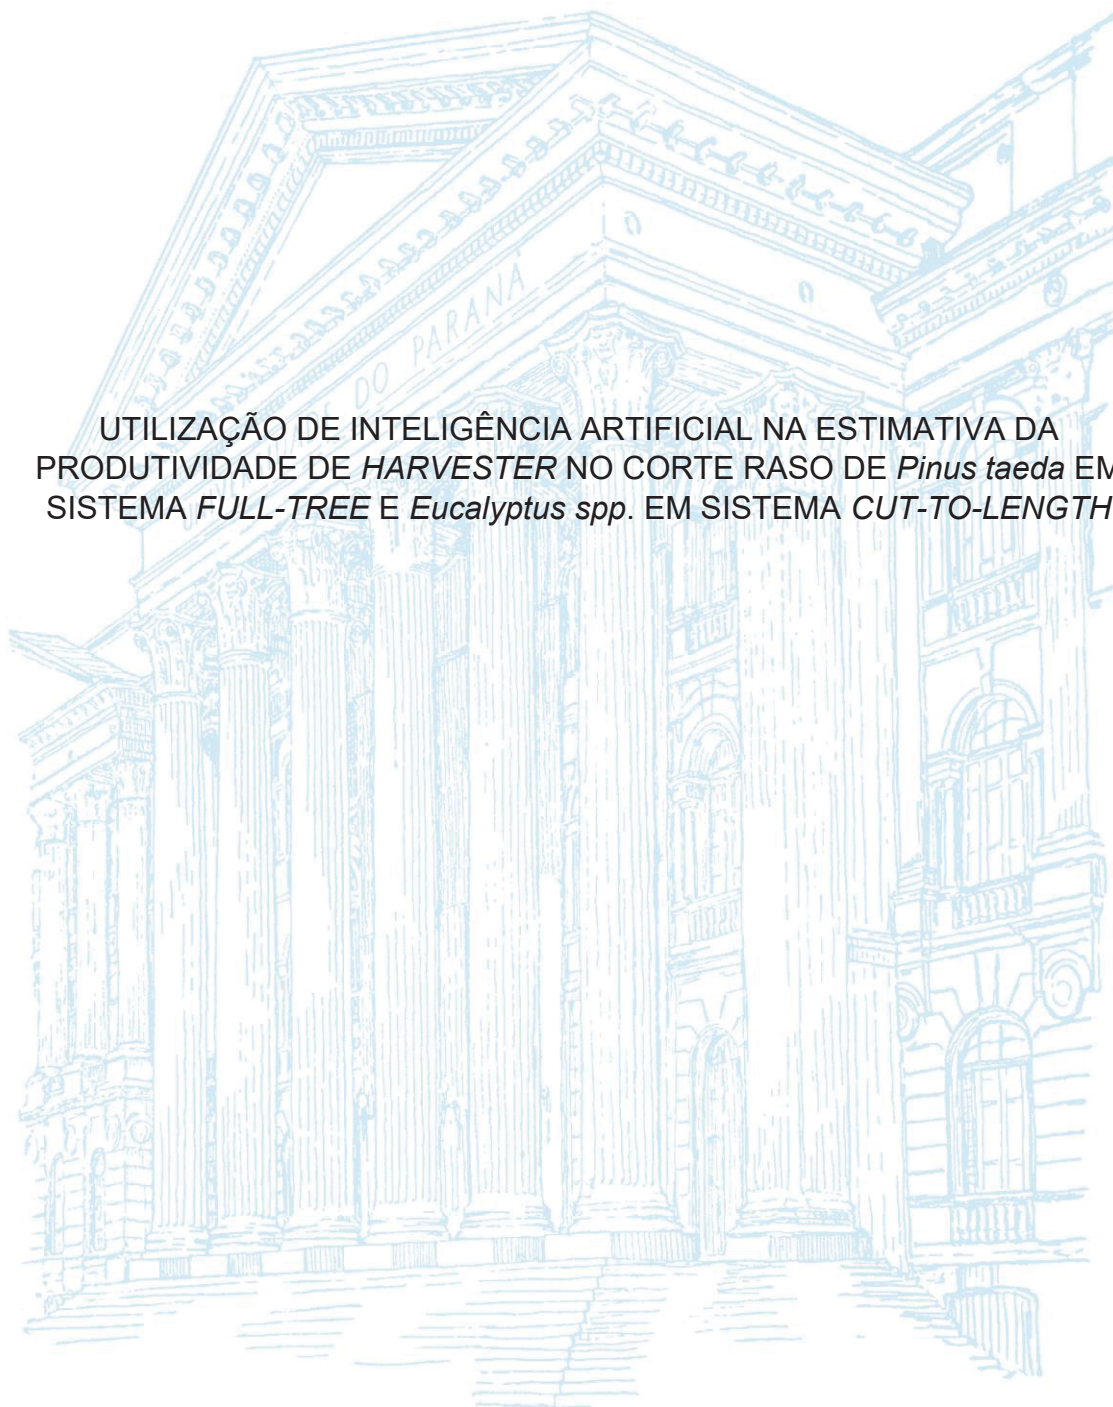


UNIVERSIDADE FEDERAL DO PARANÁ

ALEXANDRE BAUMEL DOS SANTOS

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA ESTIMATIVA DA
PRODUTIVIDADE DE *HARVESTER* NO CORTE RASO DE *Pinus taeda* EM
SISTEMA *FULL-TREE* E *Eucalyptus spp.* EM SISTEMA *CUT-TO-LENGTH*



CURITIBA

2022

ALEXANDRE BAUMEL DOS SANTOS

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA ESTIMATIVA DA
PRODUTIVIDADE DE *HARVESTER* NO CORTE RASO DE *Pinus taeda* EM
SISTEMA *FULL-TREE* E *Eucalyptus spp.* EM SISTEMA *CUT-TO-LENGTH*

Trabalho de Conclusão de Curso apresentado ao
Curso de MBA em Manejo Florestal de Precisão
do Programa de Educação Continuada em
Ciências Agrárias, da Universidade Federal do
Paraná como requisito à obtenção do título
Especialista.

Orientador: Prof. Dr. Renato C. G. Robert.

Coorientador: Prof. Dr. Razer A. N. R. Montaña.

CURITIBA

2022

À minha querida e amada mãe Cristiane, pelo enorme esforço e imenso amor.

DEDICO.

AGRADECIMENTOS

À minha família, pelo incentivo e auxílio na realização desse objetivo.

Ao meu orientador, Prof. Dr. Renato Robert pela valorosa orientação e confiança depositada na execução desse trabalho.

Aos professores Razer Montaña e Jean Sampietro, pela coorientação, boa vontade e disponibilidade fundamentais para a realização do trabalho.

À Universidade Federal do Paraná e ao curso de Engenharia Florestal, pela oportunidade e possibilidade de realização deste trabalho.

RESUMO

O presente estudo tem como objetivo tratar sobre a modelagem da produtividade de *Harvester* processador em sistema *Full-tree* em colheita de *Pinus taeda*, e *Harvester* derrubador-processador em sistema *Cut-to-Length* em colheita de *Eucalyptus dunnii* e *Eucalyptus benthamii*, através da aplicação de técnicas de inteligência artificial em comparação com métodos de regressão, utilizando volume individual e comprimento das toras como preditores. Os bancos de dados pertencem a um estudo de tempos e movimentos ao nível de turno, advindos de uma empresa florestal localizada na cidade de Otacílio Costa – SC. As técnicas de inteligência artificial avaliadas foram Redes Neurais Artificiais, Máquina de Vetor de Suporte e *Random Forests*, que foram comparadas às metodologias de Regressão Linear Múltipla e Regressão Linear por *Stepwise*, as quais foram avaliadas quanto o desempenho estatístico dos resultados das estimativas. Assim, foi calculada a produtividade por hora máquina produtiva dos equipamentos ($tPMH_{10}^{-1}$), e calculada as estatísticas descritivas desta e das variáveis independentes. Nas técnicas de regressão, foi aplicado o teste de normalidade de Kolmogorov – Smirnov, em nível de 5% de significância, que constatou a ausência de normalidade em ambas as máquinas monitoradas para a produtividade, necessitando então de transformação matemática. No aprendizado das técnicas de *Machine Learning*, foram testadas diferentes técnicas de separação da base de dados em treino e validação (*hold-out* e *cross-validation*), além de diferentes configurações dos parâmetros utilizados na modelagem dos métodos. Para o *Harvester* processador no sistema FT, as Redes Neurais apresentaram melhores resultados dos indicadores de qualidade e acurácia estatística na estimação da produtividade, em contrapartida no sistema CTL, a Regressão Linear por *Stepwise* obteve melhor desempenho no ajuste da variável de interesse do equipamento estudado, indicando um potencial do uso da Inteligência Artificial na modelagem de variáveis das Operações Florestais, bem como a validação da Regressão Linear como uma ferramenta sólida para a esta finalidade.

Palavras-chave: Colheita Florestal, Inteligência Artificial, Modelagem, Produtividade.

ABSTRACT

The present study aims to address the modeling of productivity of the Harvester processor in a Full-tree system in *Pinus taeda* harvesting, and Harvester feller-processor in a Cut-to-Length system in *Eucalyptus dunni* and *Eucalyptus benthamii* harvesting, through the application of artificial intelligence techniques compared to regression methods, using individual volume and length of logs as predictors. The databases belong to a time and motion study at the shift level, coming from a forestry company located in the city of Otacílio Costa - SC. The artificial intelligence techniques evaluated were Artificial Neural Networks, Support Vector Machine and Random Forests, which were compared to the Multiple Linear Regression and Stepwise Linear Regression methodologies, as which were evaluated regarding the statistical performance of the results of the operations. Thus, the productivity per productive machine hour of the equipment ($tPMH_{10}^{-1}$) was calculated, and the descriptive statistics of this and the independent variables statistics were calculated. In the regression techniques, the Kolgomorov - Smirnov normality test was applied, at a 5% significance level, which found the absence of normality in both machines monitored for productivity, thus requiring a mathematical transformation. In learning of Machine Learning techniques, different database separation techniques were tested in training and validation (hold-out and cross-validation), in addition to different configurations of the parameters used in modeling the methods. For the Harvester processor in the FT system, the Artificial Neural Networks have better results of the quality indicators and statistical accuracy in the estimation of productivity, in contrast to the CTL system, the Linear Regression by Stepwise obtained better performance in the adjustment of the variable of interest of the studied equipment, indicating a potential for the use of Artificial Intelligence in the modeling of variables in Forest Operations, as well as the validation of Linear Regression as a solid tool for this goal.

Keywords: Forest Harvest, Artificial Intelligence, Modeling, Productivity.

LISTA DE FIGURAS

FIGURA 1 - MAPA DE LOCALIZAÇÃO DA ÁREA DE ESTUDO.....	21
FIGURA 2 - GRÁFICOS DE DISPERSÃO DAS ESTIMATIVAS EM RELAÇÃO AOS DADOS OBSERVADOS NO SISTEMA <i>FULL-TREE</i>	35
FIGURA 3 - GRÁFICOS DE DISPERSÃO DAS ESTIMATIVAS EM RELAÇÃO AOS DADOS OBSERVADOS NO SISTEMA <i>CUT-TO-LENGTH</i>	36
FIGURA 4 - DISPERSÃO DOS RESÍDUOS DAS ESTIMATIVAS EM FUNÇÃO DA PRODUTIVIDADE NO SISTEMA <i>FULL-TREE</i>	37
FIGURA 5 - DISPERSÃO DOS RESÍDUOS DAS ESTIMATIVAS EM FUNÇÃO DA PRODUTIVIDADE NO SISTEMA CTL.....	38
FIGURA 6 - HISTOGRAMA POR CLASSE DE RESÍDUO DAS ESTIMATIVAS DE PRODUTIVIDADE DO HARVESTER NO SISTEMA <i>FULL-TREE</i>	39
FIGURA 7 - HISTOGRAMA POR CLASSE DE RESÍDUO DAS ESTIMATIVAS DE PRODUTIVIDADE DO HARVESTER NO SISTEMA <i>CUT-TO-LENGTH</i>	40

