



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

SAULO BOLDRINI GONÇALVES

**MODELAGEM MATEMÁTICA DA PRODUTIVIDADE DO CORTE
FLORESTAL MECANIZADO**

JERÔNIMO MONTEIRO - ES

2017

SAULO BOLDRINI GONÇALVES

**MODELAGEM MATEMÁTICA DA PRODUTIVIDADE DO CORTE
FLORESTAL MECANIZADO**

Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Doutor em Ciências Florestais na Área de Concentração Ciências Florestais.
Orientador: Prof. Dr. Nilton Cesar Fiedler
Coorientador: Prof^a. Dra. Mayra Luiza Marques da Silva.

JERÔNIMO MONTEIRO - ES

2017

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Setorial de Ciências Agrárias, Universidade Federal do Espírito Santo, ES, Brasil)
Bibliotecário: Felício Gomes Corteletti – CRB-6 ES-000646/O

G635m Gonçalves, Saulo Boldrini, 1989-
Modelagem matemática da produtividade do corte florestal
mecanizado / Saulo Boldrini Gonçalves. – 2017.
62 f. : il.

Orientador: Nilton Cesar Fiedler.

Coorientadores: Mayra Luiza Marques da Silva.

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

1. Máquinas florestais. 2. Florestas – Inovações tecnológicas. 3.
Projetos de desenvolvimento florestais. 4. Produtividade florestal. I.
Fiedler, Nilton Cesar. II. Silva, Mayra Luiza Marques da. III.
Universidade Federal do Espírito Santo. Centro de Ciências Agrárias e
Engenharias. V. Título.

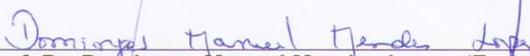
CDU: 630

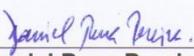
**MODELAGEM MATEMÁTICA DA PRODUTIVIDADE DO CORTE FLORESTAL
MECANIZADO**

Saulo Boldrini Gonçalves

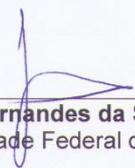
Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias e Engenharias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Doutor em Ciências Florestais na Área de Concentração Ciências Florestais.

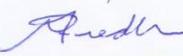
Aprovada em 27 de Setembro de 2017.


Prof. Dr. Domingos Manuel Mendes Lopes (Examinador externo)
Universidade de Trás-os-Montes e Alto Douro


Prof. Dr. Daniel Pena Pereira (Examinador externo)
Instituto Federal do Triângulo Mineiro


Prof. Dr. Luciano José Minette (Examinador interno)
Universidade Federal de Viçosa


Prof. Dr. Gilson Fernandes da Silva (Examinador interno)
Universidade Federal do Espírito Santo


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

DEDICO

A Deus, que está sempre comigo e guiando me pelo caminho da vida.

Ao meu pai José (Zequinha), a minha mãe Lucineia (Léia).

Aos meus irmãos Norton e Arthur.

Aristóteles dizia: "onde os seus talentos e as necessidades do mundo se cruzam, aí está a sua vocação (propósito)"

"Quem caminha por gosto, não se cansa"

"Nesta vida não há prêmios nem castigos, só há consequências" (provérbio chinês)

"A vida são momentos"

AGRADECIMENTOS

À Universidade Federal do Espírito Santo, em especial ao programa de Pós-Graduação em Ciências Florestais pela oportunidade de desenvolver este trabalho.

Ao professor Nilton Cesar Fiedler pelos ensinamentos, dedicação e orientação durante a realização da pesquisa e ao longo de minha formação acadêmica.

À professora Mayra Luiza Marques da Silva, pelo aceite em me coorientar e suporte no desenvolvimento do trabalho, os quais foram fundamentais para conclusão do mesmo.

Aos professores Daniel Pena Pereira, Gilson Fernandes da Silva e Luciano José Minette pela prontidão em participar da banca e pelas sugestões que muito acrescentaram a esta tese.

À Fibria na pessoa do Ângelo Conrado de A. Moura, Leonardo Cassani Lacerda e Wesley de Souza Terra por terem fornecido os dados e pela prontidão em esclarecer as dúvidas.

Ao Daniel Binoti pelo fomento da ideia do projeto

Aos colegas Evandro Ferreira da Silva, Jeferson Martins e Giovani Correia Vieira pelo apoio no processamento dos dados, os mesmos foram essenciais na realização deste trabalho.

Ao professor Domingos Manuel Mendes Lopes incentivo, dedicação e ensinamentos durante o período de doutorado sanduiche na UTAD.

À Fundação de Amparo à Pesquisa do Espírito Santo (FAPES) pela concessão da bolsa de doutorado que foi de suma importância para realização da pesquisa.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de doutorado sanduiche no exterior.

Aos meus pais, Zequinha e Leila, pelo amor incondicional, pelo cuidado mesmo a distância, por serem meus exemplos de vida. Aos meus irmãos, Norton e Arthur, pelo carinho e amizade.

Aos amigos de república, laboratório, do Programa de Pós-Graduação em Ciências Florestais e da cidade de Jerônimo Monteiro pela convivência e bons momentos durante toda essa etapa.

BIOGRAFIA

Saulo Boldrini Gonçalves, filho de José Ferreira Gonçalves e Lucineia Mulinari Boldrini Gonçalves, brasileiro, nascido em 20 de maio de 1989 na cidade de Vitória-ES.

Concluiu o ensino médio no Colégio Marista de Colatina no Espírito Santo em 2006.

Ingressou no curso de Engenharia Florestal na Universidade Federal do Espírito Santo (UFES) em agosto de 2007, concluindo o curso de graduação em dezembro de 2011.

Em março de 2012 iniciou o mestrado em Ciências Florestais na Universidade Estadual do Centro-Oeste (UNICENTRO), defendendo sua dissertação em fevereiro de 2014.

Durante o período do mestrado, em maio de 2012, iniciou uma Pós-graduação em Engenharia de Segurança do Trabalho na Universidade Tecnológica Federal do Paraná (UTFPR), defendendo seu trabalho de conclusão de curso em setembro de 2013.

Em março de 2014 iniciou o doutorado no Programa de Pós-graduação em Ciências Florestais da UFES, defendendo sua tese em setembro de 2017.

RESUMO

GONÇALVES, Saulo Boldrini. **Modelagem matemática da produtividade do corte florestal mecanizado**. 2017. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES. Orientador: Prof. Dr. Nilton Cesar Fiedler. Coorientador: Prof^a. Dra. Mayra Luiza Marques da Silva.

