



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO  
CENTRO DE CIÊNCIAS AGRÁRIAS E ENGENHARIAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

**LEONARDO CASSANI LACERDA**

**MODELAGEM DA DISPONIBILIDADE MECÂNICA EM MÁQUINAS DE  
COLHEITA DA MADEIRA**

JERÔNIMO MONTEIRO – ES

2022

**LEONARDO CASSANI LACERDA**

**MODELAGEM DA DISPONIBILIDADE MECÂNICA EM MÁQUINAS DE  
COLHEITA DA MADEIRA**

Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Doutor em Ciências Florestais na Área de Concentração Ciências Florestais.

Orientador: Prof. Dr. Nilton Cesar Fiedler  
Coorientador: Prof. Dr. Edney Leandro da Vitória.

JERÔNIMO MONTEIRO – ES

2022

Ficha catalográfica disponibilizada pelo Sistema Integrado de  
Bibliotecas - SIBI/UFES e elaborada pelo autor

---

L131m Lacerda, Leonardo Cassani, 1990-  
Modelagem da disponibilidade mecânica em máquinas de  
colheita da madeira / Leonardo Cassani Lacerda. - 2022.  
106 f. : il.

Orientador: Nilton Cesar Fiedler.

Coorientador: Edney Leandro da Vitória.

Tese (Doutorado em Ciências Florestais) - Universidade  
Federal do Espírito Santo, Centro de Ciências Agrárias e  
Engenharias.

1. Máquinas florestais. 2. Florestas - Inovações tecnológicas.  
3. Madeira - Exploração. 4. Projetos de desenvolvimento  
florestais. I. Fiedler, Nilton Cesar. II. da Vitória, Edney Leandro.  
III. Universidade Federal do Espírito Santo. Centro de Ciências  
Agrárias e Engenharias. IV. Título.

CDU: 630\*38

---

# MODELAGEM DA DISPONIBILIDADE MECÂNICA EM MÁQUINAS DE COLHEITA DA MADEIRA

Leonardo Cassani Lacerda

Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Doutor em Ciências Florestais na Área de Concentração Ciências Florestais.

Aprovada em 28 de setembro de 2022.

Documento assinado digitalmente  
 SAULO BOLDRINI GONCALVES  
Data: 29/09/2022 16:29:34-0300  
Verifique em <https://verificador.itl.br>

---

**Prof. Dr. Saulo Boldrini Gonçalves (Examinador externo)**  
Universidade Federal de Tocantins

Documento assinado digitalmente  
 FLAVIO CIPRIANO DE ASSIS DO CARMO  
Data: 29/09/2022 15:38:14-0300  
Verifique em <https://verificador.itl.br>

---

**Prof. Dr. Flávio Cipriano de Assis do Carmo (Examinador externo)**  
Universidade Federal de Campina Grande

Documento assinado digitalmente  
 EDUARDO DA SILVA LOPES  
Data: 28/09/2022 22:19:00-0300  
Verifique em <https://verificador.itl.br>

---

**Prof. Dr. Eduardo da Silva Lopes (Examinador externo)**  
Universidade Estadual do Centro Oeste PR

Documento assinado digitalmente  
 RENATO CESAR GONCALVES ROBERT  
Data: 28/09/2022 12:17:15-0300  
Verifique em <https://verificador.itl.br>

---

**Prof. Dr. Renato Cesar Gonçalves Robert (Examinador externo)**  
Universidade Federal do Paraná



---

**Prof. Dr. Nilton Cesar Fiedler (Orientador)**  
Universidade Federal do Espírito Santo

***A Deus, meus pais e irmã, e a minha esposa, por serem parte de minha perseverança, dedico...***

## **AGRADECIMENTOS**

Primordialmente, agradeço à Deus, por me possibilitar a realização deste sonho, me concedendo sabedoria e perseverança para superar todos os obstáculos e obter o título.

À Universidade Federal do Espírito Santo, em especial ao programa de Pós-Graduação em Ciências Florestais do Departamento de Ciências Florestais e da Madeira, por conceder vagas para alunos que possuem vínculo empregatício me possibilitando a realização do curso.

Ao meu orientador, professor Nilton Cesar Fiedler, por todo o apoio concedido, dedicação e orientação durante a realização da pesquisa, feito este já realizado também em minha época de Graduação e Mestrado.

Ao professor Edney Leandro da Vitória, pelo aceite em me coorientar, não medindo esforços em me auxiliar independente do dia, fornecendo suporte durante o decorrer da pesquisa.

Aos professores Saulo Boldrini Gonçalves, Flavio Cipriano de Assis do Carmo, Eduardo da Silva Lopes e Renato Cesar Gonçalves Robert, pela disponibilidade em participar da banca e as sugestões que elevaram o grau de informações da tese.

Aos meus pais Josiléia e César, pela educação e princípios que me auxiliaram a ter perseverança mediante as adversidades, pelas incansáveis orações e o suporte durante o curso, que mesmo à distância me impulsionaram a seguir adiante.

A minha esposa Jheicy que esteve ao meu lado durante todo o tempo, e mais que qualquer outra pessoa, sabe as dificuldades encontradas pelo caminho até a obtenção deste título, por sempre me apoiar, incentivar e me dar forças em seguir em frente.

A minha irmã Lara e todos os demais familiares que contribuíram com esta conquista.

Aos amigos de estudos e de laboratório, em especial ao Antônio Henrique Cordeiro pela parceria firmada no decorrer das atividades.

A todos que direta ou indiretamente me ajudaram com esta conquista.

***“Mas sejam fortes e não desanimem, pois o trabalho de vocês será recompensado.”***

***(2ª Crônicas, 15:7)***

## BIOGRAFIA

LEONARDO CASSANI LACERDA, filho de César Augusto Lacerda e Josiléia Cassani Lacerda, nascido em 08 de março de 1990, no município de Colatina, Estado do Espírito Santo, Brasil.

Concluiu o Ensino Médio na Escola de Educação Básica COOPESG Robusta, na cidade de São Gabriel da Palha - ES, em 2007.

Em 2008, ingressou na Universidade Federal do Espírito Santo (UFES), Campus Alegre – ES, Graduando-se em Engenharia Florestal em dezembro de 2012.

Em março de 2013 iniciou o curso de Mestrado do Programa de Pós-Graduação *Strictu Sensu* em Ciências Florestais, na linha de pesquisa Manejo Florestal, na Universidade Federal do Espírito Santo, em Jerônimo Monteiro – ES, submetendo-se à defesa da dissertação em dezembro de 2014.

Em setembro de 2014 foi contratado pela empresa FIBRIA CELULOSE S/A, permanecendo na mesma até seu encerramento em 2019, quando adquirida pela SUZANO Celulose e Papel, vindo a se tornar SUZANO S/A, onde permaneceu até o ano de 2021.

No ano de 2019, ingressou no curso de Doutorado do Programa de Pós-Graduação *Strictu Sensu* em Ciências Florestais, na linha de pesquisa Manejo Florestal, na Universidade Federal do Espírito Santo, em Jerônimo Monteiro – ES, submetendo-se à defesa da tese em setembro de 2022.

Em 2021, atuou no ramo da certificação ambiental no estado do Paraná, retornando em 2022 ao estado da Bahia, ingressando na Veracel Celulose S/A.

## RESUMO

LACERDA, Leonardo Cassani. **Modelagem da disponibilidade mecânica em máquinas de colheita da madeira**. 2022. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES. Orientador: Prof. Dr. Nilton Cesar Fiedler. Coorientador: Prof. Dr. Edney Leandro da Vitória.

O setor florestal representa uma fatia relevante da economia brasileira, sendo este dominado em sua maior parte pela produção de plantios do gênero *Eucalyptus*. De um modo geral, a mecanização das atividades sobretudo da colheita florestal, é considerada uma das mais importantes do processo, agregando valores que por vezes ultrapassam 50% dos custos totais das atividades. Desta forma, com a presente pesquisa objetivou-se realizar a predição da disponibilidade mecânica (DM), de máquinas que constituem os sistemas de colheita de árvores inteiras (*full-tree*) e toras curtas (CTL), por meio de redes neurais artificiais (RNA) e regressão linear. A pesquisa foi desenvolvida por meio de um banco de dados provenientes de uma empresa florestal, concentrando-se as atividades das máquinas do sistema *full-tree* no norte do estado do Espírito Santo, e as do sistema CTL no sul do estado da Bahia. Com as variáveis hora trabalhada (HT), horas paradas mecânicas (HPM), volume médio individual (VMI), árvores colhidas por hora (árv/h), metros cúbicos por hora (m<sup>3</sup>/h) e óleo hidráulico por hora (Hdr), foram realizadas a predição da disponibilidade mecânica por meio de RNA e regressão linear, tendo a variável volume médio individual (VMI), testada isoladamente com as RNA. Tendo como variável de saída a disponibilidade mecânica, os dados foram divididos aleatoriamente para serem utilizados na predição das RNA, com amostragens de 70% e 80% para treinamento e 30% e 20% para validação, respectivamente. Foram treinadas por três algoritmos (*resilient propagation*, *backpropagation* e *quick propagation*) utilizando-se de configurações variando de 5 a 11 neurônios na camada oculta, funções logística e sigmoideal com 50 redes por configuração, totalizando 8.400 redes treinadas. A análise de regressão linear utilizou apenas as variáveis que apresentaram correlação linear significativa com a produtividade, segundo matriz de coeficiente de correlação de Pearson, pelo teste t a 5% e 1% de probabilidade. Ambas as técnicas de modelagem foram avaliadas por meio de estatísticas e análise gráfica dos resíduos. As redes neurais artificiais selecionadas,

apresentaram  $R^2$  acima de 0,95, indicando forte correlação e alta exatidão em relação aos valores observados. Dentre os algoritmos de treinamento, o resiliente propagation, mostrou-se mais eficaz na predição da disponibilidade mecânica para ambos os sistemas de colheita. Já a função de ativação logística, predominou para o *full-tree* e a função sigmoideal para *cut-to-length*. A variável de entrada VMI, testada separadamente utilizando-se da melhor configuração encontrada em cada sistema, demonstrou influenciar na predição da disponibilidade mecânica. Por fim concluiu-se que as metodologias de predição para a DM, foram eficazes, tendo o sistema *full-tree* superado o CTL e para ambos as RNA superiores a modelagem por regressão linear.

**Palavras-chave:** Redes neurais artificiais; *Full-tree*; *Cut-to-length*; Mecanização florestal.

## ABSTRACT

LACERDA, Leonardo Cassani. **Prediction of mechanical availability in forest harvesting through artificial neural networks**. 2022. Thesis (Doctorate in Forest Sciences) – Federal University of Espírito Santo, Jerônimo Monteiro, ES. Advisor: Prof. Dr. Nilton Cesar Fiedler. Co-advisor: Prof. Dr. Edney Leandro da Vitória.

The forest sector represents a relevant part of the Brazilian economy, which is dominated for the most part by the production of plantations of the *Eucalyptus sp.* In general, the mechanization of activities, especially forest harvesting, is considered one of the most important in the process, adding values that sometimes exceed 50% of the total costs of the activities. Thus, the present research aimed to predict the mechanical availability of machines that constitute the harvesting systems of full-tree and Cut-to-length, through artificial neural networks and linear regression. The research was developed through a database from a forestry company, concentrating data such as the activities of the machines of the full-tree system in the north of the state of Espírito Santo, and the Cut-to-Length system in the south of the state of Bahia. With variables harvested per hour worked, hours for mechanics, average individual volume, trees harvested per hour, cubic meters per hour and hydraulic oil per hour, presented the mechanical prediction by means of individual mean volume artificial neural networks, having a variable in isolation with as individual artificial neural networks. Having mechanical availability as the output variable, the data were randomly divided to be used in the ANN prediction, with samples of 70% and 80% for training and 30% and 20% for validation, respectively. They were trained by three algorithms (resilient propagation, backpropagation and quick propagation) using configurations ranging from 5 to 11 neurons in the hidden layer, logistic and sigmoidal functions with 50 networks per configuration, totaling 8,400 trained networks. The linear regression analysis used only the variables that showed a significant linear correlation with productivity, according to Pearson's correlation coefficient matrix, using the "t" test at 5% and 1% significance. Both modeling techniques were evaluated through statistics and graphical analysis of residuals. The selected artificial neural networks presented  $R^2$  above 0.95, indicating strong correlation and high accuracy in relation to the observed values. Among the training algorithms, the resilient propagation proved to be more effective

in predicting the mechanical availability for both harvesting systems. In a another way, the logistic activation function predominated for the full-tree and the sigmoidal function for the cut-to-length. The average individual volume input variable, tested separately using the best configuration found in each system, showed to influence the prediction of mechanical availability. Finally, it was concluded that the prediction methodologies for Mechanical disponible were effective, with the full-tree system surpassing the Cut-to-length and for both ANNs superior to linear regression modeling.

**Keywords:** Artificial neural networks; Full-tree; Cut-to-length; Forest mechanization.

## LISTA DE FIGURAS

Figura 1. Etapas da colheita florestal (corte e extração).....	15
Figura 2. Representação gráfica do sistema de colheita de toras curtas.....	19
Figura 3. <i>Harvester</i> utilizado na colheita florestal pelo sistema de toras curtas. ...	21
Figura 4. <i>Forwarder</i> utilizado na colheita florestal pelo sistema de toras curtas. ..	22
Figura 5. Tipos de cabeçote do <i>feller-buncher</i> . .....	23
Figura 6. <i>Track Skidder</i> de esteiras.....	25
Figura 7. <i>Clambunk skidder</i> e <i>grapple skidder</i> de pneus. ....	25
Figura 8. Garra traçadora de esteiras. ....	26
Figura 9. Exemplo de uma RNA.....	34
Figura 10. Exemplo de uma RNA tipo <i>Perceptron</i> de multicamadas (MLP).....	35
Figura 11. Localização dos municípios de realização da pesquisa.....	43
Figura 12. <i>Feller-buncher</i> 959M. ....	44
Figura 13. <i>Skidder</i> 948L.....	45
Figura 14. Garra-traçadora 2144G. ....	45
Figura 15. Sistema de colheita florestal mecanizada <i>full-tree</i> .....	47
Figura 16. <i>Harvester</i> PC200F com cabeçote 370E. ....	48
Figura 17. <i>Forwarder</i> 895.....	48
Figura 18. Sistema de colheita florestal mecanizada <i>cut-to-length</i> .....	50
Figura 19. Histograma de frequência dos valores de HT. (a) <i>full-tree</i> e (b) CTL...51	
Figura 20. Histograma de frequência dos valores de HPM. (a) <i>full-tree</i> e (b) CTL. .....	52
Figura 21. Histograma de frequência dos valores de árvores por hora (Arv/h). (a) <i>full-tree</i> e (b) CTL. ....	53
Figura 22. Histograma de frequência dos valores de VMI. (a) <i>full-tree</i> e (b) CTL. 53	
Figura 23. Histograma de frequência dos valores de m <sup>3</sup> /h. (a) <i>full-tree</i> e (b) CTL.54	
Figura 24. Histograma de frequência dos valores de Hdr. (a) <i>full-tree</i> e (b) CTL..55	
Figura 25. Configuração de redes MLP.....	56
Figura 26. Disponibilidade mecânica estimada e observada e dispersão dos erros das redes neurais: a) <i>Resilient propagation</i> , b) <i>Quick propagation</i> e c) <i>Backpropagation</i> , para o sistema de colheita <i>full-tree</i> . ....	66

Figura 27. Disponibilidade mecânica estimada e observada e dispersão dos erros das redes neurais: A) <i>Resilient propagation</i> , B) <i>Quick propagation</i> e C) <i>Backpropagation</i> , para o sistema de colheita CTL. ....	70
Figura 28. Dendrograma para as classes de VMI. ....	74
Figura 29. Frequência de distribuição dos dados de VMI, (a) grupos de VMI, (b) Classes de VMI obtidas com o dendrograma. ....	75
Figura 30. Disponibilidade mecânica estimada e observada e dispersão dos erros das redes neurais: a) Classe I de VMI, b) Classe II de VMI e c) Classe III de VMI, para o sistema de colheita <i>full-tree</i> . ....	78
Figura 31. Disponibilidade mecânica estimada e observada e dispersão dos erros das redes neurais: A) Classe I de VMI, B) Classe II de VMI e C) Classe III de VMI, para o sistema de colheita CTL. ....	79
Figura 32. Disponibilidade mecânica observada vs estimada para o modelo de regressão (a), dispersão do erro relativo (b). ....	80
Figura 33. Disponibilidade mecânica observada vs estimada para o modelo de regressão (a), dispersão do erro relativo (b). ....	81

## LISTA DE TABELAS

Tabela 1. Características das atividades.....	43
Tabela 2. Características técnicas para as máquinas do sistema <i>full-tree</i> .....	46
Tabela 3. Características técnicas para as máquinas do sistema CTL.....	49
Tabela 4. Resumo estatístico das variáveis de entrada das redes neurais tratadas para o sistema <i>full-tree</i> .....	61
Tabela 5. Resumo estatístico das variáveis de entrada das redes neurais tratadas, para o sistema CTL.....	62
Tabela 6. Características e precisão das redes neurais artificiais (RNA) selecionadas para estimar a DM (disponibilidade mecânica) de máquinas de colheita florestal mecanizada utilizados no sistema <i>full-tree</i> .....	64
Tabela 7. Características e precisão das redes neuronais artificiais (RNA) selecionadas para estimar a DM (disponibilidade mecânica) de máquinas de colheita florestal mecanizada utilizados no sistema CTL.....	68
Tabela 8. Características e precisão das redes neuronais artificiais (RNA) encontradas nas melhores configurações por algoritmos selecionadas para estimar a DM (disponibilidade mecânica) de máquinas de colheita florestal mecanizada utilizados nos sistemas <i>full-tree</i> e CTL.....	72
Tabela 9. Agrupamento em função do VMI.....	74
Tabela 10. Características e precisão das redes neuronais artificiais (RNA) encontradas na melhor configuração para estimar a DM do sistema <i>full-tree</i> , de acordo com as classes de VMI definidas. ....	76
Tabela 11. Características e precisão das redes neuronais artificiais (RNA) encontradas na melhor configuração para estimar a DM do sistema CTL, de acordo com as classes de VMI definidas. ....	76

## SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	10
1.1. Objetivos .....	13
1.1.1. Objetivo geral .....	13
1.1.2. Objetivo específico .....	13
<b>2. REFERENCIAL TEÓRICO</b> .....	14
2.1. Setor Florestal Brasileiro.....	14
2.2. Colheita Florestal .....	14
2.2.1. Colheita florestal mecanizada.....	16
2.3. Fatores de influência sobre a colheita florestal .....	17
2.4. Sistemas de colheita da madeira .....	18
2.5. Sistema de Toras Curtas .....	19
2.5.1. <i>Harvester</i> .....	20
2.5.2. <i>Forwarder</i> .....	21
2.6. Sistema de Árvores Inteiras .....	22
2.6.1. <i>Feller-Buncher</i> .....	23
2.6.2. <i>Skidder</i> .....	24
2.6.3. Garra traçadora .....	26
2.7. Análise técnica da colheita florestal .....	27
2.8. Análise técnica - indicadores de performance.....	28
2.8.1. Disponibilidade Mecânica (DM) .....	28
2.8.2. Fatores que influenciam a disponibilidade mecânica .....	29
2.8.3. Eficiência Operacional (EO) .....	30
2.8.4. Produtividade (Pr) .....	30
2.9. Planejamento da manutenção mecânica .....	31
2.9.1. Manutenção preditiva .....	32
2.9.2. Manutenção preventiva .....	33
2.9.3. Manutenção corretiva .....	33
2.10. Redes neurais artificiais.....	34
2.10.1. Neurônio artificial.....	37
2.10.2. Algoritmos de treinamento.....	37
2.10.3. Algoritmo retropropagação do erro - <i>Backpropagation</i> .....	38
2.10.4. Algoritmo <i>Resilient Propagation</i> .....	38

2.10.5. Algoritmo <i>Quick Propagation</i> .....	38
2.11. Modelo de regressão linear .....	39
2.11.1. Modelo de regressão linear simples .....	40
2.11.2. Modelo de regressão linear múltipla .....	40
<b>3. MATERIAL E MÉTODOS</b> .....	<b>42</b>
3.1. Descrição dos dados .....	42
3.2. Banco de dados.....	42
3.3. Sistema de colheita de madeira.....	44
3.3.1. Sistema de colheita de árvores inteiras ( <i>full-tree</i> ).....	44
3.3.2. Sistema de toras curtas ( <i>cut-to-length</i> ).....	47
3.4. Disponibilidade Mecânica .....	50
3.4.1. Descrição dos fatores que influenciam a disponibilidade mecânica das máquinas ... ..	51
3.4.2. Descrição das variáveis.....	51
3.4.2.1. Horas trabalhadas .....	51
3.4.2.2. Horas de paradas mecânicas (HPM).....	52
3.4.2.3. Árvores por hora (Arv/h) .....	52
3.4.2.4. Volume médio individual (VMI) .....	53
3.4.2.5. Metros cúbicos por hora (m <sup>3</sup> /h).....	54
3.4.2.6. Óleo hidráulico por hora (Hdr) .....	54
3.5. Configuração das redes neurais artificiais .....	55
3.5.1. Modelagem das redes neurais artificiais (RNA) .....	55
3.5.2. Treinamento das redes neurais artificiais .....	55
3.5.3. Treinamento das redes em função do volume médio individual (VMI) ...	57
3.5.4. Agrupamento de dados - Dendrograma.....	58
3.6. Modelagem com regressão linear.....	58
3.6.1. Avaliação das estimativas .....	59
<b>4. RESULTADOS E DISCUSSÕES</b> .....	<b>61</b>
4.1. Variáveis estatísticas.....	61
4.2. Modelagem da disponibilidade mecânica da colheita florestal por meio de RNA.....	63
4.2.1. Sistema de colheita mecanizada <i>full-tree</i> .....	63
4.2.2. Sistema de colheita florestal mecanizada <i>Cut-to-length</i> - CTL .....	67
4.2.3. Melhores configurações de redes.....	71

4.3. Análise de agrupamento .....	73
4.3.1. Modelagem da disponibilidade mecânica por meio de RNA para classes de VMI .....	75
4.4. Regressão linear .....	80
<b>5. CONCLUSÕES .....</b>	<b>84</b>
<b>6. REFERÊNCIAS .....</b>	<b>85</b>

## 1. INTRODUÇÃO

Atualmente, o Brasil possui uma área de florestas plantadas de 9,55 milhões de hectares, um recuo de 1,4% comparado a 2020. Desse total, 78% (7,47 milhões de hectares) é representado pelo cultivo de eucalipto, 18% (1,7 milhão de hectares) de pinus e 4% de outras espécies (IBÁ, 2021).

Dado as grandes proporções territoriais do setor, as atividades que o contemplam precisam ser planejadas e executadas de forma eficiente, visando a otimização dos recursos e bons rendimentos. Dentre as atividades do setor florestal, a colheita da madeira pode ser caracterizada como um conjunto de operações realizadas no maciço florestal, visando preparar e transportar a madeira até o local de uso final.

Teixeira et al. (2018), definiu a colheita florestal como etapa mais importante do ponto de vista financeiro, sendo influenciada por fatores técnicos, ambientais, sociais, tendo a partir da década de 90, uma intensa mecanização, o que proporcionou uma redução significativa de custos e aumento de produtividade. Santos et al. (2018), associa o custo da colheita florestal mecanizada em torno de 50%, do custo final da madeira posto fábrica e/ou consumidores. A etapa de colheita pode ser dividida em duas operações distintas, sendo elas: o corte e a extração. O corte consiste na derrubada e processamento da madeira dentro do maciço florestal e possui grande influência nas operações subsequentes. A extração consiste na retirada da madeira cortada para as margens do plantio. Ambas as etapas podem ser realizadas de forma manual, semimecanizada e mecanizada (MACHADO, 2014).

A forma mais utilizada no setor, consiste no modelo mecanizado, utilizando-se de tratores florestais. A necessidade de maiores rendimentos nas operações, baixa disponibilidade de mão de obra, altos custos do processo, execução do trabalho de forma mais ergonômica e com maior eficiência, fizeram com que as empresas aderissem a mecanização como medida de segurança à cadeia produtiva para abastecimento do setor industrial/fábrica (OLIVEIRA, 2020).

A colheita florestal vive um momento de grandes inovações tecnológicas quanto a sua mecanização. Novas tecnologias cada vez mais presentes nas máquinas florestais, tem contribuído no planejamento das atividades, bem como favorecendo a otimização das atividades, muitas vezes, em tempo real. De forma

global estas inovações estão diretamente ligadas à rentabilidade do processo das empresas, podendo promover perdas ou ganhos sistêmicos na cadeia produtiva. Contudo, o setor ainda sofre com a falta de dados confiáveis para a escolha, seja do sistema e/ou das máquinas mais adequadas e mais economicamente viáveis para o processo.

A intensificação da mecanização ganhou maior notoriedade em relação a colheita florestal, levando a um processo contínuo de avaliação dos rendimentos técnicos e econômicos, devido ao grande percentual dos custos de produção agregados aos plantios comerciais. Diversos indicadores são adotados para estabelecimento e monitoramento do bom rendimento das atividades, dentre eles, um dos mais notáveis é a disponibilidade mecânica (DM). Uma boa manutenção mecânica proporciona às máquinas maior confiabilidade e operação continuada, permitindo que consigam se manter em condições de operação normal pelo maior tempo possível, impactando diretamente na redução dos custos bem como nos rendimentos operacionais (LIMA, 2019; BELCAVELLO, 2020).

Buscando meios de alcançar uma maior assertividade em tomadas de decisões que possam influenciar no rendimento das máquinas, sejam elas em produtividade ou mecanicamente, métodos computacionais avançados como as Redes Neurais Artificiais (RNA), têm sido utilizados.

Este modelo de inteligência artificial, procura desenvolver modelos computacionais, executando suas interfaces semelhantemente ao cérebro humano quando está pensando. Apresentam excelentes resultados na solução de problemas complexos em que envolvam muitas variáveis. No contexto florestal, vários trabalhos foram desenvolvidos utilizando-se do método de RNA, comprovaram a eficiência da aplicação, autores como: (GORDON, 1998; DIAMANTOPOULOU, 2005; BINOTI et al., 2009; GORGENS et al., 2009; BINOTI, 2010; LEITE et al., 2011; BINOTI, 2012; HICKEY et al., 2015; BHERING et al., 2015; SILVA RIBEIRO et al., 2016; ZANUNCIO et al., 2016; VAHEDI, 2017; LACERDA et al., 2022).

Estudos por meio de RNA se justificam por diversos fatores como: adaptabilidade (uma vez que as redes possuem a capacidade de lidar com modificações durante o processo e pode ser retreinada), tolerâncias a falhas e capacidade de trabalho com conjunto de dados de grande porte.

A predição de indicadores da colheita florestal mecanizada, em específico a disponibilidade mecânica, justifica-se, pois, uma vez sendo possível, utilizar-se de variáveis categóricas existentes no ambiente, local e máquinas, para alimentar um procedimento computacional, prever o rendimento, as análises e tomadas de decisões, tornam-se de maior facilidade.

## 1.1. Objetivos

### 1.1.1. Objetivo geral

Realizar a predição da disponibilidade mecânica em sistemas de colheita de árvores inteiras (*full-tree*) e de toras curtas (*cut-to-length* - CTL) por meio de redes neurais artificiais (RNA) e regressão linear.