LISTA DE TABELAS

TABELA 1 - VARIÁVEIS ALEATÓRIAS FORNECIDAS PARA APLICAÇÃO DO MODELO DE STEPWISE.	25
TABELA 2 - EQUAÇÕES PROPOSTAS POR STEPWISE E EQUAÇÃO LINEAR PARA ESTIMATIVA DE PRODUTIVIDADE DE HARVESTER PROCESSADOR EM SISTEMA FT, E HARVESTER DERRUBADOR EM SISTEMA CTL.....	26
TABELA 3 - PARAMÊTROS DE TREINAMENTO DAS RNAS PARA PRODUTIVIDADE DO HARVESTER.....	27
TABELA 4 - PARAMÊTROS DE TREINAMENTO DAS SVMS PARA PRODUTIVIDADE DO HARVESTER.....	27
TABELA 5 - PARAMÊTROS DE TREINAMENTO DAS RFS PARA PRODUTIVIDADE DO HARVESTER.....	28
TABELA 6 – AMOSTRAGEM DO BANCO DE DADOS UTILIZADO NO ESTUDO. .	30
TABELA 7 - ESTATÍSTICA DESCRITIVA DAS VARIÁVEIS DO HARVESTER DERRUBADOR-PROCESSADOR (CTL) E HARVESTER PROCESSADOR (FT). ...	31
TABELA 8 - TESTE DE NORMALIDADE DE KOLMOGOROV – SMIRNOV, NA VARIÁVEL PRODUTIVIDADE, REFERENTE AO EQUIPAMENTO HARVESTER NO CORTE RASO DE Eucalyptus sp. E Pinus taeda.	31
TABELA 9 - CONFIGURAÇÕES DAS TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL COM MELHOR DESEMPENHO ESTATÍSTICO.....	32
TABELA 10 - RESULTADOS DOS ÍNDICES ESTATÍSTICOS POR TÉCNICA DE SEPARAÇÃO DA BASE DE DADOS NO SISTEMA FT.	33
TABELA 11 - RESULTADOS DOS ÍNDICES ESTATÍSTICOS POR TÉCNICA DE SEPARAÇÃO DA BASE DE DADOS NO SISTEMA CTL.	33
TABELA 12 - RESULTADOS ESTATÍSTICOS DAS ESTIMATIVAS DE PRODUTIVIDADE POR INTELIGÊNCIA ARTIFICIAL E REGRESSÃO DO HARVESTER NO SISTEMA FULL-TREE.....	34
TABELA 13 - RESULTADOS ESTATÍSTICOS DAS ESTIMATIVAS DE PRODUTIVIDADE POR INTELIGÊNCIA ARTIFICIAL E REGRESSÃO DO HARVESTER NO SISTEMA CUT-TO-LENGTH.	34

LISTA DE SIGLAS

CTL	-	<i>Cut-to-Length</i>
FT	-	<i>Full-tree</i>
RNA	-	Redes Neurais Artificias
SVM	-	Máquinas de Vetores de Suporte
RF	-	<i>Random Forests</i>

SUMÁRIO

1 INTRODUÇÃO	11
1.1 OBJETIVOS	12
1.1.1 Geral.....	12
1.1.2 Específicos	12
2 REVISÃO BIBLIOGRÁFICA	13
2.1 A CULTURA DO PINUS NO BRASIL.....	13
2.2 A CULTURA DO EUCALIPTO NO BRASIL	13
2.3 COLHEITA FLORESTAL.....	14
2.3.1 Fatores que afetam a produtividade das máquinas florestais	15
2.3.2 Sistemas de Colheita Florestal	16
2.3.3 Estudo de trabalho nas operações florestais.....	18
2.4 INTELIGÊNCIA ARTIFICIAL	19
2.4.1 Aprendizado de Máquina.....	19
3. MATERIAL E MÉTODOS	21
3.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO.....	21
3.2 COLETA DE DADOS	22
3.3 PROCESSAMENTO DOS DADOS	23
3.3.1 Regressão Linear	24
3.3.2 Redes Neurais Artificiais	26
3.3.3 Máquina de Vetores de Suporte.....	27
3.3.4 <i>Random Forests</i>	28
3.4 ANÁLISE DOS DADOS.....	28
4 RESULTADOS E DISCUSSÃO	30
4.1 ESTATÍSTICA DESCRITIVA.....	30
4.2 PROCESSAMENTO DOS DADOS.....	31

4.2.1 Regressão Linear	31
4.2.2 Inteligência Artificial.....	32
4.2.3 Modelagem da produtividade	32
5 CONCLUSÃO	43
REFERÊNCIAS.....	44

1 INTRODUÇÃO

Atualmente o Brasil possui uma base de florestas plantadas consolidada, devido ao alto nível de incremento de biomassa encontrado nas plantações brasileiras frente aos demais países com atividade florestal desenvolvida (IBÁ, 2021).

Segundo Silva (2015), uma parcela significativa do custo total da madeira entregue no pátio das empresas está associada às atividades e operações da colheita e transporte florestal. As operações da colheita florestal têm início no corte da floresta e prosseguem até o carregamento da madeira nos caminhões de transporte.

Nos principais sistemas de colheita mecanizada aplicados no Brasil, utiliza-se uma máquina denominada Harvester nas suas atividades. Os sistemas de árvores inteiras (Full-tree) utiliza o equipamento exclusivamente para o processamento do fuste, já no sistema de toras curtas (Cut-to-length) o colhedor florestal é o responsável pela derrubada e processamento das árvores.

Em função do alto investimento realizado na aquisição dessas máquinas, além do elevado custo de produção, se faz necessário um controle rigoroso na predição das informações relacionadas à produtividade desses equipamentos.

A possibilidade de prever a produtividade das máquinas de colheita por meio da modelagem das operações, em diferentes condições do terreno e do povoamento, é de fundamental importância para o planejamento florestal. Assim, a equipe de gestão, terá uma ferramenta de previsão da produtividade das máquinas de colheita para cada condição de terreno e do povoamento.

Essa previsão poderá ser utilizada no planejamento operacional para discutir as estratégias e metas de produção de madeira para colheitas futuras, além de ser responsável pelo planejamento das operações ou ordens de produção. Com reflexos importantes no suprimento de madeira para a fábrica no curto, médio e longo prazos; ou com reflexos no planejamento estratégico e operacional.

Nesse sentido, os sistemas computacionais são importantes ferramentas para auxiliar no planejamento e na redução dos custos na colheita florestal. O investimento elevado em máquinas na colheita da madeira sem um planejamento adequado da operação e sem a aplicação de ferramentas tecnológicas, pode resultar em um

aumento nos custos e problemas de gestão das operações (MALINOVSKI et al., 2008).

Métodos multivariados de inteligência artificial (IA) são conhecidos sistemas computacionais para prever a saída de sistemas complexos e resolver problemas não lineares multifacetados problemas (mesmo sem informação prévia com alta precisão) (NABAVI-PELESARAEI et al. 2018).

Geralmente, são uma alternativa aos métodos tradicionais de modelagem (por exemplo, os modelos de regressão estatística) e tem maior generalização, menos suscetibilidade ao ruído e outliers e a capacidade de modelar relações não lineares em comparação com modelos de regressão (HAYKIN, 2009).

Desse modo, buscando maior acuracidade na modelagem da produtividade do Harvester nos sistemas de colheita Full-tree e Cut-to-length, por meio do uso de técnicas e ferramentas de Inteligência Artificial, comparando-as com técnicas tradicionais de regressão linear.

1.1 OBJETIVOS

1.1.1 Geral

Modelar a produtividade do *Harvester* nos sistemas de colheita *Full-tree* e *Cut-to-length*, por meio do uso de técnicas e ferramentas de Inteligência Artificial, comparando-as com técnicas tradicionais de regressão linear;

1.1.2 Específicos

- Aplicar três técnicas de inteligência artificial, bem como, duas metodologias de Regressão Linear para a estimação da produtividade de *Harvester* no processamento de árvores inteiras de *Pinus taeda* L. e no processamento de toras curtas de *Eucalyptus sp.*;
- Avaliar dois métodos de separação da base de dados em treino e teste;

2 REVISÃO BIBLIOGRÁFICA

2.1 A CULTURA DO PINUS NO BRASIL

O *Pinus taeda* L. ou do inglês “loblolly pine” ocorre naturalmente em diversos estados do Atlântico médio e sul dos Estados Unidos da América e tem uma das mais extensas geografias dentre os pinheiros. Essa espécie tem distribuição que vai do Texas até a Flórida central (28° N) a leste e, para o norte até Delaware (39° N) (SCHULTZ, 1997). Sua região de ocorrência natural é caracterizada como úmida, temperada quente com verões longos e quentes e invernos suaves.

Nesse contexto, em meados da década de 60, o cultivo comercial do *Pinus taeda* e outras espécies desse gênero foi impulsionado no país, por meio da promulgação da lei de incentivos fiscais pelo governo (KRONKA et al., 2005). Na atualidade, o Brasil tem um dos maiores programas de manejo do gênero *Pinus* do mundo (HARMS et al., 2000).

O estado do Paraná, segundo IBÁ (2021) lidera o ranking de área plantada de Pinus no Brasil, com 44% da área total com a área de 722.338 hectares, seguido por Santa Catarina, com 26% correspondendo a 430.348 mil hectares e Rio Grande do Sul com 281.548 hectares representando 17% da área plantada em todo o território brasileiro.

2.2 A CULTURA DO EUCALIPTO NO BRASIL

Eucalyptus é um gênero de plantas pertencente à família Myrtaceae que reúne mais de seiscentas espécies conhecidas comumente pelo nome “eucalipto”, as quais, em sua maioria, ocorrem naturalmente em ambientes temperados, desérticos, tropicais e sub-alpinos da Austrália continental e da Ilha da Tasmânia (BARRETO, 2019). onde segundo Abares (2019) suas florestas cobrem uma área de 101 milhões de hectares, cerca de 77% das florestas nativas deste país.

No Brasil, no início do século XX, Edmundo Navarro de Andrade sendo o precursor da silvicultura intensiva, passa a ser considerado o introdutor dos eucaliptos e o pai da nova silvicultura no país (SCHUMACHER & VIERA, 2016).

Martini (2004) relata que a partir de 1904, o gênero começa a ser utilizado pela Companhia Paulista de Estradas de Ferro, para suprir a demanda de madeira, comprovando que o eucalipto era a melhor espécie para suas necessidades através da implantação de talhões experimentais.

Na década de 70, não só para testes, mas também para plantios comerciais em pequena escala, novas procedências de *E. grandis* de Zimbábue e da África do Sul, visando formar novas populações para os programas de melhoramento genético da espécie. A partir do uso dessas sementes, houve a rápida expansão dos reflorestamentos brasileiros estimulados pelos incentivos fiscais, que tiveram início em meados da década de 1960 (EMBRAPA, 2019).

Atualmente o gênero *Eucalyptus* é o mais plantado no Brasil. Em 2019 apresentava uma área de 6,97 milhões de hectares, representando 77% do total da área plantada que se concentra principalmente em Minas Gerais, Mato Grosso do Sul e São Paulo. A produtividade média no Brasil é de 35,3 m³/ha/ano, sendo destaque com relação a todos os outros países produtores (IBÁ, 2021).

2.3 COLHEITA FLORESTAL

Segundo Machado (2014), o termo colheita florestal pode ser definido como um conjunto de operações realizadas em um maciço florestal, iniciando com a sua preparação até extração da madeira para o local de transporte, usando as técnicas e os padrões estabelecidos para se transformar a madeira em um produto final. O autor ainda cita como destaque na colheita florestal o fato de ser a atividade, mais importante, do ponto de vista técnico-econômico, e inclui como etapas: o corte (derrubada, desgalhamento e processamento), o descascamento quando realizado no campo, extração e carregamento.

Para Freitas (2005), colheita florestal é o trabalho realizado desde a preparação das árvores para serem abatidas até o transporte para o local definitivo de uso final

da madeira. Dependendo da situação, a operação de colheita florestal, envolverá também o planejamento da operação, a medição da madeira, o recebimento no local definitivo (pátio da indústria) e a sua comercialização.

No Brasil as atividades nos primórdios da colheita florestal eram realizadas de forma manual, empregados na exploração de florestas nativas, não se mensurando e se preocupando com as suas atividades produtivas. Esta forma ainda é utilizada em pequena escala, frequentemente para obtenção de madeira para o uso doméstico (MOREIRA, 2000).

As grandes empresas, atualmente, do setor florestal no Brasil dispõem de modernas e tecnológicas máquinas florestais. Diferentemente disso as médias empresas utilizam mão-de-obra especializada, mas com equipamentos adaptados. Enquanto as pequenas empresas geralmente utilizam métodos rudimentares com a sua mão-de-obra sendo de forma desqualificada (MACHADO et al., 2008).

2.3.1 Fatores que afetam a produtividade das máquinas florestais

Com relação às variáveis sujeitas de mensuração e que podem interferir na produtividade das máquinas pode-se considerar, segundo Malinovski e Camargo (2001): a declividade do terreno, a espécie a ser utilizada, o diâmetro da base e dos galhos, a altura e volume individual das árvores, o volume por hectare, o espaçamento adotado, o tipo de intervenção que irá ocorrer, tipo de rebrota, a necessidade de sortimento, a concentração de madeira, a qualidade da atividade anterior, a densidade e qualidade da malha viária, a altura de tocos após operação de corte, a distância média de extração, as dimensões e qualidade do estaleiro, comprimento da madeira, tipo de solo, teor de umidade, o tempo que a madeira permanece no campo, época do ano, a qualidade do planejamento das operações, pluviosidade, composição do sub-bosque, alinhamento e danos em florestas remanescentes.

