

LARISSA NUNES DOS SANTOS

**PREDIÇÃO DO CONSUMO ESPECÍFICO DE COMBUSTÍVEL DO
HARVESTER UTILIZANDO MODELOS LINEARES MISTOS E REDES
NEURONAIAS ARTIFICIAIS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Doctor Scientiae*.

VIÇOSA
MINAS GERAIS - BRASIL
2018

Ficha catalográfica preparada pela Biblioteca Central da Universidade
Federal de Viçosa - Câmpus Viçosa

T

S237p
2018

Santos, Larissa Nunes dos, 1991-

Predição do consumo específico de combustível do *harvester* utilizando modelos lineares mistos e redes neurais artificiais / Larissa Nunes dos Santos. – Viçosa, MG, 2018.
x, 46f. : il. (algumas color.) ; 29 cm.

Orientador: Haroldo Carlos Fernandes.
Tese (doutorado) - Universidade Federal de Viçosa.
Referências bibliográficas: f. 37-46.

1. Máquinas florestais - Consumo de combustível.
2. Máquinas florestais - Custo operacional - Programas de computador. 3. Madeira - Exploração - Máquinas. 4. Madeira - Exploração - Custos. 5. Estatística. 6. Redes neurais (Computação). I. Universidade Federal de Viçosa. Departamento de Engenharia Agrícola. Programa de Pós-Graduação em Engenharia Agrícola. II. Título.

CDD 22. ed. 631.3

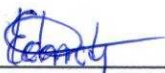
LARISSA NUNES DOS SANTOS

**PREDIÇÃO DO CONSUMO ESPECÍFICO DE COMBUSTÍVEL DO
HARVESTER UTILIZANDO MODELOS LINEARES MISTOS E REDES
NEURONAIS ARTIFICIAIS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Doctor Scientiae*.

APROVADA: 03 de maio de 2018.


Domingos Sarvio Magalhães Valente


Edney Leandro da Vitória


Luciano José Minette


Hélio Garcia Leite
(Coorientador)


Haroldo Carlos Fernandes
(Orientador)

“O sucesso nasce do querer, da determinação e persistência em se chegar a um objetivo. Mesmo não atingindo o alvo, quem busca e vence obstáculos, no mínimo fará coisas admiráveis.”

José de Alencar

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me dado forças e ter me guiado durante todo o caminho para que fosse possível completar mais uma fase da minha vida.

À minha mãe que esteve sempre ao meu lado, por sua dedicação, amor e paciência sempre me apoiando e me mostrando que nada é impossível, pessoa que sigo como exemplo.

Às minhas irmãs Amábelli e Angélica pelo companheirismo, atenção, e pela alegria compartilhada.

À Universidade Federal de Viçosa e ao Departamento de Engenharia Agrícola pela oportunidade de realização do curso de Pós-Graduação.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de estudos.

À Celulose Nipo-Brasileira S.A. (CENIBRA), pela oportunidade e confiança. Em especial ao Edvaldes José de Amaral, Sócrates Machado Borges, Antonilmar Araujo Lopes da Silva, Guilherme de Sá, Raul Santos, José Eustáquio Braga e Audeir Santos pela paciência e sugestões.

Ao professor Haroldo Carlos Fernandes pela oportunidade, orientação, compreensão, confiança, paciência e conselhos. Sem o senhor nada disso seria possível.

Aos professores Hélio Garcia Leite e Kevin Lyons pela ajuda, contribuições, ensinamentos direcionamento e esclarecimentos de todas minhas dúvidas no decorrer deste trabalho.

Aos amigos e colegas da Mecanização pelo companheirismo diário, em especial a Dinha, Jéssica, Jardênia e Nina.

À Juliana e Júnior, pelas caronas, conselhos, amizade e companheirismo. Pessoas com quem sempre posso contar.

À Flora, Diego e Roberta, pelo companheirismo, incentivo, ajuda e festejos.

À Rubén e Remo pela ajuda e sugestões.

A todos que de alguma forma contribuíram para a realização deste trabalho.

BIOGRAFIA

LARISSA NUNES DOS SANTOS, filha de João Batista Nogueira Nunes e Tânia Rodrigues dos Santos, nasceu em Itanhém, Bahia, em 03 de Julho de 1991.

De 2008 a 2012 graduou-se em Engenharia Florestal pela Faculdade Pitágoras, Teixeira de Freitas, Bahia.

Em 2012, iniciou o Programa de Pós-Graduação em Engenharia Agrícola, em nível de Mestrado, área de concentração em Mecanização Agrícola, pelo Departamento de Engenharia Agrícola da Universidade Federal de Viçosa.

Em julho de 2014, submeteu-se ao exame de defesa da dissertação, para a obtenção do título de *Magister Scientiae*.

Em agosto de 2014, iniciou o Programa de Pós-Graduação em Engenharia Agrícola, em nível de doutorado, área de concentração em Mecanização Agrícola, pelo Departamento de Engenharia Agrícola da Universidade Federal de Viçosa.

Em julho de 2017, participou do Programa de Doutorado Sanduíche no Exterior (PSDE), na University of British Columbia (UBC), Vancouver, Canadá.

Em maio de 2018, submeteu-se ao exame de defesa da tese, para a obtenção do título de *Doctor Scientiae*.

SUMÁRIO

RESUMO	vii
ABSTRACT	ix
1. INTRODUÇÃO	1
2. OBJETIVO.....	3
2.1 Objetivo Geral.....	3
2.2 Objetivos específicos	3
3. REVISÃO DE LITERATURA	4
3.1 Importância do setor florestal brasileiro	4
3.2 Mecanização da Colheita Florestal.....	4
3.3 Sistema colheita de toras curtas.....	6
3.4 Consumo de combustível de tratores	7
3.5 Modelos Lineares Mistos (MLM).....	8
3.5.1 Estimativa de Máxima Verossimilhança (ML).....	9
3.6 Redes Neurais Artificiais (RNA).....	10
3.6.1 Aprendizado das redes.....	11
3.6.2 Algoritmo <i>backpropagation</i>	12
4. MATERIAL E MÉTODOS	15
4.1 Caracterização da área de estudo.....	15
4.2 Descrição da máquina	16
4.3 Avaliação dos sensores do <i>harvester</i>	17
4.4 Descrição dos dados usados.....	19
4.5 Modelo Linear de Efeitos Mistos.....	21
4.5.1 Avaliação do modelo	21
4.6 Redes Neurais Artificiais (RNA).....	23
4.6.1 Avaliação do desempenho das RNA.....	23
4.7 Comparação entre MLM e RNA	25
5. RESULTADOS E DISCUSSÃO.....	26
5.1 Modelos Lineares Mistos (MLM).....	26
5.2 Redes Neurais Artificiais (RNA).....	29
5.3 Comparação entre MLM e RNA	33
6. CONCLUSÕES	36

7. LITERATURA CITADA37

RESUMO

SANTOS, Larissa Nunes dos, D.Sc., Universidade Federal de Viçosa, maio de 2018. **Predição do consumo específico de combustível do *harvester* utilizando Modelos Lineares Mistos e Redes Neurais Artificiais.** Orientador: Haroldo Carlos Fernandes. Coorientador: Hélio Garcia Leite.

O consumo de combustível de máquinas florestais é um dos componentes mais impactantes nos custos de colheita florestal e, por isso, grande importância é dada à sua redução. Objetivou-se com este trabalho prever o consumo específico de combustível do *harvester* em função de variáveis climáticas, dendrométricas e operacionais, utilizando modelos lineares mistos (MLM) e redes neurais artificiais (RNA). Foi utilizado um *harvester* John Deere 1270E para derrubar e processar as árvores em toras. Os dados foram obtidos através do *software* instalado no computador de bordo da máquina *TimberMatic* (John Deere) e do Boletim de Apropriação de Equipamento (BAE). As variáveis contínuas utilizadas foram: diâmetro médio da tora e ângulo frontal da máquina. As categóricas: local de corte, tipo de manejo da floresta, clima, turno de trabalho, combinação de rotação do motor e nível de treinamento do operador. O consumo específico de combustível foi usado como a variável resposta. No modelo linear misto os dados foram agrupados dentro da variável operador e, portanto, esta variável foi incluída como um intercepto aleatório. Para o emprego de RNA o banco de dados foi dividido aleatoriamente em: 70% dos dados para treinamento e 30% para validação das redes. O treinamento foi do tipo supervisionado, o algoritmo de aprendizagem utilizado foi o *resilient-propagation* e a função de ativação usada na camada oculta e de saída foi a sigmoide. Para verificar a qualidade do MLM foram usados o Critério de informação de Akaike (AIC) e o coeficiente de determinação baseado no teste da razão de verossimilhança (R_{LR}^2). Como medidas de avaliação dos resultados gerados pelas redes, foi utilizada a correlação entre os valores observados e estimados, a raiz quadrada do erro quadrático médio (RQEM), o erro relativo percentual médio e a distribuição de frequência dos erros relativos percentuais. Para comparar os resultados gerados pelo MLM e a RNA foram utilizados o erro relativo percentual e a RQEM, além da distribuição dos erros. O valor R_{LR}^2 obtido para a MLM selecionada foi de 0,84. A rede que obteve menor RQEM na

validação foi a que continha oito neurônios na camada escondida. A RQME encontrada para a RNA e MLM foi de 17,6189 e 20,9686 respectivamente, indicando maior exatidão na estimativa do consumo específico de combustível do *harvester* pela RNA. O MLM e RNA são eficientes na estimativa do consumo específico de combustível do *harvester*, com ligeira superioridade (exatidão) para a rede neuronal.

ABSTRACT

SANTOS, Larissa Nunes dos, D.Sc., Universidade Federal de Viçosa, May, 2018. **Prediction of specific fuel consumption of the harvester using Mixed Linear Models and Artificial Neural Networks**. Adviser: Haroldo Carlos Fernandes. Co-adviser: Hélio Garcia Leite.

The fuel consumption of forestry machines is one of the most impacting components of forest harvesting costs and, therefore, great importance is given to their reduction. The objective of this work was to predict the specific fuel consumption of the harvester as a function of climatic, dendrometric and operational variables using mixed linear models (LME) and artificial neural networks (ANNs). A John Deere 1270E harvester was used to fell and process trees into logs. The data were obtained through the software installed on the onboard computer of the machine, TimberMatic (John Deere) and the Equipment Appropriation Bulletin (EAB). The continuous variables used were: average log diameter and pitch machine. The categorical ones: cutting location, type of forest management, climate, work shift, combination of engine rotation and operator training level. The specific fuel consumption was used as the response variable. In the mixed linear model the data were grouped within the operator variable and, therefore, this variable was included as a random intercept. For the use of RNA the database was randomly divided into: 70% of data for training and 30% for validation of networks. The training was supervised type, the learning algorithm used was the resilient-propagation and the activation function used in the hidden layer and the output was the sigmoid. The Akaike Information Criterion (AIC) and the determination coefficient based on the likelihood ratio test (R_{LR}^2) were used to verify LME quality. As a measure of the results generated by the networks, the correlation between the observed and estimated values, the square root of the mean square error (RSME), the relative mean percentage error and the frequency distribution of the relative percentage errors were used. In order to compare the results generated by the LME and ANN, the percentage relative error and the RSME were used, besides the distribution of the errors. The R_{LR}^2 value obtained for the LME selected was 0.84. The network that obtained the lowest RSME in the validation was the one that contained eight neurons in the hidden layer. The RSME found for ANN and

LME was 17.6189 e 20.9686 respectively, indicating greater accuracy in the estimation of the specific fuel consumption of the harvester by ANN. The LME and ANN are efficient in estimating the specific fuel consumption of the harvester, with slight superiority (accuracy) for the neural network.