### 1.1.2. Objetivo específico

- Modelar a disponibilidade mecânica para os diferentes sistemas de colheita em função das variáveis operacionais por meio de redes neurais artificiais (RNA);
- Modelar a disponibilidade mecânica para os diferentes sistemas de colheita em função das variáveis operacionais por meio de regressão linear;
- Comparar a eficiência dos modelos de predição para a disponibilidade mecânica nos diferentes sistemas de colheita da madeira;

## 2. REFERENCIAL TEÓRICO

### 2.1. Setor Florestal Brasileiro

Com a criação da política de incentivos fiscais, a implantação de florestas de produção (floresta plantada), teve um rápido crescimento. Isso se deu ao final da década de 60, onde até então a exploração florestal no Brasil era quase que exclusivamente de florestas nativas, expandindo-se para o setor de plantios comerciais, atendendo diversificados mercados como: celulose e papel, serrarias, construção civil dentre outros (COELHO JÚNIOR et al., 2020; DIAS et al., 2017).

De acordo com a Indústria Brasileira de Árvores (IBÁ), atualmente o Brasil possui uma das maiores áreas de florestas plantadas do mundo, cerca de 9,55 milhões de hectares. Desse total, 78% (7,47 milhões de hectares) é representado pelo cultivo de eucalipto, 18% de pinus (1,7 milhão de hectares) (IBÁ, 2021).

Em 2020, a produção de celulose brasileira alcançou seu segundo maior volume histórico, totalizando 21 milhões de toneladas. Papel cartão, utilizado em embalagens de delivery, especialmente, chegou a 798 mil toneladas produzidas, um avanço anual de 4,9% em relação a 2019. Papelão ondulado, voltado para o e-commerce, também avançou. Houve aumento de demanda, inclusive, de pisos laminados e painéis de madeira, uma vez que o home office vem estimulando a adequação de lares para ambientes mais propícios ao trabalho (IBÁ, 2021).

No Brasil, a atividade florestal possui grande importância, para a sociedade em termos econômicos, sociais e ambientais, devido a capacidade de geração de empregos e renda, além de oferecer serviços ambientais (RAMOS et al., 2018).

### 2.2. Colheita Florestal

A colheita florestal é definida por Spinelli et al. (2019), como um conjunto de operações pré-estabelecidas realizadas em áreas de florestas plantadas, visando preparar e retirar a madeira do interior do povoamento para o local de transporte (pátio intermediário ou margens das estradas). A variedade de fatores que podem influenciar na qualidade e viabilidade da colheita florestal torna esta, uma atividade consideravelmente complexa e de alto valor agregado, podendo atingir valores que correspondem em torno de 50% dos custos totais da madeira colocada na fábrica

(GONÇALVES et al., 2021; HIESL et al., 2015; LACERDA et al., 2017; LEITE et al., 2014; SANTOS et al., 2018).

Por essa razão, um eficiente planejamento, controle das operações e conhecimento de cada uma das etapas que compõem a colheita é essencial para reduzir os custos, otimizar o trabalho e melhorar a qualidade do produto final (LANA et al., 2018).

Dito isso, a colheita de madeira é subdividida em duas grandes etapas, sendo elas: o corte e a extração (MACHADO et al., 2014) (Figura 1).

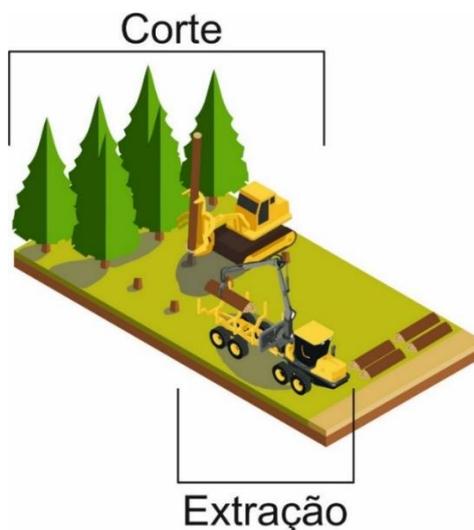


Figura 1. Etapas da colheita florestal (corte e extração).

Fonte: O autor (2022).

A etapa de corte, primeira etapa da colheita florestal, é um conjunto de atividades realizadas ainda dentro do talhão, com o objetivo de preparar a madeira para a próxima etapa da colheita, ou seja, a extração (SANT'ANNA, 2014). Dentre essas atividades é possível citar a derrubada (ato de cortar a árvore e derrubá-la sobre o solo), o desgalhamento (remoção dos galhos ao longo do fuste), destopamento (remoção da parte com diâmetro não comercial da árvore, normalmente a copa), traçamento (seccionamento do fuste em toras) descascamento (remoção da casca da árvore) e empilhamento (arranjo da madeira para facilitar a extração) (RAMOS et al., 2016).

A extração, por sua vez, é definida por Miyajima et al. (2017) como as atividades realizadas com o objetivo de retirar a madeira do interior do talhão e depositá-la no pátio de estocagem ou nas margens das estradas para posteriormente ser transportada. De acordo com Seixas e Castro (2014), a extração

é realizada, na maior parte das vezes, por duas formas distintas, sendo eles: o baldeio e o arraste. O baldeio consiste na extração da madeira sobre uma plataforma acoplada a um maquinário autopropelido, sem que a mesma tenha contato direto com o solo. Já o arraste é realizado de tal maneira que toda a árvore, ou parte dela, é apoiada sobre o solo (SEIXAS; CASTRO, 2014).

Tanto a etapa de corte quanto a etapa de extração florestal, podem ser realizadas pelo método manual, semimecanizado ou mecanizado.

### 2.2.1. Colheita florestal mecanizada

A colheita florestal mecanizada é baseada no uso de máquinas, para realizar todas as operações envolvidas nos processos da colheita (RODRIGUES, 2018). Durante as últimas décadas houve um grande avanço tecnológico nas máquinas utilizadas na colheita florestal, tal avanço possibilitou ganhos de produtividade e redução dos custos (MACHADO et al., 2014; FIEDLER, OLIVEIRA, 2018).

O incremento tecnológico advindo das máquinas de colheita florestal, propiciaram às empresas do ramo ganhos significativos de produtividade e redução dos custos. São inúmeras as vantagens desse método frente aos demais, destacando-se o alto rendimento individual, maior segurança e qualidade de trabalho dos operadores, melhor qualidade de operação, entre outras (RISSMAN et al., 2022). No entanto, apesar dos benefícios associados, a mecanização na colheita florestal acarretou altos valores de aquisição, necessidade de estrutura de manutenção mais robusta, limitação de atuação em terrenos inclinados, entre outros (LIMA; LEITE, 2014).

Devido ao alto custo de aquisição e manutenção das máquinas e equipamentos, a colheita mecanizada é empregada principalmente em empresas com maior poder de compra e com maiores áreas de plantio que exigem altos níveis de produtividade. Além do custo de aquisição mais elevado que os demais métodos, o sucesso da mecanização das atividades de colheita está condicionado a diversos fatores de influência, tais como a topografia do terreno, as condições de suporte do solo, o clima, as características do povoamento, a finalidade da madeira, as potencialidades e limitações dos operadores, o maquinário utilizado e as condições da malha viária (LIMA; LEITE, 2014).

### 2.3. Fatores de influência sobre a colheita florestal

A qualidade e viabilidade das operações de colheita florestal em um empreendimento do ramo madeireiro estão atreladas à inúmeros fatores de influência. A seguir são listadas as principais variáveis a serem consideradas durante um planejamento de execução da colheita florestal:

*a) Mecanização e nível tecnológico:* a mecanização na colheita florestal já é uma realidade em boa parte dos empreendimentos florestais no Brasil. No entanto, cada um destes empreendimentos apresenta suas peculiaridades e necessidades, diferindo-se dos demais principalmente em relação ao nível de mecanização empregado, haja vista que algumas mecanizam todo o processo e outras apenas parte do sistema (MACHADO et al., 2014);

*b) Qualidade:* dado o fato que a colheita é a última fase do processo produtivo do setor florestal, essa deverá ser realizada de maneira a atender os princípios da Qualidade Total e as exigências do mercado (HÄGGSTRÖM; LINDROOS, 2016). O termo Qualidade Total se refere à obtenção de produtos/serviços com a melhor qualidade pelo menor custo possível, proporcionando aos colaboradores qualidade de vida e segurança no trabalho e fornecendo aos consumidores um produto final seguro (NEWMAN et al., 2018);

*c) Uso múltiplo da floresta:* os plantios florestais oferecem a possibilidade de uso múltiplo de seus produtos, seja para atender consumidores diferentes ou um mesmo consumidor que necessita de diferentes características da madeira. No entanto, para que seja possível gerar múltiplos produtos, os povoamentos florestais, os sistemas de colheita e de processamento da madeira devem ser submetidos a adaptações para atender a todas as exigências, como por exemplo, o espaçamento, desbaste, espécie, modais de colheita, nível de mecanização, etc. Todas essas adaptações influenciam diretamente no desempenho da colheita florestal (MACHADO et al., 2014);

*d) Treinamento:* O avanço tecnológico inerente aos maquinários empregados na colheita florestal tem exigido cada vez mais dos empreendimentos a contratação de colaboradores treinados, capacitados e com um grau de instrução mais elevado (LINDROOS; HERA; HÄGGSTRÖM, 2017). Isso ocorre porque essas máquinas possuem além de seu alto custo agregado e necessitam de operadores

com capacidade de operação e leitura de comandos cada vez melhor (de SOUZA et al., 2008);

e) *Declividade de operação*: Os plantios de florestas comerciais, abrangem áreas de diversas características de relevo, dentre elas a declividade. Tal fator, torna-se de grande importância para a etapa da colheita, pois podem ocasionar um maior tempo para realização das atividades e conseqüentemente menor produtividade (OLIVEIRA, 2019). Máquinas providas de implementos que auxiliem neste tipo de atividade, tornam-se fator determinante para a execução.

f) *Características da floresta*: Dentre as variáveis relacionadas às características da floresta, diversas literaturas citam o volume por árvore como sendo a variável que melhor explica a produtividade alcançada pelo *harvester* (SANTOS e MACHADO, 1995; HOLTZSCHER e LANFORD, 1997; MARTINS et al., 2009), de maneira que o rendimento da operação acompanha proporcionalmente o volume individual das árvores até atingir um ponto máximo. LEITE et al. (2014) testaram a influência de diferentes espaçamentos (3 x 2,5 m; 3 x 3,33 m e 3 x 4 m) e inclinação (baixada; encosta) no desempenho do *harvester*, tendo encontrado produtividade superior na baixada e no espaçamento de 3 x 4 m.

Os fatores citados influenciam tanto durante as operações quanto durante o planejamento da colheita florestal. Em relação às fases de planejamento que antecedem o início das atividades, todas essas variáveis devem ser levadas em consideração para a escolha do melhor sistema de colheita a ser adotado.

#### 2.4. Sistemas de colheita da madeira

Os sistemas de colheita florestal são definidos como o conjunto de atividades e processos interconectados realizados no plantio florestal, desde o corte até o descarregamento nas margens da estrada ou pátios de estocagem, com o objetivo mútuo de garantir o fluxo contínuo de madeira, levando as máquinas à máxima utilização, buscando evitar pontos de gargalos no sistema produtivo (ALZAMORA, OVIEDO e RUBILAR, 2020). Os autores explicam ainda que para o sucesso dos sistemas de colheita florestal, os tomadores de decisão devem estar atentos a todos os dados que o compõem, de maneira a garantir que estes atinjam o mesmo objetivo, respeitando sempre a ordem cronológica de operação e as hierarquias entre os processos.

Segundo Amorim (2021) os sistemas de colheita de madeira podem ser variados e classificados de acordo com as características do povoamento (idade, espécie, espaçamento, volume), manejo adotado, uso final da madeira, topografia e mecanização.

De acordo com a Organização das Nações Unidas para Alimentação e Agricultura (FAO, 1977), o principal critério de classificação dos sistemas de colheita florestal é a forma na qual a madeira encontra-se na fase de extração.

Neste sentido, Machado (1985) propôs uma classificação dos sistemas de colheita de acordo com as especificações da FAO. Nessa classificação o autor listou o sistema de toras curtas, o sistema de toras compridas, o sistema de árvores inteiras, o sistema de árvores completas e o sistema de cavaqueamento. Os sistemas mais utilizados no Brasil são o de Toras Curtas e o de Árvores Inteiras (FERNANDES et al., 2009). Desta forma, na presente revisão a abordagem será sobre esses dois sistemas.

## 2.5. Sistema de Toras Curtas

O sistema de toras curtas ou *cut-to-length* (CTL), é o mais antigo e mais utilizado no Brasil e em países escandinavos. Esse método de colheita consiste na extração da madeira em toras de comprimento igual ou inferior a 6 metros, após a realização de todas as etapas de corte no interior do talhão (RODRIGUES, 2018) (Figura 2).

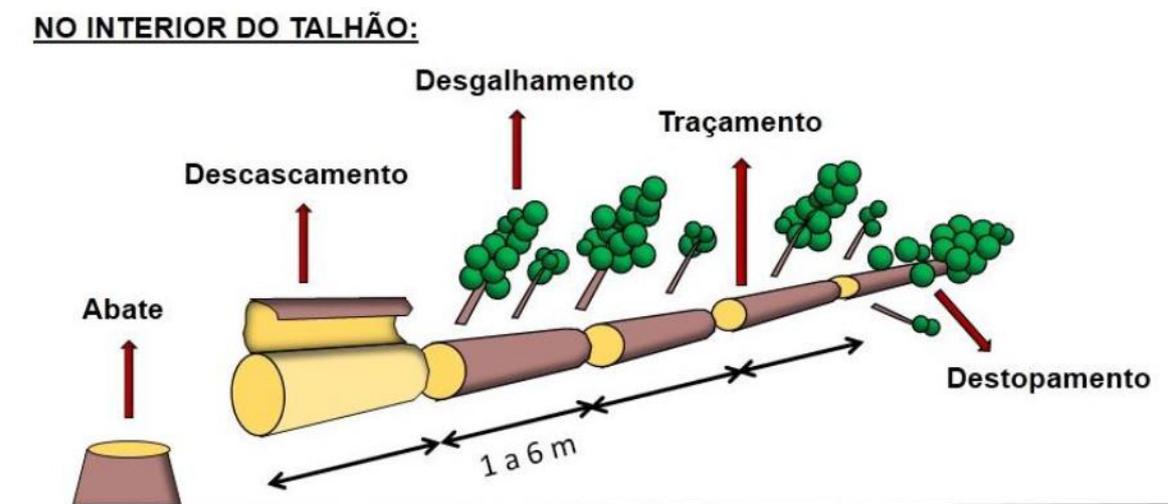


Figura 2. Representação gráfica do sistema de colheita de toras curtas.

Fonte: Rodrigues (2018).

Esse sistema pode ser realizado por qualquer um dos métodos de colheita (manual, semimecanizado ou mecanizado), porém, quando a extração é manual a limitação quanto ao tamanho das toras é maior (RODRIGUES, 2018).

No sistema de toras curtas, todos os resíduos permanecem no interior dos talhões, auxiliando assim, a ciclagem de nutrientes, servindo de base para os rodados dos maquinários evitando a compactação e permitindo o trabalho em solos úmidos. Além disso, a demanda por espaço nos pátios intermediários ou margem das estradas é menor e não existe a necessidade de trilhas de arraste, visto que a madeira é extraída por baldeio (MALINOVSKI et al., 2014; SZYMCZAK et al., 2014). Além disso, devido ao tamanho reduzido das toras, é comum que estas sejam extraídas por meio de baldeio, o que evita a formação de processos erosivos derivados do contato direto da madeira com o solo.

Quando o sistema de toras curtas é realizado pelo método de colheita mecanizado, as máquinas mais utilizadas são o *harvester* (colhedor florestal – etapa de corte) em conjunto com o *forwarder* (trator florestal auto carregável– etapa de extração) (SANTOS et al., 2018).

### 2.5.1. *Harvester*

*Harvester*, em uma tradução livre do termo, significa “colhedor”, ou seja, o *harvester* florestal é também conhecido como “colhedor florestal” e é composto por uma máquina-base e um cabeçote *harvester* (VASILEV et al., 2019). Essa denominação se dá pelo fato que essa máquina é capaz de realizar, sequencialmente, todas as etapas do corte florestal (derrubada, desgalhamento, destopamento, traçamento e descascamento) (MACHADO et al., 2014). A escolha da máquina-base e do cabeçote depende de diversos fatores, como o tipo de árvore, as condições de inclinação do terreno, quantidade a ser processada, objetivos do empreendimento, entre outros (McEWAN et al., 2020)

O cabeçote *harvester* pode ser acoplado a uma máquina-base de pneus ou de esteiras, a depender das condições e necessidades do empreendimento. A máquina-base de pneus consegue se locomover com mais facilidade e em maiores velocidades que a de esteira. No entanto, a máquina de esteiras possui melhor distribuição do peso e assim compacta menos o solo, além de apresentar maior estabilidade em terrenos inclinados que a de pneus (LIMA; OLIVEIRA, 2019).

A Figura 3 apresenta a máquina responsável pela etapa de corte do sistema de toras curtas, o *harvester*.



Figura 3. *Harvester* utilizado na colheita florestal pelo sistema de toras curtas.

Fonte: John Deere (2022a).

### 2.5.2. *Forwarder*

O *forwarder* é um trator florestal autocarregável, destinado à extração florestal (pelo método de baldeio) e empilhamento da madeira na margem das estradas ou pátio de estocagem (CARMO et al., 2015). Essa máquina possui um chassi articulado com tração do tipo 4x4, 6x6 ou 8x8, uma grua hidráulica usada no carregamento e descarregamento da caixa de carga (MACHADO et al., 2014).

A grua hidráulica dessa máquina possui capacidade de carga variando entre 300 e 1800 kg por ciclo e um alcance de 3 a 12 metros. Como cerca de 80% do tempo de trabalho dessa máquina é composto pelas operações de carregamento e descarregamento da caixa de carga, a velocidade não é uma característica essencial para a mesma. Por este motivo, a principal característica dessa máquina é a sua capacidade de superar adversidades, principalmente no que diz respeito às condições topográficas dos terrenos, onde ela consegue trabalhar em aclives de até 30% e em declives de até 60% (SEIXAS; CASTRO, 2014).

A Figura 4 apresenta a máquina responsável pela etapa de extração do sistema de toras curtas, o *forwarder*.



Figura 4. *Forwarder* utilizado na colheita florestal pelo sistema de toras curtas.

Fonte: John Deere (2022b).

## 2.6. Sistema de Árvores Inteiras

O sistema de árvores inteiras ou *full-tree*, é definido por Labelle e Lemmer (2019), como o método de colheita em que consiste na derrubada das árvores sem raízes, para posterior extração por arraste até às margens da área ou local definido para processamento. Esse sistema necessita de elevado nível de mecanização, principalmente na etapa de extração e normalmente é empregado para a colheita de árvores de grande porte. Por este fato, o sistema de árvores inteiras carece da utilização de máquinas e equipamentos especialmente desenvolvidos para este tipo de operação (MALINOVSKI et al., 2014; RODRIGUES, 2018).

Esse sistema também é muito utilizado quando se almeja a utilização dos resíduos da colheita (casca, folhas, ramos, galhos, acículas) para a produção de biomassa, haja vista que o processamento é realizado em campo aberto e a junção e transporte desses materiais são facilitados (LINDROOS; HERA; HÄGGSTRÖM, 2017). Além disso, o risco de incêndios florestais na área de plantio é significativamente reduzido devido à remoção de parte do material combustível do talhão (RODRIGUES, 2018). No entanto, a remoção dos resíduos da colheita do talhão pode resultar em diferentes impactos ambientais, como o empobrecimento do solo devido à exportação de nutrientes (AMORIM; PIMENTA; SOUZA, 2021), a potencialização dos processos erosivos gerados pela falta de cobertura do solo, maior compactação causada pelos rodados das máquinas (MENDES; SEIXAS, 2018), entre outros.

Rodrigues (2018), afirma que o fato de todas as operações de processamento das árvores serem realizadas em um único ponto, permite maior

controle das operações e portanto, maior rendimento operacional que o sistema de toras curtas. Malinovski et al. (2014), por sua vez, explicam que em países norteamericanos esse sistema se destaca pelo seu baixo custo operacional relativo. Os autores afirmam ainda que na região Sul do Brasil o sistema de árvores inteiras é bastante comum quando se realiza a colheita em corte raso (remoção de todas os indivíduos para início de novo plantio).

Assim como no sistema de toras curtas, no *full-tree* existe um modal de colheita mais utilizado, no entanto, este é constituído por pelo menos três máquinas. A combinação mais comum é: *feller-buncher* (cortador-acumulador – etapa de corte) + *skidder* (arrastador – etapa de extração) + *Garra traçadora* (etapa de processamento).

### 2.6.1. *Feller-Buncher*

O *feller-buncher*, é uma máquina florestal destinada à realização da derrubada, acumulação e disponibilização dos feixes de árvores no solo (PEREIRA et al., 2020). O *feller-buncher* é constituído por uma máquina-base, de esteira ou pneus, e um cabeçote de corte de disco, sabre ou tesoura (MIYAJIMA et al., 2021) (Figura 5).



Figura 5. Tipos de cabeçote do *feller-buncher*.

Fonte: J de Souza (2022), KOMATSU FOREST (2022) e TURBOSQUID (2022).

O corte realizado com o sabre se assemelha ao efetuado com motosserra, diferenciando apenas na força motriz da corrente, haja vista que na máquina semimecanizada essa força é gerada por um motor de combustão interna ou eletricidade e no *feller-buncher* é gerada por um motor hidráulico (SANT'ANNA, 2014). Na operação realizada com disco, possuem basicamente um motor

hidráulico que gira o disco serrilhado de metal. O disco tem espessura aproximada de 5 centímetros, peso médio de 1 tonelada e velocidade de giro de 1500 rpm (SANT'ANNA, 2014). Por fim, o cabeçote de tesoura realiza um processo de estrangulamento da árvore e com as lâminas efetua o corte (SANT'ANNA, 2014).

A principal diferença entre essa máquina e o *feller*, é o fato que o seu cabeçote possui mecanismo capaz de formar feixes de árvores simultaneamente ao corte das mesmas (RODRIGUES, 2018). Essa operação de acúmulo de árvores é possível graças ao conjunto de braços de acionamento hidráulico, um principal e um de acúmulo. No momento da operação os braços de acúmulo se fecham e somente o braço principal se abre para a captura e corte da primeira árvore. Após realizar o corte da primeira árvore, ambos os braços se fecham e somente o braço principal se abre para a captura da próxima. Após o corte, o ciclo se repete até formar o feixe (SILVA; FENNER; CATANEO, 2007; SOARES, 2018).

No que se refere ao *harvester*, é possível destacar que uma das vantagens do *feller-buncher*, relaciona-se ao maior rendimento operacional e, conseqüentemente, menor custo operacional, devido exatamente à capacidade de corte em feixes e da capacidade de direcionamento e empilhamento mais preciso das árvores (MIYAJIMA et al., 2021). No entanto, o processamento das árvores derrubadas pelo *feller-buncher*, ou seja, a segunda etapa do corte, está condicionado a uma máquina adicional, haja vista que seu cabeçote não foi desenvolvido para esta atividade.

### 2.6.2. Skidder

O *skidder* é uma máquina versátil e robusta destinada à extração de madeira por meio de arraste (dos SANTOS et al., 2013). Esse maquinário é composto por uma máquina com chassi articulado, ou não, de tração 4x4, 6x6 ou 8x8 e opções de sistema de rodagem de pneus, semiesteiras ou esteiras (MIYAJIMA et al., 2017, 2020). Alguns modelos possuem sistema de arraste equipado com cabo (*Chocker skidder*), enquanto outros podem ser equipados com garra (*Grapple skidder*) ou garra invertida (*Clambunk skidder*) (SEIXAS; CASTRO, 2014). No entanto, o *chocker skidder* é mais recomendado para o arraste de toras dispersas no talhão.

As máquinas dotadas de rodados do tipo esteira são indicadas para operações em que se exige demasiada potência e a velocidade não é crucial. Os

principais fatores que influenciam na produção dos *skidders* de esteiras são: solo, topografia, clima, condições do sub-bosque, características do talhão e dos indivíduos e planejamento de manutenção, reparos e administração (SEIXAS; CASTRO, 2014).

Na Figura 6 é ilustrada uma operação de extração com *skidder* de esteiras equipado com garra.



Figura 6. *Track Skidder* de esteiras.

Fonte: Peterson Cat (2022).

O *skidder* de pneus possui chassi articulado, que possui uma espécie de dobradiça entre a seção frontal e traseira que garante maior estabilidade e manobrabilidade da máquina (SEIXAS; CASTRO, 2014).

A Figura 7 apresenta uma operação de extração com *skidder* de pneus equipado com garra invertida e com garra.



*Clambunk Skidder*

*Grapple Skidder*

Figura 7. *Clambunk skidder* e *grapple skidder* de pneus.

Fonte: JOHN DEERE (2022c) e TIGERCAT (2022).

O *skidder* de garra invertida possui um sistema de garra hidráulica com abertura superior. O principal objetivo da garra em posição invertida é garantir a maior aderência das toras durante a extração e, mutuamente, elevar sua capacidade de carga de maneira significativa. O *skidder* de garras é indispensável em operações em conjunto com o *feller-buncher*, devido à disposição em pilhas realizada pelo derrubador-acumulador. Isso ocorre pois, em razão do manuseio das árvores ser mais rápido e simples nessa máquina, a mesma, em condições favoráveis de operação, pode atingir índices de produtividade 300% superiores aos *skidders* de cabos (SEIXAS; CASTRO, 2014).

### 2.6.3. Garra traçadora

A garra traçadora é uma máquina destinada ao seccionamento das árvores em toras menores, normalmente nas margens das estradas ou pátios de estocagem, para facilitar e viabilizar o transporte da madeira (LIMA; LEITE, 2014). Ao utilizar essa máquina, o operador utiliza-se da garra para apanhar o feixe de árvores extraídos e empilhados pelo *skidder*. Posteriormente, através dos comandos do sabre, realiza-se o corte simultâneo deste em toras menores (LIMA; LEITE, 2014).

A configuração mais usual desse maquinário é uma garra equipada com um sabre acoplada a uma retroescavadeira de esteiras com cabine com rotação de 360 graus (SIMÕES et al., 2022) (Figura 8).



Figura 8. Garra traçadora de esteiras.

Fonte: TMO Forest (2022).

## 2.7. Análise técnica da colheita florestal

Como visto, a escolha dos maquinários de colheita florestal está interligada a diversos fatores de influência que podem interferir diretamente na viabilidade e aplicabilidade dos sistemas. Desta forma, torna-se nítida a necessidade de planejamentos e análises técnicos e econômicos dos sistemas de colheita florestal para fornecer aos tomadores de decisão uma visão ampla do funcionamento das atividades, podendo assim detectar falhas, gargalos de produções e pontos críticos, onde melhorias e ajustes possam ser aplicados para que o sistema alcance os resultados desejados (FIEDLER et al., 2020; MOURA et al., 2019).

Uma das principais ferramentas utilizadas ao longo dos anos para auxiliar na análise técnica e econômica dos sistemas de colheita florestal é o estudo de tempos e movimentos (BILICI; AKAY; ABBAS, 2019). De acordo com Barnes (1977), o estudo de tempos e movimentos é uma metodologia, baseada na análise sistemática dos ciclos operacionais, que tem por alvo o planejamento, controle e racionalização das operações e a identificação e desenvolvimento do melhor método de trabalho para cada situação. Usualmente, esse método é aquele que apresenta o menor custo, a maior segurança dos colaboradores e a maior produtividade do sistema.