A produção florestal, conforme Malinovski e Camargo (2001), quando sofre intervenções de variáveis imprevistas como as chuvas fortes e repentinas, associadas, por exemplo, a alguns tipos de solo pode inviabilizar o tráfego sob

algumas condições. Variáveis independentes de planejamento, como essa, aliada à prática e ao bom senso são ferramentas fundamentais.

Os maquinários utilizados também são considerados variáveis operacionais que podem afligir a produtividade, são eles: o estado dos elementos de desgaste, a qualidade das peças de reposição, o estado dos pneus e esteiras, dependência de outros equipamentos e sistema de manejo adotado (MALINOVSKI; CAMARGO, 2001).

As variáveis operacionais devem ser controladas regularmente para que se possam executar satisfatoriamente as operações programadas. O acompanhamento operacional e manutenção dos equipamentos são de suma importância na obtenção do resultado (BERTIN, 2010).

2.3.2 Sistemas de Colheita Florestal

O sistema de colheita florestal pode ser definido como um conjunto de atividades, integradas entre si, que permitem o fluxo constante de matéria-prima, ou seja, da madeira, evitando os pontos de estrangulamento e exigindo dos equipamentos o máximo empenho de sua capacidade de utilização (MALINOVSKI; MALINOVSKI, 1998).

O sistema de toras curtas (*Cut-to-length*) trata-se do principal sistema de colheita de madeira utilizado no Brasil, sendo que todas as atividades complementares ao corte (desgalhamento, destopamento, traçamento, descascamento e empilhamento) são realizadas no local de derrubada da árvore (MACHADO, 2014), com produção de toras de até 6 m de comprimento. O sistema se realizado de forma mecanizado, é composto basicamente por duas máquinas: Harvester, que realiza o corte e processamento da madeira, e *Forwarder*, que realiza a extração da madeira na forma de baldeio, do interior para a margem do talhão.

Tal sistema pode ser empregado em povoamentos submetidos ao regime de corte raso ou desbaste, sendo neste último caso, uma das melhores alternativas, permitindo a eliminação seletiva e sistemática das árvores do povoamento (INDERFOR E MFAF, 2005). Este sistema de colheita pode ser desenvolvido por

métodos semi-mecanizados e mecanizados, sendo que o mecanizado é o mais usual quando aplicado em desbastes comerciais, em virtude da elevada capacidade de produção e maior produtividade das máquinas, apesar de seu elevado custo operacional e investimento (SPINELLI, 2004).

A colheita pelo sistema de árvores inteiras implica na extração das árvores inteiras para a margem do talhão ou pátio intermediário após a derrubada, onde são processadas em vários produtos (SPINELLI, 2004).

Segundo Adebayo et al. (2006) o típico sistema mecanizado de árvores inteiras requer quatro máquinas: feller-buncher, skidder, processador e carregador florestal. O feller-buncher derruba e acumula as árvores em feixes, posteriormente o skidder realiza a extração na forma de arraste, e por fim, o processador processa as árvores à margem da estrada ou pátio intermediário.

As maiores empresas do Sul do Brasil utilizam esse sistema em suas operações devido ao baixo custo e à tradição de uso por empresas americanas (MALINOVSKI et al., 2014).

Quando se objetiva o aproveitamento da biomassa residual, esse sistema é recomendado, pois os resíduos ficam acumulados à margem do talhão o que facilita sua utilização. Ademais, elimina a maior parte do material combustível dos talhões, prevenindo incêndios florestais e facilitando as operações silviculturais posteriores (ADEBAYO, et al., 2006).

Entretanto, suas maiores limitações estão relacionadas à maior exigência de planejamento das operações, de modo a evitar gargalos nas atividades do sistema, aumento da exportação de nutrientes dos sítios florestais e necessidade de adoção de alto nível de mecanização (MALINOVSKI et al., 2002).

2.3.2.1 Harvester

Esta máquina denominada de colhedor florestal e/ou, processador florestal, possui uma avançada tecnologia, pela capacidade de operar em situações adversas e em condições variadas. Em florestas com espaçamentos abertos, com árvores de

volume entre 0,25 e 0,35 m³, são encontradas as situações ideais de operação, não sendo indicada o uso no corte em florestas com produções abaixo de 150 m³ha⁻¹. São máquinas adequadas para operações com toras entre 2 e 6 metros de comprimento (BURLA, 2008).

O *Harvester* dispõe de uma capacidade de execução simultânea, realizando as operações de derrubada, desgalhamento, traçamento, descascamento, destopamento e empilhamento da madeira (MACHADO, 2014). É a máquina empregada para realizar as atividades de dentro as diversas alternativas dos sistemas de toras curtas e de árvores inteiras.

2.3.3 Estudo de trabalho nas operações florestais

Atualmente, há um acordo geral na comunidade internacional de Engenharia Florestal em relação aos objetivos e métodos de estudo do trabalho (BJORHEDEN, 1991). Isso advém de uma forte cooperação internacional que se iniciou informalmente no final da década de 1950 e posteriormente foi formalizada por várias redes científicas, como o Conselho de Pesquisa Florestal Nórdica (Nordic Forest Research Council, NSRJ e União Internacional de Organizações de Pesquisa Florestal (International Union of Forest Research Organizations, IUFRO) (SUNDBERG, 1988). No final da década de 1990, o pesquisador florestal internacional já tinha disponível vários documentos úteis para consultar, como a Nomenclatura do Estudo sobre o Trabalho Florestal da IUFRO (BJORHEDEN et al., 1995).

O estudo de tempos e movimentos é uma das técnicas utilizadas no planejamento e otimização das atividades de colheita de madeira. Por meio desta técnica, é possível avaliar a eficiência e a produtividade do conjunto de operações empregadas, bem como as variáveis que estão colaborando para as interrupções do trabalho (ANDRADE, 1998).

É utilizado para a determinação do tempo necessário para que uma pessoa qualificada e devidamente treinada, trabalhando em ritmo normal, leva para executar uma tarefa específica (BARNES, 1977). É uma técnica muito importante para análise

do trabalho, em função de informações relevantes em melhorias ou modificações dos processos e métodos de trabalho, geralmente associados à produtividade.

2.4 INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) pesquisa o desenvolvimento de sistemas computacionais que pensam ou atuam como seres humanos. Porém, se pretende-se dizer que um software pensa como um ser humano, tem-se de ter alguma forma que determinar como os seres humanos pensam (RUSSEL; NORVIG, 2004). Refere-se ao estudo e projeto de agentes inteligentes, em que o agente inteligente é um sistema que entende o seu ambiente e toma decisões baseadas neste e maximiza suas chances de resolver problemas (MCCARTHY, 2002).

2.4.1 Aprendizado de Máquina

O Aprendizado de Máquina (AM) inclui técnicas capazes de realizar a estimação de variáveis através de experiências passadas, baseado em funções de proximidade ou hipóteses (Faceli et al., 2001; Schikowski, 2016). Diversas são as técnicas de AM disponíveis, dentre elas a Data mining ou mineração de dados, *Random Forests* ou florestas aleatórias e Redes Neurais Artificiais.

2.4.1.1 Redes Neurais Artificiais

As RNAs são algoritmos baseados em redes biológicas de pensamento do ser humano. De acordo com Bullinaria (2014), a rede neural é composta por diversas unidades de processamento simples e se formam em camadas de redes. De acordo com Eraslan (2009), durante o treinamento, a RNA otimiza as ligações entre as unidades até a minimização do erro das previsões, atingindo a precisão especificada previamente.

Segundo Santos (2001) e Silva (2015), os algoritmos de RNAs são muito úteis e possuem grande eficiência, principalmente para problemas em que os seus processos são de difícil estimação através das equações físicas. Para Leite et al. (2015), a aplicação de RNA em empresas florestais tem se tornado cada vez maior e tornando-se uma ferramenta estratégica no planejamento.

2.4.1.2 Máquina de Vetor de Suporte (SVM)

As Máquinas de Vetores de Suporte (SVM - Support Vector Machines) podem ser usados para classificar dados linearmente separáveis e podem ser estendidos para gerar fronteiras não lineares. Há também uma formulação de SVM que pode ser usada para problemas de regressão (VAPNIK, 1995).

Segundo (HAYKIN, 1999) a máquina de vetores suporte é uma outra categoria das redes neurais alimentadas adiante, ou seja, redes cujas saídas dos neurônios de uma camada alimentam os neurônios da camada posterior, não ocorrendo a realimentação.

Basicamente a ideia por trás do SVM é encontrar uma linha de separação entre os objetos que os separa em classes. Esta linha se torna um plano ou hiperplano, em dimensões maiores. SVMs podem usar dados linearmente separáveis ou não. A figura a seguir ilustra a separação entre objetos para classificação (ARCE et al. 2020).

2.4.1.3 *Random Forests*

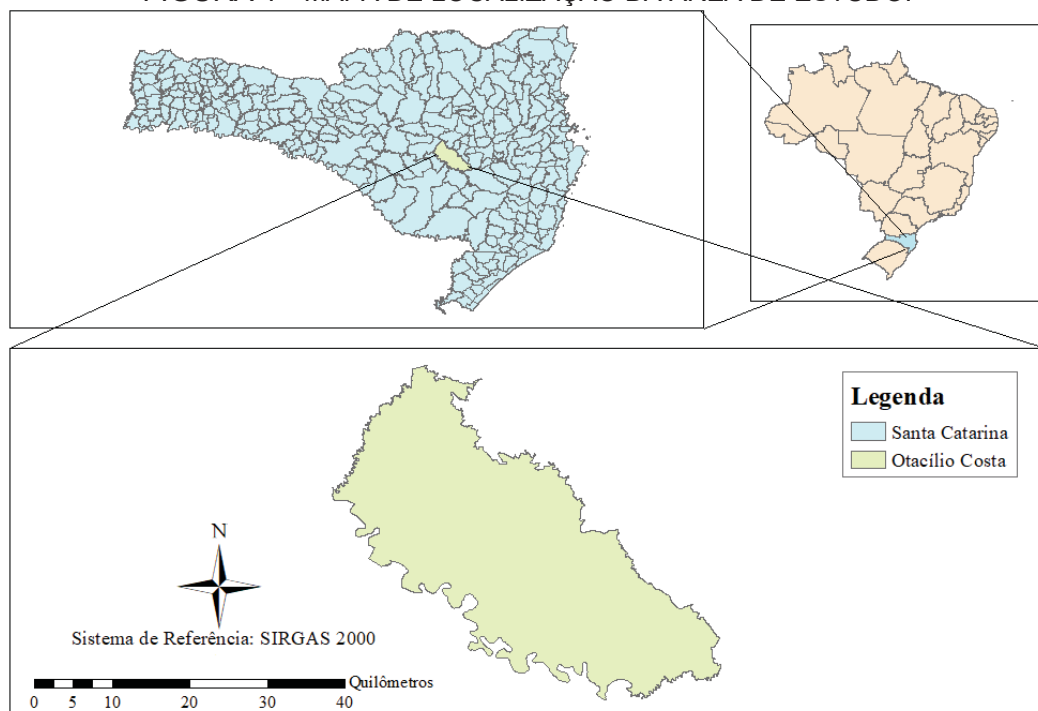
Esta técnica de aprendizado de máquina tem como objetivo construir uma estrutura de dados baseada em árvores, contendo nós, que representam regras sobre os dados de treinamento (ARCE et. al., 2020). De acordo com Schikowski (2016), as *Random forests* consistem em um conjunto de árvores de regressão que são treinadas randomicamente e cada árvore indica sua decisão sobre o valor do objeto.

3. MATERIAL E MÉTODOS

3.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

O presente estudo foi conduzido a partir de dados de colheita florestal advindos de uma empresa localizada no município de Otacílio Costa, na Serra Catarinense, Santa Catarina (FIGURA 1). O clima da região segundo a classificação de Koppen é o clima Cfb, mesotérmico, subtropical úmido, com verões frescos e sem estação seca, mas com a ocorrência de geadas severas (ALVAREZ et al., 2013).

FIGURA 1 - MAPA DE LOCALIZAÇÃO DA ÁREA DE ESTUDO.



FONTE: O autor (2021).