A produtividade das operações de colheita de madeira é uma das principais variáveis de viabilidade do empreendimento florestal, sendo, diretamente influenciada pelas características do terreno, do povoamento e do planejamento operacional. As variáveis que podem afetar a produtividade das máquinas de colheita, na maioria das vezes, são passíveis de identificação indiretas, difícil mensuração e apresentam relações complexas, dificultando a predição da produtividade das operações. Este estudo teve como objetivo gerar um modelo por meio de redes neurais artificiais (RNA) e regressão linear para estimar a produtividade do *harvester* em função das variáveis do terreno, do povoamento e do planejamento operacional. Para tanto, foi utilizada uma base de dados, de uma empresa florestal, contendo informações das operações de corte florestal mecanizado com *harvester*. As variáveis de entrada da RNA para a modelagem da produtividade do *harvester* foram (volume médio individual das árvores, volume de madeira do talhão, idade de corte, espaçamento, experiência do operador e regime de manejo). Os dados foram divididos aleatoriamente para serem utilizados no treinamento da rede (70%) e na generalização (30%). Realizou-se também o treinamento das redes com as combinações das variáveis de entrada, a fim de verificar a influência de cada variável na produtividade do *harvester*. A análise de regressão linear utilizou apenas as variáveis que apresentaram correlação linear significativa com a produtividade, segundo matriz de coeficiente de correlação de Pearson, pelo teste t a 5% e 1% de probabilidade. Ambas as técnicas de modelagem foram avaliadas por meio de estatísticas e análise gráfica dos resíduos. As redes neurais artificiais selecionadas no treinamento e na validação para a estimativa da produtividade do *harvester*, apresentaram valores de coeficiente de correlação acima de 0,89 e menores que 11,91, indicando forte correlação e alta exatidão entre as estimativas e os valores observados. A combinação das variáveis de entrada da rede que apresentou o melhor resultado foi a que utilizou todas as seis variáveis avaliadas no estudo. A regressão linear múltipla com todas as variáveis de correlação significativa foi a que teve o melhor ajuste para a produtividade do *harvester*, coeficiente de

correlação 0,83 e RMSE% 14,5. Dentre as variáveis avaliadas no modelo, a que mais explica a produtividade estimada pela regressão linear é o volume médio individual. Ambas as técnicas de modelagem foram eficientes na predição da produtividade do *harvester* no corte florestal mecanizado, mas a RNA apresentou estimativas mais precisas e pode ser indicada em substituição ao modelo tradicional de regressão linear múltipla.

Palavras-chave: Técnicas e operações florestais, Mecanização florestal, planejamento florestal, produtividade de máquinas.

ABSTRACT

GONÇALVES, Saulo Boldrini. **Mathematical modeling of mechanized forestry cutting productivity.** 2017. Thesis (Doctor in Forest Sciences) – Federal University of Espírito Santo, Jerônimo Monteiro, ES. Advisor: Prof. Dr. Nilton Cesar Fiedler. Co-advisor: Prof^a. Dra. Mayra Luiza Marques da Silva.

The productivity of the wood harvesting operations is one of the main viability variables of the forest enterprise, being directly influenced by the characteristics of the land, the stand and the operational planning. The variables that can affect the productivity of harvesting machines are, for the most part, indirectly identifiable, difficult to measure, and present complex relationships, making it difficult to predict the productivity of operations. The objective of this study was to generate a model through artificial neural networks (RNA) and linear regression to estimate harvester productivity as a function of terrain, settling and operational planning variables. For this purpose, a database was used, from a forest company, containing information on mechanized forestry cutting operations with harvester. RNA input variables for modeling harvester productivity were (individual mean volume of trees, timber volume, cutting age, spacing, operator experience and management regime). Data were randomly divided to be used the network training (70%) and generalization (30%) were used. The networks training was also performed with combinations of the input variables, in order to verify the influence of each variable on harvester productivity. Using only the variables that showed a significant linear correlation with the productivity, according to Pearson correlation coefficient matrix, by the test t_{α} 5% and 1% of probability. Both modeling techniques were evaluated by means of statistics and graphical analysis of the residues. The artificial neural networks selected in the training and validation for estimating harvester productivity presented correlation coefficient values above 0.89 and less than 11.91, indicating strong correlation and high accuracy between the estimates and the observed values. The combination of the input variables of the network that presented the best result was the one that used all six variables evaluated in the study. The multiple linear regression with all variables of significant correlation was the one that had the best fit for harvester productivity, correlation coefficient 0.83 and RMSE% 14.5. Among the variables evaluated in the model, the one that explains the productivity estimated by the linear regression is the individual mean volume. Both modeling techniques were efficient in predicting harvester productivity in mechanized

forest cutting, but RNA presented more accurate estimates and could be indicated instead of the traditional multiple linear regression model.

Keywords: Forestry techniques and operations, forest mechanization, forestry planning, machine productivity.

SUMÁRIO

1. INTRODUÇÃO	15
1.1. OBJETIVOS	18
1.1.1. Objetivo geral.....	18
1.1.2. Objetivos específicos	18
2. REVISÃO DE LITERATURA	19
2.1. Setor florestal brasileiro	19
2.2. Colheita florestal.....	19
2.2.1. Mecanização da colheita florestal	20
2.3. Corte florestal mecanizado.....	21
2.3.1. Fatores que influenciam a produtividade das máquinas de corte florestal	21
2.4. Planejamento.....	25
2.4.1. Planejamento da colheita florestal.....	27
2.4.2. Planejamento estratégico	28
2.4.3. Planejamento gerencial.....	28
2.4.4. Planejamento operacional.....	29
2.5 Redes neurais artificiais	30
2.6 Modelo de regressão linear	33
2.6.1 Modelo de regressão linear simples.....	33
2.6.2 Modelo de regressão linear múltipla.....	34
3. MATERIAL E MÉTODOS	36
3.1. Descrição dos dados	36
3.2. Sistema de colheita	37
3.3. Descrição dos fatores que influenciam no corte com <i>harvester</i>	38
3.3.1. Volume médio individual (VMI).....	38
3.3.2. Volume de madeira do talhão	39
3.3.3. Idade de corte	40
3.3.4. Espaçamento	40
3.3.5. Experiência do operador	40
3.3.6. Regime de manejo	41
3.4. Modelagem com Redes Neurais Artificiais (RNA)	41
3.4.1. Treinamento e generalização das redes neurais artificiais	41
3.5. Influência das variáveis de entrada	42
3.6. Modelagem com regressão linear	42
3.7. Avaliação das estimativas	43
4. RESULTADOS E DISCUSSÃO.....	45