O método de análise utilizado é a determinação do tempo necessário para que um colaborador treinado e capacitado necessita para a realização de cada movimento do ciclo operacional em suas condições habituais (DA SILVA et al., 2018). Desta forma, com os valores de tempos devidamente coletados e analisados, o tomador de decisões é capaz de determinar uma série de fatores derivados que podem auxiliar na organização dos ciclos operacionais e conseqüentemente no aumento da produtividade do sistema e na redução dos custos de produção (MIYAJIMA et al., 2016).

Esses fatores são conhecidos como indicadores de rendimentos operacionais e dentre eles destaca-se a disponibilidade mecânica das máquinas, eficiência operacional e a produtividade (MOURA et al., 2019).

## 2.8. Análise técnica - indicadores de performance.

### 2.8.1. Disponibilidade Mecânica (DM)

A disponibilidade mecânica refere-se a um parâmetro de análise de desempenho de máquinas florestais que avalia o período em que estas encontram-se mecanicamente disponíveis para a realização de seu trabalho (CARMO et al., 2012), ou seja, esse índice avalia o período de trabalho da máquina descontando as paradas para eventuais manutenções e reparos. De acordo com Diniz et al (2018), o índice de disponibilidade mecânica ideal para máquinas florestais deve ser sempre superior a 85%, ressaltando que para regimes de trabalhos inferiores a 24h, tal percentual deve ser elevado gradativamente.

Um dos fatores primordiais para se alcançar níveis cada vez mais elevados de disponibilidade mecânica, é garantir uma manutenção preventiva eficiente em todas as máquinas disponíveis. Isso ocorre porque a manutenção preventiva trata-se de um conjunto de medidas realizadas, antes do início das atividades, com o principal objetivo de reduzir a probabilidade de ocorrência de falhas mecânicas nas máquinas, garantindo assim, maior tempo apto para o trabalho (DINIZ et al., 2017).

Neste sentido, é evidente a necessidade do estabelecimento de setores de manutenção bem estruturados, com quantidade suficiente de peças de reparo, mecânicos capacitados e com condições necessárias para desenvolver o trabalho de manutenção das máquinas com eficiência e rapidez. Esse setor, quando bem-planejado, pode garantir maior capacidade produtiva do sistema de colheita e evitar perdas no investimento e na produção por deficiência mecânica (LACERDA, 2015).

A fórmula matemática utilizada para determinação dos índices de disponibilidade mecânica é apresentada na Equação 1, apresentada por Ganda e Silva (2019).

$$DM(\%) = \frac{HT - HPM}{HT} \times 100 \quad (1)$$

Onde:

*DM (%)* = disponibilidade mecânica, em porcentagem;

*HT* = horas totais programadas;

*HPM* = horas de parada em manutenção.

### 2.8.2. Fatores que influenciam a disponibilidade mecânica

A disponibilidade mecânica das máquinas é influenciada por diversos fatores, tanto relativos à falta de planejamento ou de monitoramento quanto à ineficiência das operações de manutenção e às condições adversas do ambiente de trabalho. Dentre estas, Fontes e Machado (2014), destacam as operações incorretas, a lubrificação inadequada dos maquinários, a falta de limpeza e as folgas.

Em relação às operações incorretas, é importante ressaltar que em parte das vezes, as falhas acontecem pela falta de habilidade do operador em realizar as atividades às quais é designado. De acordo com Rodrigues (2018), os colaboradores indicados para operar as máquinas florestais devem ser habilitados e treinados para garantir uma operação correta e alcançar a melhor produtividade e qualidade dos produtos, bem como reduzir ou eliminar a possibilidade de ocorrência de eventuais danos mecânicos gerados por erros de operação.

A lubrificação correta das máquinas é uma das principais formas de se reduzir os tempos ociosos oriundos de falhas mecânicas. Isso ocorre devido ao fato que quando se introduz, de maneira correta, o lubrificante entre as superfícies metálicas dos maquinários, é formada uma película protetora que reduz os níveis de atrito entre estas e conseqüentemente a perda de potência e desgaste destrutivo das peças é, significativamente, reduzida (BROWN; DINIZ, 2017).

Outro fator preponderante relacionado à redução do número de falhas mecânicas nas máquinas florestais diz respeito à falta de limpeza das mesmas. Este fato é decorrente das condições peculiares do setor florestal a que as máquinas são submetidas, como o acúmulo de poeira, lama, materiais oriundos da vegetação (folhas, galhos, cascas, exsudados). Quando a sujeira advinda desses e outros materiais ocorre rotineiramente, a inspeção visual de possíveis falhas mecânicas fica prejudicada, podendo gerar maior número de ocorrências e conseqüente redução da disponibilidade mecânica (FONTES; MACHADO, 2014).

Quando se fala em folgas, Roloff (2019), explica que se trata de movimentos relativos entre os componentes da máquina, que quando em desacordo com os limites preestabelecidos, podem ser responsáveis por consideráveis falhas mecânicas. Quando as folgas são insuficientes, não permitem a entrada de lubrificantes, quando são excessivas, reduzem a eficiência da lubrificação,

causando, em ambos os casos, desgastes relacionados à falta de lubrificação. Dentre as causas de falhas causadas pelas folgas incorretas, destacam-se a vibração, o torque insuficiente, impactos, lubrificação inadequada e má fixação de componentes durante as manutenções.

### 2.8.3. Eficiência Operacional (EO)

A eficiência operacional é definida no trabalho de Miyajima et al. (2016), como a relação entre o período de tempo efetivamente trabalhado e o tempo de operação programado para a máquina. Para Linhares et al. (2012), o índice de eficiência operacional mínimo aceitável para máquinas de colheita florestal é de 70% e que em situações onde o valor for inferior a esse, toda a operação deve ser revista para identificação de possíveis gargalos ou falhas operacionais.

As paradas operacionais realizadas com a finalidade de atendimento às necessidades fisiológicas, à alimentação e descanso dos operadores, às más condições de operação, qualidade de estradas e trilhas e às características do povoamento estão listadas, por Silva (2022), como diretamente responsáveis por alterações nos índices de eficiência operacional.

A fórmula matemática utilizada para determinação dos índices de eficiência operacional é apresentada na Equação 2, apresentada por (Simões et al., 2014; OLIVEIRA, 2019).

$$EO(\%) = \left( \frac{H_f}{H_f + T_p} \right) \times 100 \quad (2)$$

Onde:

$EO$  (%) = eficiência operacional, em porcentagem;

$H_f$  = refere-se às horas efetivamente trabalhadas;

$T_p$  = tempo de paradas mecânicas e operacionais, em horas.

### 2.8.4. Produtividade (Pr)

Produtividade é definida por Simões et al. (2014), como a relação entre a produção (quantidade de bens produzidos) e os recursos utilizados para atingi-la. No cenário da colheita florestal, pode-se exemplificar a produtividade como a

quantidade de árvores uma determinada máquina de colheita consegue cortar (produção) em um determinado período de tempo (recurso).

Existem inúmeros fatores que influenciam direta e indiretamente a produtividade das máquinas florestais, como o volume médio individual (VMI) das árvores, a distância de extração, o espaçamento de plantio e a topografia do terreno, a eficiência operacional das máquinas e a produtividade das florestas, entre outros (FERNANDES et al., 2009; ROCHA et al., 2009; SANTOS et al., 2013; LEITE et al., 2014; SIMÕES et al., 2014; SCHETTINO et al., 2015; BASSOLI, 2020). O conhecimento da produtividade das máquinas florestais e seus fatores de influência é indispensável para a determinação dos modais ótimos a serem empenhados em cada local e em cada condição.

A fórmula matemática utilizada para determinação dos índices de produtividade das máquinas florestais é apresentada na Equação 3, apresentada por (LACERDA, 2015; BASSOLI, 2020).

$$P_r = \frac{P}{H_f} \quad (3)$$

Onde:

$P_r$  = produtividade, na unidade desejada;

$P$  = produção, na unidade desejada;

$H_f$  = horas efetivas de trabalho.

## 2.9. Planejamento da manutenção mecânica

Ao longo dos anos os empreendimentos florestais têm considerado o planejamento de manutenção de seus maquinários uma medida estratégica para alcançar seus objetivos. Isso vem ocorrendo pelo fato de que por meio da manutenção mecânica é possível antecipar-se e evitar ou remediar falhas que podem resultar em paradas imprevistas e conseqüentemente tempos ociosos das máquinas (BROWN; DINIZ, 2017).

Desta forma, hoje em dia é consenso que o investimento em manutenção não é mais um “mal necessário”, como costumava ser definida, e sim um “bem necessário” que envolve todas as ações para que os maquinários sejam conservados ou reparados para que possam permanecer em condições aptas para o trabalho. Por isso é importante que durante o planejamento seja priorizada a

contratação de profissionais qualificados e comprometidos no processo, que estejam focados em elevar a disponibilidade mecânica com ações eficazes na manutenção (FONTES; MACHADO, 2014).

Além disso, é indispensável realizar inspeções periódicas nos maquinários, a fim de identificar possíveis falhas mecânicas que possam vir a comprometer o bom funcionamento do sistema. Nessas avaliações, deve-se preconizar com a determinação das principais causas das ocorrências, os tipos de falhas mais recorrentes e quais os melhores métodos para prevenir ou remediar as ocorrências (BROWN; DINIZ, 2017).

Os métodos de manutenção mecânica são classificados por Fontes e Machado, (2014), em dois grandes grupos, sendo eles: manutenção preventiva e manutenção corretiva.

#### 2.9.1. Manutenção preditiva

Possui o objetivo de determinar o período exato em que se deverá realizar a intervenção mantenedora, utilizando o máximo da vida útil do componente. É considerada toda e qualquer atividade de monitoramento capaz de fornecer dados suficientes para realizar uma análise de parâmetros que permitam acompanhar as condições dos componentes da máquina no decorrer do tempo, permitindo a definição do momento ótimo de intervenção (BROWN; DINIZ, 2017).

As principais vantagens da utilização do método de manutenção são as reduções dos esforços aplicados pela equipe de manutenção para remediar falhas mais severas, a atenuação da possibilidade de ocorrência de tempos ociosos causados por estas falhas e conseqüentemente o aumento considerável da disponibilidade mecânica (FONTES; MACHADO, 2014).

São aquelas realizadas de acordo com as informações recebidas durante os processos de monitoramento dos padrões indicativos de falhas. Durante essas inspeções, as principais técnicas utilizadas são a análise de vibração, de óleos lubrificantes e de temperaturas (FONTES; MACHADO, 2014).

### 2.9.2. Manutenção preventiva

A manutenção preventiva é aquela que é realizada em conformidade com os cronogramas preestabelecidos em função do tempo de uso ou dos níveis de funcionamento das máquinas. Especificamente para as máquinas florestais, é recomendado o critério de tempo em horas de funcionamento, seguindo as recomendações do fabricante (FONTES; MACHADO, 2014).

Manutenção preventiva é todo serviço realizado em máquinas que não estejam em falha, sendo realizado antes de sua ocorrência. Quando ocorre este tipo de manutenção, o ativo está em condições operacionais, podendo ou não estar com defeito. É um conjunto de operações de manutenção realizadas com o objetivo mútuo de reduzir a probabilidade de ocorrência de falhas nos maquinários. Este método busca manter as máquinas disponíveis através de inspeções sistemáticas, detecção, substituição, ajuste, calibração, limpeza, dentre outros (BROWN; DINIZ, 2017).

### 2.9.3. Manutenção corretiva

A manutenção corretiva, por sua vez, trata-se do conjunto de operações de manutenção realizadas pós falhas, com o objetivo de reparar os possíveis danos causados e tornar a máquina novamente disponível para a operação. A utilização desse método deve ser baseada na análise comparativa entre o dispêndio de capital para realizá-lo e o dispêndio para prevenir a falha, considerando também todos os custos relacionados às perdas por interrupções (BROWN; DINIZ, 2017).

É importante salientar que, ainda que seja economicamente viável, esse método pode representar um agravante operacional responsável pela redução da disponibilidade mecânica dos maquinários e conseqüentemente formação de gargalos produtivos que podem interferir diretamente na qualidade operacional do empreendimento (FONTES; MACHADO, 2014). Além disso, os tomadores de decisão, ao optarem por esse método, devem levar em consideração que a ocorrência de falhas e a realização de reparos corriqueiros não é algo saudável ao processo, tanto em relação ao maquinário quanto à segurança física dos operadores.

## 2.10. Redes neurais artificiais

O uso de ferramentas computacionais é importante para auxiliar na tarefa de planejamento e redução de custos na colheita florestal mecanizada. As RNAs constituem uma meta-heurística baseada na estrutura e funcionamento do cérebro humano, sendo úteis no reconhecimento de padrões baseados no acúmulo de experiência ou exemplos, treinamento de conhecimento armazenado e resolução de uma situação específica (BELCAVELLO, 2022).

Uma RNA, é um sistema computacional combinado por várias unidades de processamento simples (neurônios artificiais), difundidas paralelamente e interligadas de maneira específica para executar uma determinada tarefa (HAYKIN, 2001; BULLINARIA, 2014). Essas conexões estão relacionadas a pesos, e a adaptação deles é realizado por um método de treinamento ou aprendizado, que consiste em estudar as características dos dados e armazenar as informações nas redes (BINOTI, 2012).

Em definição, as RNA podem ser explicadas como forma de sistemas paralelos, em que seus neurônios artificiais estão interligados e organizados em várias camadas, formando um amplo número de conexões. Em cada uma dessas conexões, está atribuído um peso sináptico, que é ajustado para transformar cada entrada recebida de acordo com o treinamento recebido, produzindo assim os resultados almejados (Figura 9), (ARTERO, 2009; BORG et al. 2016).

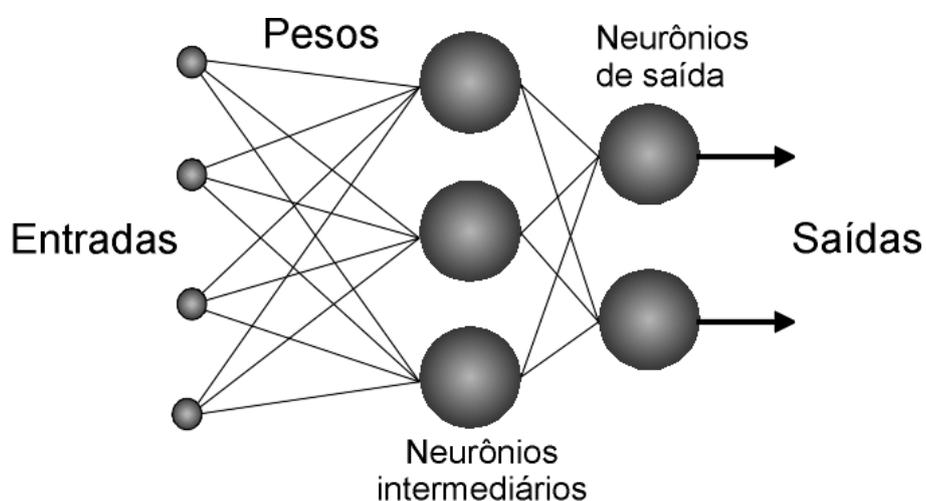


Figura 9. Exemplo de uma RNA.

Fonte: Adaptado de Silva et al. (2010a).

A maneira como os neurônios estão conectados forma a estrutura da rede. A escolha da arquitetura geralmente é feita com base no nível de complexidade do problema a ser analisado. Experimente diferentes arquiteturas até encontrar a melhor para você, pois não existe uma regra específica sobre qual escolher. As categorias de arquiteturas são separadas de acordo com o quão bem elas lidaram com os testes e qual delas teve melhor desempenho na projeção futura.

As redes podem ser classificadas quanto ao número de camadas em redes de camada única ou redes de múltiplas camadas (BRAGA et al., 2000; BULLINARIA, 2014). Dentre as principais podem ser citados o *Perceptron* de Multicamadas (PMC) ou *Multilayer Perceptron* (MLP).

Os tipos de redes neurais artificiais multicamadas *perceptron* (MLP) são os usados atualmente devido à sua versatilidade e capacidade de resolver problemas que vão dos mais simples aos mais complexos. As especificações MLP podem ser ajustadas em uma rede de acordo com a especificação do problema e a precisão desejada. No entanto, a complexidade do problema não existe uma arquitetura predefinida. É preciso estudar a melhor alternativa, a melhor arquitetura de rede. A primeira camada de uma rede tipo MLP consiste em unidades de entrada, com as variáveis independentes (Figura 10). A última camada contém as unidades de saída, anexas às variáveis dependentes. As demais unidades do modelo são denominadas unidades escondidas e constituem as camadas intermediárias (BRAGA, 2007).

A existência de uma ou mais camadas escondidas em uma MLP, possibilita a extração de estatísticas de ordem elevada do problema tratado e a melhoria da capacidade de solução de problemas (HAYKIN, 2001).

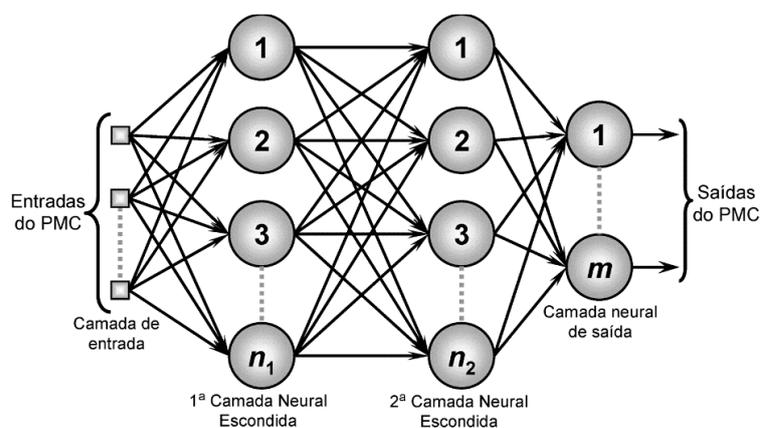


Figura 10. Exemplo de uma RNA tipo *Perceptron* de multicamadas (MLP).

Fonte: Adaptado de Silva et al. (2010a).

Depois de escolher uma arquitetura de uma rede do tipo MLP e conjuntos de dados de entradas e saídas, ela é treinada usando um algoritmo de aprendizado para estimar a relação entre as entradas e saídas. A rede neural pode então ser usada para modelar ou prever a resposta correspondente ao novo padrão. Esse processo é uma questão de conexão com problemas de conexão em relação tradicional, onde se deseja relacionar entre variáveis dependentes e dependentes (HAYKIN, 2001).

Durante o aprendizado ou treinamento, um conjunto de exemplos (por exemplo, tentativas), respostas são conhecidas, são apresentadas à rede. Alimentar dados de entrada para o sistema e obter um conjunto de respostas (saídas). As saídas da rede são comparadas com as respostas anteriormente conhecidas e, da diferença entre elas, é obtido o erro. Mediante o valor do erro, os pesos sinápticos são acomodados e o processo é repetido sistematicamente, até atingir escala satisfatória de acordo com o erro (HAYKIN, 2001; BRAGA, 2007).

Posteriormente o treinamento da rede, testa-se sua capacidade de generalização, ou seja, sua validação. Para isso, os dados que não fazem parte do conjunto de treinamentos são apresentados à rede e as respostas que ela fornece são para controlar seu desempenho. Devido a essas capacidades de processamento, tornam possível solucionar problemas complexos (de grande escala) que são, muitas das vezes, intratáveis por outras metodologias de modelagem (HAYKIN, 2001; BRAGA, 2007).

De acordo com Bullinaria (2014) a modelagem por meio de redes neurais proporciona algumas vantagens, como: adaptabilidade da rede (a rede pode ser ajustada para um novo ambiente por meio da troca de padrões de entrada, retreinada para lidar com alterações e, agir em ambiente não estacionário), facilidade de coletar novas informações do meio (dados de novos provenientes de novos ensaios, por exemplo) e resistência a falhas e ruídos (treinamento possível na presença de ambos, fato este, muito comum em dados experimentais).

As RNA estão sendo utilizadas, com êxito, no setor florestal. Gordon (1998) afirma que as redes neurais artificiais se sobressaem quando comparadas com métodos tradicionais de modelagem do crescimento florestal. Diamantopoulou (2005) completou que as redes têm alto potencial para aplicação em modelagem florestal, sendo útil como opção às técnicas tradicionais.

Binoti (2012), utilizando-se de RNA, desenvolveu um modelo para estimação da altura de árvores eficiente e que pode ser utilizado, com vantagens, em substituição aos usuais modelos hipsométricos.

De semelhante forma Gonçalves (2017), testou a modelagem de redes neurais artificiais, e as comparou com método de regressão linear, constatando que as RNA foram mais eficazes na predição das produtividades de *harvesters*, para a colheita de eucalipto.

#### 2.10.1. Neurônio artificial

Um neurônio artificial consiste na unidade de processamento simples da RNA e baseia-se na estrutura e funcionamento de um neurônio biológico. Semelhante aos neurônios biológicos, os neurônios artificiais individuais possuem capacidade computacional limitada, porém, quando agrupados, tornam-se um conjunto de neurônios artificiais conectados entre si, constituindo uma rede, sendo esta, capaz de solucionar problemas de grande complexidade (BINOTI, 2012).

Possui elementos simples como pesos sinápticos, uma unidade de soma (combinador linear), função de ativação, e um limiar de ativação aplicado externamente, que tem a função de regular a entrada da função de ativação (HAYKIN, 2001).

#### 2.10.2. Algoritmos de treinamento

O treinamento de uma RNA, é realizado por um algoritmo de treinamento, este por sua vez possui função de ajustar os pesos sinápticos da rede, até que o objetivo definido seja alcançado (HAYKIN, 2001). O algoritmo de treinamento utilizado influencia a saída dos mínimos locais, a performance da tarefa desejada e o tempo de treinamento (BINOTI, 2012).

Dentre os algoritmos mais utilizados, o algoritmo retropropagação do erro é um dos mais conhecidos. Esse algoritmo ajusta primeiramente os pesos da camada de saída conforme a diferença entre a saída desejada e a apresentada pela rede. Posteriormente, esse erro é retropropagado para os neurônios das camadas anteriores, e a resposta desejada de um neurônio de uma camada será determinada em função das camadas posteriores (SILVA et al., 2010). No entanto,

o algoritmo retropropagação do erro tem algumas desvantagens conhecidas, como convergência lenta, podendo levá-lo a ser superados por outros algoritmos (OZÇELIK et al., 2010).

Posteriormente a esse algoritmo, outros foram criados com a finalidade de melhorar o ajuste das relações e, conseqüentemente, reduzir o erro.

### 2.10.3. Algoritmo retropropagação do erro - *Backpropagation*

Também conhecido como regra delta generalizada, a aplicação desse algoritmo possui duas etapas: propagação adiante e retropropagação do erro (FREITAS, 2017).

Possui a característica em realizar o treinamento, realizar análise dos resultados e posteriormente retreinar com os valores já conhecidos, fazendo esta repetição até que se atinja o valor pré-estabelecido do erro (HAYKIN, 2001).

### 2.10.4. Algoritmo *Resilient Propagation*

Esse algoritmo pode ser considerado como uma variação do algoritmo de retropropagação do erro, considerando a variação do sinal do erro, ao invés da variação da amplitude do gradiente da função do erro (SILVA et al., 2010). Conforme os autores, a taxa de aprendizagem desse algoritmo se modifica continuamente, sendo aumentada quando os sinais dos gradientes forem os mesmos, ou reduzida quando os sinais forem diferentes, identificando assim que o limite mínimo foi superado.

*Resilient propagation* é o algoritmo que possui seus resultados em superioridade sobre os demais algoritmos de treinamento para RNA do tipo Multilayer Perceptron (MLP) em aplicações no contexto florestal (BINOTI et al., 2014; MARTINS et al., 2016; LEITE et al., 2016).

### 2.10.5. Algoritmo *Quick Propagation*

Baseando-se no método de Newton, esse algoritmo é utilizado para obtenção de raízes de uma função e é condescendente a elevadas taxas de aprendizado (LEITE et al., 2016).

Para Braga et al. (2000), a principal diferença do algoritmo *quick propagation* para o *backpropagation* é que para cada peso são utilizadas as tendências anteriores e atual do nível do erro, considerada localmente quadrática, procurando sair da posição atual para o ponto de mínimo da parábola.

De acordo com esses autores, se a aptidão atual for menor que a anterior e no mesmo sentido, o peso será combinado na mesma direção e o tamanho desse ajuste dependerá de quanto a combinação foi reduzida no ajuste prévio. Se a combinação atual for na direção oposta à inclinação associada ao ajuste anterior, isto constitui que o ponto de mínimo foi superado. Dessa forma, o ajuste subsequente será para uma posição entre a posição anterior e a atual.

### 2.11. Modelo de regressão linear

Proposto primordialmente por Sir Francis Galton em 1885, em um estudo onde evidenciou que a altura dos filhos não obrigatoriamente pode vir a representar a altura dos pais, mas tende sim a ser representativa para a média quando avaliada para a população. O termo análise de regressão define-se por um conjunto amplo de técnicas estatísticas utilizadas para modelar relações entre variáveis e prever o valor de uma ou mais que são dependentes (ou de resposta) a partir de um conjunto de variáveis independentes (ou preditoras) (MAROCO, 2003).

A análise de regressão analisa a dependência da característica de interesse, em relação a uma ou várias variáveis, com o objetivo de estimar o valor médio da característica de interesse em função dos valores conhecidos das variáveis de controle (GUJARATI, 2000; NETER et al., 2005).

Uma definição importante a ser atribuída a um modelo é quanto ao fato de este ser classificado como um modelo linear ou não linear. É importante ressaltar que não linearidade, neste caso, não se refere à curvatura da função média, mas, sim, ao espaço dos parâmetros envolvidos. Um modelo é dito linear se o espaço caracterizado por seus parâmetros for linear, ou seja, se a variável dependente aparece associada às variáveis independentes como uma combinação linear destas; caso contrário, é dito não linear (VELOSO, 2012).

### 2.11.1. Modelo de regressão linear simples

Os termos de regressão linear simples podem ser definidos como a relação linear entre a variável independente ( $X$ ) e uma dependente ( $Y$ ). Podendo ser representado pela Equação 4:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \varepsilon_i \quad i = 1, \dots, n. \quad (4)$$

Em que:

$Y_i$  = valor da variável resposta ou dependente,  $Y$ ;

$X_{i1}$  = valor da variável independente;

$\beta_0 + \beta_1$  = correspondem aos parâmetros do modelo;

$\varepsilon_i$ , = correspondem aos erros aleatórios.

Segundo Neter et al. (2005), a equação (13) é dita simples, pois demonstra a relação entre uma característica de interesse e uma variável de controle. É linear nos parâmetros, pois nenhum dos parâmetros aparece como expoente ou está sendo multiplicado ou dividido por outros parâmetros.

Para o uso de regressão linear simples, é necessário utilizar um gráfico de dispersão, que, conforme Montgomery; Runger (2003) é uma ferramenta de cada par  $(X_i, Y_i)$ , em um ponto plotado em um sistema bidimensional, a qual indica se os pontos estão eventualmente dispersos por meio de uma linha reta.

Se define uma relação linear simples, se a variável resposta é descrita por uma única variável explicativa em um modelo linear. Mas, se em vez de uma, tivermos incorporadas ao modelo linear várias variáveis independentes, teremos, então, um modelo de regressão linear múltipla.

### 2.11.2. Modelo de regressão linear múltipla

Para o modelo de regressão linear múltipla, procura-se prever uma variável dependente  $Y$ , assumindo sua relação linear com mais de uma variável independente, ou seja, inúmeras variáveis independentes  $k$  cujo modelo da  $i$ -ésima observação pode ser expressa como:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \varepsilon_i \quad i = 1, 2, \dots, n. \quad (5)$$

Em que:

$Y_i$  = valor da variável dependente;

$X_{i1} + X_{i2} + \dots + X_{ik}$  = são valores da  $i$ -ésima observação das  $p$  variáveis explicativas, (constantes conhecidas);

$\beta_0 + \beta_1 + \beta_2 + \dots + \beta_k$  = parâmetros ou coeficientes de regressão;

$\varepsilon_i, i = 1, \dots, n$  = correspondem aos erros aleatórios.