O estudo abrangeu o trabalho de equipamentos *Harvester's* utilizados em dois sistemas de colheita, sendo estes: (i) *Full-tree* (FT), onde as árvores eram derrubadas e arrastadas até a borda do talhão e, então, processadas em toras na beira do talhão por *Harvester* processador de esteiras, John Deere modelo 906 K com cabeçote Waratah 620B, que media, traçava e organizava cada segmento da árvore

(sortimentos) em diferentes pilhas conforme seu uso final; e (ii) *Cut-to-Length* (CTL), onde as árvores eram derrubadas e processadas em toras ainda dentro do talhão por *Harvester* derrubador/processador de pneus, John Deere modelo 1270 E com cabeçote Waratah 270E, que organizava um único sortimento produzido em pilhas visando facilitar a extração.

Em sistema FT a espécie avaliada foi de *Pinus taeda* L., toras destinadas a dois sortimentos, comércio e processo. No sortimento denominado “comércio” foram admitidos o mínimo de 18 cm de diâmetro na ponta fina, com comprimentos de tora variando entre 250 e 420 cm; e, para o sortimento “processo”, o diâmetro de ponta fina mínimo aceitável foi de 8 cm, com comprimentos variando entre 260 e 700 cm. Já em sistema CTL os indivíduos eram correspondentes a *Eucalyptus benthamii* Maiden et Cabbage. e *Eucalyptus dunni* (Maid), produção de toras somente de processo com comprimento médio 720 cm e 6 cm de diâmetro limite na ponta fina.

Nenhum destes sistemas passaram por desbastes, seguindo o cronograma proposto pelo regime *pulpwood*, o qual segundo Scolforo (1997) é preferencialmente utilizado por indústrias de papel e celulose, uma vez que prioriza a produção de indivíduos com menores classes diamétricas. Vale frisar que os módulos de colheita amostrados possuem idades distintas, entre 14 a 18 anos para pinus e entre 7 e 8 anos para eucalipto, implicando assim em diversos valores de volume médio individual, para ambos os bancos de dados.

3.2 COLETA DE DADOS

O método de estudo do trabalho escolhido para a coleta de dados foi ao nível de turno, seguindo uma abordagem de modelagem, conforme proposto por Magagnotti e Spinelli (2012). O método segundo os autores, corresponde na observação de um turno inteiro de trabalho, tomando nota de todos os acontecimentos que neste ocorrem.

No presente estudo, cada módulo de colheita trabalhava numa programação de dois turnos com a duração de 10 horas cada com diversas máquinas e operadores. A coleta de dados foi feita de forma de apontamento de campo manual, ou seja, pelo

próprio operador, onde este tomava nota de tempos superiores a 10 minutos. A variável dependente de interesse do estudo foi a produtividade (Pr) (em toneladas por hora máquina produtiva considerando interrupções de até 10 minutos, $(t * PMH_{10}^{-1})$), utilizando um fator de conversão médio de 1,05 (BONAZZA, 2015) tonelada por metro cúbico $(t * m^3^{-1})$.

3.3 PROCESSAMENTO DOS DADOS

Para fins de modelagem, foram consideradas como variáveis independentes: o volume médio individual (VMI) e comprimento médio ponderado das toras (CP) para o FT e somente o volume médio individual (VMI) para o CTL. Estes foram escolhidos através de estudos bibliográficos (RODRIGUES et al, 2019; PURFÜRST; ERLER, 2013; BRAMUCCI, SEIXAS, 2002; OLIVEIRA et al., 2016).

Ressalta-se que o comprimento médio ponderado, nada mais é do que a média ponderada do comprimento das toras em função da produção por turno, condição que não ocorria em CTL, pois, o comprimento das toras processadas era padronizado em 7 metros.

De posse do banco de dados com todas as variáveis de estudo, foram realizadas as estimativas de produtividade, ou também denominada rendimento operacional do *Harvester*.

As estimativas de produtividade foram realizadas por meio de duas técnicas de regressão: Múltipla e *Stepwise*, e três técnicas de inteligência artificial: Redes Neurais Artificiais (RNA), *Random Forests* e Máquina de Vetor de Suporte (SVM). Os métodos aplicados no estudo foram definidos de forma empírica, através de testes preliminares, bem como, por consultas à literatura disponível.

Para gerar um modelo usando uma base de dados conhecida (observada), deve-se aplicar uma fase de treinamento. Ao final do treinamento, o modelo é gerado e pode-se medir a sua qualidade a partir de métricas conhecidas, também conhecida como fase de teste.

O treinamento é feito usando uma parte da base de dados e os testes outra, sendo estas bases disjuntas. Isso é feito para evitar que o teste seja efetuado com dados já conhecidos do treinamento, invalidando os resultados de generalização do modelo.

O método *hold-out* separa a base em duas: base de treino e base de teste. Em geral são usadas parcelas de 80%/20% ou 70%/30%. A qualidade do modelo é a medida de qualidade obtida com a base de treino. No estudo em questão optou-se pela proporção 80%/20%.

Já no *cross-validation* a base é separada em grupos, por exemplo em 10 grupos. Na primeira rodada, 9 são usados para treino e 1 para teste. Nas rodadas posteriores o grupo de teste é alternado, de forma que cada dado da base participou tanto do treino como do teste. A medida de qualidade é a média de todas as medidas de qualidades parciais em cada rodada e o modelo final é treinado com a base toda.

O presente trabalho avalia ambas as metodologias de separação de dados e utiliza a que obter o melhor desempenho estatístico para cada algoritmo testado, com exceção das técnicas de regressão, nas quais obrigatoriamente utilizou-se o *hold-out*.

3.3.1 Regressão Linear

Os dados da variável de interesse a ser predita (produtividade por hora máquina produtiva) e das variáveis independentes aleatórias (VMI e CP) foram analisados por estatística descritiva. Feito isto, aplicou-se o teste de normalidade de Kolgomorov – Smirnov, em nível de 5% de significância, na variável dependente (produtividade). Como a variável não apresentou normalidade, esta foi transformada matematicamente até apresentar tal pressuposto estatístico e, dessa forma, ser possível prosseguir com a análise covariância e regressão linear.

Encontrada a normalidade da variável dependente e classificados os fatores fixos, iniciou-se com a construção de equações para estimativa de produtividade de *Harvester* utilizando o software estatístico *Statgraphics* com auxílio do software Microsoft® Excel®. Foi comparada a acuracidade de modelos com ajuste por regressão linear múltipla e regressão linear por *Stepwise*.

Para o ajuste da equação por regressão linear foi utilizado os valores das variáveis aleatórias sem transformação matemática. As outras equações foram ajustadas utilizando o procedimento *Stepwise*, pelo método “*forward*”, o qual testa as variáveis independentes (transformadas ou não) e as insere na equação caso agreguem uma melhora no ajuste.

A diferença entre essas técnicas de modelagem, está na utilização de transformações das variáveis na aplicação de *Stepwise* (Tabela 1). Assim, foram criadas 2 possibilidades de equações para estimar a produtividade de *Harvester* processador (FT) e 2 para *Harvester* derrubador-processador (CTL).

TABELA 1 - VARIÁVEIS ALEATÓRIAS FORNECIDAS PARA APLICAÇÃO DO MODELO DE *STEPWISE*.

FT	CTL
VMI	VMI
VMI^2	VMI^2
VMI^3	VMI^3
$1/VMI$	$1/VMI$
$\ln(VMI)$	$\ln(VMI)$
\sqrt{VMI}	\sqrt{VMI}
CP	-
CP^2	-
CP^3	-
$1/CP$	-
$\ln(CP)$	-
\sqrt{CP}	-

FONTE: O autor, 2021.

EM QUE: \ln = logaritmo natural; VMI = volume médio individual; CP = comprimento médio ponderado.

As equações ajustadas pelo método de *Stepwise* e linear, na Tabela 2, estas estão apresentadas conforme banco de dados geral e fatores fixos analisados, ainda sendo possível observar a equação linear simples e de dupla entrada, a qual geralmente é empregada pelas empresas do setor florestal.

TABELA 2 - EQUAÇÕES PROPOSTAS POR *STEPWISE* E EQUAÇÃO LINEAR PARA ESTIMATIVA DE PRODUTIVIDADE DE *HARVESTER* PROCESSADOR EM SISTEMA FT, E *HARVESTER* DERRUBADOR EM SISTEMA CTL.

FT	
Classificação	Modelos
Linear Múltipla	$\sqrt{Pr} = \beta_0 + \beta_1 * CP + \beta_2 * VMI$
<i>Stepwise</i>	$\sqrt{Pr} = \beta_0 + \beta_1 * VMI^3 + \beta_2 * \frac{1}{VMI} - \beta_3 * \log(VMI) - \beta_4 * 1\sqrt{VMI} + \beta_5 * CP^2$
CTL	
Classificação	Modelos
Linear Múltipla	$\ln Pr^2 = \beta_0 + \beta_1 * VMI$
<i>Stepwise</i>	$\ln Pr^2 = \beta_0 - \beta_1 * \sqrt{VMI}$

FONTE: O autor, 2021.

EM QUE: ln = logaritmo natural; Pr = Produtividade ($t PMH_{10}^{-1}$); VMI = volume médio individual ($m^3/\acute{a}rv$); CP = comprimento médio ponderado (cm); β_0 ; β_1 ; β_2 e β_3 ; β_4 ; β_5 = coeficientes do ajuste.

Para a modelagem referente de ambos os sistemas de colheita, na Tabela 9 estão representados os parâmetros de acuracidade dos modelos, bem como seus respectivos valores de coeficientes. Assim, pode-se observar que todas as equações apresentaram relações estatisticamente significativas, devido aos valores de P serem inferiores ao nível de probabilidade de 5%.

3.3.2 Redes Neurais Artificiais

Através do pacote “*caret*” do software *RStudio*, usando o modelo “*nnet*” foi treinada uma rede neural com base em dois parâmetros: *size* e *decay*. A métrica *size* diz respeito à quantidade de neurônios que serão alocados na camada escondida. Deve-se ter cuidado para não utilizar nem unidades demais, o que pode levar a rede a memorizar os dados de treinamento (*overfitting*), ao invés de extrair as características gerais que permitirão a generalização, nem um número muito pequeno, que pode forçar a rede a gastar tempo em excesso tentando encontrar uma representação ótima.

O *decay* é um fator de regularização da rede neural, valores muito baixos tornam o aprendizado da rede muito lento, ao passo que valores muito altos provocam oscilações no treinamento e impede a convergência do processo de aprendizado. A Tabela 3 apresenta os valores dos parâmetros utilizados no treinamento das RNAs.

TABELA 3 - PARAMÊTROS DE TREINAMENTO DAS RNAs PARA PRODUTIVIDADE DO HARVESTER.

Parâmetro	Faixa	Saltos
camadas ocultas	1	-
Size	1 a 50	1
Decay	0,1 a 0,9	0,1

FONTE: O autor, 2021.

3.3.3 Máquina de Vetores de Suporte

Utilizando o modelo “*svmRadial*” inserido no pacote “*caret*” do software *RStudio*, foi realizado o aprendizado da máquina vetor de suporte em função de duas métricas. O parâmetro “C” ou Custo da Classificação que determina o equilíbrio a acurácia e desempenho do modelo, já o “kernel” mapeia pontos em dimensões mais elevadas pode tornar mais fácil a definição de um hiperplano que separe as classes de forma mais precisa.

A escolha dos parâmetros da função kernel e o valor de custo (C) atribuído controlam a complexidade e são os valores que devem ser ajustados de maneira a evitar o *overfitting* do grupo de treinamento. Normalmente quando C é baixo o modelo é *underfited*, subajustado, ao passo que quando o valor de C é elevado pode ocorrer *overfitting*, sobreajuste, a depender do valor dos parâmetros do kernel. Os valores dos parâmetros utilizados para o aprendizado das SVMs estão disponíveis abaixo (TABELA 4):

TABELA 4 - PARAMÊTROS DE TREINAMENTO DAS SVMs PARA PRODUTIVIDADE DO HARVESTER.

Parâmetro	Faixa	Saltos
Custo (C)	100 a 1000	100
Kernel	0,1 a 0,9	0,1
	0,01 a 0,09	0,01

FONTE: O autor, 2021.

3.3.4 Random Forests

Nessa técnica de Inteligência Artificial, com o uso do pacote “*caret*” do *RStudio*, o aprendizado do modelo “*rf*” foi realizado com a manipulação do parâmetro “*mtry*”, referente ao número de atributos escolhidos aleatoriamente para cada árvore, usados para criar os nós de decisão.

Deve-se ter cuidado para não utilizar atributos demais, o que pode levar a rede a memorizar os dados de treinamento (*overfitting*), ao invés de extrair as características gerais que permitirão a generalização, nem um número muito pequeno, que pode forçar a floresta a gastar tempo em excesso tentando encontrar uma representação ótima. Na Tabela 5 estão as configurações dos parâmetros para o aprendizado das RFs.