4.1. Modelagem da produtividade do corte florestal por meio de RNA.	45
4.2. Combinações de variáveis de entrada na estimação da produtividade do <i>harvester</i>	49
4.2. Modelagem da produtividade do corte florestal por meio de regressão linear	52
5. CONCLUSÕES	57
6. REFERÊNCIAS BIBLIOGRÁFICAS	58

1. INTRODUÇÃO

No setor florestal, a colheita da madeira em florestas plantadas é definida como um conjunto de operações realizadas no povoamento florestal, que visa preparar e transportar a madeira até o pátio da indústria. Para Duarte (1994), a colheita é a etapa mais importante do ponto de vista econômico, devido a sua participação no custo final do produto e aos riscos de perda envolvidos. Tal atividade compreende duas operações: corte e extração. O corte consiste no abate e processamento da madeira dentro do povoamento, tem grande influência nas operações subsequentes (extração) e pode ser realizado de forma manual, semimecanizada e mecanizada (MACHADO, 2014).

A forma de corte mecanizada, com uso de tratores florestais é a mais utilizada pelas empresas do setor, pois, a alta demanda por produtos florestais, juntamente com a necessidade de maiores rendimentos nas operações, baixa disponibilidade de mão de obra, alto custos sociais, necessidade de executar o trabalho de forma mais ergonômica e com maior eficiência, fizeram com que as empresas aderissem a mecanização no setor florestal, a fim de garantir o abastecimento contínuo das fábricas, com qualidade e segurança (BURLA, 2008).

Para Malinovski et al. (2006), a produtividade das operações de colheita de madeira é uma das principais variáveis de viabilidade de retirada de madeira dos projetos florestais, sendo, normalmente, inversamente proporcional ao custo por m³ produzido e diretamente influenciada pelas variáveis do terreno, do povoamento e do planejamento.

De acordo com os autores, as principais variáveis que influenciam nas operações de colheita de madeira, são: topografia, características do povoamento (espécie, diâmetro médio individual, diâmetro de galhos, volume individual por árvore, volume por hectare, espaçamento, manejo aplicado, tipos de sortimentos, densidade e qualidade da malha viária, distância média de extração, tipo de solo e umidade, época do ano, pluviosidade, planejamento das operações, e qualidade das operações.

As variáveis que podem afetar a produtividade das máquinas são definidas como as passíveis de identificação imediata e direta e as indiretas (WADOUSKI, 1987). Essas variáveis na maioria das vezes, apresentam relações complexas, dificultando a modelagem da produtividade das operações.

Embora, as variáveis que afetam a produtividade das máquinas de colheita sejam conhecidas, muitas são de identificação indireta e de difícil mensuração

(qualitativas). Esses fatores dificultam modelagem da produtividade das máquinas e a construção da curva de produtividade em função das variáveis que afetam a atividade.

Neste contexto, ferramentas de inteligência artificial e modelagem matemática, como Redes Neurais Artificiais (RNA) e modelos de regressão, apresentam-se como técnicas apropriadas para serem utilizadas nessas situações, onde é necessário saber a influência das variáveis (qualitativas e quantitativas) na predição da produtividade das máquinas e a correlação de cada variável no modelo.

As RNA compõem um dos ramos da ciência da computação denominado inteligência artificial, que procura desenvolver modelos computacionais inspirados na capacidade natural do cérebro humano de pensar; apresentam ótimos resultados na solução de problemas complexos envolvendo muitas variáveis, por isso, atualmente, as RNA são aplicadas nas mais diversas áreas, como florestal, biologia, medicina, meio ambiente, indústria, engenharia, entre outras. Na área florestal, diversos estudos comprovam a eficiência da aplicação de RNA (GORDON, 1998; DIAMANTOPOULOU, 2005; BINOTI et al., 2009; GÖRGENS et al., 2009; BINOTI, 2010; LEITE et al., 2011; BINOTI, 2012).

A análise de regressão é uma das ferramentas mais utilizadas para análise de dados, sendo aplicada em quase todas as áreas de conhecimento, engenharia, física, química, ciências biológicas. O modelo de regressão é uma técnica estatística para modelar e investigar a relação entre variáveis. A simplicidade e utilidade dessa técnica são resultantes do conceito lógico de utilizar uma equação matemática para expressar a relação entre variáveis, sendo interessante devido à base matemática e bem desenvolvida teoria estatística (MONTGOMERY et al., 2001).

As pesquisas relacionadas às variáveis que influenciam a produtividade das operações florestais tornaram-se imprescindíveis, visando a minimização dos custos e otimização dos recursos disponíveis, bem como um eficiente planejamento operacional (SIMÕES; FENNER, 2010). Para Minette et al. (2008), estudar detalhadamente e identificar estas variáveis possibilitam estimar a produtividade, que podem auxiliar no planejamento do processo de produção.

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.

1.1. OBJETIVOS

1.1.1. Objetivo geral

Objetivo geral deste trabalho foi realizar a modelagem matemática da produtividade do corte florestal mecanizado utilizando redes neurais artificiais, e regressão linear.

1.1.2. Objetivos específicos

- Aplicar uma RNA capaz de realizar a modelagem da produtividade da máquina de corte florestal em função de variáveis relacionadas às características do terreno, do povoamento e do planejamento operacional;
- Identificar entre as variáveis utilizadas nos modelos de RNA quais apresentaram maior peso na estimação da produtividade da máquina de corte florestal.
- Realizar a modelagem da produtividade da máquina de corte florestal por meio do modelo de regressão linear
- Comparar a eficiência de cada modelo na predição da produtividade da máquina de corte florestal;

2. REVISÃO DE LITERATURA

2.1. Setor florestal brasileiro

Até o final da década de 60, a exploração florestal no Brasil era quase que exclusivamente de florestas nativas. A implantação de florestas de rápido crescimento deu novo impulso ao setor florestal brasileiro, com a criação da política governamental de incentivo fiscal (MACHADO, 2014).

Atualmente, com uma área de 7,84 milhões de hectares de reflorestamento, o setor brasileiro de árvores plantadas é responsável por 91% de toda a madeira produzida para fins industriais. Desse total os plantios de eucalipto ocupam 5,7 milhões de hectares. O Produto Interno Bruto do setor alcançou R\$ 71,1 bilhões, sendo responsável pela geração de R\$ 11,4 bilhões em tributos e geração de 510 mil empregos diretos (INDUSTRIA BRASILEIRA DE ÁRVORES – IBÁ, 2017).