Os coeficientes de regressão de  $\beta_0, \beta_1, \dots, \beta_k$  são descritos por Gujarati (2000) e Montgomery et al. (2001) como:

- a) o coeficiente  $\beta_0$ , chamado de coeficiente de intercepto, o qual corresponde à média de  $Y_i$  quando todas as variáveis de controle são iguais a zero;
- b) os coeficientes  $\beta_1, \dots, \beta_k$  são nominados de coeficientes de regressão parciais. O coeficiente  $\beta_k$  pode ser interpretado como a derivada parcial de  $Y_i$  em relação a  $X_{ki}$ , ou seja, é variação de  $Y$  causada por uma variação unitária em  $X_k$  dado que as demais variáveis de controle sejam constantes.

A aplicação mais comum dos modelos de regressão é na estimação da característica de interesse  $Y$  para um aglomerado de valores das variáveis de controle do modelo. Esta estimativa pode ser utilizada de duas formas: (i) estimação da resposta média e (ii) predição de novas observações. A discrepância entre essas duas observações recai no fato de que a estimativa da resposta média é calculada com base em um conjunto de valores das variáveis de controle que foi utilizado para estimar o modelo de regressão, enquanto a previsão de novos valores é estimada por meio de um conjunto de valores para as variáveis de controle.

### 3. MATERIAL E MÉTODOS

#### 3.1. Descrição dos dados

Os dados do processo de colheita florestal foram obtidos, compilados e organizados em banco de dados de acompanhamento de produção de uma empresa do setor florestal localizada na região extremo sul do Estado da Bahia e norte do Estado do Espírito Santo.

As áreas avaliadas, onde as máquinas executaram as atividades de colheita florestal, eram compostas por relevo plano à suave ondulado (com declividade máxima de até 5%), altitudes entre 10,0m e 50,0m. O clima é tropical Aw classificado segundo Köppen, com precipitação média anual entre 1.350 e 1.375 mm, sendo o período chuvoso de outubro a dezembro e o período seco de julho a setembro, tendo ainda de janeiro a junho irregularidades pluviométricas. Nessas áreas predominam os solos: argissolo amarelo abrupto A, planossolo A moderado ou A proeminente e neossolo quartzarênico (SILVA et. al, 2014). O período de coleta dos dados foi durante os meses de abril a julho de 2021.

#### 3.2. Banco de dados

Nesta pesquisa, foram analisados os sistemas de colheita de toras curtas (*cut-to-length*) com *harvester* e *forwarder* e o de árvores inteiras (*full-tree*) composto por *feller-buncher*, *skidder* e garra traçadora.

O banco de dados utilizado foi composto por informações de 12 *harvesters*, 4 *forwarders*, 2 *feller-bunchers*, 2 *skidders* e 2 garras traçadoras, 92 operadores em revezamento de três turnos com oito horas de duração em um período de 122 dias, totalizando 19.565,58 horas trabalhadas, em 202 unidades de produção (UP) com dois tipos de clones distintos. O volume médio individual (VMI) variou de 0,06 a 0,41m<sup>3</sup>. Foram utilizados dados do cadastro florestal (área útil, clone, espaçamento, manejo futuro, volume de corte sem casca (VCSC) e do inventário pré-corte (IPC), UP e VMI.

As informações foram provenientes de plantios clonais de híbridos de *Eucalyptus urophylla* e *Eucalyptus grandis* distribuídos em dois módulos. O módulo do sistema de árvores inteiras está situado no norte do Estado do Espírito Santo

nos municípios de Pedro Canário, Conceição da Barra e São Mateus e o módulo do sistema CTL está situado no extremo sul do Estado da Bahia, nos municípios de Mucuri e Nova Viçosa (Figura 11). A Tabela 1 a seguir, contém informações das atividades na área estudada.

Tabela 1. Características das atividades.

Item	<i>Full-tree</i>	<i>Cut-to-length</i>
Estado	Espírito Santo - ES	Bahia - BA
Municípios	São Mateus, Pedro Canário e Conceição da Barra	Nova Viçosa e Mucuri
Declividade de operação	< 5°	< 5°
Idade média do plantio	6,3 anos	6,1 anos
Espaçamentos	3m x 3m	3m x 3m
Tamanho de tora	≤ 6,5m	≤ 6,5m
Período de operação	24h	24h
Unidades de produção	143	59
Finalidade	Celulose	Celulose
Período de coleta	01/04/21 à 31/07/21	01/04/21 à 31/07/21

Fonte: O autor (2022).

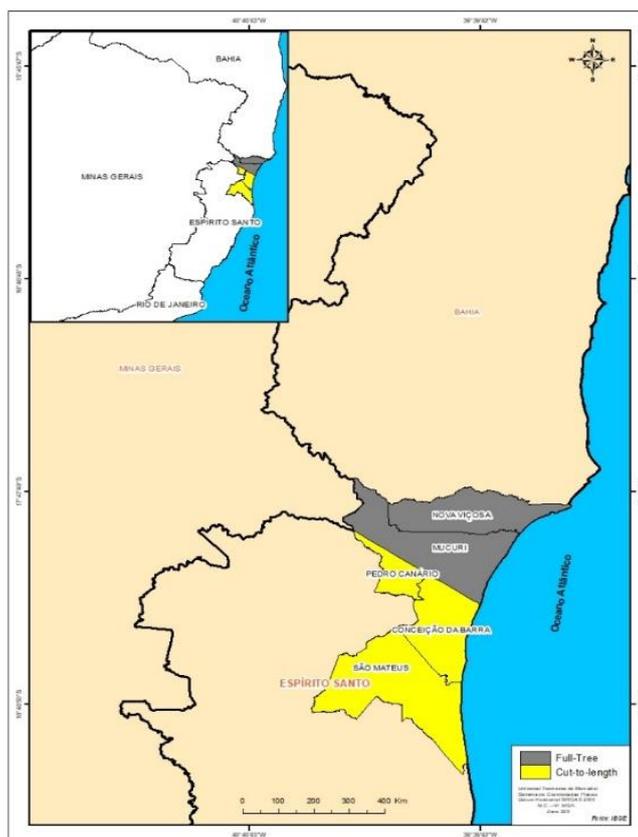


Figura 11. Localização dos municípios de realização da pesquisa.

Fonte: O autor (2022).

### 3.3. Sistema de colheita de madeira

#### 3.3.1. Sistema de colheita de árvores inteiras (*full-tree*)

Este sistema baseia-se em remover do talhão a árvore sem raízes, como operação subsequente ao corte. O processamento é realizado geralmente nas margens do talhão ou em pátios temporários. As principais máquinas utilizadas neste sistema são: *feller-buncher*, *skidder* e garras traçadoras (MACHADO, 2014).

As toras produzidas mediram tamanho máximo de 6,5m de comprimento, provenientes de plantios com média de 6,3 anos de idade e espaçamento de 3m x 3m. As máquinas utilizadas na operação do sistema *full-tree* e geração do banco de dados foram o *feller-buncher* modelo 959M (Figura 12), *skidder* 948L (Figura 13) e garra traçadora 2144G (Figura 14), ambos da marca John Deere.



Figura 12. *Feller-buncher* 959M.

Fonte: O autor (2022).



Figura 13. *Skidder 948L*.

Fonte: O autor (2022).



Figura 14. *Garra-traçadora 2144G*.

Fonte: O autor (2022).

A especificação técnica das máquinas utilizada no sistema CTL, encontram-se descritas na Tabela 2.

Tabela 2. Características técnicas para as máquinas do sistema *full-tree*.

Item	<i>Feller-buncher</i>	<i>Skidder</i>	Garra traçadora
Fabricante	John Deere	John Deere	John Deere
Modelo	959M	948L	2144G
Rotação da cabine	360°	-	360°
Peso (kg)	37.760	22.484	25.572
Comprimento (m)	7,1	8,4	9,73
Largura (m)	3,3	3,57	3,19
Nivelamento de cabine	Automático	-	-
Potência motor (Hp)	330	281	159
Cilindrada (cm <sup>2</sup> )	9,0	9,0	6,8
Torque (lb-ft)	1.527	1.276	-
Força de tração (kN)	373	262	222
Velocidade máxima (km/h)	3,6	25	4,83
Alcance do braço (m)	9,1	-	8,5
Rodados	Esteiras	Pneu	Esteiras
Chassis	Fixo	Articulado	Fixo
Capacidade de carga	-	2,1(m <sup>3</sup> )	-

Fonte: John Deere (2022).

As atividades desempenhadas pelas máquinas mencionadas para o sistema *full-tree*, podem ser descritas da seguinte forma:

#### *Feller-buncher*:

- Derrubada: consiste em uma das etapas do corte em que ocorre posteriormente após o abate das árvores e deposição dos feixes no solo;
- Direcionamento do feixe para o solo: consiste em depositar ao solo as árvores manejadas.

#### *Skidder*:

- Deslocamento vazio: deslocamento da máquina no talhão até o local da madeira acumulada a ser carregada;
- Manobra e carga: Consiste na etapa em que a máquina acumula o feixe de madeira na pinça e o prepara para o arraste;
- Arraste: deslocamento “carregado”, onde a máquina realiza a movimentação das árvores arrastando-as para as bordas do plantio;
- Manobra e descarga – Deposição dos feixes às margens da estrada e/ou local de destino.

Garra traçadora:

- Traçamento: seccionamento do fuste às margens da área em dimensões de acordo com o padrão estabelecido;
- Empilhamento: acomodação das toras pós traçamento em formato de pilha às margens da área.

A esquematização das operações realizadas no modal de colheita mecanizada *full-tree*, podem ser ilustradas conforme a Figura 15 a seguir.

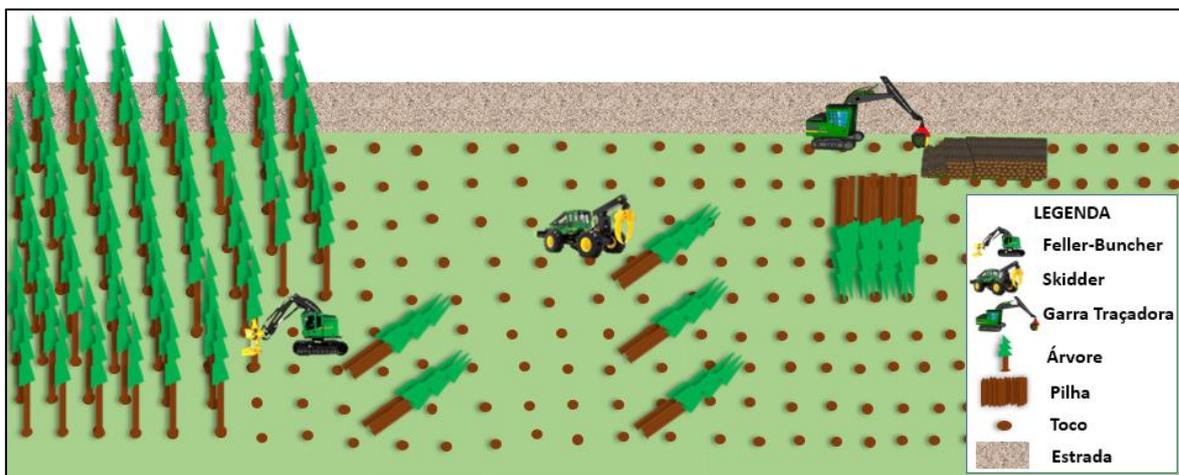


Figura 15. Sistema de colheita florestal mecanizada *full-tree*.

Fonte: O autor (2022).

A produtividade do sistema *full-tree*, foi obtida em metros cúbicos por hora efetiva ( $m^3hf^{-1}$ ), determinada pelo volume de madeira derrubada e processada no interior do talhão pelas horas de trabalho efetivo.

### 3.3.2. Sistema de toras curtas (*cut-to-length*)

O *cut-to-length* ou sistema de toras curtas, possui como características a realização de todas as atividades complementares ao corte (desgalhamento, destopo, traçamento e descascamento). Neste sistema as atividades são desenvolvidas pela combinação de um *harvester* e um *forwarder*. As toras produzidas mediram tamanho máximo de 6,5m de comprimento, provenientes de plantios com média de 6,1 anos de idade e espaçamento de 3m x 3m. As máquinas utilizadas na operação do sistema CTL e geração do banco de dados foram o *harvester* PC200 séries 8F MO, equipada com cabeçote 370E (Figura 16) e

*forwarder* 895 (Figura 17), ambos do fabricante Komatsu, com características técnicas descritas nas tabelas 1.



Figura 16. *Harvester* PC200F com cabeçote 370E.

Fonte: O autor (2022).



Figura 17. *Forwarder* 895.

Fonte: O autor (2022).

A especificação técnica das máquinas utilizada no sistema CTL, encontram-se descritas na Tabela 3.

Tabela 3. Características técnicas para as máquinas do sistema CTL.

<b>Item</b>	<b>Harvester</b>	<b>Forwarder</b>
Fabricante	Komatsu	Komatsu
Modelo	PC200 8F MO	895
Rotação da cabine	360°	-
Peso (kg)	21.900	20.700
Comprimento (m)	9,5	10,8
Largura (m)	2,90	3,3
Nivelamento de cabine	-	-
Potência motor (Hp)	155	214
Cilindrada (cm <sup>2</sup> )	6,7	7,4
Torque (lb-ft)	-	1.280
Força de tração (kN)	178	262
Velocidade máxima (km/h)	5,5	23
Alcance do braço (m)	9,38	8,5
Rodados	Esteiras	Pneu
Chassis	Fixo	Articulado
Capacidade de carga	-	20 (ton)

Fonte: Komatsu (2022).

As atividades desempenhadas pelas máquinas mencionadas podem ser descritas da seguinte forma:

Para o *harvester*:

- Derrubada: consiste em uma das etapas do corte em que ocorre o abate da árvore;
- Desgalhamento: retirada de todos os galhos da árvore por meio de um deslizamento horizontal do fuste da árvore no interior do cabeçote *harvester*;
- Descascamento: retirada da casca simultaneamente com o desgalhamento;
- Traçamento: seccionamento do fuste em dimensões de acordo com o padrão;
- Embandeiramento: formação de pequenas pilhas posteriormente ao seccionamento (organização dos toretes para a extração).

Para o *forwarder*:

- Deslocamento vazio: Deslocamento da máquina no talhão até o local da madeira embandeirada a ser carregada;
- Carregamento: Deposição da madeira no compartimento de carga;

- Deslocamento carregado: Extração da madeira do interior do talhão até a margem da estrada;
- Descarregamento: Retirada da madeira do compartimento de carga e empilhamento na margem da estrada.
- Empilhamento: Formação da pilha de madeira na borda do talhão para posteriormente transporte.

As operações realizadas no modal de colheita mecanizada de toras curtas (*cut-to-length*), podem ser ilustradas conforme a Figura 18 a seguir.

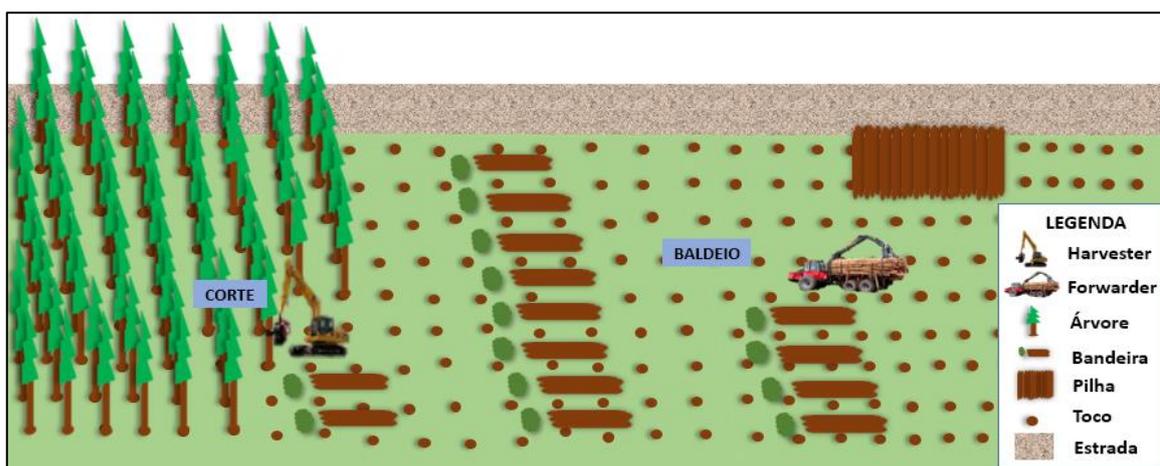


Figura 18. Sistema de colheita florestal mecanizada *cut-to-length*.

Fonte: O autor (2022).

A produtividade do sistema de árvores inteiras (CTL) foi obtida em metros cúbicos por hora efetiva ( $\text{m}^3\text{h}^{-1}$ ), determinada pelo volume de madeira derrubada e processada no interior do talhão pelas horas de trabalho efetivo.

### 3.4. Disponibilidade Mecânica

O cálculo da disponibilidade mecânica, foi realizado utilizando a seguinte equação:

$$DM(\%) = \frac{HT - HPM}{HT} \times 100 \quad (1)$$

Em que:

$DM$  (%) = Disponibilidade Mecânica em %;

$HP$  = Horas totais programadas;

$HM$  = Horas de manutenção.

### 3.4.1. Descrição dos fatores que influenciam a disponibilidade mecânica das máquinas

As variáveis avaliadas, possuíam caráter qualitativo e quantitativo. Variáveis qualitativas presentes no banco de dados são aquelas que não possuíam interferência direto nos resultados, sendo elas: data de operação, operador, identificação da máquina, diferença de produção e produção planejada.

Para as variáveis quantitativas consideradas neste estudo para a modelagem da disponibilidade mecânica (DM), para as máquinas de *cut-to-length* e *full-tree* foram: horas trabalhadas (HT); horas de parada mecânica (HPM); volume médio individual (VMI), produção em metros cúbicos por hora ( $m^3-h$ ), produção em árvores por hora (Arv/h), consumo de óleo hidráulico (Hdr).

Todas as variáveis foram extraídas dos dados de inventário pré-corte e do cadastro dos operadores, relacionadas com o registro de produção dos operadores na operação de corte dos talhões, por meio do apontamento eletrônico das máquinas utilizadas no processo (computador de bordo).

### 3.4.2. Descrição das variáveis

#### 3.4.2.1. Horas trabalhadas

A distribuição das horas trabalhadas para o *full-tree* (a) e CTL (b), podem ser observadas na Figura 19 a seguir.

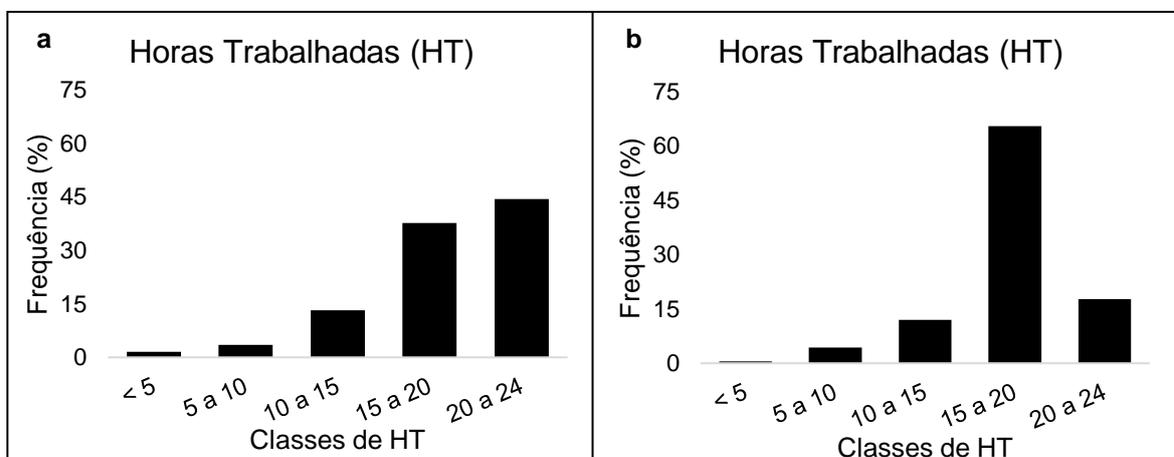


Figura 19. Histograma de frequência dos valores de HT. (a) *full-tree* e (b) CTL.

Fonte: O autor (2022).

Mediante a distribuição do histograma, notou-se que a maior quantidade de dados para o *full-tree* encontrou-se dentro da classe de 20 a 24h, enquanto CTL na classe de 15 a 20h de trabalho.

#### 3.4.2.2. Horas de paradas mecânicas (HPM)

O histograma para a variável quantitativa horas de paradas mecânicas (HPM), é demonstrado pela Figura 20. Por meio desta, notou-se para ambos os sistemas de colheita, a frequência mais representativa, ficou na classe onde contemplavam os dados de HPM inferiores a 5h, cerca de 90% parar *full-tree* e 85% para CTL.

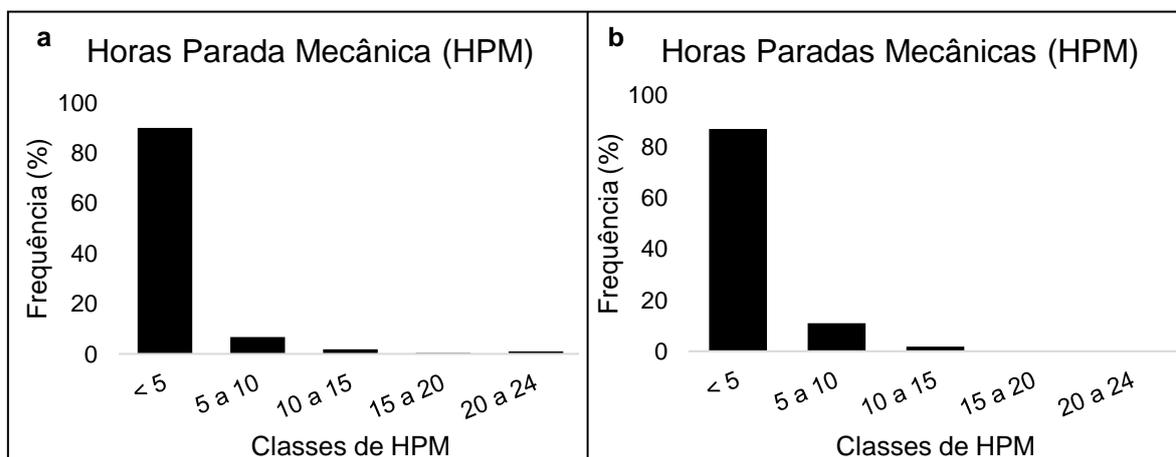


Figura 20. Histograma de frequência dos valores de HPM. (a) *full-tree* e (b) CTL.

Fonte: O autor (2022).

#### 3.4.2.3. Árvores por hora (Arv/h)

Para a variável de meta de corte de árvores por hora (Arv/h), a quantidade de árvores concentrou-se em classes de valores bem distintos, fato este diretamente relacionado às características das máquinas utilizadas em cada sistema (*feller-buncher* e *harvester*). Para o *full-tree*, 60% dos dados concentraram-se nas classes de 200 a 400 e 400 a 600 árvores por hora enquanto CTL a maior parte (45%) na classe de 100 a 150 árvores por hora. A Figura 21, contempla os histogramas com as divisões citadas.

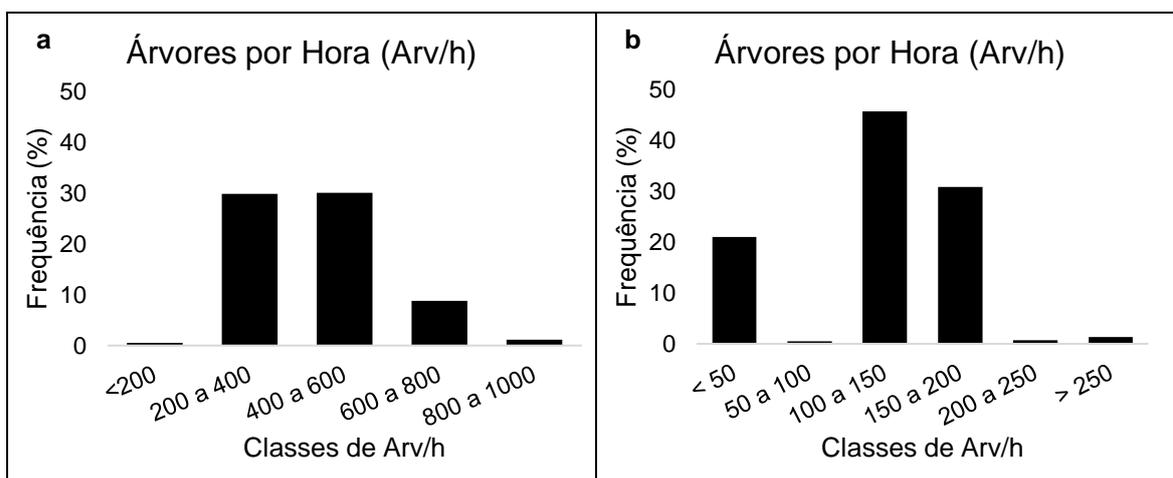


Figura 21. Histograma de frequência dos valores de árvores por hora (Arv/h). (a) *full-tree* e (b) CTL.

Fonte: O autor (2022).

#### 3.4.2.4. Volume médio individual (VMI)

O VMI do povoamento tem uma relação direta com a produtividade das máquinas que contemplam a colheita florestal, à medida que aumenta o volume médio individual das árvores, maior será a produtividade da máquina (GONÇALVES, 2017). Por se tratar de povoamentos de madeira de eucalipto para produção de celulose, o VMI dos talhões colhidos foi baixo, não ultrapassou o valor de  $0,41\text{m}^3$ . A amplitude dos valores de VMI dos talhões avaliados pode ser observada na Figura 22, onde a classe de VMI com amplitude entre 0,08 e 0,14, concentraram a maior porcentagem dos dados, 45% para o *full-tree* e 80% para o CTL.

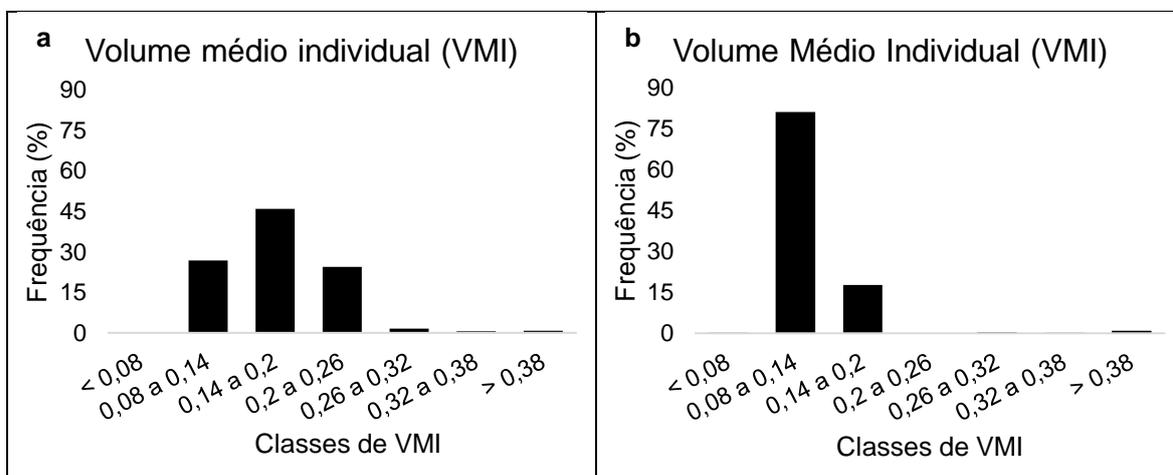


Figura 22. Histograma de frequência dos valores de VMI. (a) *full-tree* e (b) CTL.

