia utilizando redes neurais artificiais e autômatos celulares. **Floresta**, v. 48, n. 1, p. 93-102, 2018.
- ROCHA, J. H. T. et al. Reflorestamento e recuperação de atributos químicos e físicos do solo. **Floresta Ambient**, v. 22, n. 3, p. 299-306, 2015.

RODRIGUEZ, J. D.; PEREZ, A.; LOZANO, J. A. Sensitivity analysis of k-fold cross validation in prediction error estimation. **IEEE transactions on pattern analysis and machine intelligence**, v. 32, n. 3, p. 569-575, 2009.

SCHETTINO, S.; MINETTE, L. J.; SOUZA, A. P. Correlação entre volumetria de florestas de eucalipto e produtividade e custos de máquinas de colheita de madeira. **Revista Árvore**, v. 39, n. 5, p. 935-942, 2015.

SCHOENINGER, E. R. et al. Uso de redes neurais artificiais como uma alternativa para mapeamento de biomassa e carbono orgânico no componente arbóreo de florestas naturais. **Ambiência**, v. 4, n. 3, p. 529-549, 2008.

SHE, J.; CHUNG, W.; KIM, D. Discrete-event simulation of ground-based timber harvesting operations. **Forests**, v. 9, n. 11, p. 683, 2018.

SILVA, G. F. da. et al. O método das restrições na solução de um problema de planejamento florestal multiobjetivo. **Revista Brasileira de Ciências Agrárias**, v. 1, n. 1, p. 41-48, 2006.

SILVA, J. P. M. et al. Redes neurais artificiais para estimar a densidade básica de madeiras do cerrado. **Pesquisa Florestal Brasileira**, v. 38, 2018.

SILVA, N.; NATHANSOHN, B. M. Análise da produção científica em Inteligência Artificial na área da Ciência da Informação no Brasil. In: **XIX Encontro nacional de pesquisa em ciência da informação (XIX ENANCIB)**. 2018.

SIMÕES, D.; FENNER, P. T. Influência do relevo na produtividade e custos do Harvester. **Scientia Forestalis**, p. 107-114, 2010.

SOARES, E.; QUINTELLA, C.; CAMPOS, C. CityTracks-RT: Uma aplicação para detecção do modo de transporte em tempo real nos centros urbanos. In: **Anais do XIII Simpósio Brasileiro de Sistemas de Informação. SBC, 2017**. p. 222-229.

SOARES, F. C. et al. Predição da produtividade da cultura do milho utilizando rede neural artificial. **Ciência Rural**, v. 45, n. 11, p. 1987-1993, 2015.

SOARES, F. C. et al. Redes neurais artificiais na estimativa da retenção de água do solo. **Ciência Rural**, v. 44, n. 2, p. 293-300, 2014.

SOARES, N. S. et al. Competitividade da cadeia produtiva da madeira de eucalipto no Brasil. **Revista Árvore**, v. 34, n. 5, p. 917-928, 2010.

SZYMCZAK, D. A. et al. Compactação do solo causada por tratores florestais na colheita de *Pinus taeda* L. na região sudoeste do Paraná. **Revista Árvore**, v. 38, n. 4, p. 641-648, 2014.

VALENÇA, M. J. S.; LUDERMIR, T. B. Explicando a relação entre as variáveis de uma rede neural—iluminando a “caixa preta”. **XVII Simpósio Brasileiro de Recursos Hídricos—São Paulo**, 2007.

VALENTE, G. de F. S. et al. 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.

VALVERDE, S. R. et al. O comportamento do mercado da madeira de eucalipto no Brasil. **Biomassa & Energia**, v. 1, n. 4, p. 393-403, 2004.

VAN NGUYEN, T. H. et al. Using artificial neural networks (ANN) for modeling predicting hardness change of wood during heat treatment. In: **IOP Conference Series: Materials Science and Engineering**. IOP Publishing, 2018. p. 032044.

VINICIUS, M. A. et al. INDÚSTRIA 4.0. **Revista Pesquisa e Ação**, v. 5, n. 1, p. 127-147, 2019.

WILCKEN, C. F. et al. Guia prático de manejo de plantações de eucalipto. **Botucatu: FEPAF**, 2008.