Para Oliveira (2013), o setor florestal se destaca como importante e relevante para a economia e a sociedade brasileira, contribuindo com uma parcela importante para a geração de produtos, tributos, divisas, empregos e renda, além de ser um setor estratégico no fornecimento de matéria-prima para o desenvolvimento da indústria de base florestal.

O destaque do setor florestal no desenvolvimento socioeconômico do Brasil foi resultante de uma série de eventos marcantes, tais como os incentivos fiscais para reflorestamento, grandes avanços tecnológicos na silvicultura e na mecanização das operações florestais (SHIMIZU, 1995; MENDES, 2010).

2.2. Colheita florestal

A colheita florestal é definida como um conjunto de operações realizadas no maciço florestal, tendo em vista a preparação e o transporte da madeira até o pátio da indústria, por meio de técnicas e medidas pré-estabelecidas, com o objetivo de transformá-la em produto final (TANAKA, 1986). Dentre as atividades do setor florestal, a colheita e transporte florestal é a etapa mais importante do ponto de vista econômico, representando de 50% do custo final da madeira posto-fábrica (MACHADO, 2014).

Para Arce et al. (2004), a colheita florestal representa a operação final de um ciclo de produção, em que são obtidos os produtos mais valiosos, constituindo um dos

fatores que determinam a rentabilidade do negócio. É uma atividade complexa, dada ocorrência de vários fenômenos climáticos, biológicos e relacionados a relação homem com as máquinas que podem afetar a produtividade das operações e, conseqüentemente, os custos e a produção.

As atividades da colheita podem ser divididas em três fases: corte (incluindo a derrubada, o desgalhamento e o processamento), extração (que corresponde à colocação da madeira em um local de fácil acesso) e transporte para o local de utilização, sendo que o desafio dos técnicos florestais é otimizar todas as operações envolvidas, uma vez que diversas máquinas, equipamentos, métodos e sistemas são utilizados.

2.2.1. Mecanização da colheita florestal

A colheita florestal teve um processo evolutivo lento e rudimentar, definido por métodos manuais e uso de força animal. Até a década de 1940, praticamente não se utilizavam máquinas na colheita florestal. A modernização do sistema se deu somente no início na década de 1970, com a produção de maquinários de porte leve e médio como motosserras e os tratores agrícolas equipados com implementos florestais (MACHADO, 2014).

Entre as décadas de 70 e 80, o setor teve um crescimento significativo devido ao programa de incentivos fiscais, intensificando o plantio de florestas homogêneas, que visavam reduzir o desmatamento promovendo o uso de madeira derivada de reflorestamentos (SILVA et al., 2012). Em 1980, surgiram as máquinas específicas para a colheita florestal. No entanto, somente após 1994 com a abertura das importações juntamente com a carência e o aumento do custo de mão de obra, houve a intensificação da mecanização da colheita florestal (PEREIRA, 2011).

As máquinas disponíveis no mercado para realização das diversas operações de colheita florestal são para derrubada de árvores: a motosserra, o *feller-buncher*, e o *harvester*. No processamento, utilizam-se a motosserra, o *harvester*, a garra traçadora e o *Slasher*. O descascamento, quando executado no campo, é realizado por descascadores móveis, *harvester* ou processador. Na atividade de extração são utilizados os tratores agrícolas adaptados sejam com caçambas ou por guinchos, *forwarders*, caminhões, *skidders* e cabos aéreos. E no carregamento e descarregamento dos veículos de transporte usam-se os carregadores com guas

hidráulicas, ou ainda no caso do carregamento visando à extração utiliza-se o próprio forwarder (MACHADO, 2014).

2.3. Corte florestal mecanizado

O corte é a separação da árvore da cepa a partir do seu local de crescimento. É a primeira etapa da colheita de madeira tendo grande influência na realização das operações subsequentes. O mesmo compreende as operações de derrubada, desgalhamento, medição, traçamento e pré extração. As atividades devem ser planejadas com bastante antecedência em relação a sua execução e considerar a minimização dos custos, a otimização dos rendimentos e a redução dos impactos ambientais (SANT'ANNA, 2014).

Segundo os mesmos autores a evolução das tecnologias de produção florestal e os maiores investimentos no setor possibilitaram a mecanização total das atividades de corte. As principais máquinas utilizadas no corte mecanizado são o *harvester* e o *feller buncher*.

O *harvester* é uma máquina base de pneus ou esteiras, autopropelida, constituída por um conjunto motriz de alta mobilidade dentro da floresta e boa estabilidade, um braço hidráulico e um cabeçote processador (AMABILINI,1991).

O trator florestal colhedor (*harvester*), possui a capacidade de efetuar o processamento da madeira ainda no local de abate (LIMA; LEITE, 2014). No processamento realiza, simultaneamente, as operações de derrubada, desgalhamento, traçamento, destopamento, descascamento (opcional) e pré-extração (enleiramento ou empilhamento) da madeira (MALINOVSKI; MALINOVSKI, 1998).

O *harvester* é considerado um dos tratores florestais mais moderno, por possuir um cabeçote que realiza várias funções e opera em condições adversas, elevando a sua aceitação. Diversos parâmetros podem influenciar a produtividade dos *harvesters*, como o volume médio das árvores, declividade da área, comprimento de seccionamento das toras e eficiência do operador (BURLA, 2008).

2.3.1. Fatores que influenciam a produtividade das máquinas de corte florestal

A produtividade das operações de colheita florestal é uma das principais variáveis de viabilidade de retirada de madeira dos projetos florestais, sendo,

normalmente, inversamente proporcional ao custo por m³ produzido e diretamente influenciada pelas variáveis do terreno, do povoamento e do planejamento feito pelos técnicos e exigidos pelas fontes consumidoras (MALINOVSKI et al., 2006).

Wadouski (1987) distingue as variáveis que podem afetar a produtividade das máquinas: as passíveis de identificação imediata e direta e as indiretas. Como de identificação direta, podem-se citar: os volumes a serem extraídos, a extensão da área a explorar, as características dos fustes, a porcentagem e diâmetro dos galhos, a topografia, a malha viária, a distância média de arraste, a intensidade e distribuição das chuvas e a necessidades de sortimentos diversos. Por outro lado, muitas outras variáveis são de difícil determinação (indiretas), e a intensidade com que irão afetar os trabalhos deve ser cuidadosamente estimada. Assim, o grau de erodibilidade dos solos, a qualidade e disponibilidade de mão-de-obra, as necessidades impostas pelo manejo florestal, os riscos de compactação dos solos e a possibilidade de bruscas variações climáticas impõem limitações, mais ou menos severas, à aplicação dos sistemas de colheita de madeira, em função da conjunção positiva ou negativa.