TABELA 5 - PARAMÊTROS DE TREINAMENTO DAS RFS PARA PRODUTIVIDADE DO HARVESTER.

Parâmetro	Faixa	Saltos
Atributos	1 a 3	1

FONTE: O autor, 2021.

3.4 ANÁLISE DOS DADOS

As estimativas geradas através das técnicas de estimação da produtividade foram avaliadas quanto à qualidade e acurácia estatística. A qualidade foi determinada através dos critérios estatísticos, sendo: erro quadrático médio absoluto e relativo da variável estimada (EQUAÇÃO 1), coeficiente de determinação entre os dados estimados e observados (EQUAÇÃO 2), resíduos percentuais das estimativas (EQUAÇÃO 3) e análise gráfica da dispersão dos dados e de resíduos.

$$RMSE\% = \frac{100}{\bar{y}} * \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_I)^2}{n}} \quad (1)$$

ONDE: RMSE%: erro quadrático médio, %; \bar{y} : média dos valores observados; Y_i : valores observados; \hat{Y}_I : valores estimados; n: número de observações.

$$r^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})}{\sum_{i=1}^n (Y_i - \bar{Y})} \quad (2)$$

ONDE: r^2 : coeficiente de determinação; \bar{Y} : média dos valores observados; Y_i : valores observados; \hat{Y}_i : valores estimados; n : número de observações.

$$\hat{\epsilon}_i \% = \left(\frac{Y_i - \hat{Y}_i}{Y_i} \right) * 100 \quad (3)$$

ONDE: $\hat{\epsilon}_i$ %: erro médio relativo, %; Y : valores observados; \hat{Y} : valores estimados.

Os ajustes foram avaliados graficamente conforme a dispersão dos dados estimados frente aos dados observados, a distribuição dos resíduos em relação à variável observada e o gráfico de frequência dos resíduos da estimativa por classes de produtividade do processador florestal, visando fundamentar a escolha do melhor modelo.

4 RESULTADOS E DISCUSSÃO

4.1 ESTATÍSTICA DESCRITIVA

O banco de dados abrangeu 6018 observações (TABELA 6), para a maioria das variáveis analisadas, com exceção do comprimento ponderado, os coeficientes de variação foram maiores que 20% (TABELA 7), indicando que, segundo a classificação proposta por Gomes e Garcia (2002), ocorre uma alta variação no banco de dados, uma vez que este mede a dispersão relativa das observações (Hoffman, 2016). Através deste mesmo coeficiente podemos observar que o banco de dados referente ao *Harvester* derrubador-processador (CTL), apresenta maior heterogeneidade nos dados e menor produtividade em relação ao *Harvester* processador (FT). Este comportamento pode ser decorrente devido ao fato que *Harvester* em sistema CTL possui a função de derrubar, processar e organizar as toras dentro do talhão.

TABELA 6 – AMOSTRAGEM DO BANCO DE DADOS UTILIZADO NO ESTUDO.

n	CP (cm)	VMI (m ³ /árv)	Pr(t PMH ₁₀ ⁻¹)
1	625,44	0,350	44,10
2	619,44	0,360	51,64
3	665,22	0,460	40,42
4	636,88	0,460	49,25
.	.	.	.
.	.	.	.
.	.	.	.
6018	NA	0,280	23,10

FONTE: O autor, 2021.

EM QUE: Pr = produtividade real; VMI = volume médio individual; CP = comprimento ponderado; CV% = coeficiente de variação relativo; NA= não se aplica.

TABELA 7 - ESTATÍSTICA DESCRITIVA DAS VARIÁVEIS DO *HARVESTER* DERRUBADOR-PROCESSADOR (CTL) E *HARVESTER* PROCESSADOR (FT).

Parâmetro	FT			CTL	
	$Pr(t\ PMH_{10}^{-1})$	VMI (m ³ /árv)	CP (cm)	$Pr(t\ PMH_{10}^{-1})$	VMI (m ³ /árv)
Observações	4324	4324	4324	1694	1694
Média	61,3	0,4523	620,8	24,2	0,284
Desvio padrão	13,6	0,1153	66,4	6,7	0,0792
Mínimo	21,5	0,23	260	0,7	0,11
Máximo	94,4	1,55	700	55,9	0,71
CV%	22,10%	25,50%	10,70%	27,60%	27,90%

FONTE: O autor, 2021.

EM QUE: Pr = produtividade real; VMI = volume médio individual; CP = comprimento ponderado; CV% = coeficiente de variação relativo.

4.2 PROCESSAMENTO DOS DADOS

4.2.1 Regressão Linear

Como requisito para a realização da modelagem da variável de interesse pelos métodos de Regressão Linear, foi realizado o teste de normalidade de Kolmogorov – Sminov, para a variável produtividade com 95% de confiança (TABELA 8).,

TABELA 8 - TESTE DE NORMALIDADE DE KOLMOGOROV – SMIRNOV, NA VARIÁVEL PRODUTIVIDADE, REFERENTE AO EQUIPAMENTO *HARVESTER* NO CORTE RASO DE *Eucalyptus sp.* E *Pinus taeda*.

Operação	P - Valor e Significância	
	Pr	\sqrt{Pr}
FT	0,00ns	0,24*
	Pr	$\ln Pr^2$
CTL	0,00ns	0,06*

FONTE: O autor, 2021.

EM QUE: Pr = produtividade; ln = logaritmo natural; ns = não significativo; * = significativo em um nível de confiança de 95%.

Assim, para alcançar a normalidade dos dados e, então, dar continuidade aos ajustes foi necessária a transformação desta (TABELA 7). Portanto, define-se assim que nos modelos ajustados a variável dependente deve ser raiz quadrada da

produtividade, para *Harvester* processador e logaritmo natural da produtividade ao quadrado, para *Harvester* derrubador-processador.

4.2.2 Inteligência Artificial

Após a realização da testagem das diversas configurações dos algoritmos avaliados no presente estudo, a Tabela 9 demonstra os arranjos que apresentaram os melhores resultados estatísticos para cada técnica utilizada por sistema de colheita:

TABELA 9 - CONFIGURAÇÕES DAS TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL COM MELHOR DESEMPENHO ESTATÍSTICO.

método	parâmetro	FT	CTL
		Valor	valor
RNA	size	6	33
	decay	0,5	0,2
SVM	custo (C)	10	10
	Kernel	0,1	0,1
RF	Atributos	1	1

FONTE: O autor, 2021.

4.2.3 Modelagem da produtividade

Quanto à separação da base de dados em treino e teste, de maneira geral, o método *cross-validation* apresentou melhor desempenho estatístico. Para o sistema de colheita *Full-tree*, no aprendizado da Rede Neural Artificial e da *Random Forests* foi a utilizada, enquanto no ajuste da Máquina de Vetor Suporte, a técnica de *hold-out* registrou resultados mais satisfatórios (TABELA 10).

TABELA 10 - RESULTADOS DOS ÍNDICES ESTATÍSTICOS POR TÉCNICA DE SEPARAÇÃO DA BASE DE DADOS NO SISTEMA FT.

Método	Hold-out		Cross-validation	
	r²	RMSE	r²	RMSE
RNA	0,5742	8,5658	0,5868	8,4380
SVM	0,5857	8,4516	0,5852	8,4567
RF	0,5235	9,0613	0,5502	8,8039

FONTE: O autor, 2021.

No CTL, para as três técnicas de Inteligência Artificial, a partição dos dados por meio do *cross-validation* gerou um melhor desempenho frente ao *hold-out*, dessa forma sendo a técnica aplicada para a obtenção dos resultados no presente trabalho (TABELA 11).

TABELA 11 - RESULTADOS DOS ÍNDICES ESTATÍSTICOS POR TÉCNICA DE SEPARAÇÃO DA BASE DE DADOS NO SISTEMA CTL.

Método	Hold-out		Cross-validation	
	r²	RMSE	r²	RMSE
RNA	0,2393	5,6250	0,2413	5,6180
SVM	0,2412	5,6467	0,2477	5,6216
RF	0,2210	5,6919	0,2246	5,6786

FONTE: O autor, 2021.

O desempenho estatístico resultante do comportamento dos critérios estatísticos com base nas estimativas de produtividade é apresentado pelas Tabelas 12 e 13, para as cinco técnicas de estimação estudadas por sistema de colheita. Espera-se que os resultados de RMSE e Erro Relativo Médio sejam menores possíveis, e a coeficiente de determinação, sendo a principal métrica dentre as citadas, seja maior.

Ressalta-se que os resultados abaixo foram obtidos da porção referente à validação dos dados, buscando uma capacidade de generalização e evitando tendenciosidade nos resultados do modelo.

TABELA 12 - RESULTADOS ESTATÍSTICOS DAS ESTIMATIVAS DE PRODUTIVIDADE POR INTELIGÊNCIA ARTIFICIAL E REGRESSÃO DO HARVESTER NO SISTEMA FULL-TREE.

Estatística	R.L. Múltipla	R.L. Stepwise	RNA	SVM	RF
r^2	0,4073385	0,5722526	0,586833	0,58573	0,550231
RMSE(t PMH ₁₀ ⁻¹)	10,14463	8,589254	8,437969	8,45162	8,803877
RMSE (%)	17,31638	14,66143	14,40319	14,4265	15,02778
$\hat{\epsilon}_i\%$	-1,089421	-1,741226	-2,39412	-2,89111	-2,52048

FONTE: O autor, 2021.

ONDE: r^2 : coeficiente de determinação; RMSE: erro quadrático médio absoluto; RMSE%: erro quadrático médio relativo; $\hat{\epsilon}_i\%$: erro médio relativo.

Com relação aos resultados oriundos do sistema *Full-tree*, observa-se que as técnicas de Redes Neurais e Máquina de Vetores de Suporte apresentaram um melhor desempenho estatístico, com valores próximos entre os índices calculados, na sequência, de forma decrescente, a Regressão Linear por *Stepwise*, o algoritmo de *Random Forests* e por último, a Regressão Linear Múltipla, que via de regra, é o método utilizado no planejamento das atividades de empresas do setor florestal.

TABELA 13 - RESULTADOS ESTATÍSTICOS DAS ESTIMATIVAS DE PRODUTIVIDADE POR INTELIGÊNCIA ARTIFICIAL E REGRESSÃO DO HARVESTER NO SISTEMA CUT-TO-LENGTH.

Estatística	R.L. Múltipla	R.L. Stepwise	RNA	SVM	RF
r^2	0,2183014	0,2535521	0,2413156	0,2477316	0,2245843
RMSE(t PMH ₁₀ ⁻¹)	5,717632	5,598916	5,618019	5,621605	5,678649
RMSE (%)	23,56148	23,07226	23,15098	23,77316	23,42897
$\hat{\epsilon}_i\%$	-3,711285	-2,815278	-4,811225	-2,80663	-4,92293

FONTE: O autor, 2021.


ONDE: r^2 : coeficiente de determinação; RMSE: erro quadrático médio absoluto; RMSE%: erro quadrático médio relativo; $\hat{\epsilon}_i\%$: erro médio relativo.

De maneira similar, os resultados referentes ao sistema CTL, indicaram como técnica com pior desempenho a Regressão Linear Múltipla, e depois, a técnica de *Random Forests*, porém nesse caso, a Regressão Linear por *Stepwise* se mostrou mais eficiente na modelagem da produtividade do *Harvester*, comparada às

metodologias de RNA e SVM, pois apresentou menores valores de RMSE e um maior coeficiente de determinação.

A análise gráfica de dispersão e de resíduos, surge como uma ferramenta para a validação da análise dos critérios estatísticos previamente realizada. Sendo assim, as Figuras 2 e 3 apresentam a dispersão das estimativas em relação aos valores observados, para o conjunto de generalização por sistema de colheita estudado.