1. INTRODUÇÃO

A colheita florestal mecanizada demanda grande consumo de combustível, por utilizar máquinas em quase todas as suas etapas. Para realização do corte florestal a principal máquina utilizada no sistema de toras curtas em povoamentos equiâneos é o *harvester*. Esta máquina tem por função derrubar, desgalhar, descascar e traçar a madeira em toras com comprimentos pré-definidos, deixando-as pronta para sua extração.

O consumo médio de óleo Diesel por hora de um *harvester* é de 20 litros. O seu consumo está relacionado com a potência necessária para realizar o seu descolamento, por ser uma máquina robusta e pesada, e por realizar operações que demandam grande potência. O abastecimento desta máquina pode ser feito a cada 20 horas de trabalho, quando esta possui um tanque com capacidade de 435 litros de combustível, isto é, o *harvester* é abastecido todos os dias.

O alto preço do óleo Diesel no Brasil associado ao alto consumo de combustível das máquinas florestais tem despertado as empresas do setor a adotarem medidas de planejamento e controle do consumo de combustível na colheita de madeira. O custo com combustível é um dos mais representativos no custo operacional do *harvester*. Por esta razão, é importante identificar os fatores que influenciam o consumo de combustível para que medidas de redução possam ser desenvolvidas.

Os modelos de consumo de combustível para máquinas florestais que incluem variáveis climáticas, fisiográficas, dendrométricas e operacionais são escassos. Isto provavelmente devido ao fato de que é necessário envolver um grande número de variáveis com alto grau de detalhe. Essas variáveis podem ser contínuas, categóricas, fixas ou aleatórias e, portanto, exigem análise mais complexa, como modelos de efeitos mistos e redes neuronais artificiais (RNA).

Em modelos lineares de efeitos mistos (LME) as variáveis independentes incluem efeitos fixos e aleatórios. Esses modelos permitem a análise conjunta de dados desbalanceados utilizando o método da verossimilhança e verossimilhança restrita, possibilitam atribuir diferentes estruturas da matriz de variância e covariância aos efeitos aleatórios, além de

permitirem a modelagem da heterogeneidade de variância (WYZYKOWSKI et al., 2015).

As RNA são sistemas computacionais que simulam o efeito de aprendizagem do cérebro humano. São normalmente compostas por um grande número de neurônios artificiais interconectados (VERLINDEN et al., 2008), formando uma complexa rede de processamento, distribuição e armazenamento de informações, que pode modelar facilmente qualquer sistema complexo, com alto grau de precisão (LU et al., 2012). As redes neuronais artificiais podem ser utilizadas para a classificação de padrões, aproximação de funções, otimização, previsão e controle automático dentre outras aplicações (GUO et al., 2012).

2. OBJETIVO

2.1 Objetivo Geral

Objetivou-se com este trabalho prever o consumo específico de combustível do *harvester* em função de variáveis climáticas, dendrométricas, fisiográficas e operacionais utilizando Modelos Lineares Mistos e Redes Neurais Artificiais.

2.2 Objetivos específicos

Especificamente, pretendeu-se com este trabalho:

- Modelar o efeito aleatório do operador no consumo específico de combustível do *harvester* utilizando modelos lineares mistos (MLM);
- Determinar a influência das variáveis climáticas, dendrométricas, fisiográficas e operacionais sobre o consumo específico de combustível do *harvester*;
- Treinar, validar e aplicar redes neurais artificiais (RNA) para predição do consumo específico de combustível da máquina em função de variáveis climáticas, dendrométricas, fisiográficas e operacionais.
- Avaliar a qualidade da predição do consumo específico de combustível do *harvester* utilizando MLM e RNA.

3. REVISÃO DE LITERATURA

3.1 Importância do setor florestal brasileiro

O setor florestal brasileiro é uma referência mundial por sua atuação pautada pela sustentabilidade, competitividade e inovação. As árvores de povoamentos equiâneos são destinadas à produção de celulose, papel, painéis de madeira, pisos laminados, carvão vegetal e biomassa. Esses povoamentos contribuem na mitigação dos efeitos das mudanças climáticas; provendo diversos serviços ambientais, como a regulação dos ciclos hidrológicos, o controle da erosão e da qualidade do solo, a conservação da biodiversidade e a provisão de oxigênio para o planeta. Além disso, o Brasil está entre os principais produtores de celulose, papel e painéis de madeira no mundo (IBÁ, 2017).

Sua grande competitividade no mercado interno e externo ocorre em razão de suas características edáficas e climáticas, que permitem a colheita em curta rotação (5 e 7 anos para o eucalipto) quando comparado a outros países (até 35 anos para o eucalipto) (MOREIRA; OLIVEIRA, 2017). Ainda conforme estes autores, o desenvolvimento tecnológico obtido nas áreas de silvicultura e manejo florestal é muito expressivo.

Em 2016, o país tinha uma área de 7,84 milhões de hectares de reflorestamento, sendo 5,7 milhões de hectares de plantios de eucalipto e 1,6 milhões de hectares de plantios de Pinus. Neste mesmo ano, o país liderou o ranking global de produtividade florestal, com cerca de $36 \text{ m}^3 \text{ ha}^{-1} \text{ ano}^{-1}$, aos 7 anos, quando em regime de alto fuste (eucalipto) e cerca de $30 \text{ m}^3 \text{ ha}^{-1} \text{ ano}^{-1}$ no caso de pinus. O setor florestal brasileiro é responsável por 91% de toda a madeira produzida para fins industriais e 6,2% do PIB Industrial no País, tendo promovido em 2016, 3,7 milhões de empregos diretos, indiretos e resultantes do efeito renda (IBÁ, 2017).

3.2 Mecanização da Colheita Florestal

A colheita florestal no Brasil iniciou-se de forma rudimentar, com a utilização de técnicas manuais, com machado ou serra manual e, ou, com força animal. Essas técnicas se caracterizavam por sua alta exigência de esforço

físico e alto risco de acidentes. Até a década de 40, praticamente não se utilizavam máquinas na colheita florestal. A modernização do setor iniciou em 1970, quando surgiram motosserras e tratores agrícolas equipados com implementos florestais. Em 1980, vieram as máquinas específicas para a colheita florestal. No entanto, somente em 1994 com a abertura das importações, a carência e o aumento do custo de mão de obra, houve a intensificação da mecanização da colheita (PEREIRA, 2010)

No final da década de 70 com as importações de máquinas e equipamentos florestais, muitas empresas se depararam no início com baixa eficiência operacional e altos riscos de acidentes de trabalho, devido à falta de adequação dessas máquinas às condições locais (MINETTE et al., 2008).

A evolução da mecanização da colheita florestal intensificou-se nos últimos anos, desencadeando um processo contínuo de análise dos rendimentos operacionais e de estimativa de custos (SIMÕES et al., 2010b).

Atualmente, em razão da quantidade de marcas e modelos existentes para a realização do corte e extração florestal, as empresas utilizam uma variada linha de máquinas e equipamentos na colheita de madeira, sendo responsabilidade de cada uma optar pelo sistema mais adequado (NASCIMENTO et al., 2011).

A colheita mecanizada é atrativa para empresas florestais devido aos menores custos de produção, menores índices de acidentes e doenças ocupacionais, baixo contingente de mão de obra, maior qualidade do produto final, redução de impactos ambientais e maior eficiência operacional, em relação ao corte não mecanizado (PAULA, 2011; VIEIRA et al., 2016).

Outro ponto importante a ser considerado no sistema mecanizado diz respeito ao melhor controle sobre a produtividade dos funcionários, com dispositivos que monitoram a produção e o tempo efetivo de trabalho (VIEIRA et al., 2016).

A escolha do sistema de colheita florestal é dependente da fisiografia e idade do povoamento (LIMA, 2017). A inclinação do terreno por exemplo tem relação direta com a produtividade das máquinas, sendo considerada uma variável limitante nesta operação (BURGIN et al., 2017).

3.3 Sistema colheita de toras curtas

O sistema de colheita florestal é um conjunto de atividades interconectadas, que possibilitam o fluxo constante de madeira e a máxima utilização de máquinas e equipamentos. Ele é influenciado pelas características fisiográficas, principalmente a inclinação do terreno, estoque de colheita do povoamento, regime de corte, uso final de madeira, máquinas e equipamentos (MACHADO et al., 2014).

No Brasil o sistema de toras curtas (cut-to-length) é amplamente utilizado na colheita do eucalipto (SIMÕES et al., 2010a), sendo o mais difundido no país, por permitir o aumento da produtividade, redução de custos de produção, tomando a operação mais lucrativa (LEITE, 2012).

Neste sistema a execução de todos os processos termina no próprio local onde a árvore foi derrubada. As toras produzidas medem até cerca de 6 m de comprimento (LEITE, 2012). O sistema de toras curtas é caracterizado por utilizar equipamentos de alta tecnologia, os quais tem como vantagem altos rendimentos operacionais (LEITE et al., 2014).

O *harvester* (Figura 1) é a principal máquina utilizada na derrubada e processamento da madeira no sistema de toras curtas. O processamento da madeira consiste, no desgalhamento, em alguns casos, no descascamento das árvores e no corte em toras de comprimento pré-determinado, deixando as toras agrupadas e prontas para serem removidas da área de colheita (BURLA et al., 2012, SILVA et al., 2010a).



Figura 1 - *Harvester*. Fonte: John Deere

Definido como um trator florestal automotriz o *harvester* é constituído de uma máquina base automotriz com rodado de pneus de baixa pressão e alta flutuação, esteiras metálicas ou mistas (pneus com esteiras), lança hidráulica para alcance das árvores que em conjunto com o cabeçote realizam as operações de derrubada, desgalhamento, descascamento, e traçamento da madeira (LEITE et al., 2013).

Seu custo de aquisição é relativamente alto, exige mão de obra qualificada, tendo como elemento determinante para obtenção de lucro ou prejuízo o tempo gasto para a execução da atividade. Por isso as empresas florestais com intuito de reduzir os custos do corte florestal costumam operar em um regime de trabalho de aproximadamente 22 horas por dia, sendo a vida útil das máquinas utilizadas geralmente de quatro a cinco anos (SANTOS et al., 2017).

O rendimento do *harvester* é influenciado por variáveis ambientais e operacionais que podem restringir seu uso, como: densidade do talhão, inclinação do terreno, classe de solo, volume médio por árvore, nível de treinamento do operador, condições da máquina, manutenção e direção de operação (LEITE et al., 2013).

3.4 Consumo de combustível de tratores

A mensuração da quantidade de combustível consumida é uma métrica importante para avaliar o desempenho de um motor. O consumo de combustível pode ser expresso de duas maneiras: em relação ao tempo ($L h^{-1}$; $kg h^{-1}$, etc.) e em relação ao trabalho mecânico desenvolvido, consumo específico ($g cv^{-1} h^{-1}$; $g kW^{-1} h^{-1}$, etc.) (MIALHE, 1996).

Com o aumento crescente do preço do combustível é necessário planejar e controlar o consumo nas operações que demandam alta quantidade de combustível (SILVEIRA et al., 2004). Isto porque o consumo de combustível é um dos itens que mais impacta os custos operacionais do *harvester*, uma vez que a operação de corte demanda potência máxima do motor (SIMÕES et al., 2010a). O melhor uso do potencial do motor, visando a diminuição do consumo de combustível, reduz os custos de produção de tratores (MARCHETTI, 2006).