2.3.1.1. Volume individual das árvores

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

Para Akay et al. (2004) a produtividade das máquinas está muito relacionada ao tamanho da árvore, sendo que conforme aumenta o volume da árvore, aumenta-se a produtividade, porém, desde que o tempo de processamento seja o mesmo. Isso foi comprovado por Moreira (2000), que analisou diversos sistemas de colheita de madeira e verificou uma tendência de aumento na produtividade das máquinas com o aumento do volume médio das árvores.

Burla (2008) afirma que o volume médio individual é o principal fator de influência na produtividade de um *harvester*. Bramucci e Seixas (2002) também determinaram ser o volume médio das árvores a variável que melhor explicou, isoladamente, as produtividades alcançadas pelos *harvesters*.

2.3.1.2. Volume de madeira do talhão

O volume de madeira do talhão está fortemente relacionado ao aumento do volume individual das árvores. Assim, é natural que seja encontrado influência dessa variável sobre a produtividade dos *harvesters* (BRAMUCCI; SEIXAS, 2002).

Os mesmos autores, ao estudarem a produtividade do *harvester*, verificaram que as curvas de regressão da produtividade e volume de madeira são semelhantes às curvas da produtividade em relação ao volume individual por árvore.

2.3.1.3. Idade de corte

A idade é a quantidade de meses em que as árvores se encontram antes da colheita. O aumento da idade possui uma relação natural com o aumento do volume individual das árvores, uma vez que o volume individual é apontado como a variável que mais afeta a produtividade das máquinas de colheita. Assim, pode se afirmar que a idade influencia na produtividade das mesmas (BRAMUCCI; SEIXAS, 2002).

Bramucci (2001), analisou as principais variáveis técnicas que interferem na produtividade do corte e processamento de madeira por meio de “harvester” verificou técnicas que interferem na produtividade do corte e processamento de madeira por meio de “harvester” verificou um aumento da produtividade dos “ da máquina com o aumento da idade de corte. Esse aumento foi bastante evidente na faixa entre 72 e 120 meses.

2.3.1.4. Espaçamento

O espaçamento influencia a produtividade das máquinas de colheita, principalmente na operação de corte, na qual elas têm de se deslocar entre uma árvore e outra. Quanto maior for a distância entre as árvores, maior será o tempo para o deslocamento e, conseqüentemente, menor a produtividade (MALINOVSKI et al., 2006).

Rezende et al. (1983) estudando o espaçamento ótimo de eucalipto para produção de madeira com fins energéticos, afirmam que o custo de colheita pode chegar até 50% dos custos totais num espaçamento menor, em comparação com as plantações de maior espaçamento. Esta pesquisa foi feita com *Eucalyptus* ssp. Com três espaçamentos de 2, 3 e 6 m² por planta, resultando que, os espaçamentos

menores, tendem a ser mais econômicos para a produção de fitomassa para fins energéticos, mas, os custos de colheita crescem com a diminuição do espaçamento entre as plantas.

2.3.1.5. Experiência do operador

A produtividade de trabalho das máquinas depende diretamente da habilidade do operador, além de não permanecer constante ao longo do tempo (PURFÜRST; ERLER, 2011).

Richardson e Makkonen (1994), afirmam que quanto maior o tempo de experiência do operador, maior a produtividade atingida, alcançando incremento de 45% após dois anos de experiência. Corroborando com autores Bramucci (2001) verificou em seu estudo uma tendência no aumento de produtividade das máquinas de colheita com o aumento de horas em operação.

Malinovski et al. (2006) afirmam que o desempenho do operador está relacionado com o tempo de experiência e produtividade média dos operadores. O desempenho médio dos operadores é de extrema influência na produtividade das máquinas de colheita florestal, afetando todas as máquinas com intensidades diferentes, conforme for o nível de desenvolvimento tecnológico de cada uma.

Leonello et al. (2012) avaliaram o desempenho de operadores de *harvester* em função do tempo de experiência na atividade. Em relação ao rendimento do volume de madeira colhido, verificaram que houve um aumento expressivo nos primeiros 18 meses, mantendo-se constante até os 26 meses, e uma tendência à redução após os 44 meses, devido a acomodação do cotidiano.

2.3.1.6. Regime de manejo

A perpetuação dos povoamentos florestais de eucalipto pode ser feita por meio de três regimes: alto fuste e talhadia (RIBEIRO et al., 2002).

O regime de alto fuste prioriza a produção de madeira de menores diâmetros, sendo usado para maximizar a produção por unidade de área. É o manejo utilizado para obtenção de matéria prima nas grandes empresas para produção de celulose, painéis de madeira reconstituída, carvão e energia. Sua característica é de não promover intervenções de desbaste ou desrama na floresta até o corte final (corte

raso), variando com a qualidade do sítio e a espécie: eucalipto em torno de 7 anos e pinus em torno de 14 anos (SCOLFORO e MAESTRI, 1998).

O sistema de alto fuste também é conhecido como implantação ou reforma. A implantação é o plantio na área ocupada por outra cultura. Já a reforma é realizada após o corte raso da floresta, quando é feito o replantio da área (reforma) que normalmente é realizado com a troca de material genético na entrelinha do plantio antigo (IPEF, 2008). Segundo Klein et al (1997), o fator que mais fortemente conduz à decisão de reformar a floresta é a produtividade. Por sua vez a produtividade está condicionada ao potencial genético da floresta e sobretudo pela sobrevivência das cepas após o corte.

O regime de talhadia é a condução do crescimento dos brotos nas cepas da floresta recém cortada, dando-se início a um novo ciclo florestal, sendo somente aplicável às espécies florestais que tenham capacidade de brotar após o seu corte. A utilização deste sistema justifica-se por proporcionar menores custos na produção madeireira, produção de madeira de menores dimensões, dispensa de preparo de solo e aquisição de mudas, e ciclos de cortes mais curtos com antecipação de retornos financeiros mais rápidos (LAMPRECHT, 1990; EVANS, 1992).