Fonte: O autor (2022).

### 3.4.2.5. Metros cúbicos por hora (m<sup>3</sup>/h)

A variável metros cúbicos por hora (m<sup>3</sup>/h), consiste no cálculo simples de Arv/h x VMI, de acordo com os dados estudados, o sistema *full-tree* concentrou-se em maior parte, o volume de produção na classe entre 50 a 100 m<sup>3</sup>/h (58% dos dados), seguido por 30% na classe de 100 a 150 m<sup>3</sup>/h, para o CTL, 45% dos dados encontrou-se na classe de 15 a 30 m<sup>3</sup>/h, e 35% na classe de 0 a 15 m<sup>3</sup>/h. As classes distintas para os sistemas de colheita, estão relacionadas às capacidades técnicas de produção das máquinas estudadas. A Figura 23, contempla o histograma para os dados de m<sup>3</sup>/h.

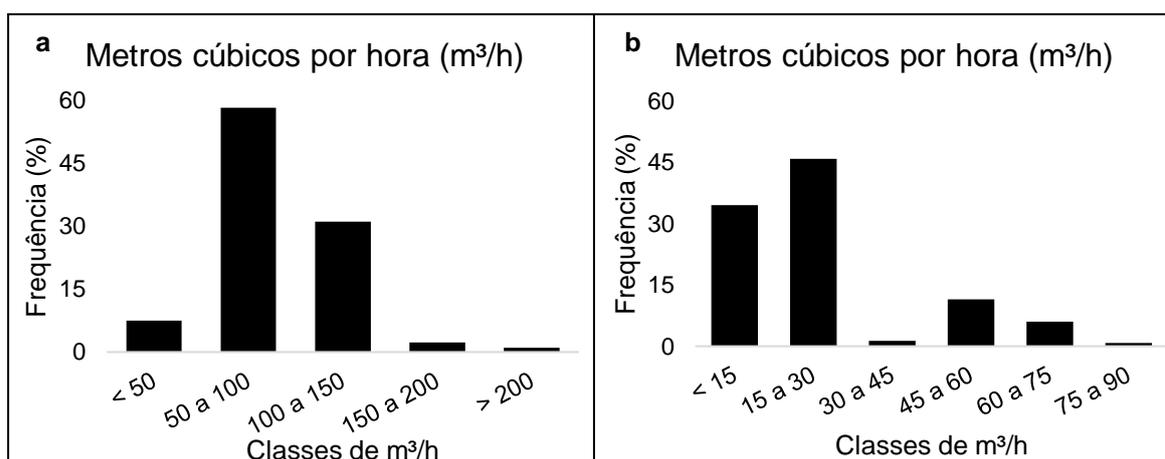


Figura 23. Histograma de frequência dos valores de m<sup>3</sup>/h. (a) *full-tree* e (b) CTL.

Fonte: O autor (2022).

### 3.4.2.6. Óleo hidráulico por hora (Hdr)

O consumo de óleo hidráulico foi um dos itens contemplados no banco de dados e utilizado como variável de entrada, tal variável está relacionada à “saúde” da máquina, conseqüentemente ligada a disponibilidade mecânica (DM) da mesma. Para ambos os sistemas de colheita avaliados a classe com valores de consumo de Hdr de até 0,5 litros por hora, foi a mais evidente, contendo cerca de 90% dos valores para o *full-tree* e 80% para o CTL. A Figura 24 a seguir, contempla por meio do histograma a distribuição entre as classes.

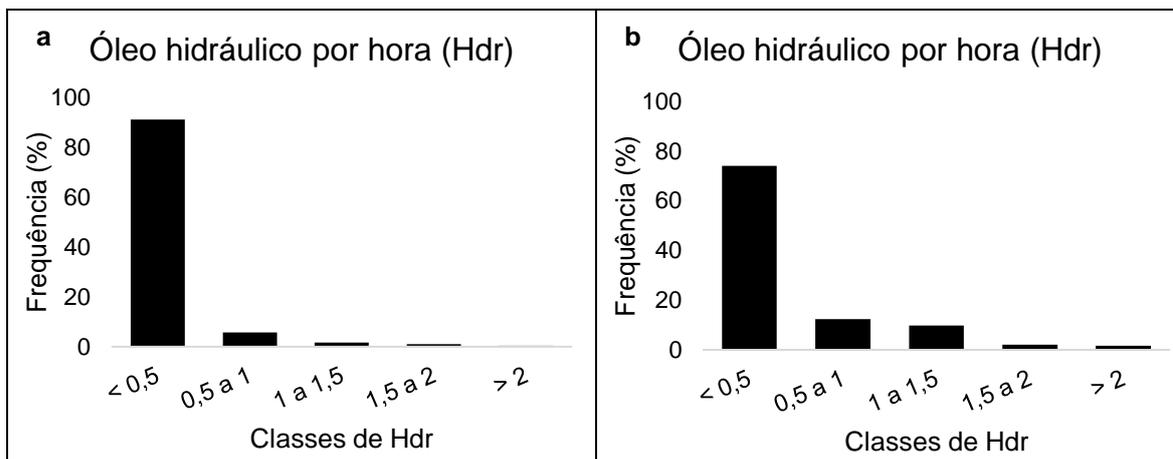


Figura 24. Histograma de frequência dos valores de Hdr. (a) *full-tree* e (b) CTL.

Fonte: O autor (2022).

### 3.5. Configuração das redes neurais artificiais

#### 3.5.1. Modelagem das redes neurais artificiais (RNA)

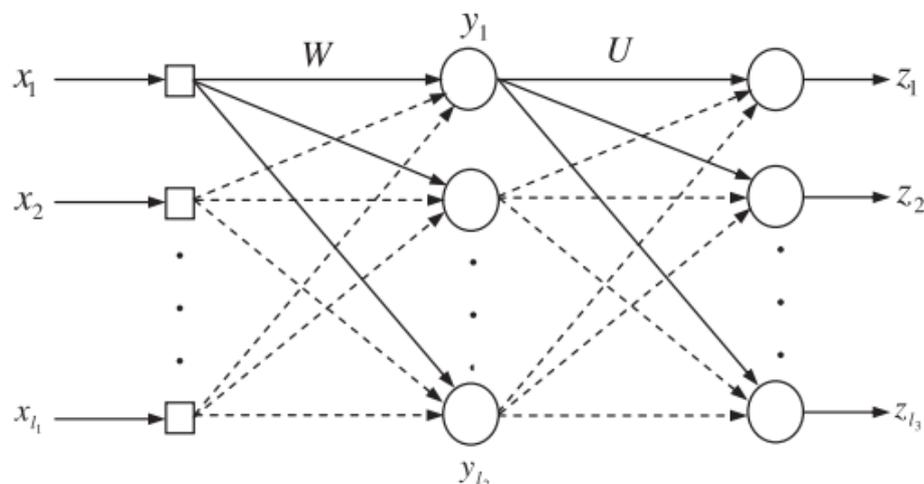
As RNA consideraram variáveis quantitativas na solução de problemas. Com a utilização do software *NeuroDAP* versão 4.0.6, foram selecionadas as variáveis de entrada, HT, HPM, VMI,  $m^3/h$ , Arv/h e Hdr, para cada sistema de colheita (*full-tree* e CTL), tendo como saída a disponibilidade mecânica.

No software os critérios foram selecionados de acordo com a configuração a ser testada, sendo eles: número de neurônios da camada oculta, percentual de amostragem entre treino e validação, tipo de algoritmo de treinamento, número de redes e função de ativação. Cada configuração foi realizada de forma alternada de acordo com a quantidade de característica de cada variável.

#### 3.5.2. Treinamento das redes neurais artificiais

O treinamento de uma RNA também denominado aprendizagem, consiste no ajuste dos parâmetros da rede, através de um algoritmo de aprendizagem, sendo para esta pesquisa, três algoritmos utilizados, *resilient propagation*, *backpropagation* e *quick propagation*, tais algoritmos tem por função extrair características dos dados fornecidos objetivando gerar redes que desempenhem a tarefa de interesse.

As RNA's foram as do tipo *Perceptron* de Múltiplas Camadas (MLP). As MLP são formadas por duas camadas de neurônios artificiais que processam dados de camadas intermediárias e de saída, além de uma camada de neurônios artificiais de entrada (Figura 25).



$X_i$  = variável de entrada;  $Y_i$  = camada oculta;  $W$  = pesos (conexão);  $U$  = caminho de resposta (conexão);  $z_i$  = resposta de saída.

Figura 25. Configuração de redes MLP.

Fonte: Adaptado de Silva et al. (2010a).

As redes foram treinadas alternando o número de neurônios na camada oculta, os algoritmos de treinamento (*backpropagation*, *resilient propagation* e *quick propagation*) e as funções de ativação (logística e sigmoideal). Para a definição do número de camadas ocultas utilizou-se a fórmula:

$$n = 2 * \sqrt{n} + n2 \leq n1 \leq 2 * n + 1 \quad (6)$$

Em que:

$n$  = número de entradas da rede neural;

$n1$  = quantidade de neurônios da camada oculta;

$n2$  = quantidade de neurônios da camada de saída.

Foram treinadas um total de 168 configurações, variando de 5 a 11 neurônios na camada oculta, com amostragens percentuais de treino e validação de 70% treino com 30% de validação e de 80% treino com 20%, totalizando 8400 redes treinadas. O critério de parada utilizado foi o número de 3.000 ciclos e erro médio de 0,0001. Portanto, o treinamento da rede foi interrompido ao atingir algum desses critérios.

Posteriormente ao treinamento das redes, foram selecionadas 6 redes sendo elas a de melhor resultado para cada algoritmo de treinamento, sendo três do *full-tree* e três para o CTL. As redes foram selecionadas com base na correlação entre a disponibilidade mecânica observada e estimada e a raiz quadrada do erro quadrático médio.

$$REQM(\%) = \frac{100}{\overline{DM}} \sqrt{\frac{\sum_{i=1}^n (DM_i - \overline{DM})^2}{n}} \quad (7)$$

$$erro(\%) = \frac{(\widehat{DM}_i - DM_i)}{DM_i} \times 100 \quad (8)$$

Em que:

$\overline{DM}$  é a média dos valores totais da disponibilidade mecânica;

$n$ : é o número total de observações;

$DM$  é o valor da disponibilidade mecânica observada e

$\widehat{DM}$  é o valor da disponibilidade mecânica estimada.

A REQM (%) avalia a precisão da estimativa, e quanto menor, mais preciso, e a correlação indica o grau e a direção da associação entre a disponibilidade mecânica estimada e a observada.

### 3.5.3. Treinamento das redes em função do volume médio individual (VMI)

Diversos autores afirmam que o volume individual das árvores é a variável que mais explica as variações nas produtividades das máquinas de colheita florestal (RICHARDSON; MAKKONEN, 1994; HOLTZSCHER; LANFORD, 1997; MALINOVSKI et al., 2006; MARTINS et al., 2009; SIMÕES et al., 2014).

De evidente relevância nas atividades de colheita florestal mecanizada, a variável VMI, foi testada de forma isolada a fim de verificar sua relação com a predição da disponibilidade mecânica. Para tanto, a mesma foi dividida em classes de VMI, por meio de análise multivariada de agrupamento, dendrograma.

### 3.5.4. Agrupamento de dados - Dendrograma

A análise multivariada de agrupamento foi realizada com o objetivo de agrupar os dados coletados numericamente semelhantes em relação às classes de VMI. Na formação dos grupos, a medida de dissimilaridade da distância euclidiana foi adotada, e a similaridade entre os grupos foi identificada por meio do método *Unweighted Pair Group Method with Arithmetic Average* (UPGMA). Neste método, as médias aritméticas das medidas de dissimilaridade foram utilizadas. A construção do dendrograma é estabelecida pelos modelos ajustados de menor dissimilaridade (Puiatti et al., 2014).

### 3.6. Modelagem com regressão linear

O método tradicional empregado para modelar a disponibilidade mecânica para os modais de colheita florestal utilizou-se modelos de regressão linear simples, com base nas variáveis independentes “x” para estimar a variável dependente “y”. Segue o modelo:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \varepsilon_i \quad i = 1, 2, \dots, n. \quad (9)$$

Em que:

$Y_i$  = Disponibilidade mecânica observada (%);

$X_{i1} + X_{i2} + \dots + X_{ik}$  = variáveis que influenciam na disponibilidade mecânica das máquinas (HT, HPM, m<sup>3</sup>/h, Arv/h, VMI e Hdr);

$\beta_0 + \beta_1 + \beta_2 + \dots + \beta_k$  = coeficientes da equação de regressão;

$\varepsilon_i, i = 1, \dots, n$  = correspondem aos erros aleatórios.

Foi avaliado se as variáveis hora operada (HO), hora parada mecânica (HPM), volume médio individual (VMI), volume em metros cúbicos hora (m<sup>3</sup>h<sup>-1</sup>), número de árvores por hora (Arv/h) e consumo de óleo hidráulico por hora (Hdr), do estudo apresentavam correlação linear significativa, com a disponibilidade mecânica das máquinas para ambos os modais de colheita florestal e entre as mesmas variáveis independentes. Para isso, foi obtido o grau de associação, efetuando-se a análise da matriz de coeficiente de correlação (r) de Pearson, pelo

teste t a 5% e 1% de probabilidade. Assim, as variáveis que apresentaram associação linear com a disponibilidade mecânica das máquinas foram adicionadas ao modelo 1.

### 3.6.1. Avaliação das estimativas

A avaliação das estimativas geradas pelas redes neurais e pelos modelos de regressão foi feita por meio de estatísticas e análise gráfica dos resíduos. As estatísticas empregadas foram a correlação entre os valores estimados e observados, a disponibilidade mecânica das máquinas e a raiz do erro quadrado médio (RMSE%). A análise gráfica consistiu na inspeção estatística da dispersão dos erros (resíduos) percentuais em relação aos valores observados (equação 10):

$$erro(\%) = \frac{(Y - \hat{Y})}{Y} \times 100 \quad (10)$$

Em que:

$Y$  = é o valor observado (disponibilidade mecânica (%)) nos apontamentos de corte mecanizado;

$\hat{Y}$  = é o valor estimado (disponibilidade mecânica (%)) pela RNA ou regressão.

A correlação entre os valores observados e estimados ( $r_{yy}$ ) (equação 11) indica a força e a direção da relação entre as duas variáveis. Embora não permita inferir diretamente sobre igualdade entre valores observados e estimados (CAMPOS; LEITE, 2009), a correlação indica o grau de associação entre valores observados e estimados e, juntamente com a análise de resíduos, permite inferir sobre a qualidade da estimação.

$$r_{yy} = \frac{cov(Y, \hat{Y})}{\sqrt{s^2(Y)}s^2(\hat{Y})} \quad (11)$$

Em que:

$cov$  = covariância.

$s^2$  = variância.

A correlação assume valores entre 0 e 1, de forma que quanto maior for o coeficiente de correlação (próximo de 1), maior é a precisão das estimativas. O coeficiente de correlação pode ser interpretado qualitativamente da seguinte forma

(SHIMAKURA, 2006): de 0,9 a 1,0, existe uma correlação muito forte; de 0,7 a 0,89, indica uma correlação forte; de 0,4 a 0,69 há uma correlação moderada.

A raiz do erro quadrado médio (RMSE) (equação 12) avalia a diferença quadrática média entre os valores observados e os valores estimados. Quanto menor o RMSE, melhor a precisão da estimativa (MEHTÄTALO et al., 2006), sendo:

$$RMSE(\%) = 100 \sqrt{\frac{\sum_{i=1}^n (DM_i - \widehat{DM}_i)^2}{n}} / y \quad (12)$$

Em que:

$\widehat{DM}_i$  = média dos valores observados;

$n$  = número total de observações.

## 4. RESULTADOS E DISCUSSÕES

### 4.1. Variáveis estatísticas

Por meio da utilização do software *NeuroDAP*, foram introduzidos os dados provenientes da base de dados fornecida pela empresa em questão, selecionando as variáveis qualitativas e quantitativas para treinamento das redes, tornou-se possível validar a estimativa da disponibilidade mecânica para os sistemas *full-tree* e CTL quando correlacionada com diferentes variáveis na camada intermediária das redes.

Mediante análise, é apresentado na Tabela 4, o resumo estatístico para a estimativa da disponibilidade mecânica das máquinas de colheita florestal utilizadas nos sistemas *full-tree* e na Tabela 5 para CTL. Tal análise proporcionou identificar nas variáveis, a presença de possíveis outliers ou inconsistências nos valores, podendo estes serem tratados e/ou retirados da análise.

Tabela 4. Resumo estatístico das variáveis de entrada das redes neurais tratadas para o sistema *full-tree*.

Variável de Entrada	Média	Desvio Padrão	Mínimo	Máximo	Assimetria	Curtose
HT	17,48	3,87	0,00	23,41	-1,98	4,63
HPM	1,69	2,96	0,00	22,36	4,17	21,78
VMI	0,16	0,05	0,06	0,41	1,24	2,80
m <sup>3</sup> /h	71,47	32,67	0,00	277,82	1,16	4,88
Arv/h	443,66	295,70	6,01	1181,00	-0,47	-1,04
Hdr	0,09	0,30	0,00	2,57	4,26	21,15

HT: horas trabalhadas; HPM: horas de parada mecânica; VMI: volume médio individual; m<sup>3</sup>/h: volume em metros cúbicos por hora; Arv/h: números de árvores colhidas por hora; Hdr: Óleo hidráulico consumido por hora.

Fonte: O autor.

Tabela 5. Resumo estatístico das variáveis de entrada das redes neurais tratadas, para o sistema CTL.

<b>Variável de Entrada</b>	<b>Média</b>	<b>Desvio Padrão</b>	<b>Mínimo</b>	<b>Máximo</b>	<b>Assimetria</b>	<b>Curtose</b>
HT	17,39	3,53	0,00	22,66	-1,96	4,14
HPM	1,73	2,59	0,00	24,00	2,94	12,88
VMI	0,12	0,04	0,07	0,40	4,37	29,78
m <sup>3</sup> /h	13,57	17,33	0,00	88,74	1,62	1,26
Arv/h	114,72	60,70	0,00	265,72	-0,98	0,15
Hdr	0,25	0,91	0,00	15,00	11,08	156,84

HT: horas trabalhadas; HPM: horas de parada mecânica; VMI: volume médio individual; m<sup>3</sup>/h: volume em metros cúbicos por hora; Arv/h: números de árvores colhidas por hora; Hdr: Óleo hidráulico consumido por hora.

Fonte: O autor.

O resumo estatístico apresentado nas Tabelas 4 e 5 tornam-se de grande importância, pois a variabilidade dos dados utilizados como entrada das informações para treino e validação das redes neurais, pode definir a importância em termos de pesos sinápticos destas variáveis no modelo. As variáveis VMI e Hdr, foram as que apresentaram a menor variabilidade em relação a suas médias, sendo de  $\pm 0,05$  e  $0,30$  respectivamente. Tendo as demais variáveis apresentando uma dispersão média ou alta, tornou-se importante para a assertividade das configurações das redes.

Coeficientes de assimetria e curtose não são critérios de definição ou escolha das variáveis de entrada de acordo com suas normalidades de dados, porém, a distribuição dos dados pode interferir nos pesos sinápticos destas variáveis e as configurações de redes podem ser ajustadas.

Durante a fase de treinamento, a rede usou o conjunto de treinamento até que um estado imóvel fosse alcançado, sendo o critério de parada adotado, erro médio em  $0,0001$  e o número de ciclos em  $3000$ , fazendo que os valores de aprendizagem de uma rede se encerrassem, seguindo assim para a próxima rede.

Ao analisar valores como o desvio padrão, é possível deduzir que os valores e a dispersão dos dados reais e previstos são comparáveis.

Para a fase de teste, foi utilizada a esquematização por meio de pesos ajustados para os dados, tendo assim o objetivo de testar as redes e suas respectivas características, avaliando sua aptidão em relação ao treino.

#### 4.2. Modelagem da disponibilidade mecânica da colheita florestal por meio de RNA

##### 4.2.1. Sistema de colheita mecanizada *full-tree*

É descrito na Tabela 6 as características e análises estatísticas das RNA's geradas, tanto no treinamento quanto na validação, para estimar a disponibilidade mecânica de máquinas de colheita florestal mecanizada no sistema *full-tree*.

Tabela 6. Características e precisão das redes neurais artificiais (RNA) selecionadas para estimar a DM (disponibilidade mecânica) de máquinas de colheita florestal mecanizada utilizados no sistema *full-tree*.

Neurônios na camada oculta	Algoritmo de treinamento	Número de ciclos	Amostragem	Função de ativação		Treino		Validação	
				Treino	Validação	R <sup>2</sup>	RQME	R <sup>2</sup>	RQME
5	<i>Resilient propagation</i>	3000	80/20	Logística	Logística	0,997253	0,010696	0,999374	0,015797
	<i>Backpropagation</i>	3000	70/30	Logística	Logística	0,968508	0,064955	0,977236	0,066074
	<i>Quick propagation</i>	3000	70/30	Logística	Logística	0,997319	0,010015	0,987295	0,022104
6	<i>Resilient propagation</i>	3000	80/20	Logística	Logística	0,997605	0,009989	0,990257	0,014265
	<i>Backpropagation</i>	3000	80/20	Sigmoidal	Sigmoidal	0,933437	0,033733	0,873303	0,038246
	<i>Quick propagation</i>	3000	70/30	Logística	Logística	0,997301	0,010318	0,987050	0,022398
7	<i>Resilient propagation</i>	3000	80/20	Logística	Logística	0,997608	0,009985	0,988441	0,014907
	<i>Backpropagation</i>	3000	70/30	Logística	Logística	0,967314	0,065921	0,976040	0,057641
	<i>Quick propagation</i>	3000	70/30	Logística	Logística	0,997308	0,009993	0,987097	0,022288
8	<i>Resilient propagation</i>	3000	80/20	Logística	Logística	0,997607	0,009984	0,987239	0,015251
	<i>Backpropagation</i>	3000	80/20	Logística	Logística	0,960012	0,070202	0,933051	0,067890
	<i>Quick propagation</i>	3000	70/30	Logística	Logística	0,997309	0,009967	0,987471	0,021918
9	<i>Resilient propagation</i>	3000	<b>80/20</b>	<b>Logística</b>	<b>Logística</b>	<b>0,997611</b>	<b>0,009974</b>	<b>0,989005</b>	<b>0,015528</b>
	<i>Backpropagation</i>	3000	70/30	Logística	Logística	0,968400	0,064206	0,978671	0,063225
	<i>Quick propagation</i>	3000	<b>70/30</b>	<b>Logística</b>	<b>Logística</b>	<b>0,997324</b>	<b>0,009931</b>	<b>0,987872</b>	<b>0,021528</b>
10	<i>Resilient propagation</i>	3000	80/20	Logística	Logística	0,997606	0,009987	0,989237	0,013964
	<i>Backpropagation</i>	3000	<b>70/30</b>	<b>Logística</b>	<b>Logística</b>	<b>0,971972</b>	<b>0,067657</b>	<b>0,981402</b>	<b>0,063054</b>
	<i>Quick propagation</i>	3000	70/30	Logística	Logística	0,997305	0,009951	0,987480	0,021888
11	<i>Resilient propagation</i>	3000	80/20	Logística	Logística	0,997610	0,009978	0,989154	0,015751
	<i>Backpropagation</i>	3000	70/30	Logística	Logística	0,970682	0,064136	0,979014	0,061231
	<i>Quick propagation</i>	3000	70/30	Logística	Logística	0,997312	0,009953	0,988269	0,021181

Fonte: O autor (2022).

A partir dos resultados descritos na Tabela 6, foi possível perceber que os valores do  $R^2$  variaram de 0,9334 (*backpropagation* – 6 neurônios) a 0,9976 (*resilient propagation* – 9 neurônios) no treinamento e de 0,8733 (*backpropagation* – 6 neurônios) a 0,9993 (*resilient propagation* – 5 neurônios) na validação. Já os valores de raiz quadrada do erro médio (RQME) variaram de 0,0099 (*quick propagation* – 9 neurônios) a 0,0702 (*backpropagation* – 8 neurônios) no treinamento e de 0,0139 (*resilient propagation* – 10 neurônios) a 0,067 (*backpropagation* – 8 neurônios) na validação. Esses resultados evidenciaram uma forte correlação e alta exatidão entre as estimativas e os valores observados, haja vista que, de acordo com Du et al. (2021), quanto maiores são os valores de  $R^2$  e menores são os valores de RQME, mais explicativo é o modelo, ou seja, melhor ele se ajusta à amostra.

Outro dado a ser observado nos resultados da Tabela 6 é que o algoritmo *resilient propagation* apresentou os maiores coeficientes de correlação em quase todas as RNA's treinadas, com exceção da rede com 5 neurônios, onde o *quick propagation* apresentou maior  $R^2$  (0,997319). A RNA configurada com 9 neurônios na camada oculta e algoritmo de treinamento *resilient propagation* apresentou os melhores resultados de  $R^2$  (0,997611 e 0,989005) e RQME (0,009974 e 0,015528), no treinamento e na validação, respectivamente. Esse resultado evidencia a eficiência do algoritmo *resilient propagation* na previsão da disponibilidade mecânica do conjunto *feller-buncher / skidder / Garra traçadora*, sistema *full-tree*.

Em relação à função de ativação, foi atestada a eficiência da função Logística na determinação da DM, dado o fato que esta foi utilizada nas redes com melhores resultados de correlação. Os autores Othman e Abdelwahab (2021) também utilizaram a função de ativação logística em sua pesquisa acerca da previsão dos parâmetros de compactação do solo e identificaram esta como a função mais eficiente. Os autores Rocha et al. (2021), explicam que o desempenho superior dessa função se deve a sua oscilação, entre linearidade e não linearidade, que possibilita considerável representação de acontecimentos não-lineares em casos de aproximação de funções para previsões de variáveis quantitativas, como é o caso da DM (Lopes et al., 2020; Rocha et al. 2021).

A análise gráfica dos erros e a correlação entre valores observados e estimados das combinações das redes, para o sistema de colheita *full-tree*, está ilustrado na Figura 26. Esses resultados mostram que os valores estimados foram

muito próximos dos valores observados e foram uniformemente distribuídos por um todo.