Os motores de ciclo Diesel obtêm maior eficiência em baixas rotações, devido a maior capacidade em admitir oxigênio (comburente), maior tempo para completar o ciclo da combustão e menor atrito entre os componentes

dinâmicos e estáticos do motor (MÁRQUEZ, 2012). Com isso, motores que operam em menores regimes de rotação tendam a apresentar um menor consumo de combustível (FIORESE et al., 2015).

Alguns fatores que podem afetar o consumo de combustível de tratores são: as condições da superfície do solo (MONTEIRO et al., 2011), a velocidade de deslocamento (GABRIEL FILHO et al., 2010), a pressão interna dos pneus e regime de rotação do motor (SANTOS et al., 2016).

Para Borges et al. (2017), o tipo, a cobertura e o estado de compactação do solo, a fisiografia, as características técnicas do trator, a seleção adequada de engrenagens e a rotação do motor, feita pelo operador, de acordo com as condições de trabalho, merecem atenção especial por terem influência diretamente no consumo de combustível.

Em povoamentos equiâneos o consumo de combustíveis e lubrificantes é função das condições fisiográficas, clima, vias de acesso, produtividade dos povoamentos e fatores que interagem diretamente na realização da operação (OLIVEIRA JÚNIOR; MORAIS FILHO, 2006).

3.5 Modelos Lineares Mistos (MLM)

Um modelo estatístico explica as observações de uma variável dependente por meio dos efeitos que se atribuem a outra série de variáveis independentes. Esses efeitos podem ser de natureza fixa ou aleatória, conforme representem, respectivamente, constantes a serem estimadas ou realizações de uma variável aleatória com distribuição de probabilidade conhecida (CAMARILHA FILHO, 2002).

Um modelo de efeito misto é um modelo estatístico, em que o conjunto de preditores inclui efeitos fixos e aleatórios (BALDI et al., 2013). O efeito de um fator é considerado fixo, quando os níveis em estudo forem escolhidos pelo pesquisador, de maneira que a inferência é restrita a esses níveis (BAUTISTA, 2014). O efeito de um fator é considerado aleatório, quando os níveis em estudo são provenientes de uma amostra aleatória de uma população de referência, sendo a inferência extrapolada para a população de referência (PINHEIRO; BATES, 2000).

A análise da parte fixa, é realizada a partir da estimação e testes de hipóteses sobre funções estimáveis de efeitos fixos. A análise da parte aleatória refere-se à predição dos efeitos aleatórios, na presença de efeitos

fixos, e na estimação dos componentes de variância associadas aos efeitos aleatórios (BAUTISTA, 2014).

Os modelos mistos são usados com dados agrupados e tem por finalidade descrever uma variável resposta em função de covariáveis, conhecendo a correlação entre as observações no mesmo grupo. Os efeitos aleatórios são usados para representar dependência dentro do grupo (PINHEIRO; BATES, 2000; MAEKAWA, 2016). De acordo com Lyons et al. (2010) em estudos florestais, é comum que os dados sejam agrupados em blocos de corte e os dados em cluster são uma aplicação típica para Modelos Lineares Mistos (MLM).

Os MLMs são uma das técnicas de regressão mais sofisticadas, a qual permite ao usuário trabalhar com os dados na sua perfeita originalidade sem a necessidade de transformar variáveis para atender algumas pressuposições básicas de análise de regressão clássica como a: independência entre as observações, distribuição aleatória, normal, e idêntica dos resíduos com média zero e variância constante (CARVALHO, 2013; GOUVEIA et al., 2015). No Brasil, essa técnica ainda é recente e existem relativamente poucos trabalhos que usam a modelagem mista (NICOLETTI et al., 2016).

3.5.1 Estimativa de Máxima Verossimilhança (ML)

O método da máxima verossimilhança consiste na obtenção da moda ou maximização da função de verossimilhança das observações (HERBACH, 1959). Este método é iterativo e produz sempre estimativas positivas de componentes de variância, mas estas são viesadas devido ao método não considerar a perda de graus de liberdade resultante da estimação dos efeitos fixos do modelo (CAMARINHA FILHO, 2002).

Apesar de serem tendenciosos, os estimadores de máxima verossimilhança são consistentes, isto é, convergem assintoticamente para o valor dos parâmetros (HARTLEY; RAO, 1967). No caso de dados desbalanceados os estimadores de máxima verossimilhança (ML) e os estimadores de máxima verossimilhança restrita (REML) são viesados SEARLE (1987).

O ML pode ser útil para comparar modelos com diferentes estruturas de efeito fixo, uma vez que este também fornece estimadores dos efeitos fixos (WOOD, 2011).

3.6 Redes Neurais Artificiais (RNA)

A Rede Neuronal Artificial (RNA) é uma meta-heurística baseada na estrutura e no funcionamento do cérebro e do sistema nervoso central humano (SILVA, 2014), sendo útil no reconhecimento de padrões a partir do acúmulo de experiência ou de exemplos (ONUSIC et al., 2006). Uma característica das RNA é o processamento paralelo de informações, alta velocidade de processamento, capacidade de generalização de seu conhecimento, adaptação ao meio. Por ser uma técnica não-paramétrica e não-linear, possibilita o mapeamento de dados de entrada com dados de saída associados (TODT et al., 2006).

As RNA geralmente são organizadas em camadas: camada de entrada (variáveis apresentadas à rede); camadas intermediárias ou ocultas (realiza a maior parte do processamento) e camada de saída (obtenção do resultado final). Cada camada é composta por unidades processadoras (neurônios) conectadas através do peso sináptico, que estabelece a influência entre as unidades processadoras interligadas. Os pesos são definidos durante o treinamento (aprendizado) (BIONDI NETO et al., 2004).

Atualmente, muitas formas de RNA são propostas e usadas com variações, principalmente no número de neurônios por camada, tipo de função de ativação dos neurônios, número de camadas ocultas e tipo de conexão entre os neurônios. Interferem no tempo de treinamento e na eficiência de uma RNA o algoritmo utilizado e os parâmetros e coeficientes utilizados em seu treinamento (BINOTI et al., 2014).

Cada neurônio da RNA é uma unidade de processamento composto por uma função de ativação, que gera um valor de saída para o neurônio a partir do somatório dos valores que chegam a ele (HAYKIN, 2002). Conforme esse autor, a função de ativação mais comum na construção de redes neuronais artificiais é a sigmoide (Equação 1):

$$\varphi(v) = \frac{1}{1 + \exp \beta u} \quad (1)$$

em que,

φ = função de ativação sigmoide;

β = estimativa do parâmetro que determina inclinação da função sigmoide; e

u = potencial de ativação da função.

Recomenda-se o uso de RNA com a configuração mais simples possível e menor número de neurônios possível na camada oculta, com o intuito de evitar o sobre ajuste (*overfitting*). Ou seja, evitar o aprendizado exagerado das informações contidas nos dados apresentados às redes. Caso contrário, as redes treinadas acabam copiando, não apenas a semelhança estrutural entre as variáveis, mas, também, o ruído (erro da relação). Estas redes com *overfitting* não podem ser utilizadas no conjunto de dados por inteiro, pois sua capacidade de generalização foi comprometida. Também, configurações mais simples facilitam o processo de busca e otimização da configuração para determinada tarefa (RUSSELL; NORVIG, 2010).

3.6.1 Aprendizado das redes

As redes neurais artificiais têm a capacidade de aprender a partir de seu ambiente e melhorar o seu desempenho por meio da aprendizagem (processo iterativo de ajuste dos pesos sinápticos e níveis de bias). O tipo de aprendizagem é determinado pela forma de ajuste dos pesos (HAYKIN, 2002). Todo o conhecimento adquirido pela rede fica acumulado nos pesos sinápticos. Analogamente à sinapse do neurônio biológico, o peso é a “memória” da rede (GORGENS, 2006). Os métodos de treinamento podem ser divididos em: aprendizado não supervisionado e aprendizado supervisionado (BINOTI, 2010).

No aprendizado não supervisionado não há um agente externo para supervisionar o processo, ficam disponíveis para a rede somente os padrões de entrada. Nele a rede processa as entradas e, detectando suas regularidades, tenta progressivamente estabelecer representações internas para codificar características e classificá-las automaticamente. Este tipo de aprendizado só pode ser utilizado quando existe redundância nos dados de entrada, para que se consiga identificar padrões em tais dados (FERNEDA, 2006).

No aprendizado supervisionado existe um supervisor externo que disponibiliza a rede tanto os valores de entrada quanto os valores de saída esperados. Este é o tipo de aprendizado mais comum para treinamento das RNA. Nele a rede compara o valor de saída calculado com o valor esperado, e avalia o erro decorrente das diferenças entre ambos. Se existir alguma diferença os pesos sinápticos são modificados de forma a minimizar o erro e

encontrar a melhor relação entre as informações de entrada e saída (FIORIN et al, 2011).

3.6.2 Algoritmo *backpropagation*

Um dos algoritmos de aprendizado supervisionado mais utilizado foi a regra delta (correção de erros) e sua generalização para rede de múltiplas camadas, ou seja, o algoritmo de *backpropagation* (retropropagação do erro) (FACCIO; WERNER, 2010).

O treinamento através do algoritmo *backpropagation* ocorre em duas fases (Figura 2). A primeira fase é denominada de propagação adiante (*forward*), em que os sinais da amostra de treinamento são introduzidos as entradas da rede e são propagados camada a camada até a geração das respectivas saídas. Nesta fase os pesos sinápticos permanecem inalterados. A segunda fase é chamada de propagação reversa ou retropropagação (*backward*) (SILVA et al., 2010b) onde o sinal de erro é propagado da camada de saída para a camada de entrada (HAYKIN, 2002). Esta fase utiliza a saída desejada e a saída calculada pela RNA na fase de propagação para ajustes dos pesos das conexões da rede (RIBEIRO, 2007).




Figura 2 - Fluxo de processamento do algoritmo *backpropagation*. Os dados seguem da entrada para a saída no sentido *forward*, e os erros, da saída para entrada no sentido *backward*. Fonte: Braga et al., 2000.

A medida de erro (Equação 2) a ser minimizada é a soma dos erros quadráticos (GORGENS, 2006):

$$\varepsilon(t) = 1/2 \sum_{i=1}^k (d_i(t) - y_i(t))^2 \quad (2)$$

em que,

$d_i(t)$ = i-ésima saída desejada o t-ésimo ciclo de treinamento; e

$y_i(t)$ = i-ésima saída observada no t-ésimo ciclo de treinamento.

De forma simplificada pode-se descrever o funcionamento do algoritmo *backpropagation* da seguinte forma (BRAGA, et al., 2000):

1. Inicializar pesos e parâmetros;
2. Determinar a saída da rede através da fase *forward*. Nesta fase, primeiro a entrada é apresentada à primeira camada da rede, a camada C^0 . Para cada camada C^i a partir da camada de entrada, após os nodos da C^i ($i > 0$) calcularem seus sinais de saída, estes servem como entrada para a definição das saídas produzidas pelos nodos da camada C^{i+1} .
3. Comparar as saídas produzidas com as saídas desejadas; e
4. Atualizar pesos dos nodos através da fase *backward*. Esta fase inicia-se da última camada até chegar à camada de entrada. Nela os nodos da camada atual ajustam seus pesos de forma a reduzir seus erros. Sendo o erro de um nodo das camadas intermediárias calculado utilizando os erros dos nodos da camada seguinte conectados a ele, ponderados pelos pesos das conexões entre eles.
5. Repetir os passos 2, 3, e 4 até o erro ser mínimo ou até a realização de um dado número de ciclos.