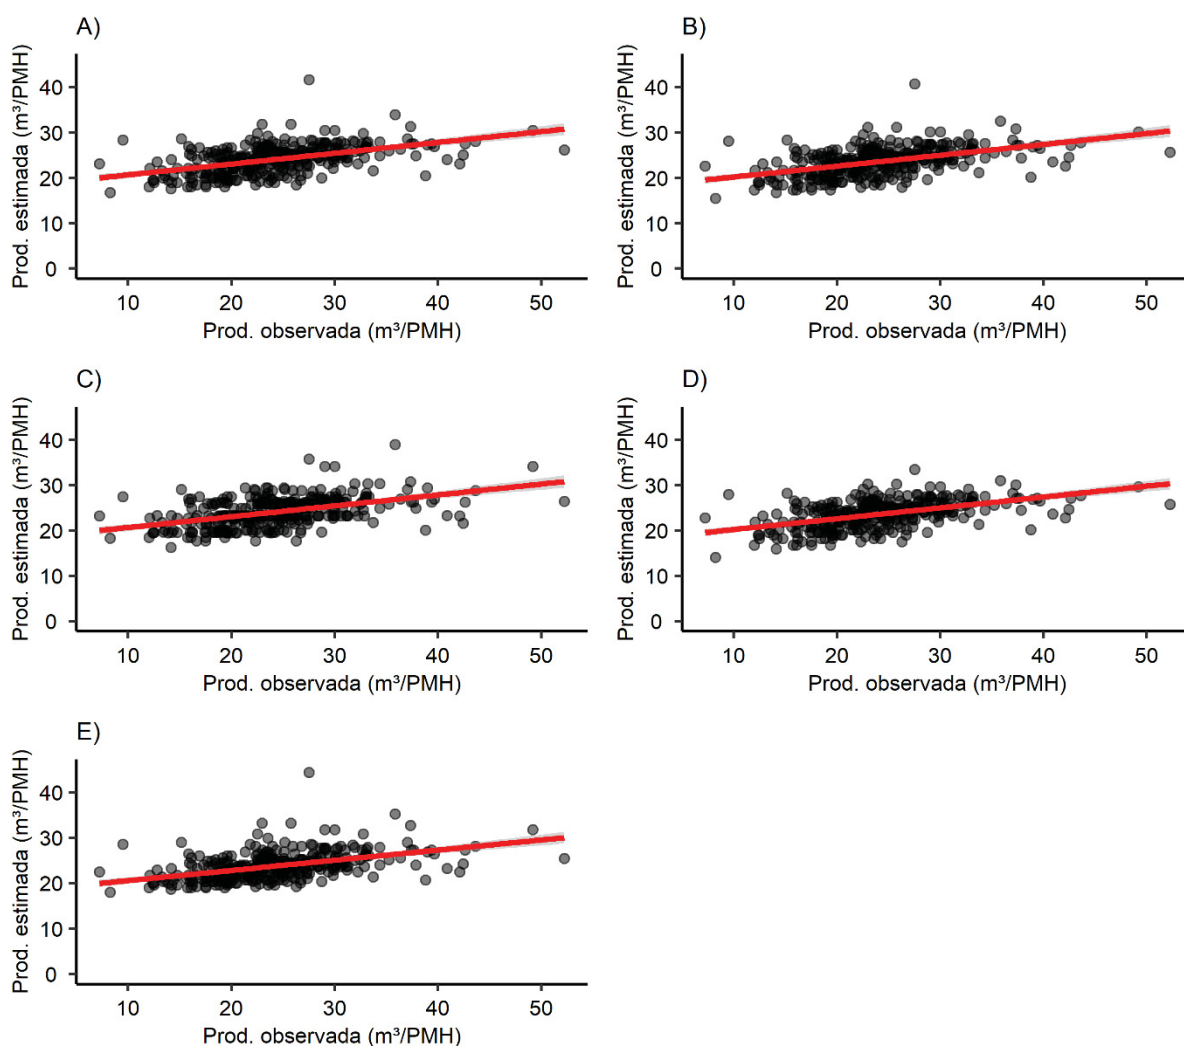
FIGURA 2 - GRÁFICOS DE DISPERSÃO DAS ESTIMATIVAS EM RELAÇÃO AOS DADOS OBSERVADOS NO SISTEMA *FULL-TREE*.



FONTE: O autor, 2021.

ONDE: A) Redes Neurais Artificiais; B) Máquinas de Vetores de Suporte; C) *Random Forests*; D) Regressão Linear por *Stepwise*; E) Regressão Linear Múltipla.

FIGURA 3 - GRÁFICOS DE DISPERSÃO DAS ESTIMATIVAS EM RELAÇÃO AOS DADOS OBSERVADOS NO SISTEMA CUT-TO-LENGTH.



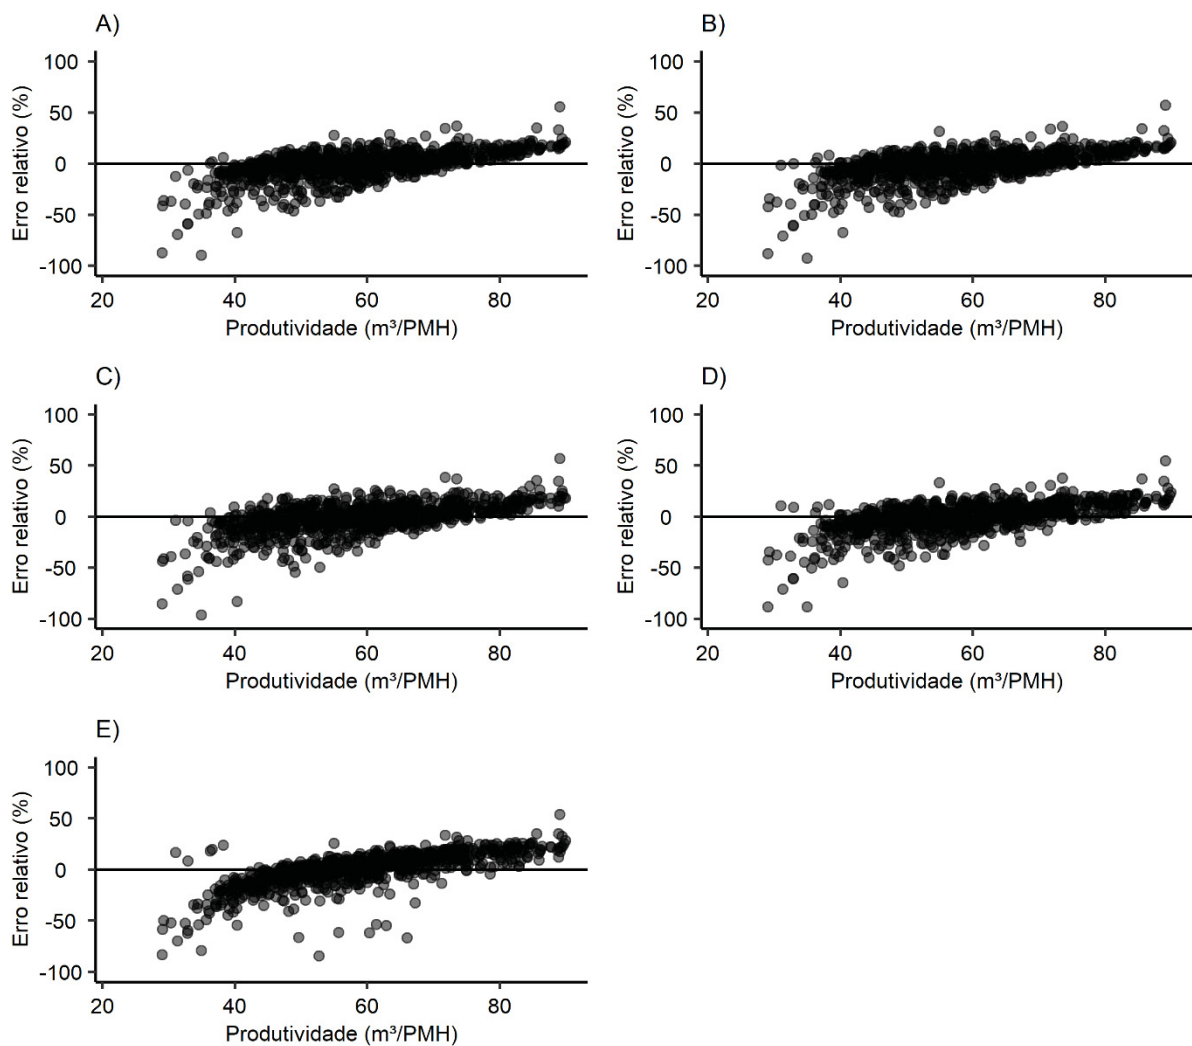
FONTE: O autor, 2021.

ONDE: A) Redes Neurais Artificiais; B) Máquinas de Vetores de Suporte; C) *Random Forests*; D) Regressão Linear por *Stepwise*; E) Regressão Linear Múltipla.

De maneira geral, como era esperado, os modelos tiveram boa capacidade preditiva em valores próximos à média e maiores divergências nos valores extremos,

superestimando valores de menor grandeza e subestimando valores maiores, em função da escassez de informações nessas faixas de produtividade do *Harvester*. Essa tendência pode ser confirmada através da análise gráfica dos resíduos em função da produtividade do *Harvester*, observada nas Figuras 4 e 5 e dos histogramas dos resíduos nas Figuras 6 e 7.

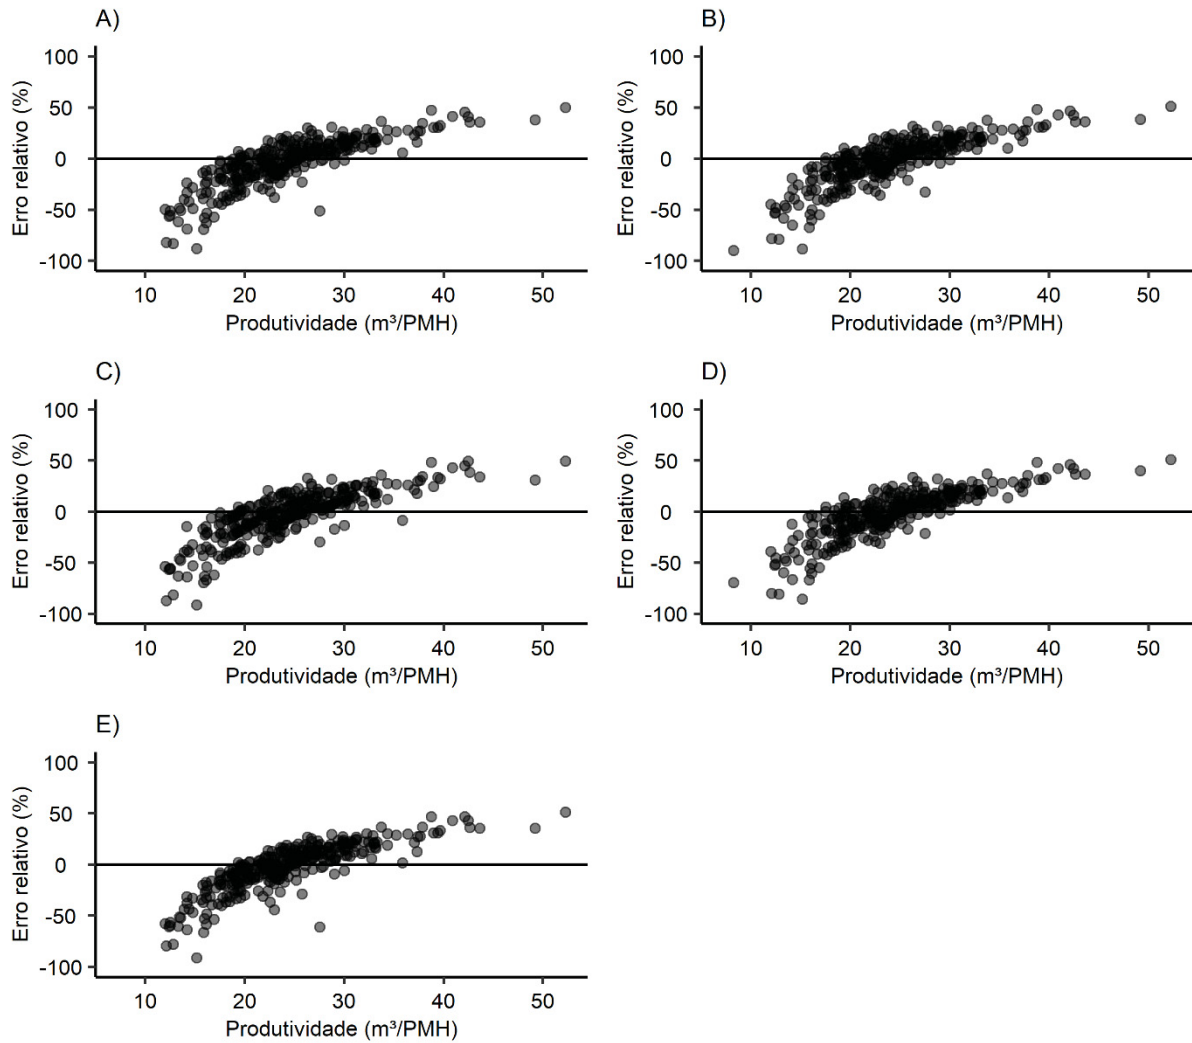
FIGURA 4 - DISPERSÃO DOS RESÍDUOS DAS ESTIMATIVAS EM FUNÇÃO DA PRODUTIVIDADE NO SISTEMA *FULL-TREE*.



FONTE: O autor, 2021.