A adoção do sistema de talhadia pelas empresas florestais tem sido deixado de lado em função da grande oscilação da produção em segunda rotação Simões (1981), que em geral tem se mostrado menor, devido ao aumento do número de falhas, comprometendo o planejamento de abastecimento da fábrica. Ainda sim, a evolução do melhoramento genético permitiu a substituição de materiais menos produtivos por material melhorado, mais produtivo, e melhor adaptado às condições do sítio.

Malinovski e Camargo (2001), citam o tipo de rebrota na área como uma variável mensurável que pode interferir na produtividade das máquinas.

2.4. Planejamento

O planejamento tem um papel decisivo no processo de gerência, uma vez que os planos são as bases por meio das quais as organizações obtêm e aplicam recursos para alcançar seus objetivos, permitindo medir e monitorar o alcance dos objetivos e adotar medidas corretivas, quando necessário (STOONER e FREEMAN, 1985).

Neste sentido, MEGGINSON et al. (1986) ampliaram as funções do planejamento ao relatarem que planejar refere-se a escolher um curso de ação e

decidir antecipadamente o que deve ser feito, em que seqüência, quando e como, proporcionando bases para ações administrativas efetivas. Segundo esses autores, o planejamento é importante para: i) ajudar a administração face às mudanças do ambiente; ii) permitir que os administradores vejam o quadro operativo interno com maior clareza; iii) ajudar no estabelecimento de responsabilidade; iv) proporcionar ordem às operações e coordenação entre as várias partes da organização; v) fazer com que os objetivos sejam mais específicos e bem conhecidos; vi) minimizar a adivinhação; e poupar tempo, esforço e dinheiro.

O planejamento envolve o levantamento e avaliação da situação atual e sua comparação com a situação desejada. A partir desta comparação são traçadas as estratégias para a execução das atividades, visando alcançar esta situação desejada em um determinado período do tempo. A partir do planejamento, as diferentes atividades dentro de uma empresa são ordenadas e organizadas, dentro de certo espaço de tempo, visando atingir a meta econômica (SCHNEIDER, 2009).

Para atender os objetivos do planejamento é necessário que o gerente realize um processo contínuo de tomada de decisão (atividade inerente ao planejamento), que exige bons julgamentos, experiência, análise quantitativa, criatividade, suposições e conhecimento do ambiente envolvido (STOONER e FREEMAN, 1985).

O processo de tomada de decisão é constituído por quatro fases: inteligência, projeto, escolha e implementação. Esse processo inicia-se com o exame da realidade, onde um possível problema pode ser identificado e definido (fase inteligente). Um problema surge quando um indivíduo não está satisfeito com a realidade presente ou prevista e sua identificação ocorre quando se busca modificar a realidade e alcançar a situação futura desejada (TURBAN e ARONSON, 1998).

Uma vez identificado e definido um problema, é necessário escolher ou construir um modelo que o represente. Esta é a fase de projeto, na qual o modelo, construído através de simplificações e suposições, é utilizado gerando subsídios para tomada de decisão. O modelo mais apropriado para um dado problema depende da natureza matemática das relações entre as variáveis envolvidas, dos objetivos, da extensão e do controle sobre as variáveis e do nível de incerteza associado (ANDRADE, 1990). A fase de projeto termina com a validação e verificação do modelo, podendo levar a necessidade de coleta de novos dados e redefinição do problema (TURBAN e ARONSON, 1998).

O próximo passo é a escolha de uma ou mais alternativas geradas na fase de projeto, ou seja, a fase de escolha, onde são adotadas ferramentas de suporte à

decisão, por exemplo, modelos de pesquisa operacional e matemática financeira (RODRIGUES, 2001).

Após teste de adequação da solução do modelo tem-se a última etapa do processo (fase de implementação da solução) que culmina com a verdadeira solução do problema (TURBAN e ARONSON, 1998).

2.4.1. Planejamento da colheita florestal

A colheita de madeira é uma atividade de grande importância no setor florestal, dada a sua elevada participação no custo final do produto. Em virtude da existência e interação de inúmeros fatores técnicos, econômicos, ambientais e ergonômicos que interferem de forma dinâmica nas operações, o planejamento florestal torna-se essencial com vistas à organização, racionalização e otimização das operações (MACHADO; LOPES, 2014).

As máquinas de colheita florestal, apesar de sofisticadas e produtivas, estão expostas à diversas variáveis ambientais que podem restringir seu uso. Por isso, é importante ter um conhecimento detalhado para um planejamento adequado das operações (LEITE, 2012).

Entre os fatores técnicos podem-se citar: as características da floresta, terreno, finalidade da madeira, rendimento das máquinas, demanda de madeira. Dentre os econômicos: recursos financeiros, custos operacionais das máquinas, manutenção mecânica. Ambientais: capacidade de suporte do solo, condições climáticas e sistemas de colheita. Por fim os ergonômicos: ruído, vibração, temperatura e luminosidade do ambiente de trabalho, características ergonômicas das máquinas e treinamento (MACHADO; LOPES, 2014).

O uso de ferramentas computacionais é importante para auxiliar na tarefa de planejamento e redução dos custos na colheita florestal. O investimento elevado em máquinas de colheita sem um planejamento adequado da operação e sem a aplicação de ferramentas tecnológicas podem resultar em um aumento nos custos, visto que o preço por hora dessas máquinas é elevado (MALINOVSKI et al., 2008).

Em função dos níveis de abordagens e objetivos, o planejamento pode ser classificado em: estratégico, gerencial e operacional (TAVARES, 1991).

2.4.2. Planejamento estratégico

É voltado para a escolha dos objetivos da organização e a seleção de alternativas a serem consideradas para o cumprimento desses objetivos (MACHADO; LOPES, 2014).

O planejamento estratégico abrange toda a organização e tem características principais como: horizonte de planejamento de longo prazo, é definido pela cúpula da organização, correspondendo ao plano maior, ao qual todos os demais estão subordinados (TAVARES, 1991). Para Assumpção (1996), esse planejamento manipula os dados e gera informações, sem deixar de considerar sua interface com o mercado e de analisar alternativas de investimento para atingir seus objetivos de longo prazo.

Na colheita florestal, o planejamento estratégico consiste em planejar a colheita em um horizonte de longo prazo, 10 a 20 anos, no qual, em função dos dados dos povoamentos florestais e da demanda de madeira estabelecida pela indústria, são definidas as alternativas de manejo, os volumes de madeira e os talhões disponíveis para a colheita em cada ano do horizonte de planejamento, bem como a necessidade de compra de madeira do mercado (MACHADO; LOPES, 2014).