O algoritmo *backpropagation* é baseado no método do gradiente, em que o vetor de parâmetros (pesos) é ajustado no sentido oposto ao do vetor gradiente. Este método é classificado como um método indireto de primeira ordem já que utiliza apenas a informação do gradiente (primeira derivada) da função de custo para o ajuste dos pesos da rede. Os métodos de primeira ordem são conhecidos pela baixa eficiência no tratamento de problemas de larga escala, pois apresentam taxas de convergência lenta ou inexistente, especialmente em regiões próximas a mínimos locais (RIBEIRO, 2007; OLIVEIRA et al., 2015).

Visando a melhoria na eficiência do *backpropagation* variações foram criadas. Dentre elas pode-se citar o *resilient propagation*, o qual é considerado

uma alternativa mais eficiente e recomendada para RNA do tipo Multilayer Perceptron (LEAL et al., 2015).

O algoritmo *Resilient propagation* possui uma taxa de aprendizagem dinâmica, isto é, a taxa de aprendizagem é atualizada para cada conexão dos neurônios, com intuito de diminuir o erro de maneira independente para cada neurônio (OLIVEIRA et al., 2015). Nele os pesos e a taxa de aprendizado são modificados somente uma vez em cada época de treinamento. Cada peso possui uma taxa de variação específica, a qual varia em função do tempo. Quando a derivada parcial muda de sinal, indica que a última mudança foi grande suficiente para que o sistema saltasse sobre um ponto de mínimo da função de erro, portanto o valor da taxa de variação é reduzido pelo fator η^- . Já quando a derivada parcial mantém o seu sinal, indica que o sistema está movendo permanentemente em uma única direção, o que resulta num aumento de taxa de variação proporcional ao fator η^+ (FREITAS et al., 2002): O ajuste dos pesos é feito após a apresentação completa de todo o padrão de treinamento à rede (BIONDI NETO et al., 2006).

A principal diferença entre o *resilient backpropagation* e as outras variações do *backpropagation* é que o ajuste dos pesos dos neurônios da rede e da taxa de aprendizado depende apenas dos sinais dos gradientes da função erro, não dependendo, portanto de sua magnitude. A função de erro é responsável pela especificação de um critério de desempenho que está associado à rede (FREITAS et al., 2002).

4. MATERIAL E MÉTODOS

4.1 Caracterização da área de estudo

O trabalho foi conduzido em uma empresa florestal do estado de Minas Gerais, entre as coordenadas 19°19'3,3" S e 42°23'34,9" W, zona 23, datum SAD-1969. A região possui clima Aw, segundo a classificação de Köppen (1948), tropical, com verões quentes e chuvosos e invernos secos, precipitação média anual de 1.374 mm, e temperatura média anual de 23,5°C (PREFEITURA MUNICIPAL DE BELO ORIENTE, 2011).

As áreas utilizadas (Tabela1) incluíram inclinações de 0° até 35° com predomínio de Latossolo amarelo. A coleta de dados foi realizada de setembro a outubro de 2016.

Tabela 1 - Caracterização das áreas utilizadas.

Área	Área total (ha)	Tipo de solo predominante	Classe de inclinação ¹	Volume médio por árvore (m ³)	CR usado ²
1	1,25	Latossolo amarelo	Plano	0,19	1
2	0,42	Neossolo flúvico	Plano	0,25	1
3	0,47	Cambissolo háplico	Plano	0,19	1
4	2,06	Cambissolo háplico	Ondulado	0,17	1
5	2,02	Cambissolo háplico	Plano	0,20	1, 2, 3, 4, e 5
6	0,20	Cambissolo háplico	Plano	0,14	1
7	0,44	Latossolo amarelo	Plano	0,24	5
8	1,18	Latossolo amarelo	Ondulado	0,23	1 e 2
9	1,59	Latossolo amarelo	Plano	0,29	1, 2, 3, 4, e 5
10	2,41	Latossolo amarelo	Plano	0,22	1
11	0,59	Latossolo amarelo	Fortemente ondulado	0,17	1, 2, 3, 4, e 5
12	0,13	Latossolo amarelo	Plano + Ondulado	0,14	1
13	0,51	Latossolo amarelo	Plano	0,20	1, 3, 4, e 5
14	0,32	Cambissolo háplico	Fortemente ondulado	0,20	1
15	0,09	Latossolo amarelo	Ondulado	0,15	1
16	0,91	Latossolo amarelo	Plano	0,20	1
17	0,97	Latossolo amarelo	Plano	0,15	1
18	0,57	Latossolo amarelo	Ondulado	0,17	1
19	0,87	Latossolo amarelo	Plano	0,23	1
20	0,25	Latossolo amarelo	Fortemente ondulado	0,13	1, 2, e 3

21	0,30	Latossolo amarelo	Fortemente ondulado	0,13	1, 2, 4, e 5
22	0,51	Latossolo amarelo	Plano	0,16	1
23	0,23	Latossolo amarelo	Ondulado + Fortemente ondulado	0,12	1

¹ Classe de inclinação: 1=Plano (0° a 8°); Ondulado (8,1° a 27°) e Fortemente ondulado (27,1° a 35°).

² CR = combinação de rotação utilizada.

4.2 Descrição da máquina

Um trator florestal *harvester* da marca John Deere, modelo 1270E foi utilizado para derrubar e processar as árvores em toras. A máquina é equipada com um motor John Deere Tech, modelo Plus 6090, de potência nominal igual a 228 cv (168 kW), contendo seis pneus e esteiras unindo os pneus dianteiros. O cabeçote usado foi o John Deere modelo H270 (Figura 3A), com um sistema de guincho com tração auxiliar HAAS acoplado na sua traseira (Figura 3B).



Figura 3 - A – modelo *harvester* John Deere 1270E; B – âncora utilizada.

O software operacional *TimberMatic* (John Deere) foi usado na máquina. Este *software* (Figura 4) permite o ajuste de todas as configurações da máquina (tais como: calibração da serra de corte, ajuste da pressão dos rolos, determinação da velocidade da lança, etc.) e constantes monitoramentos do seu estado (ex: temperatura do líquido de arrefecimento do motor, temperatura do óleo hidráulico, etc.) e desempenho (detalhes da produção), armazenando as informações com a frequência desejada.



Figura 4 - Software *TimberMatic* utilizado.

4.3 Avaliação dos sensores do *harvester*

Os sensores utilizados para coletar os dados a partir do *harvester* incluíam o comprimento (sensores de pulso) e diâmetro da tora, inclinômetro da máquina e consumo de combustível.

O sensor de comprimento da tora (Figura 5), localizado na roda de medição independente no cabeçote do *harvester*, foi utilizado para determinar o comprimento da tora a partir da rotação do motor de alimentação.




Figura 5 - Sensor de comprimento da tora. A – roda de medição do cabeçote; B – Sensor de pulso presente na parte posterior da roda de medição.

O diâmetro da tora foi estimado por potenciômetros (Figura 6) localizados em ambas as facas desgalhadoras. Os potenciômetros estimam o diâmetro da tora de acordo com o ângulo das facas.




Figura 6 - Sensor de diâmetro. A – facas desgalhadoras do cabeçote *harvester*; B – potenciômetros.

A inclinação da máquina foi estimada por inclinômetros acoplados ao *harvester* e o consumo de combustível (Equação 3) foi medido por sensores de pressão instalados depois do filtro de combustível.

$$C = \frac{L}{T} \quad (3)$$

em que,

C = consumo de combustível ($L s^{-1}$);

L = volume de combustível consumido nas operações de derrubada e processamento de uma árvore derrubar e processar uma árvore (L); e,

T = tempo de operações de derrubada e processamento (s).

Antes da coleta de dados, a precisão dos sensores utilizados foi verificada pela comparação de dados coletados pelo *harvester* com dados medidos manualmente no campo. Para isto, foi instalado um experimento com delineamento inteiramente casualizado com dez repetições desses dois tratamentos (*harvester* e manual). Cada parcela foi composta por dez árvores. As áreas de coleta tinham até 10° de inclinação e a floresta era homogênea. As áreas foram divididas de acordo com o volume médio individual das árvores em duas classes: até $0,23 m^3$ e acima de $0,23 m^3$.

O comprimento e o diâmetro das toras produzidas após a derrubada e processamento das árvores na amostra de teste foram coletados manualmente utilizando fita métrica e paquímetro. Após o final de cada parcela, o *harvester* foi reabastecido para obter o consumo de combustível da parcela. A inclinação do terreno foi medida com um clinômetro Hanglöf EC II (Figura 7).



Figura 7 - Modelo do clinômetro Hanglöff EC II utilizado.

O erro relativo percentual e a raiz quadrada do erro quadrático médio (RQEM) foram utilizados para avaliar a exatidão dos dados do *TimberMatic*. O erro relativo percentual obtido para a classe 1 foi de: 10,80% para o diâmetro e 12,20% para o volume por árvore, e para a classe 2 de: 11,14% e 21,30% respectivamente para o diâmetro e volume por árvore. Como as classes de produtividade da floresta não exercem influência sobre a medição dos sensores de consumo de combustível do *harvester* e comprimento da tora, foi calculado apenas um erro relativo percentual para as duas classes, sendo esses valores 0,40% e -0,87% respectivamente.

4.4 Descrição dos dados usados

Os dados foram coletados durante 32 dias, com o *harvester* trabalhando três turnos de oito horas, iniciando o primeiro turno às 00:00 horas. Quatro operadores foram utilizados para executar a colheita devido à operação ocorrer também aos finais de semana e feriados. O diâmetro, o ângulo frontal da máquina e o consumo horário de combustível, foram obtidos com o uso dos sensores do *harvester*, o qual fornecia essas informações em tempo real através do *TimberMatic*.

Com intuito de obter as informações disponíveis no *TimberMatic*, o programa *VM Capture 6* (Microsoft Corporation) foi instalado no computador de bordo da máquina e sua função era capturar as imagens da tela do computador de bordo como vídeo. O processamento dos dados contidos no vídeo foi feito pelo MATLAB R2015a.

Informações adicionais foram coletadas através do Boletim de Apropriação de Equipamento (BAE) complementadas pelo operador. O operador registrava no BAE o local, turno de trabalho, seu nome e se o guincho era usado (áreas acima de 27°). Todos os dados coletados continham o horário

e isto permitiu o cruzamento das informações para gerar observações em nível de árvore.

Modificações foram feitas nas configurações da rotação do motor. A rotação foi modificada quando apenas a lança era usada (R1), quando apenas se dirigia a máquina (R2) e quando se fazia ambas as atividades (R3). Cinco combinações de rotação foram utilizadas, 1600-1600-1600 rpm; 1600-1400-1600 rpm; 1400-1600-1600 rpm; 1200-1400-1600 rpm; 1700-1700-1700 rpm para R1, R2, e R3 respectivamente. As combinações de rotações são limitações da rotação de trabalho do *harvester* para diferentes funções. O motor gera até 2100 rpm, entretanto, a combinação de rotação usual da empresa era 1600-1600-1600 rpm.

As variáveis contínuas e categóricas utilizadas estão listadas na Tabela 2, e a análise descritiva das variáveis contínuas está na Tabela 3. O consumo específico de combustível (Equação 4) foi usado como a variável resposta no modelo.

$$C_S = \frac{L}{VT} \cdot 3600 \quad (4)$$

em que,

C_S = consumo específico de combustível ($L m^{-3} h^{-1}$);

L = litros de combustível gastos para derrubar e processar uma árvore (L);

V = volume da árvore (m^3); e,

T = tempo para derrubar e processar a árvore (s).

Tabela 2. Descrição das variáveis utilizadas.