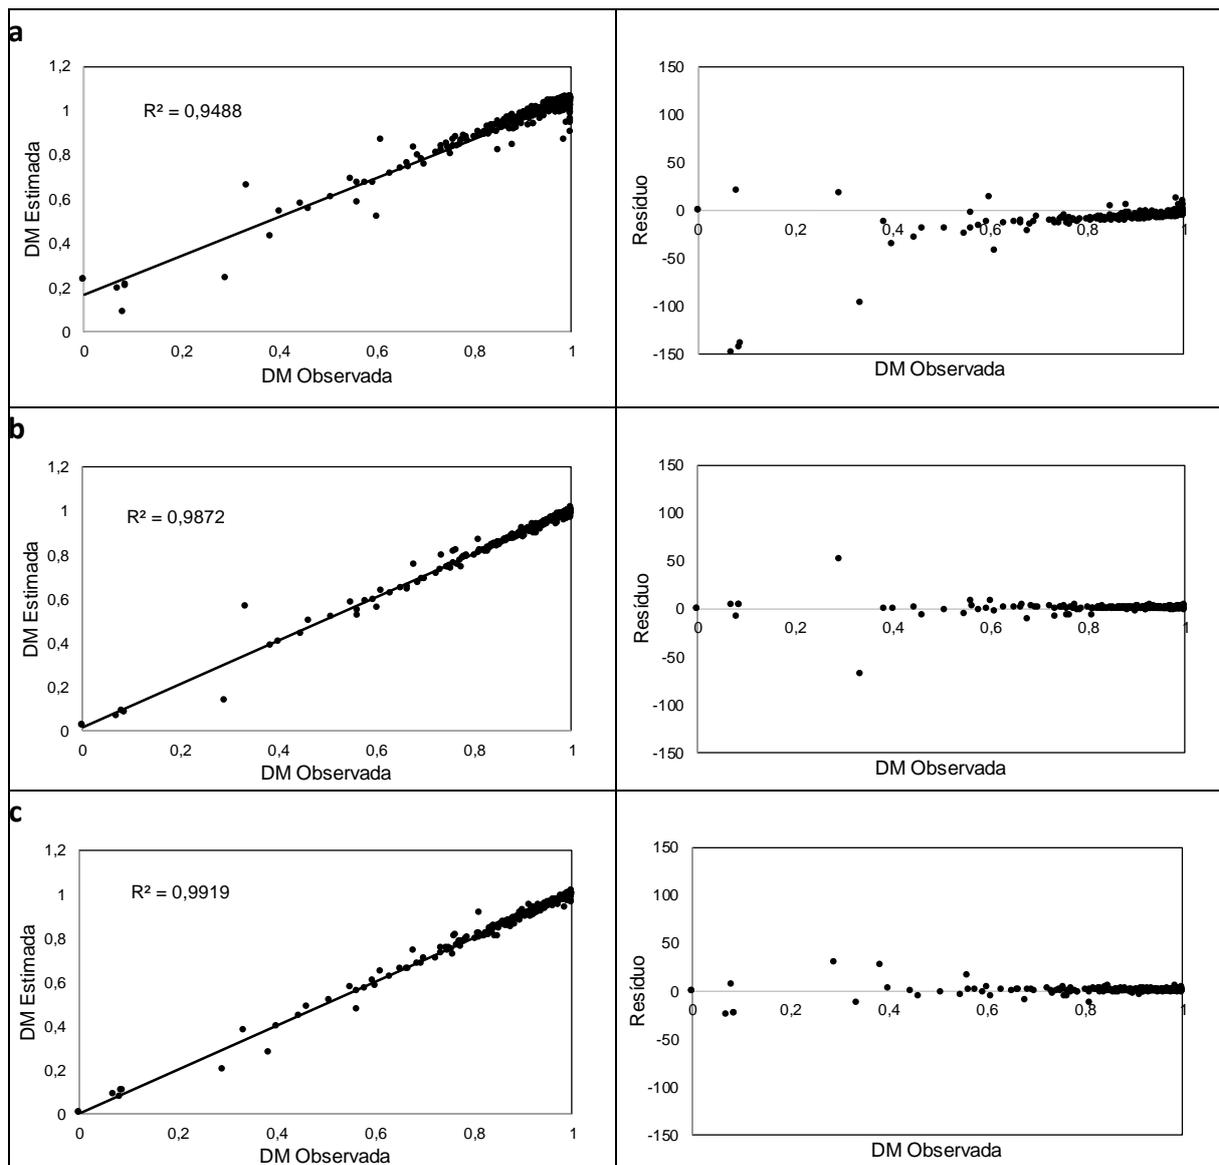


Figura 26. Disponibilidade mecânica estimada e observada e dispersão dos erros das redes neurais: a) *Resilient propagation*, b) *Quick propagation* e c) *Backpropagation*, para o sistema de colheita *full-tree*.

Fonte: O autor (2022).

A partir da análise dos resultados apresentados na Figura 26, percebe-se que de acordo com a classificação proposta por Evans (1996), todos os algoritmos de treinamento apresentaram correlação muito forte, evidenciando assim, a confiabilidade das redes treinadas com estas configurações. De acordo com a classificação dos coeficientes de correlação propostos pelo autor supracitado,  $R^2$  superiores a 0,90 indicam que a variação dos valores estimados é fortemente

explicada pelos valores observados. Os gráficos dos resíduos, também apresentados na Figura 26, corroboram os resultados dos gráficos de correlação, sendo que o algoritmo *resilient propagation*, que apresentou menor  $R^2$  (0,9488), apresentou a maior variação percentual dos erros.

#### 4.2.2. Sistema de colheita florestal mecanizada *Cut-to-length* - CTL

Na Tabela 7, são descritas as características e análise estatística das RNA's geradas, tanto no treinamento quanto na validação, para estimar a disponibilidade mecânica de máquinas de colheita florestal mecanizada utilizados no sistema *cut-to-length*.

Tabela 7. Características e precisão das redes neurais artificiais (RNA) selecionadas para estimar a DM (disponibilidade mecânica) de máquinas de colheita florestal mecanizada utilizados no sistema CTL.

Neurônios na camada oculta	Algoritmo de treinamento	Número de ciclos	Amostragem	Função de ativação		Treino		Validação	
				Treino	Validação	R <sup>2</sup>	RQME	R <sup>2</sup>	RQME
5	<i>Resilient propagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,996937	0,009965	0,988316	0,014976
	<i>Backpropagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,977945	0,022166	0,848544	0,001537
	<i>Quick propagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,996686	0,009716	0,995658	0,010617
6	<i>Resilient propagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,997045	0,008981	0,992857	0,011223
	<i>Backpropagation</i>	3000	<b>70/30</b>	<b>Sigmoidal</b>	<b>Sigmoidal</b>	<b>0,981117</b>	<b>0,020580</b>	<b>0,848617</b>	<b>0,041351</b>
	<i>Quick propagation</i>	3000	<b>70/30</b>	<b>Sigmoidal</b>	<b>Sigmoidal</b>	<b>0,997056</b>	<b>0,009022</b>	<b>0,996449</b>	<b>0,009702</b>
7	<i>Resilient propagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,997037	0,009807	0,987285	0,015223
	<i>Backpropagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,975992	0,023110	0,842923	0,038621
	<i>Quick propagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,996618	0,009964	0,996358	0,009802
8	<i>Resilient propagation</i>	3000	<b>70/30</b>	<b>Sigmoidal</b>	<b>Sigmoidal</b>	<b>0,997137</b>	<b>0,009707</b>	<b>0,987436</b>	<b>0,015108</b>
	<i>Backpropagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,974305	0,023879	0,855494	0,038781
	<i>Quick propagation</i>	3000	80/20	Logística	Logística	0,996624	0,010382	0,996204	0,009102
9	<i>Resilient propagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,997116	0,009795	0,990229	0,013237
	<i>Backpropagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,975113	0,023511	0,849786	0,037553
	<i>Quick propagation</i>	3000	70/30	Logística	Logística	0,996750	0,009958	0,849800	0,010540
10	<i>Resilient propagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,996995	0,009871	0,987487	0,014714
	<i>Backpropagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,974016	0,024013	0,852646	0,038093
	<i>Quick propagation</i>	3000	80/20	Logística	Logística	0,996623	0,009976	0,996603	0,008280
11	<i>Resilient propagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,997109	0,009737	0,993245	0,010835
	<i>Backpropagation</i>	3000	70/30	Sigmoidal	Sigmoidal	0,964008	0,028226	0,849945	0,038362
	<i>Quick propagation</i>	3000	80/20	Logística	Logística	0,996611	0,009962	0,996099	0,008983

Fonte: O autor (2022).

Os resultados apresentados na Tabela 7, evidenciaram que os  $R^2$  variaram de 0,9640 (*backpropagation* – 11 neurônios) a 0,9971 (*resilient propagation* – 8 neurônios) no treinamento e de 0,8429 (*backpropagation* – 7 neurônios) a 0,9966 (*quick propagation* – 10 neurônios) na validação. Os valores de RQME, por sua vez, variaram de 0,0089 (*resilient propagation* – 6 neurônios) a 0,0282 (*backpropagation* – 11 neurônios) no treinamento e de 0,0015 (*backpropagation* – 5 neurônios) a 0,0413 (*backpropagation* – 6 neurônios) na validação. Assim como na análise dos algoritmos para a estimativa da DM das máquinas no sistema *full-tree*, esses resultados evidenciaram uma forte correlação e alta exatidão entre as estimativas e os valores observados.

Novamente o algoritmo *resilient propagation* apresentou-se como o mais eficiente na previsão da disponibilidade mecânica, desta vez para o conjunto *harvester / forwarder* (sistema CTL). Esse resultado pode ser visualizado na Tabela 7, onde os maiores coeficientes de correlação em quase todas as RNA's treinadas, foram identificados nesse algoritmo, com exceção da rede com 6 neurônios, onde o *quick propagation* apresentou maior  $R^2$  (0,99706). A RNA configurada com 8 neurônios na camada oculta e algoritmo de treinamento *resilient propagation* apresentou os melhores resultados de  $R^2$  para o treinamento (0,996603).

Na análise do sistema de colheita florestal em toras curtas (CTL), a função de ativação do tipo sigmoidal foi mais eficiente na determinação da DM, dado o fato que esta foi utilizada nas redes com melhores resultados de correlação. Ao propor uma metodologia baseada em redes neurais para previsão de custos de reparo e manutenção de tratores, os autores Rohani, Abbaspour-Fard e Abdolahpour (2011), atestaram esta função como a mais eficiente.

Outro dado a ser visualizado na Tabela 7, é que a composição de calibração de treinamento (70%) e validação (30%) foi a que apresentou maiores resultados de  $R^2$  e menores valores de RQME, no treinamento. No sistema *full-tree*, no entanto, a composição que apresentou maiores resultados de  $R^2$  e menores valores de RQME, no treinamento, foi a calibração de treinamento (80%) e validação (20%).

Com o objetivo de representar graficamente os erros e a correlação entre valores observados e estimados das combinações das redes, para o sistema de colheita CTL, os resultados estão apresentados na Figura 27.

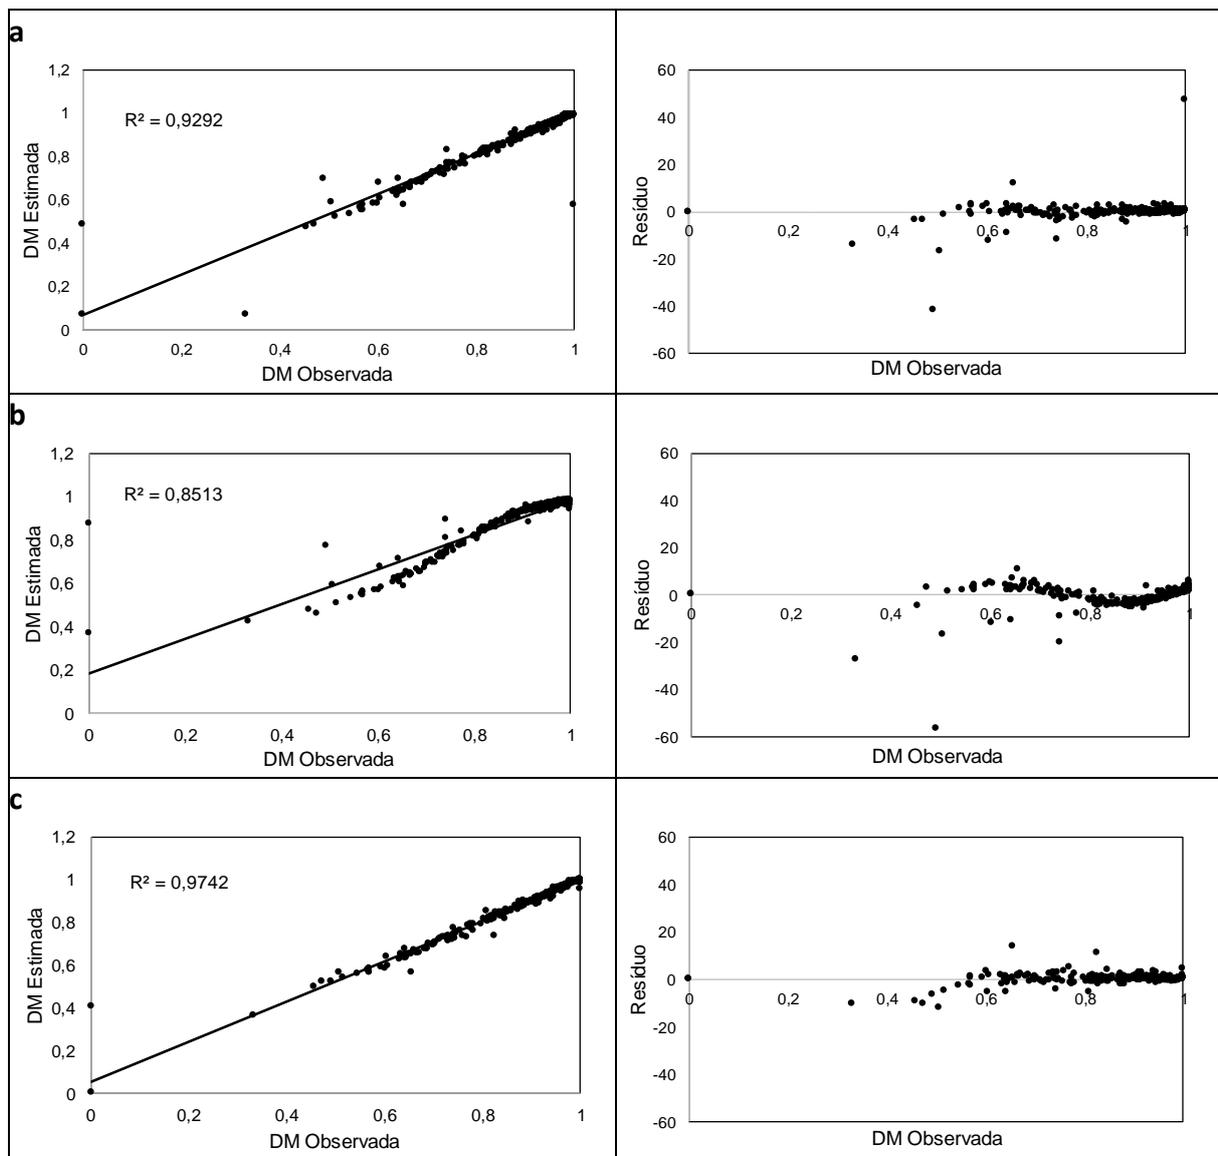


Figura 27. Disponibilidade mecânica estimada e observada e dispersão dos erros das redes neurais: A) *Resilient propagation*, B) *Quick propagation* e C) *Backpropagation*, para o sistema de colheita CTL.

Fonte: O autor (2022).

A partir da classificação da correlação existente entre os valores estimados e observados, os algoritmos *resilient propagation* e *backpropagation*, apresentaram uma correlação muito forte, sendo, respectivamente, representadas por 0,9292 e 0,9742. O algoritmo *quick propagation*, por sua vez, obteve resultado inferior, não seguindo, portanto, o padrão apresentado pelo algoritmo na análise da DM no sistema de colheita *full-tree*. Desta forma, 85,13% da variação da disponibilidade mecânica estimada foi explicada pela disponibilidade mecânica observada, sendo classificada, neste sentido, como uma correlação forte. Assim como na análise do sistema *full-tree*, os gráficos dos resíduos, apresentados na Figura 27, corroboram os resultados dos

gráficos de correlação, sendo que o algoritmo *quick propagation*, que apresentou menor  $R^2$  (0,8513), apresentou a maior variação percentual dos erros.

Com relação à performance dos critérios estatísticos para as diferentes configurações, com o uso do algoritmo *quick propagation* é notável o declínio de performance, evidenciado no gráfico pelas estatísticas de qualidade. A diferença pode ser explicada de acordo com a quantidade de número de neurônios na camada escondida (MARTINS et al., 2020). Logo, faz-se extremamente necessário utilizar uma rede com o número ideal de neurônios na camada oculta permitindo, desta forma, que o modelo seja parcimonioso e não gere problemas como *overfitting* e *underfitting* (CUNHA NETO et al., 2019).

#### 4.2.3. Melhores configurações de redes

A Tabela 8 apresenta os resultados acerca das características e precisão das redes encontradas nas melhores configurações por algoritmos selecionadas para estimar a DM das máquinas utilizadas nos sistemas *full-tree* e *cut-to-length*.

Tabela 8. Características e precisão das redes neuronais artificiais (RNA) encontradas nas melhores configurações por algoritmos selecionadas para estimar a DM (disponibilidade mecânica) de máquinas de colheita florestal mecanizada utilizados nos sistemas *full-tree* e CTL.

Sistema de Colheita	Neurônios na camada oculta	Algoritmo de treinamento	Número de ciclos	Amostragem	Função de ativação		Treino		Validação	
					Treino	Validação	R <sup>2</sup>	RQME	R <sup>2</sup>	RQME
<i>Full-tree</i>	9	<i>Resilient propagation</i>	3000	80/20	<b>Logística</b>	<b>Logística</b>	0,997611	0,009974	0,989005	0,015528
<i>Full-tree</i>	9	<i>Quick propagation</i>	3000	70/30	<b>Logística</b>	<b>Logística</b>	0,997324	0,009931	0,987872	0,021528
<i>Cut-to-length</i>	8	<i>Resilient propagation</i>	3000	70/30	<b>Sigmoidal</b>	<b>Sigmoidal</b>	0,997137	0,009707	0,987436	0,015108
<i>Cut-to-length</i>	6	<i>Quick propagation</i>	3000	70/30	<b>Sigmoidal</b>	<b>Sigmoidal</b>	0,997056	0,009022	0,996449	0,009702
<i>Cut-to-length</i>	6	<i>Backpropagation</i>	3000	70/30	<b>Sigmoidal</b>	<b>Sigmoidal</b>	0,981117	0,020580	0,848617	0,041351
<i>Full-tree</i>	10	<i>Backpropagation</i>	3000	70/30	<b>Logística</b>	<b>Logística</b>	0,971972	0,067657	0,981402	0,063054

Fonte: O autor (2022).

A partir da Tabela 8, é possível corroborar todas as informações mencionadas anteriormente. Inicialmente, a tabela em questão evidencia que, tanto para o sistema *full-tree*, quanto para o CTL, os algoritmos com maior e menor  $R^2$  foram respectivamente o *resilient propagation* e o *backpropagation*. A ordenação de eficiência dos algoritmos foi, portanto, igual em ambos os sistemas.

De acordo com Heaton (2011), Martins et al. (2016) e Rocha et al (2021), o algoritmo *resilient propagation* possibilitou redes com elevada precisão nas estimativas devido à maior adaptabilidade mediante o treinamento. Isso porque nesses cenários os parâmetros não carecem de definição prévia. Dessa forma, o próprio algoritmo escolhe os melhores valores para os parâmetros.

No entanto, a função de ativação das RNA treinadas que apresentaram os melhores resultados de predição de DM para os dois sistemas foi diferente, sendo a função logística a melhor para os sistemas *full-tree* e a sigmoideal a mais eficiente para o sistema *cut-to-length*. Esse fato é justificado porque, de acordo com Nguyen et al. (2021), a função de ativação sigmoideal é mais precisa, em relação à função de ativação logística, quando aplicada a um conjunto de amostras mais amplo. Desta forma, essa informação corrobora os resultados encontrados, dado o fato que a amostragem do sistema *cut-to-length* foi maior em função do número total de maquinários utilizados ser igualmente superior. Enquanto no sistema *full-tree* foram analisadas 6 máquinas (2 *feller-buncher* + 2 *skidders* + 2 garras traçadoras), no CTL foram avaliadas 16 máquinas (12 *harvesters* + 4 *forwarders*).

#### 4.3. Análise de agrupamento

Pelo método *Unweighted Pair Group Method with Arithmetic Average* (UPGMA), foi possível estabelecer um agrupamento da variável de entrada VMI. A construção do dendrograma é estabelecida pelos modelos ajustados de menor dissimilaridade (Puiatti et al., 2014). Os grupos classificados pelo VMI estão apresentados na Tabela 9.

Tabela 9. Agrupamento em função do VMI.

Grupos	Intervalos de agrupamento de VMI
1	$0,06 < \text{VMI} \leq 0,10$
2	$0,10 < \text{VMI} \leq 0,15$
3	$0,15 < \text{VMI} \leq 0,20$
4	$0,20 < \text{VMI} \leq 0,25$
5	$0,25 < \text{VMI} \leq 0,30$
6	$0,30 < \text{VMI} \leq 0,41$

Fonte: O autor (2022).

Mediante a disponibilização dos grupos ao método as classes foram agrupadas conforme a Figura 28.

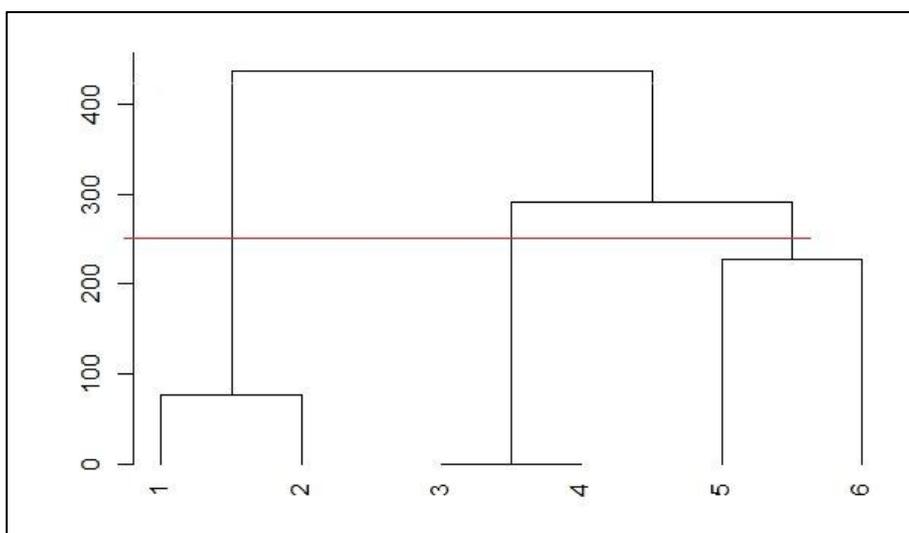


Figura 28. Dendrograma para as classes de VMI.

Fonte: O autor (2022).

O dendrograma obtido pela análise de agrupamento (Figura 28) permitiu a divisão da variável VMI em classes. Quando a distância euclidiana de corte foi definida em 250, formaram-se três classes: Classe I, II e III de VMI (Figura 29). As classes formadas, tiveram médias de:  $0,11 \text{ m}^3$ ;  $0,20 \text{ m}^3$ ; e  $0,30 \text{ m}^3$ , respectivamente. A linha horizontal interceptou o dendrograma entre as 200 e 300 distâncias euclidianas, configurando os seguintes grupos de clones: Classe I formado pelos grupos de VMI 1 e 2 (72,7% dos dados); Classe II pelos grupos 3 e 4 (25,2%); e Classe III formada pelos grupos 5 e 6 (2,1% dos dados) (Figura 29).

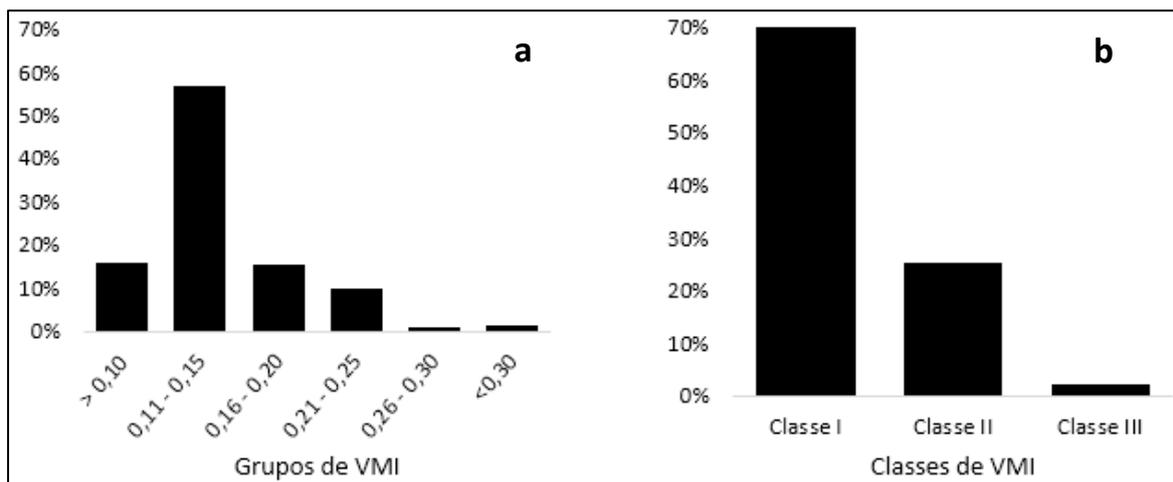


Figura 29. Frequência de distribuição dos dados de VMI, (a) grupos de VMI, (b) Classes de VMI obtidas com o dendrograma.

Fonte. O autor (2022).

#### 4.3.1. Modelagem da disponibilidade mecânica por meio de RNA para classes de VMI

De acordo com as classes de VMI apresentadas na Figura 30, foram delimitadas as melhores configurações das RNA's para estimar a DM do sistema *full-tree* (Tabela 10) e do CTL (Tabela 11).

Tabela 10. Características e precisão das redes neuronais artificiais (RNA) encontradas na melhor configuração para estimar a DM do sistema *full-tree*, de acordo com as classes de VMI definidas.

Classes de VMI	Neurônios na camada oculta	Algoritmo de treinamento	Número de ciclos	Amostragem	Função de ativação		Treino		Validação	
					Treino	Validação	R <sup>2</sup>	RQME	R <sup>2</sup>	RQME
Classe I	9	<i>Resilient propagation</i>	3000	80/20	<b>Logística</b>	<b>Logística</b>	0,996314	0,009832	0,980279	0,020875
Classe II	9	<i>Resilient propagation</i>	3000	80/20	<b>Logística</b>	<b>Logística</b>	0,998132	0,009995	0,997628	0,007740
Classe III	9	<i>Resilient propagation</i>	3000	80/20	<b>Logística</b>	<b>Logística</b>	0,999058	0,009537	0,997739	0,044183

Fonte: O autor (2022).

Tabela 11. Características e precisão das redes neuronais artificiais (RNA) encontradas na melhor configuração para estimar a DM do sistema CTL, de acordo com as classes de VMI definidas.

Classes de VMI	Neurônios na camada oculta	Algoritmo de treinamento	Número de ciclos	Amostragem	Função de ativação		Treino		Validação	
					Treino	Validação	R <sup>2</sup>	RQME	R <sup>2</sup>	RQME
Classe I	8	<i>Resilient propagation</i>	3000	70/30	<b>Sigmoidal</b>	<b>Sigmoidal</b>	0,995402	0,009257	0,997690	0,009248
Classe II	8	<i>Resilient propagation</i>	3000	70/30	<b>Sigmoidal</b>	<b>Sigmoidal</b>	0,998099	0,009148	0,755790	0,015177
Classe III	8	<i>Resilient propagation</i>	3000	70/30	<b>Sigmoidal</b>	<b>Sigmoidal</b>	0,999512	0,007542	0,914455	0,302778

Fonte: O autor (2022).

A partir dos resultados apresentados nas Tabelas 10 e 11, percebe-se que em qualquer uma das classes para os dois sistemas, o algoritmo de treinamento que apresentou melhores resultados de  $R^2$  foi o *resilient propagation*. No entanto, a função de ativação das redes treinadas que apresentaram os melhores resultados de predição de DM para os dois sistemas e o número de neurônios na camada oculta foi diferente. No sistema CTL, a melhor função de ativação foi a sigmoideal. No sistema *full-tree*, por sua vez, a função de ativação melhor foi a logística. Assim como dito anteriormente e corroborado por Nguyen et al. (2021), isso ocorre em função da diferença dos tamanhos dos conjuntos de amostras entre os sistemas.