ONDE: A) Redes Neurais Artificiais; B) Máquinas de Vetores de Suporte; C) *Random Forests*; D) Regressão Linear por *Stepwise*; E) Regressão Linear Múltipla.

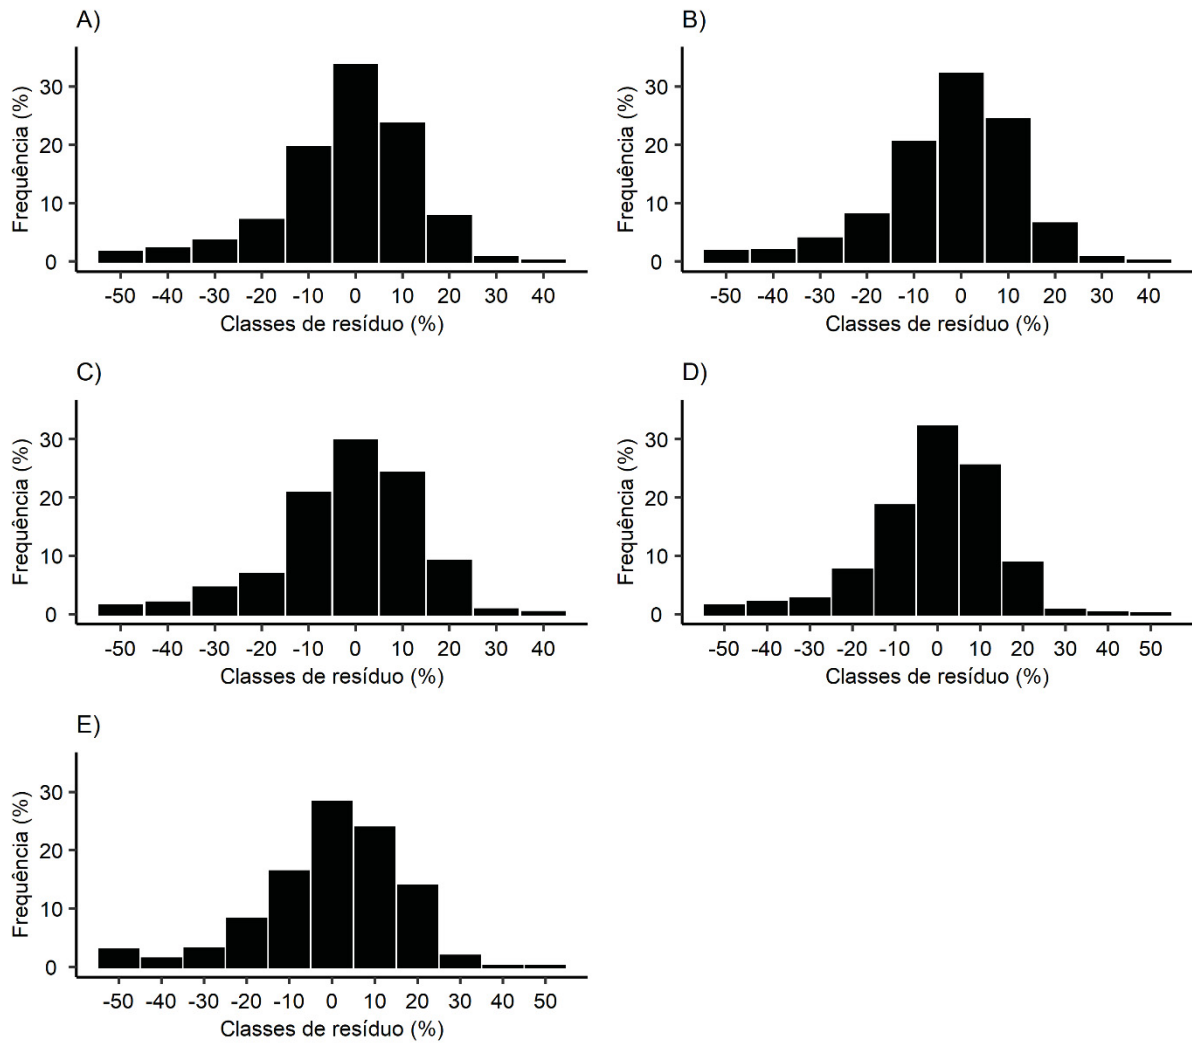
FIGURA 5 - DISPERSÃO DOS RESÍDUOS DAS ESTIMATIVAS EM FUNÇÃO DA PRODUTIVIDADE NO SISTEMA CTL.



FONTE: O autor, 2021.

ONDE: A) Redes Neurais Artificiais; B) Máquinas de Vetores de Suporte; C) *Random Forests*; D) Regressão Linear por *Stepwise*; E) Regressão Linear Múltipla.

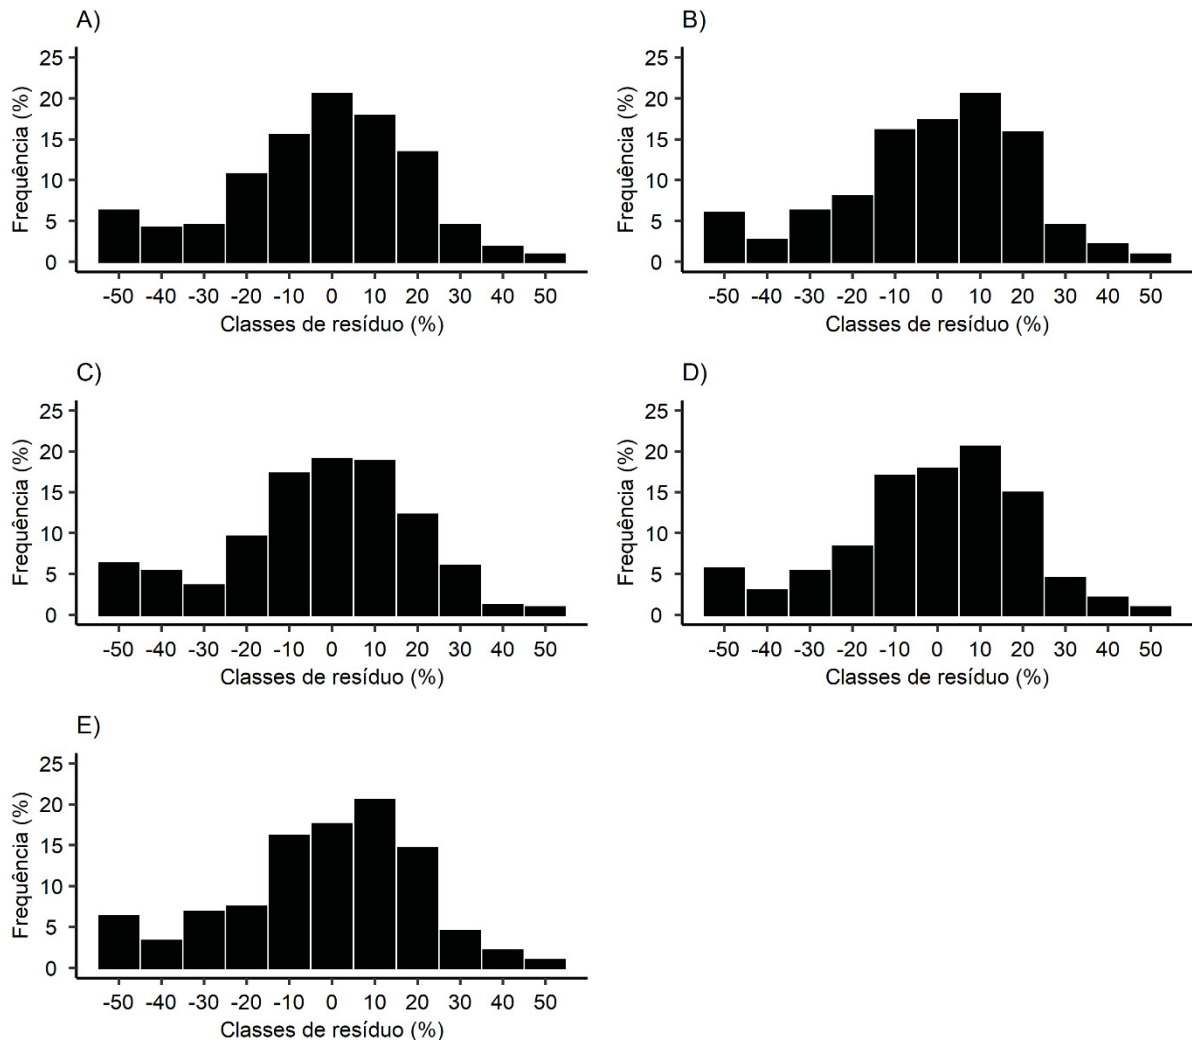
FIGURA 6 - HISTOGRAMA POR CLASSE DE RESÍDUO DAS ESTIMATIVAS DE PRODUTIVIDADE DO HARVESTER NO SISTEMA FULL-TREE



FONTE: O autor, 2021.

ONDE: A) Redes Neurais Artificiais; B) Máquinas de Vetores de Suporte; C) *Random Forests*; D) Regressão Linear por *Stepwise*; E) Regressão Linear Múltipla.

FIGURA 7 - HISTOGRAMA POR CLASSE DE RESÍDUO DAS ESTIMATIVAS DE PRODUTIVIDADE DO HARVESTER NO SISTEMA *CUT-TO-LENGTH*.



FONTE: O autor, 2021.

ONDE: A) Redes Neurais Artificiais; B) Máquinas de Vetores de Suporte; C) *Random Forests*; D) Regressão Linear por *Stepwise*; E) Regressão Linear Múltipla.

Por se tratar de análises complementares, os resultados apresentados permitem um parecer conclusivo sobre o desempenho similar das técnicas de Redes Neurais Artificiais, Máquina de Vetor de Suporte e Regressão Linear por *Stepwise*, variando de acordo com o sistema de colheita avaliado ou forma de exibição gráfica utilizado. Outro padrão observado na análise, é a diferença entre os modelos de *Random Forests* e Regressão Linear Múltipla em relação às demais, validando os

resultados obtidos por meio dos critérios de qualidade e acurácia estatística previamente analisados.

O estudo indicou que em situações em que há uma base de dados mais sólida e as variáveis independentes possuem uma forte correlação com a variável dependente, como foi o caso do sistema *Full-tree*, os algoritmos de Inteligência Artificial desempenham um papel melhor que as ferramentas tradicionalmente utilizadas para este fim. Por outro lado, onde há uma escassez de informações na base de dados, bem como uma correlação fraca entre as variáveis utilizadas na pesquisa, exemplificado no sistema CTL, os métodos de Regressão Linear, principalmente por *Stepwise*, geram estimativas com maior qualidade estatística.

Proto et al. (2020) relataram resultados superiores de coeficiente de correlação e RMSE de Redes Neurais Artificiais em comparação à Regressão Linear Múltipla na produtividade de operações de colheita de *Castanea sativa*, *Pinus nigra* var. *Calabrica Delamareno*, *Fagus sylvatica* L. e *Abies alba* Mill. nos sistemas *Full-tree* e *Tree-length* na Itália, corroborando com os resultados obtidos no atual estudo.

Gonçalves (2017) em sua tese de doutorado constatou que ambas as técnicas de modelagem foram eficientes na predição da produtividade do *Harvester* no sistema de toras curtas, mas a RNA apresentou estimativas mais precisas e pode ser indicada em substituição ao modelo tradicional de regressão linear múltipla.

A Regressão OLS (Método dos Mínimos Quadrados) ainda provou ser um método eficaz para prever a produtividade do *Harvester* no sistema CTL com um número limitado de observações e variáveis, mas a SVM apresenta grande potencial se tratando de uma grande quantidade de dados juntamente com o desenvolvimento de vários aplicativos de *big data* (LISKI et al., 2020).

A utilização da Regressão Linear e suas várias formas ainda consegue executar um bom papel nas predições das variáveis nas Operações Florestais, porém com o avanço da indústria 4.0 de automatização de processos e manuseio um grande volume de informações, às técnicas de Inteligência Artificial mostram um grande potencial nessa linha de pesquisa. As mesmas têm um melhor desempenho que os modelos de regressão, devido a sua estrutura massiva e paralelamente distribuída

(camadas); habilidade de aprender e generalizar, que as tornam capazes de resolver problemas complexos; tolerância a falhas e ruídos; possibilidade de modelar diversas variáveis e suas relações não lineares; e analogia neurobiológica (HAYKIN, 2001).

Vale ressaltar que a diferença nos critérios estatísticos analisados no presente trabalho, provavelmente é fruto das diferentes funções executadas pelas máquinas, onde o *Harvester* processador, como a própria nomenclatura indica, é responsável somente pelo processamento do fuste previamente derrubado por um *Feller-Buncher* e arrastado por um *Skidder* até a beira da estrada, minimizando os deslocamentos e tornando a modelagem da produtividade mais assertiva.