Variável	Abreviatura	Classificação	Número de níveis
Consumo específico de combustível ($L m^{-3} h^{-1}$)	C_S	Contínua	-
Diâmetro da tora (m)	D	Contínua	-
Ângulo frontal da máquina (graus)	A	Contínua	-
Local (talhão)	L	Categórica	23
Tipo de manejo da floresta (plantio ou talhadia)	M	Categórica	2
Turno de trabalho	TT	Categórica	3
Combinações de rotação	CR	Categórica	5
Operador	a	Categórica	4

Tabela 3. Análise descritiva das variáveis contínuas.

Variável	Máximo	Mínimo	Média	Desvio padrão
Consumo específico de combustível (L m ⁻³ h ⁻¹)	142,00	33,79	79,91	26,55
Diâmetro da tora (m)	0,26	0,062	0,12	0,017
Ângulo frontal da máquina (graus)	35,00	0,00	9,00	7,19

4.5 Modelo Linear de Efeitos Mistos

Os dados do consumo específico de combustível (C_S) foram submetidos ao teste de normalidade Kolmogorov-Smirnov, porém, estes não apresentaram distribuição normal, por este motivo, no MLM, optou-se por usar o logaritmo natural de C_S ($\ln C_S$) para que fosse produzida a distribuição mais próxima do normal. Os dados foram agrupados dentro da variável operador e, portanto, esta variável foi incluída como um intercepto aleatório. O modelo linear misto (Equação 5) foi ajustado pelo método da máxima verossimilhança (ML). O *software* usado foi o SAS Institute 2009.

$$\ln S_C = \beta_0 + \beta_1 D + \beta_2 A + \sum_{j=1}^{23} \beta_j L_j + \sum_{k=1}^2 \beta_k M_k + \sum_{l=1}^2 \beta_l Cl_l + \sum_{m=1}^3 \beta_m TT_m + \sum_{n=1}^5 \beta_n CR_n + a_i + \varepsilon \quad (5)$$

em que,

$\ln C_S$ = logaritmo natural do consumo específico de combustível;

β_0 = efeito médio da população (intercepto);

β_1 = coeficiente para D ;

β_2 = coeficiente para A ;

β_j = coeficiente para L_j ;

β_k = coeficiente para M_k ;

β_l = coeficiente para Cl_l ;

β_m = coeficiente para TT ;

β_n = coeficiente para CR ;

a_i = efeito aleatório do i -ésimo operador, $i = 1,2,3,4$.

4.5.1 Avaliação do modelo

O teste da razão de verossimilhança foi utilizado para testar a contribuição das variáveis omitidas em modelos aninhados e também, a

significância de efeitos fixos (LYONS et al., 2010), sendo obtido de acordo com a Equação 6 (VERBEKE; MOLENBERGHS, 1997):

$$TRV = -2\ln\left(\frac{L_{ML0}}{L_{ML1}}\right) \quad (6)$$

em que,

L_{ML0} e L_{ML1} = as máximas verossimilhanças estimadas (L_{ML}) sob a hipótese nula e sob a hipótese alternativa, respectivamente.

A máxima verossimilhança é:

$$L_{ML} = \prod_{i=1}^N \left\{ (2\pi)^{-n/2} |V|^{-\frac{1}{2}} \exp\left(-\frac{1}{2}(y - Xb)^T V^{-1}(y - Xb)\right) \right\} (2\pi)^{-\frac{1}{2}n}$$

Também, o Critério de Informação de Akaike (AIC) e o Coeficiente de determinação, baseado no Teste da Razão de Verossimilhança (R_{LR}^2) foram utilizados na avaliação da qualidade do ajustamento.

O AIC é definido pela Equação 7, onde o número de parâmetros estimados pelo modelo está incluído como penalidade pela complexidade do modelo (ZUUR et al., 2009). Quanto menor o valor de AIC melhor é o modelo avaliado (MENDONÇA et al., 2015):

$$AIC = -2L_{ML} + 2p \quad (7)$$

em que,

p = número de parâmetros estimados no modelo.

O R_{LR}^2 (Equação 8 proposta por Magee, 1990) mede a associação multivariada entre os resultados e os efeitos fixos no modelo linear misto. Esta abordagem assume que diferentes modelos apenas em relação aos efeitos fixos tem a mesma estrutura de covariância (EDWARDS et al., 2008):

$$R_{LR}^2 = 1 - \exp\left(\frac{-2}{n}(l_m - l_o)\right) \quad (8)$$

em que,

l_m = log de verossimilhança do modelo de interesse;

l_o = log de verossimilhança do modelo nulo com apenas uma interceptação nos efeitos fixos; e,

n = número de observações.

4.6 Redes Neurais Artificiais (RNA)

O banco de dados foi dividido aleatoriamente da seguinte forma: 70% para treinamento e 30% para validação das redes. O *software* utilizado para obtenção das redes foi o Neuro 4.0.6.

Os dados utilizados para geração das redes foram padronizados de acordo com a Equação 9. Esta etapa consistiu na transformação de cada variável numérica em valores entre 0 e 1:

$$V_n = \frac{V - V_{min}}{V_{max} - V_{min}} \quad (9)$$

em que,

V_n = valor normalizado;

V = valor da observação;

V_{max} = valor máximo das observações; e

V_{min} = valor mínimo das observações.

Neste trabalho, o treinamento foi tipo supervisionado. A camada de entrada foi constituída de 42 neurônios, sendo um para cada variável numérica, um para cada nível de cada variável categórica e 1 neurônio com entrada fixa de valor 1, referente ao limiar de excitação. As redes foram constituídas de apenas uma camada oculta, sendo que o número de neurônios nessa camada variou de 1 a 21. O algoritmo de aprendizagem supervisionado utilizado foi o *resilient-propagation* (RPROP+). A função de ativação usada na camada oculta e saída foi a logística.

No total foram treinados 175 RNA Multilayer Perceptron (MPL), sendo selecionadas as três que proporcionam uma melhor correlação entre valores estimados e observados. Como critério de parada do algoritmo de treinamento utilizou-se o número total de ciclos ou épocas, que representam a quantidade de vezes que os dados são apresentados ao algoritmo (LEITE et al., 2016), sendo este valor igual a 3.000.

4.6.1 Avaliação do desempenho das RNA

Foram utilizadas como medidas de avaliação dos resultados gerados pelas redes, a correlação entre os valores observados e estimados ($r_{Y,\hat{Y}}$), a

Raiz Quadrada do Erro Quadrático Médio (RQEM %), o erro relativo percentual médio (ER%) e a distribuição de frequência deste erro.

- Correlação de Person ($r_{Y,\hat{Y}}$): foi utilizada para determinar o grau de associação entre os valores observados e estimados. A análise de correlação (Equação 10) unida a análise de resíduos permite concluir sobre a qualidade da estimação. Quanto mais próxima de 1, maior a correlação entre as variáveis (BINOTI, et al., 2015).

$$r_{Y\hat{Y}} = \frac{n^{-1}[\sum_{i=1}^n (\hat{Y}_i - \bar{Y})(Y_i - \bar{Y})]}{\sqrt{[n^{-1} \sum_{i=1}^n (\hat{Y}_i - \hat{Y}_m)^2][n^{-1} \sum_{i=1}^n (Y_i - \bar{Y})^2]}} \quad (10)$$

em que:

Y_i = valores observados;

\hat{Y} = valores estimados;

\hat{Y}_m = a média das estimativas de Y ;

\bar{Y} = a média aritmética de Y ; e

n = número de observações.

- RQEM (%): o erro quadrático médio (Equação 11) foi utilizado com o intuito de visualizar a dimensão do erro da estimativa realizada pela rede (MOURA et al., 2010). Quanto menor o RQEM, melhor é a precisão da estimativa. Uma estimativa perfeita deverá ter o RQEM igual à zero (SILVA et al., 2014).

$$\text{RQEM}(\%) = \frac{100}{\bar{Y}} \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (11)$$

em que,

\bar{Y} = média dos valores observados;

n = número total de observações;

Y_i = valores observados; e

\hat{Y}_i = valores estimados.

- O erro (resíduos) relativo percentual médio (ER%) foi obtido através da Equação 12.

$$ER\% = \frac{\sum(\hat{Y}-Y)/Y}{n} \cdot 100 \quad (12)$$

em que:

\hat{Y} = valores estimados; e

Y = valores observados; e

n = número de observações.

4.7 Comparação entre MLM e RNA

Os parâmetros de avaliação utilizados para comparar os resultados gerados pelos Modelos Lineares Mistos (MLM) e as Redes Neurais Artificiais (RNA), foram o erro relativo percentual (Equação 12) e a Raiz Quadrada do Erro Quadrado Médio (RQEM) (Equação 11).

5. RESULTADOS E DISCUSSÃO

5.1 Modelos Lineares Mistos (MLM)

As estimativas dos efeitos fixos e aleatórios para a Equação 5 estão apresentados na Equação 13. O valor R_{LR}^2 obtido para esta equação foi de 0,84. O valor previsto marginal é definido como $\hat{y} = Xb$ e o valor previsto condicional é definido como $\hat{y} = Xb + Zu$, onde y é o vetor conhecido de dados observados (resposta), b é vetor desconhecido de efeitos fixos, u é o vetor desconhecido de efeitos aleatórios e X e Z são a matriz de incidência de efeitos fixos e aleatórios respectivamente (RESENDE, 2002).

$$\begin{aligned} \ln S_C = & 6,0264 - 14,5600^a D + 0,001328^a A + 0,08938^a L_2 + 0,1536^a L_3 + \\ & 0,05955^a L_4 + 0,04544^a L_5 + 0,1562^a L_7 - 0,04418^a L_{10} + 0,2086^a L_{11} - \\ & 0,1387^a L_{12} + 0,09322^a L_{14} + 0,09341^a L_{16} + 0,2039^a L_{17} + 0,1326^a L_{18} + \\ & 0,1141^a L_{19} + 0,2322^a L_{20} + 0,1219^a L_{21} + 0,06873^a M_1 - 0,1018^a TT_1 - \\ & 0,01382^a TT_2 - 0,0503^a CR_4 + 0,07706^b a_1 \end{aligned} \quad (13)$$

^a Indica que a inclinação é significativamente diferente de 0, $\alpha = 0,05$.

^b Indica que a média condicional é significativamente diferente da média marginal, $\alpha = 0,05$.

Valores de L_j , M_k , Cl_l , TT_m , CR_n , e a_i igual a 0 ou 1 (ausência ou presença da variável).

A Equação 13 indica que $\ln C_S$ diminui com o aumento de D . Os valores mais altos do consumo específico de combustível ocorreram quando os volumes das árvores eram baixos (abaixo de 0,25 m³). Isso indica que uma parte do trabalho realizado durante a fase de queda e processamento é independente do tamanho da árvore.

Em relação a A , nota-se que o aumento de seus valores resultou no aumento de $\ln C_S$, devido à maior força de tração necessária para vencer a força da gravidade, principalmente nas áreas até 27 ° de inclinação frontal do terreno onde o corte é realizado em aclave, e a maior dificuldade de colher em áreas acima de 27° (áreas de guincho), o que reduz a produtividade horária do *harvester*. Nas áreas em que o guincho é utilizado, a colheita é realizada em declive, o que reduz a visão geral do operador ao realizar as operações, muitas

vezes fazendo-os adotar posturas de trabalho inadequadas, reduzindo o controle operacional das atividades (LEITE et al., 2013).