Segundo os mesmos autores, nesta etapa são confeccionadas planilhas de inventário das áreas florestais definido: o regime de manejo a ser adotado em cada talhão, selecionados os sistemas de colheita e elaborados os mapas com a localização dos projetos a serem colhidos. Normalmente são estudados vários cenários com base em critérios técnico-econômicos, garantindo a eficiência no processo de suprimento de madeira, as informações apoiarão posteriormente o planejamento gerencial e operacional. Nesses estudos, o uso das técnicas de pesquisa operacional pode auxiliar o planejador na tomada de decisões.

2.4.3. Planejamento gerencial

É executado em nível de departamento, sendo projetado para horizontes de médio prazo, geralmente anual (TAVARES, 1991). O planejamento gerencial é responsável em apoiar os planos estratégicos e traduzi-los em planos específicos para uma área distinta da organização (HARTZELL, 2015). Tem como objetivo programar colheitas em áreas específicas, em uma escala de tempo menor que o planejamento estratégico (ANDERSSON, 2005).

Após estabelecidas as disponibilidades e os programas de abastecimento de madeira para o ano subsequente, são distribuídas as cotas mensais, com a definição dos volumes e a localização dos talhões e da sequência da colheita; verificação no campo da situação atual das estradas; identificação das estradas a serem utilizadas; e definição dos maquinários e equipamentos. Esses procedimentos farão parte do planejamento gerencial, podendo este ser subdividido em macro e microplanejamento (MACHADO; LOPES, 2014).

O macroplanejamento consiste no planejamento em nível de projeto (fazendas e hortos), envolvem as operações que ocorrerão fora dos talhões. Contempla desde a operação de roçada pré-corte, caso necessário, até a entrega da madeira na indústria, atendendo às restrições ambientais e operacionais e servindo para:

- Dimensionar os recursos humanos e os maquinários;
- Identificar as condições topográficas da área de colheita;
- Definir a sequência e o posicionamento dos módulos de colheita;
- Definir as rotas de transporte, com seus pontos de carregamento, pátios e viradouros;
- Definir o posicionamento para localização da infraestrutura de apoio, como manutenção;
- Estabelecer melhorias necessária na malha viária e obras de arte, como cascalhamento de trechos de estradas e reformas de ponte; e
- Estabelecer programas de manutenção e apoio logístico.

O microplanejamento refere-se ao planejamento em nível de talhão, envolvendo todas as operações que ocorrerão dentro dele. Normalmente é realizado 30 dias antes do início da colheita com objetivo de:

- Definir a marcação e identificação dos eitos de corte;
- Estabelecer rotas de extração;
- Determinar a direção, sentido e distância média de extração;
- Identificar pontos restritos para a operação de colheita; e
- Delimitar áreas proibidas de corte.

2.4.4. Planejamento operacional

O planejamento operacional é mais detalhado, sendo executado para cada tarefa ou atividade, projetado para horizonte de planejamento de curto prazo e é destinado ao alcance das metas específicas (TAVARES, 1991).

Este planejamento retrata as operações que ocorrem semanalmente ou diariamente, e tem referência nas informações providas do planejamento estratégico e gerencial, como decisões de colheita das unidades selecionadas e o tipo de produto a gerar (MITCHELL, 2004).

Segundo Machado e Lopes (2014), no planejamento operacional devem-se identificar os seguintes fatores relevantes:

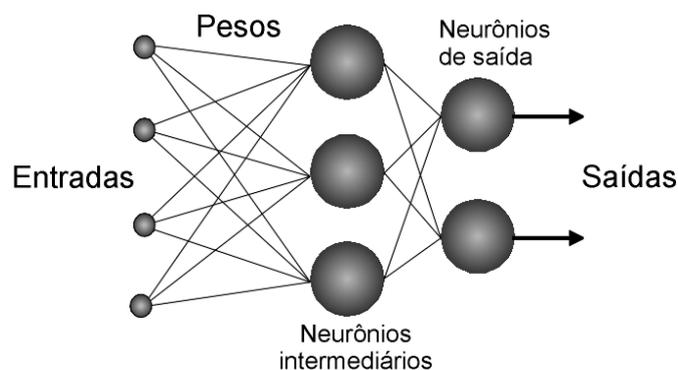
- Área total do projeto e individual de cada talhão;
- Volume de madeira a ser colhido;
- Características da floresta (espécie, volume, diâmetro);
- Topografia; e
- Disponibilidade de máquinas, equipamentos e mão de obra.

2.5. Redes neurais artificiais

Redes neurais artificiais (RNA) são redes de neurônios artificiais, ou seja, uma RNA é um sistema computacional paralelo constituído de várias unidades de processamento simples, conectadas entre si, de uma maneira específica para desempenhar uma determinada tarefa. As RNA se baseiam no funcionamento do cérebro humano; simulam, também, sua composição, similar aos neurônios biológicos (BULLINARIA, 2014).

Artero (2009), definiu as RNA como sistemas paralelos, com seus neurônios artificiais interligados e dispostos em várias camadas, formando um grande número de conexões. Em cada uma dessas está associado um peso sináptico, que é ajustado para transformar cada entrada recebida, produzindo os resultados desejados (Figura 1).

Figura 1. Exemplo de uma RNA.



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

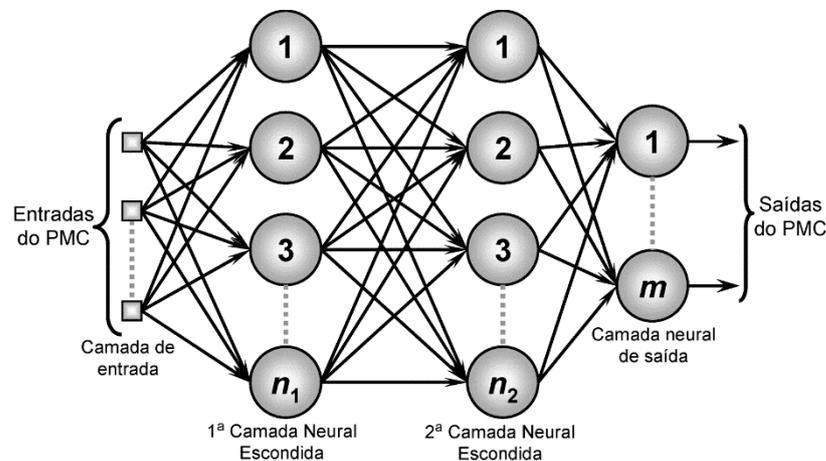
A forma pela qual os neurônios estão interconectados constitui a arquitetura da rede. Geralmente essa escolha se faz por meio do nível de complexidade do problema a ser analisado. Deve-se experimentar várias arquiteturas até se chegar a mais conveniente, pois não existe uma regra a ser seguida, as diversas arquiteturas têm que ser testadas e escolhidas a que melhor se comporta para cada problema.