O *Harvester* derrubador/processador está sujeito a diversos fatores que influenciam no seu rendimento operacional, tais como a atividade de derrubada, a organização das pilhas para o posterior baldeio do *Forwarder* e o deslocamento entre as árvores a serem derrubadas, os quais o equipamento destinado exclusivamente ao processamento não é submetido, gerando uma dificuldade na criação de modelos matemáticos capazes de expressar com maior exatidão a variável de interesse do estudo.

A evolução desse ramo de pesquisa das ciências florestais passar por uma padronização do maquinário utilizado nas operações de colheita e dos procedimentos operacionais adotados pelas empresas do setor, métodos mais aprimorados de coleta de dados, assim como a adoção de novas ferramentas capazes de criarem modelos matemáticos cada vez mais fidedignos à realidade do campo.

5 CONCLUSÃO

Após as análises realizadas foi possível concluir:

Dentro das técnicas de Inteligência Artificial, a que apresentou os melhores resultados na estimação da produtividade do *Harvester* nas análises realizadas foram as Redes Neurais Artificiais para o sistema de colheita *Full-tree* e as Máquinas de Vetores de Suporte para o sistema *Cut-to-length*.

A Regressão Linear por *Stepwise* mostrou resultados mais satisfatórios tanto no *Full-tree* quanto no *Cut-to-length* para a estimação da produtividade do *Harvester*.

Quando comparadas as técnicas de IA com as de Regressão Linear, no *Full-tree* as RNAs ainda apresentam o melhor desempenho entre todos os modelos estudados, entretanto no CTL, a Regressão Linear por *Stepwise* obteve os melhores resultados.

Com relação aos métodos de separação de base de dados, o *cross-validation* apresentou valores superiores dos indicadores de desempenho e acurácia estatística para todos os algoritmos de IA em ambos os sistemas de colheita estudados, com exceção da Máquina Vetor de Suporte no *Full-tree*.

REFERÊNCIAS

- ABARES. Australian forest profiles: Eucalypt. Australian Bureau of Agricultural and Resource Economics and Sciences, Canberra, Department of Agriculture, p. 5, 2019. Disponível em: <<https://www.agriculture.gov.au/abares/forestsaustralia/profiles/eucalypt-2019>>. Acesso em: 25 nov. 2021.
- ADEBAYO, A. B; HAN, H.; JOHNSON, L. Productivity and cost of cut-to-length and whole-tree harvesting in mixed-conifer stand in Northern Idaho. In: WORKING GLOBALLY – SHARING FOREST ENGINEERING CHALLENGES AND TECHNOLOGIES AROUND THE WORLD, 2006, Coeur d’Alene – Idaho. Proceedings... Coeur d’Alene: Council on Forest Engineering (COFE), 2006. p. 127 – 136.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAROVEK, G. Köppen’s climate classification map for Brazil. Meteorologische Zeitschrift, v. 22, n. 6, p. 711 – 728, 2013.
- ANDRADE, S. C. Avaliação técnica, social, econômica e ambiental de dois subsistemas de colheita florestal no litoral norte da Bahia. 1998. 125p. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, 1998.
- BARNES, R. M. Estudo de movimentos e de tempos: projeto e medida do trabalho. São Paulo: Edgard Blücher LTDA, 1977. 635 p.
- BARRETO, C. A. Eucalipto, água e sociedade: a construção de representantes no Vale do Paraíba, SP. Tese (Doutorado em Ecologia Aplicada) – Centro de Energia Nuclear da Agricultura, Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, São Paulo, 2019.
- BERTIN, S.A.V. Análise de dois modais de sistemas de colheita mecanizados de eucalipto em 1ª rotação. Botucatu. Dissertação (mestrado) Universidade Estadual paulista, Faculdade de Ciências Agrônomicas, 2010. Disponível em:< <http://www.pg.fca.unesp.br/Teses/PDFs/Arq0548.pdf>> Acesso em: 24 nov. 2021.
- BJÖRHEDEN, R.; APEL, K.; SHIBA, M.; THOMPSON, M. A. IUFRO Forest workstudy nomenclature. Garpenberg: Departament of Operational Efficiency, Swedish University of Agricultural Science, 1995. 16 p.
- BRAMUCCI, M.; SEIXAS, F. Determinação e quantificação de fatores de influência sobre a produtividade de “harvesters” na colheita florestal. Scientia Florestalis, n. 62, p. 62-74, 2002.
- BULLINARIA, J. A. Introduction to Neural Computation - Notas de Aula. 2014. Disponível em: <http://www.cs.bham.ac.uk/~jxb/inc.html>. Acesso em: 12 de outubro de 2021.

BURLA, E. R. Avaliação técnica e econômica do harvester na colheita do eucalipto. Viçosa, MG, 2008. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Viçosa, 2008. Disponível em: <<https://www.locus.ufv.br/bitstream/handle/123456789/3517/texto%20completo.pdf?squence=1&isAllowed=y>> Acesso em: 23 nov. 2021.

EMBRAPA – EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. O eucalipto. 2019. Disponível em: <https://www.embrapa.br/florestas/transferecia-de-tecnologia/eucalipto> Acesso em: 25 de novembro de 2021.

ERASLAN, E. The Estimation of Product Standard Time by Artificial Neural Networks in the Molding Industry. *Mathematical Problems in Engineering*. 12p. 2009.

FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. C. P. L. F. Inteligência artificial: uma abordagem de aprendizado de máquina. Rio de Janeiro: LTC, 378p., 2011.

FREITAS, K.E. Análise técnica e econômica da colheita florestal mecanizada. 2005. 27p. Trabalho de Conclusão de Curso (Graduação em Engenharia de Produção) - Universidade Federal de Viçosa, Viçosa, 2005.

GONÇALVES, S. B. Modelagem matemática da produtividade do corte florestal mecanizado. Jerônimo Monteiro, ES, 2017. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Espírito Santo, Centro de Ciências Agrárias e Engenharias, 2017. Disponível em: <<https://repositorio.ufes.br/handle/10/7710>> Acesso em: 26 nov. 2021.

HARMS, W. R.; WHITESELL, C. D.; DeBELL, D. S. Growth and development of loblolly pine in a spacing trial planted in Hawaii. *Forest Ecology and Management*, Amsterdã, v. 126, p. 13-14, 2000.

HAYKIN, S. *Redes Neurais, Princípios e prática*. 2. ed. [S.l.]: Bookman, 2001.

INDERFOR; MFAF - MINISTRY FOR FOREIGN AFFAIRS OF FINLAND. *Tecnología de Cosecha Forestal Finlandesa y su aplicación en el Sector Forestal de Argentina y Uruguay*. Buenos Aires: INDERFOR/MFAF, 143. p. 2005.

INDÚSTRIA BRASILEIRA DE ÁRVORES – IBÁ. Anuário estatístico do IBÁ, 2020, ano base 2019. Disponível em: <https://iba.org/images/shared/Biblioteca/IBA_RelatorioAnual2020.pdf> Acesso em: 25 nov. 2021.

LISKI, E.; JOUNELA, P.; KORPUNEN, H.; SOSA, A.; LINDROOS, O.; JYLHÄB, P. Modeling the productivity of mechanized CTL harvesting with statistical machine learning methods. *International Journal of Forest Engineering*. vol. 31, n. 3, p. 253-262, 2020. Disponível em: <<https://doi.org/10.1080/14942119.2020.1820750>> Acesso em: 24 nov. 2021.

MACHADO, C. C. *Colheita Florestal*. 3 ed., Viçosa: Editora UFV. 468. p. 2014.

MACHADO, C. C. et al. O Setor Florestal Brasileiro e a Colheita Florestal. In: Colheita Florestal / Carlos Cardoso Machado (Editor) Viçosa: UFV, 2ª Edição., p.15-42, 2008. 501p.: il.

MALINOVSKI, J.R., CAMARGO, C.M.S. A Eucaliptocultura no contexto brasileiro, Revista Madeira, Brasília, nº 59, Set., 2001. Disponível em: <http://www.remade.com.br/br/revistadamadeira_materia.php?num=11&subject=Eucaliptocultura&title=A%20Eucaliptocultura%20no%20Contexto%20Brasileiro>. Acesso em: 24 nov. 2021.

MALINOVSKI, J. R.; CAMARGO, C. M. S.; MALINOVSKI, R. A. Sistemas. In: MACHADO, C. C. Colheita florestal. 1º edição. Viçosa: UFV, 2002. p. 145 - 167.

MALINOVSKI, J. R.; CAMARGO, C. M. S.; MALINOVSKI, R. A.; MALINOVSKI, R. A.; CASTRO, G. P. Sistemas. In: MACHADO, C. C. Colheita florestal. 3º edição. Viçosa: UFV, 2014. p. 178 - 205.

MALINOVSKI, J. R.; MALINOVSKI, R. A. Evolução dos sistemas de colheita de Pinus na Região Sul do Brasil. Curitiba-PR, FUPEF, 1998. 138p.

MCCARTHY, J. Actions and other events in situation calculus. Proceedings of KR-2002, 2002.

MOREIRA, T. M. F. Análise técnica e econômica de subsistemas de colheita de madeira de eucalipto em terceira rotação. Viçosa. Tese (Mestrado)-Universidade federal de viçosa, 2000. Disponível em: <<http://alexandria.cpd.ufv.br:8000/teses/157373f.pdf> > Acesso em: 25 nov. 2021.

OLIVEIRA A.; VISSER, R.; ACUNA, M.; MORGENROTH, J. Automatic GNSS-enabled harvester data collection as a tool to evaluate factors affecting harvester productivity in a Eucalyptus spp. harvesting operation. Uruguay: International Journal of Forest Engineering, v.27, n.1, p. 15-28, 2016. Disponível em: <<http://dx.doi.org/10.1080/14942119.2015.1099775>>. Acesso em 24 nov. 2021.

PROTO, A. R.; SPERANDIO, G.; COSTA, C.; MAESANO, M.; ANTONUCCI, F.; MACRÌ, G.; MUGNOZZA, G. S.; ZIMBALATTI G. A Three-Step Neural Network Artificial Intelligence Modeling Approach for Time, Productivity and Costs Prediction: A Case Study in Italian Forestry, Croatian Journal of Forestry Engineering, v. 41, n.1, p. 35-47, 2020. Disponível em: < <https://doi.org/10.5552/crojfe.2020.611>> Acesso em: 26 nov. 2021.

PURFÜRST, F.T.; ERLER, J. The Human Influence on Productivity in Harvester Operations, International Journal of Forest Engineering, v.22, n.2, p. 15-22, 2011. Disponível em: <<http://dx.doi.org/10.1080/14942119.2011.10702606>>. Acesso em 25 nov. 2021.

RODRIGUES, C. K.; SOUZA, A. L. S.; RETSLAFF, F. M. S.; CORTE, A. P. D.; LOPES E. S. Modelagem geoestatística aplicada ao microplanejamento da colheita de madeira em povoamento de eucalipto. BIOFIX Scientific Journal v. 4 n. 2 p. 172-176, 2019.

SANTOS, C. C. Modelagem de bacias urbanas com redes neurais artificiais. 105p. Dissertação (Mestrado em Engenharia Hidráulica) - Escola Politécnica, Universidade de São Paulo - USP, São Paulo, 2001.

SCHIKOWSKI, A. B. Estimativa do volume e da forma do fuste utilizando técnicas de aprendizado de máquina. 73p. Dissertação (Mestrado em Engenharia Florestal), Universidade Federal do Paraná, PR, 2016.

SCHULTZ, R. P. Loblolly pine: the ecology and culture of loblolly pine (*Pinus taeda* L.). Washington, DC: USDA, Forest Service, 1997. 493 p. (Agricultural Handbook, 713).
SCHUMACHER, M. V.; VIEIRA, M. Silvicultura do Eucalipto no Brasil. Santa Maria - RS: UFSM, 2016.

SEIXAS, F.; BATISTA, J. L. F. Comparação técnica e econômica entre harvesters de pneus e com máquina base de esteiras. *Ciência Florestal*, v. 24, n. 1, p. 185-191, 2014.

SILVA, F. Aplicação de redes neurais artificiais para estimar a produtividade do forwarder na extração de madeira. 63p. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2015.

SPINELLI, R. Harvesting of Thinnings. Florence: National Council for Research, Timber and Tree Institute, 6p, 2004.

VAPNIK, V. N. The nature of statistical learning theory. New York, NY, USA: Springer-Verlag New York, Inc., 1995. ISBN 0387945598. Disponível em: <<http://portal.acm.org/citation-.cfm?id=211359>>. Acesso em: 23 nov. 2021.