Nesta análise, o local 23 foi definido como o nível de referência, e a predição marginal dos locais 10 e 12 foi menor ($p < 0,05$), em razão de L_{10} e L_{12} serem áreas plana, enquanto a referência (L_{23}) possui inclinações do terreno de 8 a 35°. Para os outros locais, o marginal previsto de $\ln C_S$ foi maior ($p < 0,05$). Observando a Figura 8, é possível perceber que o local que possui maior valor médio de C_S é o 20, provavelmente devido a maior inclinação do terreno (acima de 27°), e terem sido colhidas aproximadamente 90 árvores por hora nesta área, resultando em um menor tempo utilizado para realização da colheita de uma árvore. Em áreas de guincho a produtividade média do *harvester* é de 70 árvores por hora.




Figura 8 - Box plot do consumo específico de combustível ($L \cdot m^{-3} \cdot h^{-1}$) por local.

Ao considerar M_2 (talhadia) como a referência do nível, a predição marginal de $\ln C_S$ para as áreas de plantio (M_1) foi maior ($p < 0,05$), devido ao volume de madeira presente nessas áreas ser geralmente menor do que nas áreas onde M_2 é utilizado, fazendo com que o tempo de colheita de uma árvore seja menor, aumentando a produtividade horária do *harvester* (árvores/h) e assim o seu trabalho.

Para o turno de trabalho do operador, quando TT_3 é definido como o nível de referência, o marginal previsto lnC_S para TT_1 e TT_2 foi menor ($p < 0,05$), possivelmente devido ao turno 1 (das 00:00 às 08:00 da manhã) e 2 (das 08:00 da manhã às 16:00 da tarde) serem os menos produtivos, o que reduz o trabalho realizado pela máquina e seu consumo horário. A produtividade da colheita no segundo turno é afetada principalmente pelas paradas programadas para manutenção serem realizadas de preferência neste turno. O turno menos produtivo é o primeiro devido à menor visibilidade, sono, maior necessidade de atenção e esforço visual do operador (ALVES et al., 2015).

Observa-se ainda que apenas a combinação de rotação 4 (1200-1400-1600 rpm) foi diferente de zero ($p < 0,05$). Nesta análise, a combinação de rotação 5 (1700-1700-1700) foi definida como o nível de referência, e a predição marginal de lnC_S para CR_4 foi menor ($p < 0,05$) devido CR_4 ser suficiente para realizar a operação de corte independentemente da situação (local, inclinação do site frontal e lateral, clima, etc.). O uso da combinação de rotação 4 resultou na redução do consumo específico de combustível em aproximadamente 1% para todas as condições de trabalho do *harvester*.

Observando a variável aleatória operador, pode-se observar na Equação 13 que o condicional previsto lnC_S para o operador 1 foi maior ($p < 0,05$) do que o marginal previsto lnC_S , sendo a_1 o mais produtivo. As características da área e da floresta são fatores importantes na produtividade do operador 1, uma vez que por exemplo, em áreas planas, sem falhas de plantio, com baixo volume médio individual das árvores, e floresta reta, sua produtividade é acima de 110 árvores por hora, enquanto que, em áreas onde o guincho é utilizado sua produtividade horária é de aproximadamente 80 árvores.

Nota-se a partir da Figura 9, que os locais onde o operador 1 trabalhou que apresentaram maiores valores médio de consumo específico de combustível foram o 15 e o 17, por estes serem caracterizados como planos e por possuírem árvores com volume médio de $0,15 \text{ m}^3$.




Figura 9 - Box plot do consumo específico de combustível ($L m^{-3} h^{-1}$) dos locais onde a atividade de derrubada e processamento foi realizada apenas pelo operador 1.

5.2 Redes Neurais Artificiais (RNA)

As redes que resultaram em maiores valores de correlação e menores valores de RQEM estão apresentadas na Tabela 4. Devido à complexidade para estimativa do consumo específico de combustível do *harvester* ($L h^{-1} m^{-3}$) os resultados encontrados foram satisfatórios.

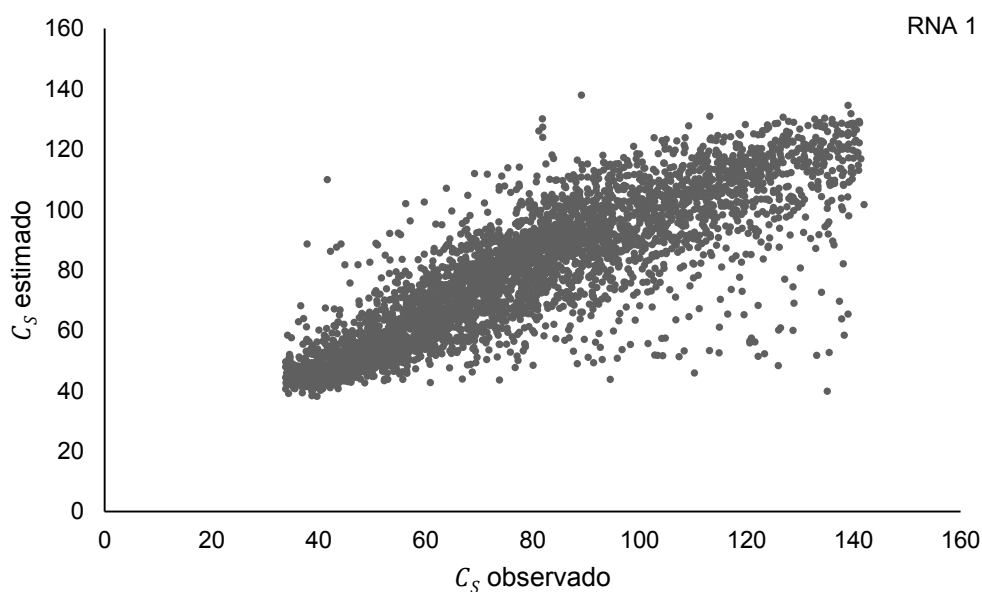
A rede que obteve maior correlação (0,85%) e menor valor de RQEM (17,62%) na validação foi a 1, o que significa que foi necessário um menor número de neurônios para extrair a relação entre as variáveis independentes e o consumo específico de combustível. Dentre as redes avaliadas, esta foi a que apresentou maior capacidade de generalização, isto é, geração de respostas coerentes a dados desconhecidos.

Recomenda-se que nas aplicações de RNA sejam escolhidas configurações mais simples, com o menor número de neurônios possível na camada oculta, a fim de evitar o *overfitting* e facilitar o processo de busca e otimização da configuração para uma determinada tarefa (BULLINARIA, 2009).

Tabela 4 - Resultado estatístico das RNA selecionadas para predizer o consumo específico de combustível do *harvester* ($L h^{-1} m^{-3}$).

Arquitetura	Correlação		RQEM (%)	
	Treino	Validação	Treino	Validação
1 MPL 39-8-1	0,8463	0,8493	17,6588	17,6189
2 MPL 39-9-1	0,8483	0,8484	17,5064	17,7642
3 MPL 39-20-1	0,8542	0,8421	17,2641	17,9454

A partir das redes selecionadas realizou-se a generalização para comprovar a aplicação da metodologia (BINOTI et al., 2013). Os resíduos das estimativas e as distribuições de frequências dos erros relativos percentuais estão apresentados nas Figuras 10 e 11. Na Figura 10 é possível perceber que todas as redes selecionadas apresentaram tendência de subestimação e superestimação dos valores estimados. A inclusão de variáveis como: o genótipo (clone), estado pessoal do operador no momento da operação e temperatura ambiente podem aumentar a precisão das estimativas.








Figura 10 – Relação entre os valores estimados e observados do consumo específico de combustível (C_s).

Verifica-se a partir da Figura 11, que 80% dos erros das três redes selecionadas concentraram-se entre -17,5% e 22,5%, sendo que aproximadamente 60% dos erros encontram-se em $\pm 12,5\%$, indicando eficiência da RNA ao predizer o consumo específico de combustível.

Utilizando redes neurais artificiais para a predição do consumo específico de combustível e temperatura de exaustão de um motor a Diesel a partir da rotação do motor, pressão efetiva média e tempo de injeção, Parlak et al. (2006), afirmaram que esta é uma técnica alternativa e prática para avaliar

os parâmetros do motor, devido à sua capacidade de aprender e generalizar uma ampla gama de condições experimentais. O erro relativo médio encontrado por estes autores foi de 2%, no entanto a coleta de dados foi realizada em laboratório enquanto neste trabalho a coleta foi feita em condições de campo, estando a máquina exposta a inúmeras variáveis que podem influenciar o consumo de combustível e assim dificultar sua predição.

Ao predizer o consumo de combustível (gal h^{-1}) de motores de tratores agrícolas utilizando como variáveis de entrada a rotação do motor (rpm), tipo do chassi (tração nas duas rodas, tração nas quatro rodas, e roda dentada mecânica), condição do acelerador, potência na barra de tração (hp), potência na TDP (hp), e carga, Rahimi-Ajdadi e Abbaspour-Gilandeh (2011) observaram que as redes forneceram resultados rápidos, precisos e confiáveis de forma eficaz.






Figura 11 - Frequência percentual dos erros relativos percentuais do consumo específico de combustível ($L h^{-1} m^{-3}$) estimados pelas RNA.

5.3 Comparação entre MLM e RNA

A Raiz Quadrada do Erro Quadrado Médio (RQEM %) obtida com a RNA 2 (item 5.2) e com o MLM foi de 17,6189 e 20,9686 respectivamente, indicando maior eficiência na estimação do consumo específico de combustível do *harvester* pela RNA.

Ao estimar o consumo de combustível das operações agrícolas com base no perfil do solo mobilizado, resistência mecânica e patinação do trator, sistema de preparo, engrenagem e rotação do motor Borges et al. (2017) observaram que as redes neurais artificiais multicamadas do tipo perceptron

são adequadas para estimar o consumo de combustível. Observando a Figura 12, nota-se que apesar de ambos os métodos tenderem a subestimar e superestimar os valores estimados, ocorreu uma maior subestimação no modelo linear misto. Este fato pode ser explicado uma vez que foi utilizada uma RNA com estrutura não linear, o que contribuiu para melhoria da extração de características dos dados.

Em alguns casos, as RNA têm resultado em 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, 2002).




Figura 12 – Relação entre os valores estimados e observados do consumo específico de combustível (C_S) utilizando Redes Neuronais Artificiais (RNA) e Modelos Lineares Mistos (MLM).

Verifica-se ainda, pela Figura 13, que a maioria dos erros da RNA (72,2%) e MLM (64,0%) se concentram em $\pm 17,5\%$, sendo estes valores aceitáveis, devido à complexidade de estimação do C_S . O desempenho obtido pelo modelo linear de efeitos mistos está relacionado a sua habilidade de caracterizar os padrões de comportamento de grupos e indivíduos, reconhecer

diferenças de grupos e indivíduos e incorporar covariáveis adicionais (KRUEGER; TIAN, 2004).

Devido ao bom desempenho da RNA e do MLM, a escolha do método para predição do consumo específico de combustível do *harvester* deverá levar em consideração o uso final desta informação. Se o objetivo da predição for a gestão de custos com combustível, a RNA será a metodologia mais adequada devido a sua maior exatidão. Por outro lado, se o objetivo for melhorar o desempenho operacional da máquina durante a realização da operação de corte, o MLM será a melhor alternativa, uma vez que este método permite avaliar a influência de cada variável de entrada utilizada, e assim tomar medidas operacionais que contribuam para redução do consumo de combustível no campo. Este tipo de avaliação também pode ser feita pela RNA, através dos algoritmos de Olden, Garson e Lekprofile, porém, no caso do MLM a análise é direta e mais simples.