Outro ponto a ser observado nas Tabela 10 e 11, é que quanto maior o intervalo de VMI, maior é o  $R^2$  da rede, tanto no treino quanto na validação. A classe I, neste sentido, apresentou o menor  $R^2$  para ambos os sistemas de colheita, sendo de 0,996314 para o *full-tree* e de 0,995402 para o CTL. A classe III, portanto, foi a que apresentou os maiores  $R^2$ , apresentado 0,999058 no *full-tree* e 0,999512 no CTL. Quando se trata da predição de produtividade do *harvester*, por exemplo, os autores Gonçalves et al. (2021), encontraram uma relação inversamente proporcional com o VMI, ou seja, quanto maior o VMI, menor a precisão das redes

Pelos resultados obtidos, pode-se confirmar que é possível a predição da disponibilidade mecânica por meio de RNA, sendo mais precisa de acordo com o incremento do VMI, ou seja, possuindo um maior  $R^2$ .

Na Figura 30 são apresentadas as disponibilidades mecânicas estimadas e observadas e dispersão dos erros das redes neurais para cada uma das classes para o sistema *full-tree*.

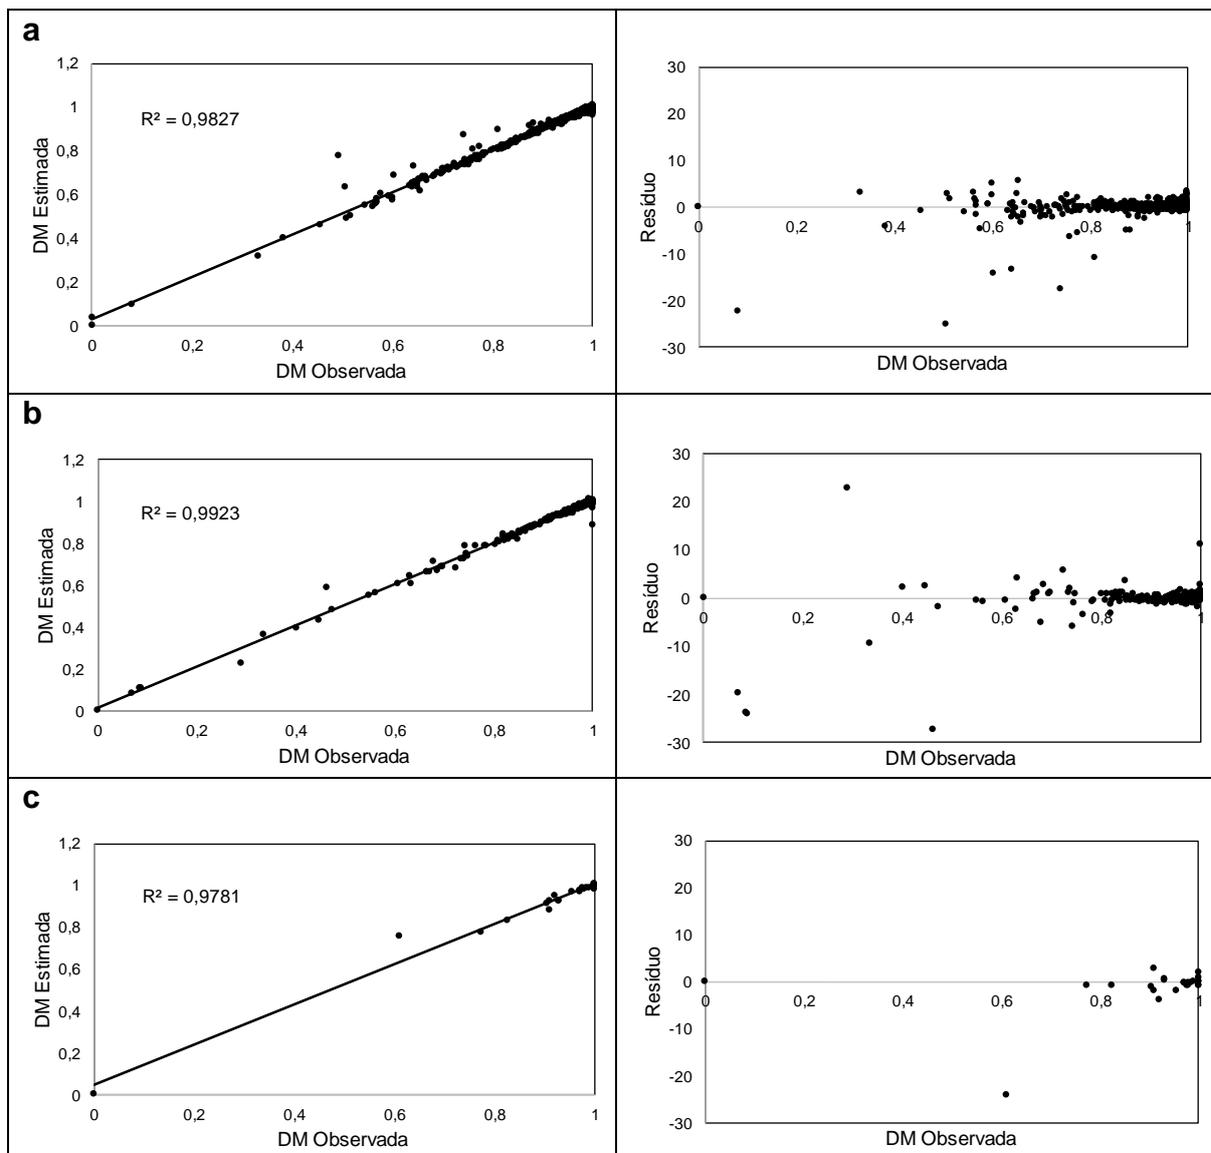


Figura 30. Disponibilidade mecânica estimada e observada e dispersão dos erros das redes neurais: a) Classe I de VMI, b) Classe II de VMI e c) Classe III de VMI, para o sistema de colheita *full-tree*.

Fonte: O autor (2022).

A partir da classificação da correlação existente entre os valores estimados e observados (Figura 30), percebe-se que no sistema *full-tree*, todas as classes apresentaram uma correlação muito forte, ou seja, coeficiente de correlação acima de 90% (EVANS, 1996). A classe de VMI que apresentou maior  $R^2$  foi a classe II ( $R^2 = 0,9923$ ), seguida da classe I ( $R^2 = 0,9827$ ) e da classe III ( $R^2 = 0,9781$ ). Os gráficos dos resíduos, apresentados na Figura 30, corroboram os resultados dos gráficos de correlação, sendo que a classe III, que apresentou menor  $R^2$ , apresentou a maior variação percentual dos erros.

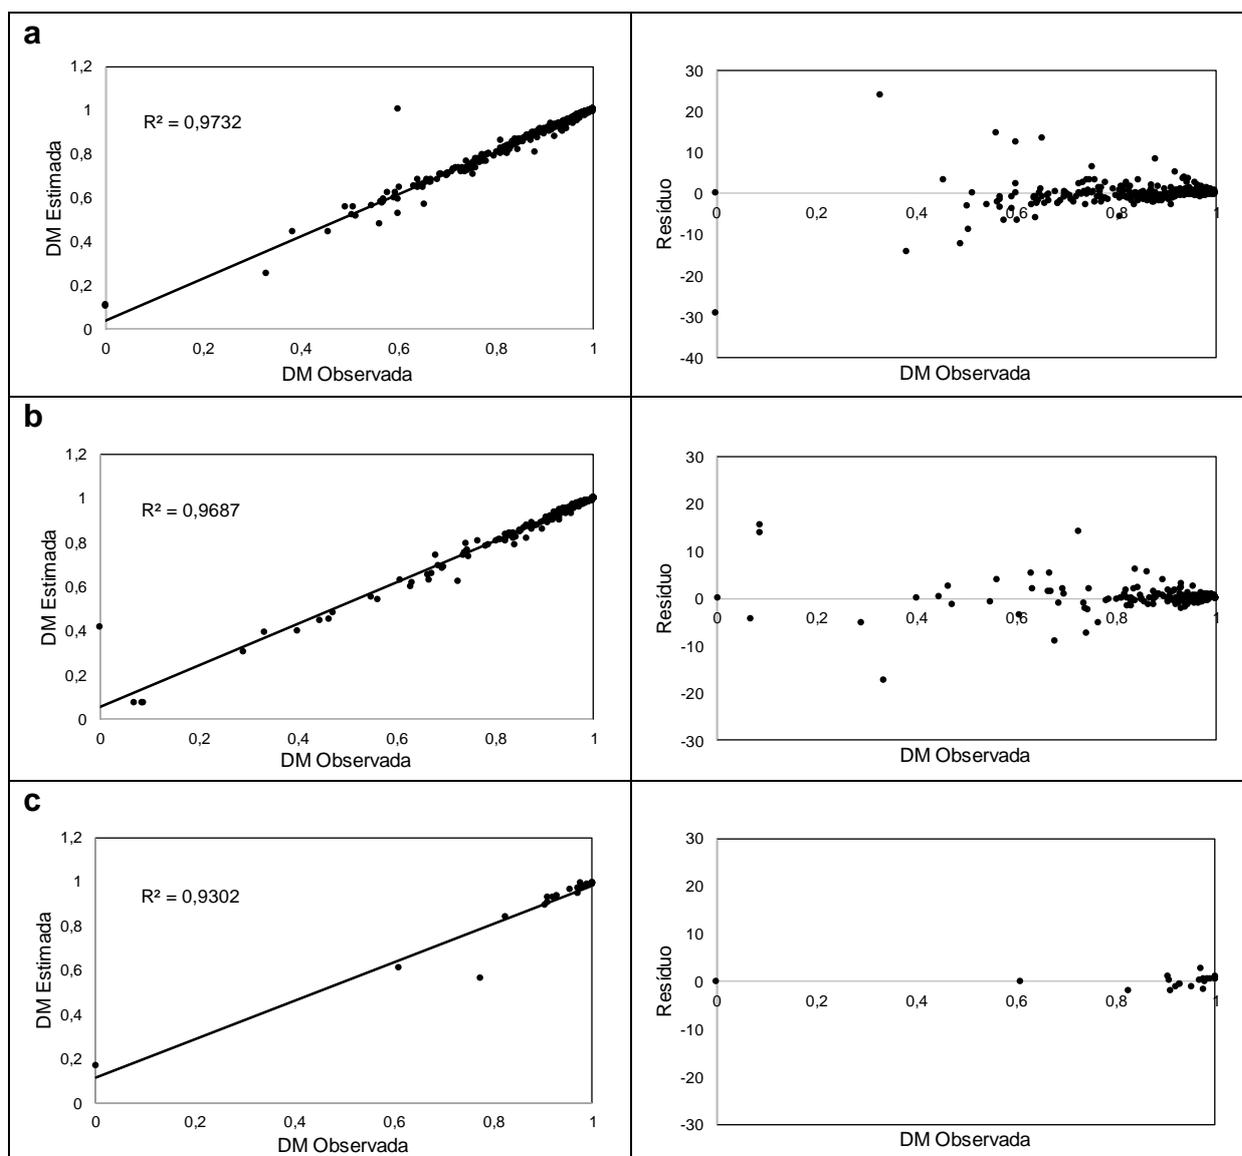


Figura 31. Disponibilidade mecânica estimada e observada e dispersão dos erros das redes neurais: A) Classe I de VMI, B) Classe II de VMI e C) Classe III de VMI, para o sistema de colheita CTL.

Fonte: O autor (2022).

A figura 31, apresentou os gráficos de correlação existente entre os valores estimados e observados do sistema CTL, apesar de também ter apresentado uma alta correlação, demonstrou padrão diferente dos gráficos relativos ao sistema *full-tree*. No CTL a classe de VMI que apresentou maior  $R^2$  foi a classe I ( $R^2 = 0,9732$ ), seguida da classe II ( $R^2 = 0,9687$ ). No entanto, assim como no sistema *full-tree*, a classe III apresentou o menor coeficiente de correlação ( $R^2 = 0,9302$ ) e, conseqüentemente, a maior variação percentual dos erros, como visto nos gráficos de resíduos.

#### 4.4. Regressão linear

A avaliação das estimativas de DM para o sistema de colheita florestal *full-tree* do modelo de regressão em função das variáveis de correlação significativa está representada pela equação 13, e sua representação gráfica pela figura 32.

Equação de regressão para o sistema *full-tree*:

$$\widehat{DM} = 0,987 + 0,001^* \times HT - 0,041^* \times HPM - 5,027 \times 10^{-6}^* \times Arv/h - 0,006^{ns} \times VMI - 8,139 \times 10^{-5}^* \times M^3H - 0,004^{ns} \times Hdr \quad (13)$$

Em que:

$\widehat{DM}$  = Disponibilidade mecânica;

$HT$  = Horas trabalhadas;

$HPM$  = Horas parada mecânica;

$VMI$  = Volume médio individual;

$Arv/h$  = Quantidade de árvores colhidas por hora;

$M^3H$  = Volume em metros cúbicos colhidos por hora;

$Hdr$  = Consumo de óleo hidráulico por hora.

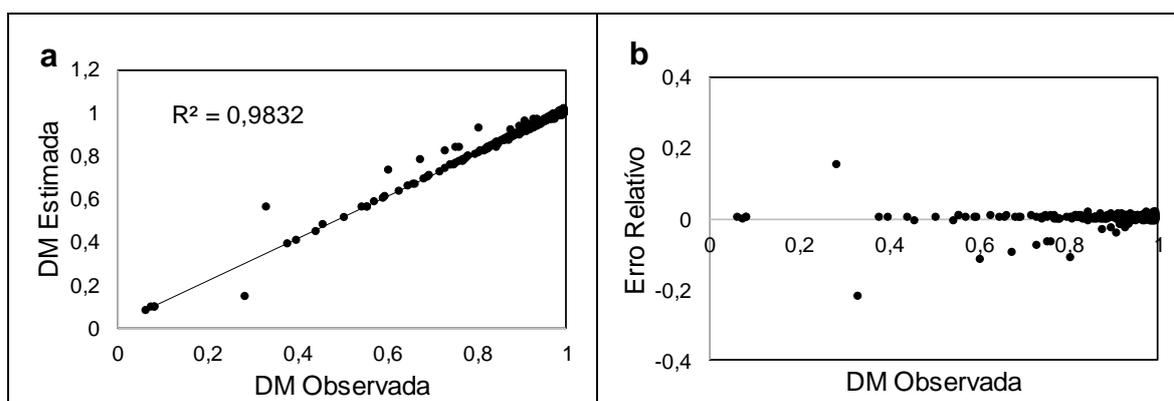


Figura 32. Disponibilidade mecânica observada vs estimada para o modelo de regressão (a), dispersão do erro relativo (b).

Fonte: O autor (2022).

A partir da análise gráfica das estatísticas e dos resíduos apresentadas na Figura 32, é possível afirmar que o modelo de regressão linear múltipla escolhido para a estimação da disponibilidade mecânica das máquinas em relação às variáveis quantitativas e qualitativas (horas trabalhadas, horas de parada mecânica, volume médio individual, produtividade e consumo de óleo hidráulico), em geral, apresentou bom ajuste aos dados. A correlação da estimativa por

regressão linear foi considerada muito forte, haja vista que foi superior a 90% (0,9832) (EVANS, 1996).

A mesma classificação de correlação (muito forte) ocorreu na estimativa da DM dos maquinários utilizados no sistema de colheita CTL, como pode ser visualizado na Figura 33.

O modelo de regressão linear ajustado de acordo com as variáveis para o sistema de colheita CTL, pode ser expresso de acordo com a equação 14, e sua representação gráfica pela figura 33.

Equação de regressão para o sistema CTL:

$$\widehat{DM} = 0,972 + 0,002^* \times HT - 0,041^* \times HPM - 0,0001^* \times Arv/h - 0,015^{ns} \times VMI - 0,0003^* \times M^3H - 0,0002^{ns} \times Hdr \quad (14)$$

Em que:

$\widehat{DM}$  = Disponibilidade mecânica;

$HT$  = Horas trabalhadas;

$HPM$  = Horas parada mecânica;

$VMI$  = Volume médio individual;

$Arv/h$  = Quantidade de árvores colhidas por hora;

$M^3H$  = Volume em metros cúbicos colhidos por hora;

$Hdr$  = Consumo de óleo hidráulico por hora.

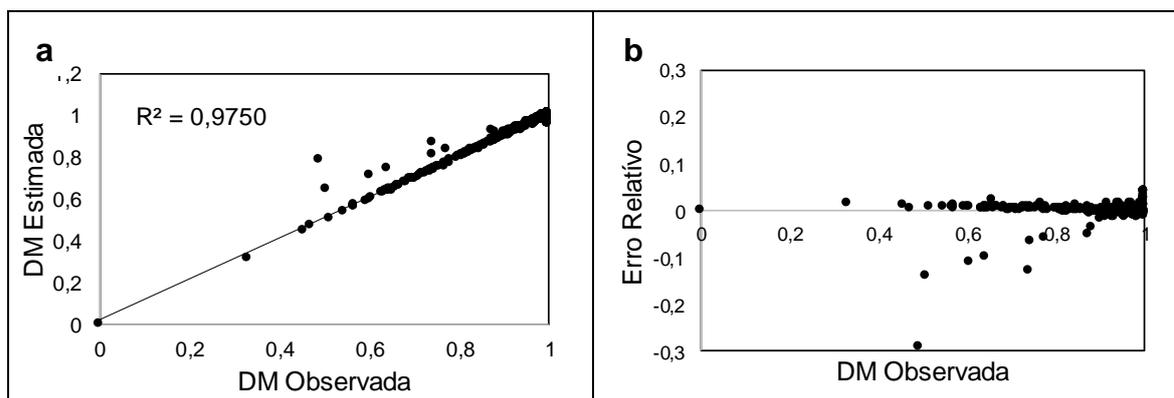


Figura 33. Disponibilidade mecânica observada vs estimada para o modelo de regressão (a), dispersão do erro relativo (b).

Fonte: O autor (2022).

De maneira geral a modelagem com redes neurais artificiais, para estimar a DM em função das variáveis operacionais estudadas para os sistemas de colheita de madeira mecanizados, apresentou estimativas mais precisas em comparação ao modelo de regressão linear múltipla, tanto no *full-tree*, quanto no CTL.

A maior eficiência das redes neurais frente à regressão no manejo dos recursos florestais tem sido evidenciada por inúmeros pesquisadores. O autor Gonçalves (2017), por exemplo, evidenciou uma precisão maior da estimativa de produtividade do corte mecanizado florestal com *harvester*, através das RNA's. Binoti (2012), por sua vez, atestou essa superioridade de eficiência das redes neurais em comparação com a regressão linear, durante sua pesquisa acerca do emprego de redes neurais artificiais em mensuração e manejo florestal. Belcavello (2022) determinou que a estimativa da produtividade do *harvester* na colheita de madeira é mais precisa quando se utiliza as redes neurais em vez da regressão.

Neste sentido, é possível justificar a presente pesquisa a partir da eficiência da predição de disponibilidade mecânica das máquinas de colheita florestal, tanto pelo sistema de árvores inteiras (*full-tree*) quanto pelo de toras curtas (*cut-to-length*), por meio da aplicação de redes neurais artificiais. Os modelos permitiram conhecer a correlação de cada variável com a operacionalidade das máquinas e demonstraram a importância das mesmas, na estimação da disponibilidade mecânica.

A partir dessas informações, o gestor florestal pode executar um planejamento eficiente da colheita, no que diz respeito ao planejamento das operações e à criação de estratégias e medidas para reduzir os tempos ociosos ocasionados pelas falhas mecânicas das máquinas, como dimensionamento do estoque de peças, distribuição de mão e obra e equipamentos de apoio, necessários para garantir a disponibilidade das máquinas, pois, tais fatores influenciam diretamente a produtividade dos sistemas, que por sua vez, determina a segurança no abastecimento de madeira na fábrica no curto, médio e longo prazos (GONÇALVES, 2017).

De modo geral, o sistema de colheita *full-tree*, mostrou-se com leve superioridade estatística quanto em predizer a disponibilidade mecânica das máquinas, tendo a função logística se sobressaído perante a sigmoideal. Tal resultado pode ser explicada pela quantidade de máquinas presentes no sistema, quando comparado com o CTL.

A nível de amostragem, quando treinado em percentual de 80% para treino e 20% para validação, o resultado obtido demonstrou remota superioridade estatística que ao nível 70% treino e 30% validação. Porém, esta amostragem foi

mais presente entre os melhores resultados quando analisado todo o montante de resultados.

Para ambos os sistemas, as máquinas avaliadas são consideradas de baixo horímetro, ou seja, menos de 5000 horas e/ou 1 ano de atividade em empresa de grande porte. Mesmo com a comprovada semelhança, as máquinas *feller-buncher*, *skidder* e garra traçadora, foram mais assertivas em relação a predição da DM.

*Resilient propagation*, foi o algoritmo de treinamento mais preciso dentre os demais, resultado este, também encontrado por (LACERDA et al. 2022).

Ao se aplicar a melhor configuração obtida para cada sistema, a classe III, que continha a menor amplitude de dados, porém de maior VMI, obteve  $R^2$  para o treinamento das RNA mais elevado, mostrando-se assim, de melhor adaptabilidade. De forma semelhante, os resultados obtidos por meio de RNA, mostrou-se de maior precisão, quando comparados com modelos de estatística convencionais, como a regressão linear, atestados nesta pesquisa.

## 5. CONCLUSÕES

Mediante os resultados do estudo, pode-se concluir que:

- A técnica de RNA se mostrou eficiente na modelagem da disponibilidade mecânica para os sistemas de colheita florestal *full-tree* e *cut-to-length*;
- Foi possível estabelecer configurações de RNA capazes de prever a disponibilidade mecânica das máquinas do *full-tree* e CTL, mediante aplicação das variáveis estudadas.
- O algoritmo de treinamento *resiliente propagation*, mostrou-se mais eficaz na predição da disponibilidade mecânica para ambos os sistemas de colheita quando comparado com os demais algoritmos;
- Regressão linear, mostrou ser uma boa ferramenta na predição da disponibilidade mecânica para sistemas *full-tree* e CTL;
- A predição da disponibilidade mecânica por meio de RNA mostrou-se superior à de regressão linear;
- A predição por meio de RNA, mostrou-se com leve superioridade para o sistema de colheita *full-tree*, quando comparado ao CTL.

## 6. REFERÊNCIAS

ALZAMORA, R. M.; OVIEDO, W.; RUBILAR, R. Life cycle analysis to estimate CO<sub>2</sub> e emissions from forest harvesting systems in intensively managed *Pinus radiata* plantations. **Scandinavian Journal of Forest Research**, v. 37, n. 2, p. 144-152, 2022.

AMORIM, E. P.; PIMENTA, A. S.; SOUZA, E. C. DE. Aproveitamento dos resíduos da colheita florestal: estado da arte e oportunidades. **Research, Society and Development**, v. 2021, n. 2, p. 1–20, 2021.

ARTERO, A. O. **Inteligência artificial: teórica e prática**. 1. ed. São Paulo: Livraria da física, 2009. 230p.

BARNES, R. M. **Estudo de Movimentos e de Tempos: Projeto e Medida do Trabalho**. 6. ed. São Paulo, SP: Edgard Blucher, 1977.

BASSOLI, H. M.; MIYAJIMA, R. H.; PALUDO, V.; FENNER, P. T. Influência da largura da faixa de trabalho na operação de corte com *feller-buncher*. **Advances in Forestry Science**. v. 7, n. 2, p. 1067-1072, 2020.

BELCAVELLO, M. O.; ALVES, D. S.; VITÓRIA, E. L.; LACERDA, E. G.; LOCATELLI, T.; FREITAS, I. L. J. Artificial neural networks in estimating the productivity of a forest harvesting machine. **IOSR Journal of Engineering**. v. 12, n. 1, p. 2278-8719, 2022.

BERENDT, F.; FORTIN, M.; SUCHOMEL, C.; SCHWEIER, J. Productivity, Costs, and Selected Environmental Impacts of Remote-Controlled Mini Forestry Crawlers. **Forests**, v. 9, n. 10, p. 591, 2018.

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

BILICI, E.; AKAY, A. E.; ABBAS, D. Assessing the effects of site factors on the productivity of a feller buncher: a time and motion analysis. **Journal of Forestry Research**, v. 30, n. 4, p. 1471–1478, 2019.

BINOTI, M. L. M. S.; BINOTI, D. H. B.; GLERIANI, J. M.; LEITE, H. G. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. **Revista Árvore**, v. 33, n. 6, p. 1133-1139, 2009.

BINOTI, M. L. M. S. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. 2012. 138f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2012.

BINOTI, M. L. M. S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 64f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2010.

BORG, D.; PINTO, F. F.; SUETAKE, M.; BRANDÃO, D. Neural networks as a diagnosing tool for industrial level measurement through noncontacting radar type and support to the decision for its better application. **IFAC (International Federation of Automatic Control)**. v. 40, n. 30, p. 349-354. 2016.

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro, RJ. Editora LTC, 262 p. 2000.

BROWN, R. O.; DINIZ, C. C. Colheita Florestal e Manutenção de Equipamentos Móveis. In: *Semana de Aperfeiçoamento em Engenharia Florestal*, UFPR, 1ed., 2017, Curitiba. **SEAFLO**. Curitiba: UFPR, 2017. P.01-41.

BULLINARIA, J. A. **Introduction to Neuronal Computation**. Notas de aula. 2014. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/inc.html>>. Acesso em: 06 de abril de 2022.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 3. ed. revisada e ampliada. Viçosa: UFV, 2009. 548 p.

CASTRO, R. R.; PAULINO, E. J.; BINOTI, M. L. M. D. S.; COLODETTE, J. L. Redes Neurais Artificiais para a estimação da densidade básica da madeira. **Scientia Forestalis**, v.44, n. 109, p. 149-154, 2016.

COELHO JÚNIOR, L. M.; NUNES, A. M. M.; PÁDUA, J. F. F.; SANTOS JÚNIOR, E. P.; LIMA, P. A. F. The Brazilian development of the forest rapid growth for energy. **Braz. J. of Develop.**, Curitiba, v. 6, n. 5, p. 28111-28125, 2020.

CUNHA NETO, E. M.; BEZERRA, J. C. F.; VERAS, H. F. P.; GOUVEIA, D. M.; ARAUJO, E. C. G.; SILVA, T. C. 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.

DAVID, H. C.; FIEDLER, N. C.; BAUM, L. Ergonomia e segurança na colheita florestal: uma revisão ante a NR 17 e a NR 31. **Enciclopédia Biosfera**, Centro Científico Conhecer - Goiânia, v.10, n.18, p. 1537, 2014.

DA SILVA, G. M.; GINDRI, E. P.; BENETTI, B. B.; DEPOI, J. S.; WERNER, V.; BRANDELERO, C.; OTTONELLI, J. Avaliação operacional de trabalhadores durante o uso de motorroçadoras laterais. **TECNOLÓGICA**, v. 22, n. 1, p. 96–100, 2018.

DA SILVA, M. L. MIRANDA, G. M.; CORDEIRO, S. A. Custos. In: MACHADO, C. C. **Colheita Florestal**. 3. ed. Viçosa, MG: Editora UFV, 2014. p. 253–287.

DE OLIVEIRA, D.; LOPES, E. da S.; FIEDLER, N. C. Avaliação técnica e econômica do *Forwarder* na extração de toras de *Pinus*. **Scientia Forestalis**, n. 84, p. 525–533, 2009.