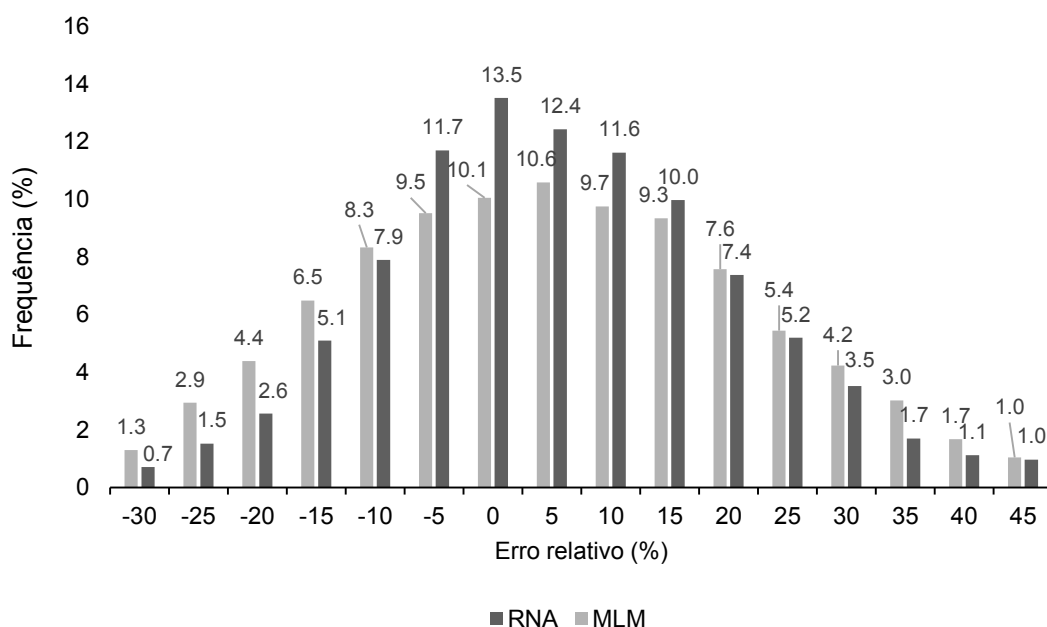


Figura 13 - Frequência percentual dos erros relativos percentuais dos logaritmos naturais do consumo específico de combustível (L h⁻¹ m⁻³) estimados pela Rede Neuronal Artificial (RNA) e Modelo Linear Mistos (MLM).

6. CONCLUSÕES

- A variável local foi a que mais influenciou o consumo específico de combustível do *harvester*;

- O condicional previsto do logaritmo natural do consumo específico de combustível ($\ln C_S$) para o operador 1 e 3 é maior e menor ($p < 0,05$), respectivamente, do que o marginal previsto $\ln C_S$;

- O uso da combinação de rotação 4 (CR_4) resulta em menores valores de $\ln C_S$ quando comparado a combinação de rotação 5 (CR_5), reduzindo o consumo específico de combustível em aproximadamente 1% para todas as condições de trabalho do *harvester*.

- A produtividade da máquina e o volume da madeira estão diretamente relacionados ao consumo específico de combustível, sendo que, quanto maior a produtividade horária e menor o volume de madeira, maior será o consumo;

- O modelo Linear de Efeitos Mistos (MLM) e a Rede Neuronal Artificial (RNA) são eficientes na estimativa do consumo específico de combustível do *harvester*, com ligeira superioridade (exatidão) para a rede neuronal.

7. LITERATURA CITADA

ALVES, E. G.; FIEDLER, N. C.; CARMO, F. C. A.; LOPES, E. S.; LACHINI, E.; EUGENIO, F. C. Efeito do turno de trabalho na produção e produtividade de máquinas de colheita de madeira. **Nativa**, Sinop, v. 03, n. 03, p. 201-204, 2015.

BAUTISTA, E. A. L. **Modelos lineares mistos e generalizados mistos em estudos de adaptação local e plasticidade fenotípica de Euterpe edulis**. 2014. 124 f. Tese (Doutorado em Estatística e Experimentação Agronômica) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2014.

BALDI, I.; PAGANO, E.; BERCHIALLA, P.; DESIDERI, A.; FERRANDO, A.; MERLETTI, F.; GREGORI, D. Modeling healthcare costs in simultaneous presence of asymmetry, heteroscedasticity and correlation. **Journal of Applied Statistics**, v. 40, n. 2, p. 298-310, 2013.

BIONDI NETO, L.; MELLO, J. C. C. B. S.; GOMES, E. G.; MEZA, L. A. Estimativa de valores ausentes com redes neurais artificiais: o caso dos custos de construção civil. **Revista de Economia e Administração**, v.3, n.2, p. 87-96, 2004.

BIONDI NETO, L.; SIEIRA, A. C. C. F.; DANZIGER, B. R.; SILVA, J. G. S. Neuro-CPT: Classificação de Solos usando-se Redes Neurais Artificiais. **Engevista**, v. 8, p. 37-48, 2006.

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

BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, v.37, n.4, p.639-645, 2013.

BINOTI, D. H. B.; BINOTI, M, L. M. S.; LEITE, H. G. Configuração de Redes Neurais Artificiais para Estimação do Volume de Árvores. **Ciência da Madeira**, v. 5, n. 1, p.58-67, 2014.

BINOTI, M. L. M.; LEITE, H. G.; BINOTI, D. H. B.; GLERIANI, J. M. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Cerne**, Lavras, MG, v. 21, n. 1, p. 97-105, 2015.

BORGES, P. H. M.; MENDOZA, Z. M. S. H.; MAIA, J. C. S. BIANCHINI, A.; FERNANDES, H. C. Estimation of fuel consumption in agricultural mechanized operations using artificial neural network. **Eng. Agríc., Jaboticabal**, v.37, n.1, p.136-147, 2017.

BRAGA, A.P. et al. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000. 250 p.

BULLINARIA, J. A. Introduction to Neural Computation. **Notas de aula**. 2009. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/inc.html>>. Acesso em: 07 mai. 2018.

BURGIN, M. R. B.; LOPES, E. S.; RODRIGUES, C. K. Efeito do volume individual e declividade do terreno na produtividade do *harvester* no desbaste de Pinus. **Agropecuária Científica no Seminário**, Pastos, PB, v. 13, n. 4, p. 322-328, 2017.

BURLA, E. R.; FERNANDES, H. C.; MACHADO, C. C.; LEITE, D. M.; FERNANDES, P. S. Avaliação técnica e econômica do *harvester* em diferentes condições operacionais. **Revista Engenharia na Agricultura**, Viçosa, MG, v. 20, n. 5, p. 412-422, 2012.

CAMARINHO FILHO J.A. **Modelos lineares mistos: estruturas de matrizes de variâncias e covariâncias e seleção de modelos**. 2002. 85 f. Tese (Doutorado em Estatística e Experimentação agronômica) - Universidade de São Paulo, Piracicaba, 2002.

CARVALHO, S. P. C. **Estimativa volumétrica por modelo misto e tecnologia laser aerotransportado em plantios clonais de *Eucalyptus* sp.**

2013. 105 f. Tese (Doutorado em Recursos Florestais) – Universidade de São Paulo/Escola Superior de Agricultura “Luiz de Queiroz”, Piracicaba, SP, 2013.

EDWARDS, L. J.; MULLER, K. E.; WOLFINGER, R. D.; QAQISH, B. F.; SCHABENBERGER, O. An R^2 statistic for fixed effects in the linear mixed model. **Statistics in Medicine**, 27: p. 6137–6157, 2008.

FACCIO, K.; WERNER, L. Comparando gráfico CUSUM e Redes Neurais Artificiais no contexto do Controle Estatístico de Qualidade. **Revista INGEPRO**, v.2, n.11, p. 1-12, 2010.

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. **Ci. Inf.**, Brasília, v.35, n. 1, p.25-30, 2006.

FIGEISE, D. A.; MARASCA, I.; FERNANDES, B. B.; SANDI, J.; MORELLI-FERREIRA, F.; LANÇAS, K. F. Desempenho de três tratores agrícolas em ensaios de tração. **Revista de Agricultura Neotropical**, v. 2, n. 2, p. 68-76, 2015.

FIORIN, D. V.; MARTINS, F. R.; SCHUCH, N. J.; PEREIRA, E. B. Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. **Revista Brasileira de Ensino de Física**, v. 33, n. 1, p. 1309, 2011.

FREITAS, A. A. C.; SILVA, I. N.; SOUZA, A. N. Aplicação de redes neurais na estimação da temperatura interna de transformadores de distribuição imersos em óleo. **Revista Controle & Automação**. v.13, n. 3, p.266-274, 2002.

GABRIEL FILHO, A.; LANÇAS, K. P.; LEITE, F.; ACOSTA, J. J. B.; JESUINO, P. R. Desempenho de trator agrícola em três superfícies de solo e quatro velocidades de deslocamento. **Revista Brasileira de Engenharia Agrícola e Ambiental**. v.14, n.3, p.333–339, 2010.

GORGENS, E. B. **Estimação do volume de árvores utilizando redes neurais artificiais**. 2006, 94 f. Dissertação (Mestrado em Ciência Florestal) – Universidade federal de Viçosa, Viçosa, MG, 2006.

GOUVEIA, J. F.; SILVA, J. A. A.; FERREIRA, R. L. C.; GADELHA, F. H. L.; LIMA FILHO, L. M. A. Modelos volumétricos mistos em clones de *eucalyptus* no

polo gesseiro do Araripe, Pernambuco. **Floresta**, Curitiba, PR, v. 45, n. 3, p. 587-598, 2015.

GUO, Z.; ZHAO, W.; LU, H.; WANG, J. Multi-step forecasting for wind speed using a modified EMD-based artificial neural network model. **Renewable Energy**, 37, p. 241-249, 2012.

HARTLEY, H. O.; RAO, J. N. K. Maximum-likelihood estimation for the mixed analysis of variance model. **Biometrika**, v. 54, p.93-108, 1967.

HERBACH, L. H. Properties of model II-type analysis of variance tests, A: optimum nature of the F-test for model II in the balanced case. **Ann. Math. Statist.**, v. 30, n. 4, p. 939-959. 1959.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2002. 900 p.

IBÁ. **Relatório 2017**. Indústria Brasileira de Árvores - IBÁ. 2017. 80 p.

KÖPPEN, W. **Climatologia com un studio de los climas de la tierra**. México: Fondo de Cultura econômica, 1948. 478 p.

KRUEGER, C.; TIAN, L. A Comparison of the General Linear Mixed Model and Repeated Measures ANOVA Using a Dataset with Multiple Missing Data Points. **Biological Research for Nursing**. v. 6, n. 2, p. 151-157, 2004.

LEAL, F. A.; MIGUEL, E. P.; MATRICARDI, E. A. T.; PEREIRA, R. S. Redes neurais artificiais na estimativa de volume em um plantio de eucalipto em função de fotografias hemisféricas e número de árvores. **Rev. Bras. Biom.**, São Paulo, v.33, n.2, p.233-249, 2015.

LEITE, E. D. S. **Modelagem técnica e econômica de um sistema de colheita florestal mecanizada de toras curtas**. 2012. 130 f. Tese (Doutorado em Engenharia Agrícola) - Universidade Federal de Viçosa, Viçosa, MG, 2012.

LEITE, E. D. S.; FERNANDES, H. C.; MINETTE, L. J.; LEITE, H. G.; GUEDES, I. L. Modelagem técnica e de custos do *harvester* no corte de madeira de eucalipto no sistema de toras curtas. **Scientia Forestalis**, Piracicaba, SP, v. 41, n. 98, p. 205-215, 2013.

LEITE, E. D. S.; MINETTE, L. J.; FERNANDES, H. C.; SOUZA, A. P. D.; AMARAL, E. J. D.; LACERDA, E. D. G. Desempenho do harvester na colheita de eucalipto em diferentes espaçamentos e declividades. **Revista Árvore**, Viçosa, MG, v. 38, n. 1, p. 000-000, 2014.

LEITE, H. G.; BINOTI, D. H. B.; OLVEIRA NETO, R. R.; LOPES, P. F.; CASTRO, R. R.; PAULINO, E. J.; BINOTI, M. L. M. S.; COLODETTE, J. L. Redes Neurais Artificiais para a estimação da densidade básica da madeira. **Sci. For.**, Piracicaba, v. 44, n. 109, p. 149-154, 2016.

LIMA, V. F. **Análise comparativa de produção florestal e consumo de combustível em harvesters no sistema full tree**. 2017. 35 f. Monografia (Especialização em Engenharia de Produção) - Universidade Tecnológica Federal do Paraná, Ponta grossa, 2017.

LU, C.; LEE, T.; LIAN, C. Sales forecasting for computer wholesalers: A comparison of multivariate adaptive regression splines and artificial neural networks. **Decision Support Systems**, 54, p. 584-596, 2012.

LYONS, K.; XING, L.; NELSON, J. D. Using Linear Mixed Effects in Helicopter Logging Data. **Forest Science**, v. 56, n. 4, p. 356-365, 2010.

MACHADO, C. C.; SILVA, E. N. D.; PEREIRA, R. S.; CASTRO, G. P. O setor florestal brasileiro e a colheita florestal. In: MACHADO, C. C. (Ed.). **Colheita florestal**. 3. ed. Viçosa, MG: Universidade Federal de Viçosa, 2014. p.15-45.

MAEKAWA, E. S. **Estimativa do custo da colheita mecanizada de cana-de-açúcar utilizando modelos de regressão**. 2016, 70 f. Dissertação (Mestrado em Ciências) - Escola Superior de Agricultura "Luiz de Queiroz". Piracicaba, SP, 2016.

MAGEE, L. R^2 Measures Based on Wald and Likelihood Ratio Joint Significance Tests. **The American Statistician**, v. 44, n. 3, 1990.

MARCHETTI, I. **Sistema automatizado para aviação do consumo de Biodiesel em tratores agrícolas**. 2006. 82 f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Estadual do Oeste do Paraná, Cascavel, 2006.

MÁRQUEZ, L. **Tractores Agrícolas: Tecnologías y utilización**. Madrid: B&h Editores, 2012. 844 p.

MENDONÇA, A. R.; CARVALHO, S. P. C.; CALEGARIO, N. Modelos hipsométricos generalizados mistos na predição da altura de *Eucalyptus sp.* **CERNE**, v. 21, n. 1, p. 107-115, 2015.

MIALHE, L.G. **Máquinas Agrícolas - Ensaio & Certificação**. Piracicaba, SP: Fundação de Estudos Agrários "Luiz de Queiroz", 1996. 723 p.

MINETTE, L. J.; SILVA, E. N.; MIRANDA, G. D. M.; SOUZA, A. P. D.; FIEDLER, N. C. Avaliação técnica da operação de extração de *Eucalyptus spp.* utilizando o trator autocarregável e o trator floresta transportador "forwarder" na região sul da Bahia. **Revista Engenharia na Agricultura**, Viçosa, MG, v. 16, n. 3, p. 312-317, 2008.

MONTEIRO, L. A.; LANÇAS, K. P.; GUERRA, S. P. S. Desempenho de um trator agrícola equipado com pneus radiais e diagonais com três níveis de lastros líquidos. **Eng. Agríc., Jaboticabal**, v.31, n.3, p.551-560, 2011.

MOREIRA, J. M. M. A. P.; OLIVEIRA, E. B. **Importância do setor florestal brasileiro com ênfase nas plantações florestais comerciais**. In: OLIVEIRA, Y. M. M. de; OLIVEIRA, E. B. de (Ed.). *Plantações florestais: geração de benefícios com baixo impacto ambiental*. Brasília, DF: Embrapa, 2017. p. 11-20.

MOURA, R. G.; HERDIES, D. L.; MENDES, D.; MENDES, M. C. D. Avaliação do modelo regional ETA utilizando as análises do CPTEC e NCEP. **Revista Brasileira de Meteorologia**, v.25, n.1, p. 46-53, 2010.

NASCIMENTO, A. C.; LEITE, A. M. P.; SOARES, T. S.; FREITAS, L. C. Avaliação Técnica e Econômica da Colheita Florestal com *Feller-Buncher*. **Cerne**, Lavras, MG, v.17, n.1, p. 9-15, 2011.

NICOLETTI, M. F. MACHADO, S. A.; CARVALHO, S. P. C.; FIGUEIREDO FILHO, A.; SANQUETTA, C. R. Descrição do perfil do fuste de árvores por meio das funções de afilamento. **Sci. Agrar. Parana.**, Marechal Cândido Rondon, v. 15, n. 4, p. 365-372, 2016.

OLIVEIRA, T. P.; BARBAR, J. S.; SOARES, A. S. Predição do tráfego de rede de computadores usando redes neurais tradicionais e de aprendizagem profunda. **RITA**, v. 22, n. 1, p.10-28, 2015.

ONUSIC, L. M.; CASA NOVA, S. P. C.; SILVA, A. C.; HUMES, L. L. Estudo exploratório utilizando as técnicas de análise por envoltória de dados e redes neurais artificiais na previsão de insolvência de empresas. **Facef Pesquisa**, v.9, n.2, p.125-136, 2006.

PARLAK, A.; ISLAMOGLU, Y.; YASAR, H.; EGRISOGUT, A. Application of artificial neural network to predict specific fuel consumption and exhaust temperature for a Diesel engine. **Applied Thermal Engineering**. v. 26, n. 8-9, p. 824-828, 2006.

PAULA, E. N. D. S. O. D. **Avaliação técnica, de custos e ambiental de dois modelos de harvester na colheita florestal**. 2011. 82 f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 2011.

PEREIRA, R. S. Inovações da colheita e transporte de madeira. **Revista Opiniões**, p. 41, Jun./Ago., 2010. Disponível em: < <http://revistaonline.revistaopinioes.com.br/revistas/flo/11/#page/40>>. Acesso em: 21 Mai. 2014.

PINHEIRO, J.C.; BATES, D.M. **Mixed-effects models in S and SPLUS**. Springer, New York, 2000. 537p.

PREFEITURA MUNICIPAL DE BELO ORIENTE. 2011. **Institucional**. Geografia. Disponível em:<<http://www.beloorientemg.gov.br/detalhada/materia/info/geografia/6512>>. Acesso em: 31 abr. 2018.

RAHIMI-AJDADI, F.; ABBASPOUR-GILANDEH, Y. Artificial Neural Network and stepwise multiple range regression methods for prediction of tractor fuel consumption. **Measurement**, v. 44, p. 2104–2111, 2011.

RESENDE, M. D. V. Software SELEGEN - REML/BLUP. Colombo: **Embrapa Florestas**, 2002. 67p.

RIBEIRO, E. N. **Utilização de redes neurais artificiais e tecnologia FT-NIR para predição do número KAPPA em um processo KRAFT de cozimento de madeira em indústria de celulose**. 2007. 144 f. Dissertação (Mestrado em

Engenharia Industrial) – Centro Universitário do Leste de Minas Gerais, Coronel Fabriciano, 2007.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach**. 3 ed., Upper Saddle River, N.J.: Prentice Hall, 2010. 1132 p.

SANTOS, D. W. F. N.; FORASTIERE, P. R.; FURTADO JÚNIOR, M. R.; VALENTE, D. S. M.; FERNANDES, H. C. Parâmetros ergonômicos e operacionais de um conjunto trator escarificador em função da rotação do motor e pressão interna dos pneus. **Rev. Cienc. Agrar.**, v. 59, n. 4, p. 401-408, 2016.

SANTOS, L. N.; FERNANDES, H. C.; SILVA, R. M. F.; SILVA, M. L.; SOUZA, A. P. Avaliação de custos das atividades de derrubada e processamento da madeira realizada pelo trator florestal *harvester*. **Revista Árvore**, Viçosa, MG, v.41, n. 5, p. 1-9, 2017.

SEARLE, S. R. **Linear models for unbalanced data**. New York: John Wiley, 1987, 536 p.

SILVA, I. A. F. **Aplicações de redes neurais e neuro fuzzy em engenharia biomédica e agronomia**. 2014. 82f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia do Campus de Ilha Solteira, UNESP, Ilha Solteira, SP, 2014.

SILVA, A. A. V.; SILVA, I. A. F.; TEIXEIRA FILHO, M. C. M.; BUZETTI, S.; TEIXEIRA, M. C. M. Estimativa da produtividade de trigo em função da adubação nitrogenada utilizando modelagem neuro fuzzy. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, PB, v.18, n.2, p.180–187, 2014.

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

SILVA, E. N. D.; MACHADO, C. C.; MINETTE, L. J.; SOUZA, A. P. D.; FERNANDES, H. C.; SILVA, M. L. D.; JACOVINE, L. A. Avaliação técnica e econômica do corte mecanizado de *Pinus sp.* com *harvester*. **Revista Árvore**, Viçosa, MG, v. 34, n. 4, p. 745-753, 2010a.

SILVEIRA, G. L.; MACHADO, C. C.; SOUZA, A. P.; LEITE, H. G.; SANTOS, H. N.; FERNANDES, D. C. M. Avaliação de parâmetros de consumo de combustível do Tritrem no transporte de madeira. **Revista Árvore**, Viçosa, MG, v.28, n.1, p.99-106, 2004.

SIMÕES, D.; FENNER, P. T.; ESPERANCINI, M. S. T. Avaliação técnica e econômica da colheita de florestas de eucalipto com harvester. **Scientia Forestalis**, Piracicaba, SP, v. 38, n. 88, p. 611-618, 2010a.

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 b.

TODT, V.; RUBERT, C.; SILVA, J. D. S.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E. Classificador adaptativo para o reconhecimento de alvos em imagens CCD/CBERS. **Revista Brasileira de Cartografia**, v. 58, n. 3, p.293-305, 2006.

VERBEKE, G.;MOLENBERGHS, G. **Linear Mixed Models in Praticce: A SAS-Oriented Approach**. New York: Springer, 1997. 319 p.

VERLINDEN, B.; DUFLOU, J. R.; COLLIN, P.; CATTRYSSE, D. Cost estimation for sheet metal parts using multiple regression and artificial neural networks: A case study. **International Journal of Production Economics**, 111, p. 484-492, 2008.

VIEIRA, G. C.; FREITAS, L. C.; CERQUEIRA, P. H. A.; SILVA, E. F.; BRITO, G. S.; SOUZA, A. M. Custos Operacionais e de Produção na Atividade mecanizada de Corte Florestal. **Nativa**, Sinop, v.4, n. 5, p. 342-346, 2016.

WYZYKOWSKI, J.; CUSTÓDIO, A. A. P.; CUSTÓDIO, A. A. P.; GOMES, N. M.; MORAIS, A. R. Análise do diâmetro de copa do cafeeiro recepado utilizando um modelo não linear misto. **Rev. Bras. Biom.**, São Paulo, v.33, n.3, p.243-256, 2015.

WOOD, S. N. Fast stable restricted maximum likelihood and marginal likelihood estimation of semiparametric generalized linear models. **Journal of the Royal Statistical Society**, v. 73, n.1, p. 3-36, 2011.

ZUUR, A. F.; IENO, E. N.; WALKER, N. J.; SVELIEV, A. A.; SMITH G. M.
Mixed Effects Models and Extensions in Ecology with R. Statistics for
Biology and Health, 2009, 579 p.