DE SOUZA, M. A.; PIRES, C. B.; SILVEIRA, F. C. Colheita florestal: mensuração e análise dos efeitos das variáveis controláveis e não controláveis no custo das atividades de corte e descasque mecanizado. **Revista de Contabilidade e Organizações**, v. 2, n. 3, p. 73-99, 2008.

DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and electronics in agriculture**, v.10, p.235-244, 2005.

DIAS, A. C. C.; MARCHESAN, R.; PIERONI, G. B.; ALMEIDA, V. C.; VIEIRA, R. S.; DE MORAES, C. B. Qualidade da Madeira para Produção de Lâminas de *Araucaria Angustifolia* (Bert.) O. Kuntze. **Floresta**, Curitiba, PR, v. 47, n. 3, p. 333-341, 2017.

DINIZ, C. C. C.; LOPES, E. da S.; MIRANDA, G. de M.; KOEHLER, H. S. Preventive maintenance as a determinant for reduction maintenance costs of a Feller Buncher. **BIOFIX Scientific Journal**, v. 2, n. 2, p. 43-47, 2017.

DINIZ, C. C. C.; OLIVEIRA, F. M.; CERQUEIRA, C. L.; SILVA, S. A.; SILVA, V. A. F. Modelagem da disponibilidade mecânica do harvester em floresta de baixo volume individual. **Scientia Rural**. v. 19, n.2, p. 10. 2018.

DO CARMO, F. C. de A.; SILVA, E. N.; FIEDLER, N. C.; MORAES, F. Avaliação técnica de três modelos de *Harvester*'s. **Enciclopédia Biosfera**, v. 8, n. 14, p. 1091–1099, 2012.

DO CARMO, F. C. de A.; FIEDLER, N. C.; MINETTE, L. J.; SOUZA, A. P. 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.

DOS SANTOS, P. H. A.; SOUZA, A. P.; MARZANO, F. L. da CUNHA.; MINETTE, L. J. Produtividade e custos de extração de madeira de eucalipto com *Clambunk Skidder*. **Revista Árvore**, v. 37, n. 3, p. 511–518, 2013.

DU, C.; FAN, W.; MA, Y.; JIN, H.; ZHEN, Z. The Effect of Synergistic Approaches of Features and Ensemble Learning Algorithms on Aboveground Biomass Estimation of Natural Secondary Forests Based on ALS and Landsat 8. **Sensors**, v. 21, n. 17, p. 5974, 2021. DOI: 10.3390/s21175974

EVANS, J. D. **Straightforward statistics for the behavioral sciences**. Thomson Brooks/Cole Publishing Co., 1996.

FAO. **Planning forest roads and harvesting systems**. Rome, 1977. 158p.

FERNANDES, H. C.; LOPES, S. E.; TEIXEIRA, M. M.; MINETTE, L. J.; RINALDI, P. C. N.; BERNARDES, A. M. Avaliação das características técnica e econômica de um sistema de colheita florestal de árvores inteiras. **Scientia Forestalis**, v. 37, n. 83, p. 225–232, 2009.

FIEDLER, N. C.; CAMPOS, A. A.; CALDEIRA, M. V. W.; LIMA, J. S. S.; RAMALHO, A. H. C.; LOPES, E. S. Economic and operational analysis of mechanized forest implementation. **Revista Árvore**, v. 44, p. 1–9, 2020.

FIEDLER, N. C.; OLIVEIRA, M. P. **Motores e máquinas florestais**. Alegre, ES: CAUFES, 2018.

FONTES, J. M.; MACHADO, C. C. Manutenção mecânica. In: MACHADO, C. C. **Colheita florestal**. 2. ed. Viçosa: UFV, 2008. p. 265.

FONTES, J. M.; MACHADO, C. C. Manutenção Mecânica. In: MACHADO, C. C. **Colheita Florestal**. 3. ed. Viçosa, MG: Editora UFV, 2014. p. 288–335.

FREIRE, G. de M.; HEIMANN, J. de P.; da CUNHA, L. H. R. Análise da produção científica de brasileiros acerca da certificação florestal. **Revista Brasileira Multidisciplinar**, v. 24, n. 2, p. 263-279. 2021.

GANDA, L. da S.; SILVA, Z. A. P. G. da. G. Aspectos econômicos da exploração florestal nos trópicos: um estudo de caso da atividade de arraste em uma floresta manejada no estado do Amazonas, 2017. **Scientia Naturalis**, v. 1, n. 5, p. 56-71, 2019.

GONÇALVES, S. B.; FIEDLER, N. C.; SILVA, J. P. M.; SILVA, G. F.; SILVA, M. L. M.; MINETTE, L. J.; PEREIRA, D. P.; LOPES, D. M. M.; SILVA, E. F.; RAMALHO, A. H. C.; SANTOS, J. S.; AGUIAR, M. O.; NETO, J. O. M.; FILHO, R. N. A. Machine learning techniques to estimate mechanised forest cutting productivity. **Southern Forests**, v. 83, n. 4, p. 276–283, 2021.

GONÇALVES, S. B. **Modelagem matemática da produtividade do corte florestal mecanizado**. 2017. 62f. Tese (Doutorado em Ciência Florestal) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES, 2017.

GUJARATI, D. N. **Econometria básica**. 2 ed. São Paulo: Makron Books, 2000. 846 p.

GORDON, C. **Artificial Neural Network Modeling of Forest Tree Growth**. 1998. 76 f. Dissertação (Mestrado) – University of the Witwatersrand, 1998).

GÖRGENS, E. B.; LEITE, H. G.; SANTOS, H. N.; GLERIANI, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, v.33, n.6, p. 1141-1147, 2009.

HÄGGSTRÖM, C.; LINDROOS, O. Human, technology, organization and environment – a human factors perspective on performance in forest harvesting. **International Journal of Forest Engineering**, v. 27, n. 2, p. 67-78, 2016.

HAYKIN, S. **Redes neuronais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

HEATON, J. **Programming Neural Networks with Encog3 in Java** (2nd ed., 240 p.). Heaton Research, Incorporated, 2011.

HICKEY, C.; KELLY, S.; CARROLL, P.; O'CONNOR, J. Prediction of forestry planned end products using dirichlet regression and neural networks. **Forest Science**, v.61, n.2, p.289-297, 2015.

HIESL, P.; WARING, T. M.; BENJAMIN, J. G. The effect of hardwood component on grapple skidder and stroke delimber idle time and productivity – an agent-based model. **Computers and Electronics in Agriculture**, v. 118, p. 270–280, 2015.

HOLTZSCHER, M.A.; LANFORD, B.L. Tree diameter effects on cost and productivity of cut-to-length systems. **Forest Products Journal**, v.47, n. 3, p. 25-30, 1997. IBÁ – Indústria Brasileira de Árvores. **Relatório 2021**: Ano base 2019. Brasília, 2021.

J DE SOUZA. **Feller de tesoura**. Disponível em: <<https://www.jdesouza.com.br/cabecotes-de-corte-cabecote-de-tesoura>>. Acesso em: 25 mar. 2022.

JOHN DEERE. **Forwarder 1510E | Forwarders Série E | John Deere BR**. Disponível em: <<https://www.deere.com.br/pt/forwarders/1510e/>>. Acesso em: 24 mar. 2022a.

JOHN DEERE. **Harvester 1270E | Harvesters Série E | John Deere BR**. Disponível em: <<https://www.deere.com.br/pt/harvesters/1270e/>>. Acesso em: 24 mar. 2022b.

JOHN DEERE. **Skidder 648L | Skidders Série L | John Deere BR**. Disponível em: <<https://www.deere.com.br/pt/skidders/648l/>>. Acesso em: 25 mar. 2022c.

KOMATSU FOREST. **Komatsu XA233**. Disponível em: <<https://www.komatsuforest.com.br/produtos/cabecotes-feller/xa233>>. Acesso em: 25 mar. 2022.

LABELLE, E. R.; LEMMER, K. J. Selected Environmental Impacts of Forest Harvesting Operations with Varying. **Croatian Journal of Forest Engineering**, v. 40, n. 2, p. 239–257, 2019.

LACERDA, L. C.; Da VITÓRIA, E. L.; FIEDLER, N. C.; CARMO, F. C. A.; GONÇALVES, S. B.; RAMALHO, A. H. C.; ALVES, D. S. Prediction of Mechanical Availability in Mechanized Eucalyptus Forest Harvesting Using Artificial Neural Networks. **Journal of Agricultural Science**, v. 14, n. 3, p. 157-163, 2022.

LACERDA, L. C.; FIEDLER, N. C.; CHICHORRO, J. F.; MINETTE, L. J.; CARMO, F. C. A. Analysis of the production capacity from a harvester in the forest in own and outsourced modules. **Revista Árvore**, v.41, n.1, p. 41-48, 2017.

LACERDA, L. C.; FIEDLER, N. C.; CHICHORRO, J. F.; CARMO, F. C. A.; MENDONÇA, A. R. Análise operacional da extração florestal mecanizada em módulos próprios e terceirizados. **Nativa**, v. 3, p. 205-209, 2015.

LANA, G. C.; TIMOFEICZYK JUNIOR, R.; SILVA, D. A.; MALINOVSKI, R. A.; BURATTO, D. A. Analysis of the cost of forest harvesting for the production of charcoal for iron and steel industry. **Floresta**, Curitiba, PR, v. 48, n. 4, p. 453-462, out/dez. 2018.

LEITE, E. Da S.; MINETTE, L. J.; FERNANDES, H. C.; SOUZA, A. P.; AMARAL, E. J.; LACERDA, E. Das G. Desempenho do harvester na colheita de eucalipto em diferentes espaçamentos e declividades. **Revista Árvore**, v. 38, n. 1, p. 1–7, 2014.

LEITE, H. G.; BINOTI, D. H. B.; DE OLIVEIRA NETO, R. R.; LOPES, P. F.; DE LIMA, G. F.; OLIVEIRA, F. M. Manutenção mecânica, eficiência operacional e custo de produção de harvesters de pneus e esteiras. **Scientia Rural**, Ponta Grossa, v. 1, ed. 19, p. 01-13, 2019.

LIMA, J. S. DE S.; LEITE, Â. M. PINTO. Mecanização. In: MACHADO, C. C. **Colheita Florestal**. 3. ed. Viçosa, MG: Editora UFV, 2014. p. 46–73.

LINHARES, M.; JÚNIOR, C. R. S.; CAMPOS, F.; YAMAJI, F. M. Eficiência e desempenho operacional de máquinas Harvester e Forwarder na colheita florestal. **Pesquisa Agropecuária Tropical**, v. 42, n. 2, p. 212–219, 2012.

LINDROOS, O.; LA HERA, P.; HÄGGSTRÖM, C. Drivers of Advances in Mechanized Timber Harvesting – a Selective Review of Technological Innovation. **Croatian Journal of Forest Engineering**, v. 38, n. 2, p. 243 – 258, 2017.

LOPES, L. S. S.; RODE, R.; PAULETTO, D.; BALONEQUE, D. D.; SANTOS, F. G.; SILVA, A. R.; BINOTI, D. H. B.; LEITE, H. G. Uso de regressão e redes neurais artificiais na estimativa do volume de *Khaya ivorensis*. **Revista Ciência da Madeira**, v. 11, n. 2, p. 74-84, 2020.

MACHADO, C. C. et al. O setor florestal brasileiro e a colheita florestal. In: MACHADO, C. C. **Colheita Florestal**. 3. ed. Viçosa: Editora UFV, 2014. v. 3p. 15–45.

MACHADO, C. C. **Exploração Florestal**. 4 ed. Viçosa, MG: Editora UFV, 1985, 60p.

MACHADO, C.C.; LOPES, E.S. Planejamento. In: MACHADO, C.C., (Ed.). **Colheita florestal**. 3 ed. Viçosa, MG: UFV, 2014. p. 206-251.

MALINOVSKI, J. R. et al. Sistemas. In: MACHADO, C. C. **Colheita Florestal**. 3. ed. Viçosa, MG: Editora UFV, 2014. v. 3p. 178–202.

MALINOVSKI, R.A.; MALINOVSKI, R. A.; MALINOVSKI, J.R.; YAMAJI, F. M. 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. **Revista Floresta**, v.36, n.2, p.166-182, 2006.

MAROCO, J.; **Análise Estatística – Com utilização do SPSS**, 2ª edição; Edições Sílabo; 2003.

MARTINS, E.R.; BINOTI, M.L.M.S.; LEITE, H.G.; BINOTI, D.H.B.; DUTRA, G.C. Configuração de redes neurais artificiais para estimação da altura total de árvores de eucalipto. **Agrária**, v.11, n.2, p.117-123, 2016.

MARTINS, E.R.; BINOTI, M.L.M.S.; LEITE, H.G.; BINOTI, D.H.B.; DUTRA, G.C. MASIOLI, W.; FIEDLER, N. C.; LOPES, E. da S.; de OLIVEIRA, F. M. Exposição de trabalhadores a ruído e vibração em atividades de colheita florestal semimecanizada. **Pesquisa Florestal Brasileira**, v. 40, 2020. 7p.

MARTINS, R.J.; SEIXAS, F.; STAPE, J.L. Avaliação técnica e econômica de um harvester trabalhando em diferentes condições de espaçamento e arranjo de plantio em povoamento de eucalipto. **Revista Scientia Forestalis**, v. 37, n. 83, p. 253-263, 2009.

McEWAN, A.; MARCHI, E.; SPINELLI, R.; BRINK, M. Past, present and future of industrial plantation forestry and implication on future timber harvesting technology. **Journal of Forestry Research**, v. 31, p. 339–351, 2020.

MENDES, J. C. T.; SEIXAS, F. Avaliação dos impactos da colheita florestal nos atributos físicos do solo em uma reserva legal. **Scientia Forestalis**, v. 46, n. 118, p. 143–155, 2018.

MINETTE, L. J.; SILVA, E. N.; FREITAS, K. E.; SOUZA, A. P.; SILVA, E. P. Análise técnica e econômica da colheita florestal mecanizada em Niquelândia, Goiás. **Revista Brasileira de Engenharia Agrícola e Ambiental - Agriambi**, v. 12, n. 6, p. 659–665, 2008.

MIYAJIMA, R. H.; TONIN, R. P.; PASSOS, J. R. S.; FENNER, P. T. A influência da declividade do terreno e do tempo de experiência dos operadores no rendimento do *Feller Buncher*. **Scientia Forestalis**, v. 44, n. 110, p. 443–451, 2016.

MIYAJIMA, R. H. TONIN, R. T.; FENNER, P. T.; SIMÕES, D. Análise quantitativa do risco técnico-econômico de um trator florestal Skidder. **BIOFIX Scientific Journal**, v. 2, n. Especial I MECFOR, p. 12, 2017.

MIYAJIMA, R. H. PASSOS, J. R. S.; FENNER, P. T.; SIMÕES, D. Extração de eucalipto com *Grapple Skidder*: abordagem de produtividade operacional e custos de produção. **Scientia Forestalis**, v. 48, n. 128, p. 1–13, 2020.

MIYAJIMA, R. H.; FENNER, P. T.; BATISTELA, G. C.; SIMÕES, D. Effect of feller-buncher model, slope class and cutting area on the productivity and costs of whole tree harvesting in Brazilian eucalyptus stands. **Forests**, v. 12, n. 8, 2021.

MONTGOMERY, D. C.; VINING, G. C. PECK, E. A. **Introduction to linear regression analysis**. 3 Ed. New York: J. Wiley, 2001, 641 p.

MONTGOMERY, D. C.; RUNGER, G. C. **Applied Statistics and Probability for Engineers**. John wiley & sons, ed. 6, 811p., 2010.

MOURA, J. P. V. M.; SOUSA, R. A. T. M.; CARVALHO, M. P. L. C.; MÔRA, R. Análise técnica e econômica de sistema de extração de toras longas de *Tectona grandis* com trator arrastador adaptado em floresta plantada. **Advances in Forestry Science**, v. 6, n. 4, p. 783, 2019.

NETER, J.; WASSERMAN, W.; KUTNER, M.H. **Applied linear statistical models, regression, analysis of variance and experimental designs**. Richard D. Irwing, Inc. 1985, 1127p.

NEWMAN, S. M.; KEEFE, R. F.; BROOKS, R. H.; AHONEN, E. Q.; WEMPE, A. M. Human Factors Affecting Logging Injury Incidents in Idaho and the Potential for Real-Time Location-Sharing Technology to Improve Safety. **Safety**, v. 4, n. 4, p. 43, 2018.

NGUYEN, V.; LE, T.; TROUNG, H.; LE, M. V.; NGO, V.; NGUYEN, A. T.; NGUYEN, H. Q. Applying Bayesian optimization for machine learning models in predicting the surface roughness in single-point diamond turning polycarbonate. **Mathematical Problems in Engineering**, v. 2021, 2021.

OLIVEIRA, D. **Análise operacional e custos de sistemas de colheita de madeira em povoamentos de eucalipto**. Dissertação (mestrado) - Universidade Estadual do Centro-Oeste. Irati, PR, 116p, 2013.

OLIVEIRA, H. F. **Análise de custos na extração de madeira no município de Juara**. 2016. 42f. Monografia (Engenharia Florestal) - Universidade Federal de Mato Grosso, Instituto de Ciências Agrárias e Ambientais (ICAA) – Sinop, MT, 2016.

OLIVEIRA, F. M.; LOPES, E. S.; FIEDLER, N. C.; KOEHLER, H. S. Indicador para avaliação da urgência na intervenção ergonômica de máquinas de colheita de madeira. **Revista Árvore**. v. 44, n. 28, p. 10, 2020.

OLIVEIRA, J. L. C.; OLIVIERA, F. M. Análise técnica da extração de madeira de pinus em áreas declivosas. **Scientia Rural**. v. 19, n. 49, p. 12, 2019.

OTHMAN, K.; ABDELWAHAB, H. Prediction of the Soil Compaction Parameters Using Deep Neural Networks. **Transportation Infrastructure Geotechnology**, v. 1, n. 123456789, p. 40, 2021.

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

PENG, C.; WEN, X. **Recent applications of artificial neural networks in forest resource management: an overview**. 1999. Disponível em: <https://www.aaai.org/Papers/Workshops/1999/WS-99-07/WS99-07-003.pdf>. Acesso em 15 de maio de 2022.

PEREIRA, G.; FENNER, P. T.; BATISTELA, G. C.; SIMÕES, D. Análise técnica-econômica da derrubada de *Eucalyptus* sp. com *Feller-Buncher*: uma abordagem estocástica. **Scientia Forestalis**, v. 48, n. 126, p. 1–13, 2020.

PETERSON CAT. **555D | Peterson CAT**. Disponível em: <<https://www.petersoncat.com/products/new/track-skidders/tsk>>. Acesso em: 25 mar. 2022.

PUIATTI, G.; CECON, P. NASCIMENTO, M.; NASCIMENTO, A.; FINGER, F.; PUIATTI, M.; SILVA, F.; SILVA, A. Comparação dos métodos de agrupamento de Tocher e UPGMA no estudo de divergência genética em acessos de alho. **Revista da Estatística da Universidade Federal de Ouro Preto**. Ouro Preto, v. 3, n. 3, p. 275-279, 2014.

RAMOS, J.; BROWN, R.; SCHUSTER, L.; NAKAJIMA, N.; ROBERT, R. C. Análise técnica de um sistema de colheita mecanizada de toras curtas em desbaste na região do norte pioneiro do Paraná. **Enciclopédia Biosfera**, Centro Científico Conhecer – Goiânia, v.13 n.23, p. 1764, 2016.

RAMOS, W. F.; RUVIO, M. L. P.; JARDIM, M. A. G.; SOUSA, L. M. Geração de resíduos madeireiros do setor de base florestal na região metropolitana de Belém, Pará. **Ciência Florestal**, v. 28, n. 4, p. 1823-1830, 2018.

RISSMAN, A. R.; GEISLER, E.; GORBY, T.; RICKENBACH, M. G. “Maxed Out on Efficiency”: Logger Perceptions of Financial Challenges Facing Timber Operations. **Journal of Sustainable Forestry**, v. 41, n. 2, p. 115–133, 2022.

RICHARDSON, R.; MAKKONEN, I. The performance of cut-to-length systems in Eastern Canada. FERIC Technical Report, n.109, p.1-16, 1994.

ROCHA, E. B. Da.; FIEDLER, N. C.; ALVES, R. T.; LOPES, E. S. Produtividade e custos de um sistema de colheita de árvores inteiras. **CERNE**, v. 15, n. 3, p. 372–381, 2009.

ROCHA, J. E. C. da; NOGUEIRA JÚNIOR, M. R.; TAVARES JÚNIOR, I. da S.; SOUZA, J. R. M. de; LOPES, L. S. de S.; SILVA, M. L. da. Configuração de redes neurais artificiais para relação hipsométrica de árvores de *Eucalyptus* spp. **Scientia Forestalis**, v. 49, n. 132, p. e3706, 2021. DOI: 10.18671/scifor.v49n132.08.

RODRIGUES, C. K. **Colheita e Transporte Florestal**. 1. ed. Curitiba, PR: A autora, 2018.

RODRIGUES, C. K.; LOPES, E. S.; OLIVEIRA, D.; SAMPIETRO, J. A. Influência do volume das árvores no desempenho do processador florestal *Harvester* em povoamento de eucalipto. **BIOFIX Scientific Journal**, v. 3, n. 2, p. 237, 2018.

ROHANI, A.; ABBASPOUR-FARD, M. H.; ABDOLAHPOUR, S. Prediction of tractor repair and maintenance costs using Artificial Neural Network. **Expert Systems with Applications**, v. 38, n. 7, p. 8999-9007, 2011.

ROLOFF, C. **Apostila de mecanização florestal**. 1 ed., Visconde Leopoldo, CEEPRO – Visconde Leopoldo, 2019, 79p.

SANT’ANNA, C. DE M. Corte. In: MACHADO, C. C. **Colheita Florestal**. 3. ed. Viçosa: Editora UFV, 2014. v. 3p. 74–105.

SANTOS, D. W. F. do N.; FERNANDES, H. C.; VALENTE, D. S. M.; LEITE, E. da S. Análise técnica e econômica de dois subsistemas de colheita de madeira de toras curtas. **Revista Brasileira de Ciências Agrárias**, v.13, n.2, p. 1981-0997, 2018.

SANTOS, S. L. M.; MACHADO, C. C. Análise técnico-econômica do processamento de madeira de eucalipto em áreas planas, utilizando o processador. **Revista Árvore**, v. 19, n. 3, p. 346-57, 1995.

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.

SEIXAS, F.; CASTRO, G. P. Extração. In: MACHADO, C. C. **Colheita Florestal**. 3. ed. Viçosa: Editora UFV, 2014. v. 3p. 106–161.

SHIMAKURA, S. E. **Interpretação do coeficiente de correlação**. 2006. Disponível em: < <http://leg.ufpr.br/~silvia/CE003/node74.html> >. Acesso em: 20 de março de 2017.

SILVA, A. A.; MACHADO, C. C.; GOMES, R. R. M.; SCHETTINI, B. L. S.; MINETTE, L. J.; NUNES, I. L.; VILLANOVA, P. H. Forest extraction management with the indicator of overall efficiency of forest machines (oefm). **Revista Árvore**. v. 46, n. 1, p. 8. 2022.

SILVA RIBEIRO, R. B.; GAMA, J. R. V.; SOUZA, A. L.; LEITE, H. G.; SOARES, C. P. B.; SILVA, G. F. Métodos para estimar o volume de fustes e galhos na Floresta Nacional do Tapajós. **Revista Árvore**, v.40, n.1, p.81-88, 2016.

SILVA, M. L.; JACOVINE, L. A. G.; VALVERDE, S. R. Economia florestal. 2 ed. 2 reimpressão. Viçosa, MG: Universidade Federal de Viçosa, 2012. 178 p.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010a. 399p.

SILVA, J. R. DA; FENNER, P. T.; CATANEO, A. Avaliação do desempenho operacional de trator florestal “Feller-Buncher”. **Revista de Ciências Agroveterinárias**, v. 6, n. 1, p. 29–34, 2007.

SIMÕES, D.; IAMONTI, I. C.; FENNER, P. T. Avaliação técnica e econômica do corte de eucalipto com *feller-buncher* em diferentes condições operacionais.

**Ciência Florestal**, Santa Maria, v. 20, n. 4, p. 649-656, 2010.

SIMÕES, D. AVELINO, L. T.; MUNIS, R. A.; BATISTELA, G. C.; MIYAJIMA, R. H. Grapple saw's operating conditions influence on the productivity and cost of processing felled trees. **Floresta**, v. 52, n. 1, p. 64–73, 2022.

SIMÕES, D.; FENNER, P. T.; ESPERANCINI, M. S. T. Produtividade e custos do *Feller-Buncher* e processador florestal em povoamento de eucalipto de primeiro corte. **Ciência Florestal**, v. 24, n. 3, p. 621–630, 2014.

SOARES, N. S.; SOUSA, E. P.; SILVA, M. L. In: **Congresso da Sociedade Brasileira de Economia, Administração e Sociologia Rural**. 46, 2008, Rio Branco. Anais... Disponível em: <<http://www.sober.org.br/palestra/9/214.pdf>>. Acesso em: 20 junho. 2022.

SPINELLI, R.; VISSER, R.; BJÖRHEDEN, R.; RÖSER D. Recovering Energy Biomass in Conventional Forest Operations: a Review of Integrated Harvesting Systems. **Current Forestry Reports**, v. 5, p. 90–100, 2019.

SZYMCZAK, D. A. BRUN, E. J.; REINERT, D. J.; FRIGOTTO, T.; MAZZALIRA, C. C.; LÚCIO, A. D.; MARAFIGA, J. 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.

TANAKA, O.P. Exploração e transporte da cultura do eucalipto. **Informe Agropecuário**, n. 141, p. 24-30, 1986.

TEIXEIRA, R. C.; SANTOS, D. W. F. N.; FERNANDES, H. C.; DADALTO, J. P. Desempenho técnico e econômico do feller-buncher em distintas características dendrométricas do povoamento florestal. **Nativa**. v. 6, n. especial, p; 782-786, 2018.

TIGERCAT. **C640E clambunk skidder with S860C shovel logger - Tigercat**. Disponível em: <<https://www.tigercat.com/video/c640e-clambunk-skidder-s860c-shovel-logger/>>. Acesso em: 25 mar. 2022.

TMO FOREST. **GARRA TRAÇADORA - TMO**. Disponível em: <<https://tmo.com.br/produtos/implementos-para-escavadeira-florestal/garra-tracadora/>>. Acesso em: 25 mar. 2022.

TURBOSQUID. **modelo 3d Tigercat 855D rastreador feller buncher sucio - TurboSquid 1487502**. Disponível em: <<https://www.turbosquid.com/es/3d-models/tigercat-855d-tracked-feller-3d-model-1487502>>. Acesso em: 25 mar. 2022.

VAHEDI, A. A. Monitoring soil carbon pool in the Hyrcanian coastal plain forest of Iran: Artificial neural network application in comparison with developing traditional models. **Catena**, v.152, p.182-189, 2017.

VASILEV, A. S.; SHEGELMAN, I. R.; GALAKTIONOV, O. N.; KUZNETSOV, A. V.; SUKHANOV, Y. V.; SHTYKOV, A. S. Using the Knowledge Base as a Tool for Improving Forestry Technology (By Example, Harvester Head). **Journal of Computational and Theoretical Nanoscience**, v. 16, n. 7, p. 3076-3086, 2019.

VELOSO, R. B. **Proposta de um modelo não linear de crescimento e produtividade florestal**. 2012. 103f. Tese (Doutorado em Ciências Florestais) – Universidade Federal de Lavras, Lavras, MG, 2012.

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