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

As RNA tipo *Multilayer Perceptron* (MLP) são as mais empregadas atualmente, por serem muito versáteis e capazes de resolver problemas desde os mais simples até os mais complexos. Nas redes tipo MLP, camadas intermediárias são inseridas entre as camadas de entrada e de saída, em um número que pode ser ajustado em função da complexidade do problema e da precisão desejada. Porém, não existe uma arquitetura predefinida de acordo com a complexidade dos problemas. É necessário pesquisar a melhor alternativa, isto é, a melhor arquitetura da rede. A primeira camada de uma rede tipo MLP consiste de unidades de entrada, com as variáveis independentes (Figura 2). A última camada contém as unidades de saída, associadas às variáveis dependentes. Todas as outras unidades do modelo são denominadas unidades escondidas e constituem as camadas intermediárias (BRAGA, 2007).

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

Figura 2. Exemplo de uma RNA tipo Perceptron de multicamadas (MLP).



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

Escolhida a arquitetura de uma rede tipo MLP e dado o conjunto de entrada e de saída, procede-se ao seu treinamento, empregando o algoritmo de aprendizado, para estimar as relações funcionais entre as entradas e as saídas. A rede neural pode ser empregada, então, para modelar ou prever a respostas correspondente a um novo padrão. Esse procedimento é semelhante a um problema de regressão, na estatística convencional, em que se deseja encontrar uma relação entre variáveis independentes (entradas) e dependentes (saídas) (HAYKIN, 2001).

No processo de aprendizado ou treinamento, um conjunto de exemplos (ensaios, por exemplo), com as respostas já conhecidas é apresentado à rede. Os dados de entrada são fornecidos ao sistema e é obtido o conjunto de respostas (saídas). As saídas da rede são comparadas com as respostas previamente conhecidas e, da diferença entre elas, é obtido o erro. Com o valor do erro, os pesos sinápticos são ajustados e o processo é repetido iterativamente, parando quando o erro atingir patamares satisfatórios (BRAGA, 2007).

Após o treinamento da rede, é testada sua capacidade de generalização (validação). Para tal, apresenta-se à rede dados que não fizeram parte do conjunto de treinamento e analisam-se as respostas fornecidas por ela, verificando-se seu desempenho. Essas duas capacidades de processamento tornam possível resolver problemas complexos (de grande escala) que são intratáveis por outros métodos de modelagem (HAYKIN, 2001; BRAGA, 2007).

Assim, a modelagem por meio de redes neurais apresenta algumas vantagens, como: adaptabilidade da rede (a rede pode ser adaptada para um novo ambiente por meio da troca de padrões de entrada, retreinada para lidar com modificações e, atuar em ambiente não estacionário), facilidade de capturar novas informações do meio (dados de novos ensaios, por exemplo) e tolerância a falhas e ruídos (treinamento possível na presença de ambos, o que é comum em dados experimentais (BULLINARIA, 2014).

As redes neurais artificiais estão sendo aplicadas, com êxito, no setor florestal. Gordon (1998) afirma que as RNA são vantajosas em comparação aos métodos tradicionais de modelagem do crescimento florestal. Diamantopoulou (2005) conclui ainda que as redes têm grande potencial para aplicação em modelagem florestal, sendo útil como alternativa as técnicas tradicionais.

Binoti (2012), propôs um modelo para estimação da altura de árvores por meio de redes neurais artificiais eficiente e que pode ser empregado, com vantagens, em substituição aos usuais modelos hipsométricos.

2.6. Modelo de regressão linear

O termo regressão foi proposto pela primeira vez por Sir Francis Galton em 1885, num estudo onde demonstrou que a altura dos filhos não tende a refletir a altura dos pais, mas tende sim a “regredir” para a média da população. Atualmente, o termo análise de regressão define um conjunto vasto de técnicas estatísticas usadas para modelar relações entre variáveis e predizer o valor de uma ou mais variáveis dependentes (ou de resposta) a partir de um conjunto de variáveis independentes (ou preditoras) (MAROCO, 2003).

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

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

2.6.1. Modelo de regressão linear simples

Os modelos de regressão linear simples definem-se como a relação linear entre a variável dependente (Y) e uma variável independente (X). A equação representativa do modelo de regressão linear simples é dado por:

$$Y = \beta_0 + \beta_1 X_i + \varepsilon_i, \quad i = 1, \dots, n. \quad (1)$$

onde:

Y_i = representa o valor da variável resposta ou dependente, Y ;

X_i = representa o valor da variável independente, X ;

ε_i , = são variáveis aleatórias que correspondem ao erro;

β_0 e β_1 = correspondem aos parâmetros do modelo.

Segundo Neter et al. (2005), a equação (1) é dita simples, pois representa a relação entre uma característica de interesse e uma variável de controle, é linear nos parâmetros, pois nenhum dos parâmetros aparece como expoente ou está sendo multiplicado ou dividido por outros parâmetros.

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

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

2.6.2. Modelo de regressão linear múltipla

No modelo de regressão linear múltipla procura-se prever uma variável dependente Y , assumindo sua relação linear com mais de uma variável independente, ou seja, inúmeras variáveis independentes k cujo modelo da i -ésima observação pode ser expressa como:

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

Onde:

Y_i = representa o valor de variável dependente

$X_{i1}, X_{i2}, \dots, X_{ip}, i = 1, \dots, n$ = são os valores da i -ésima observação das p variáveis explicativas, (constantes conhecidas);

$\beta_0, \beta_1, \beta_2, \dots, \beta_k$ = são os parâmetros ou coeficientes de regressão;

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

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

a) o coeficiente β_0 , chamado de coeficiente de intercepto, o qual corresponde à média de Y_i quando todas as variáveis de controle são iguais a zero;

b) os coeficientes β_1, \dots, β_k são chamados de coeficientes de regressão parciais. O coeficiente β_k pode ser interpretado como a derivada parcial de Y_i em relação a X_{ki} , ou seja, é variação de Y causada por uma variação unitária em X_k dado que as outras variáveis de controle sejam constantes.

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

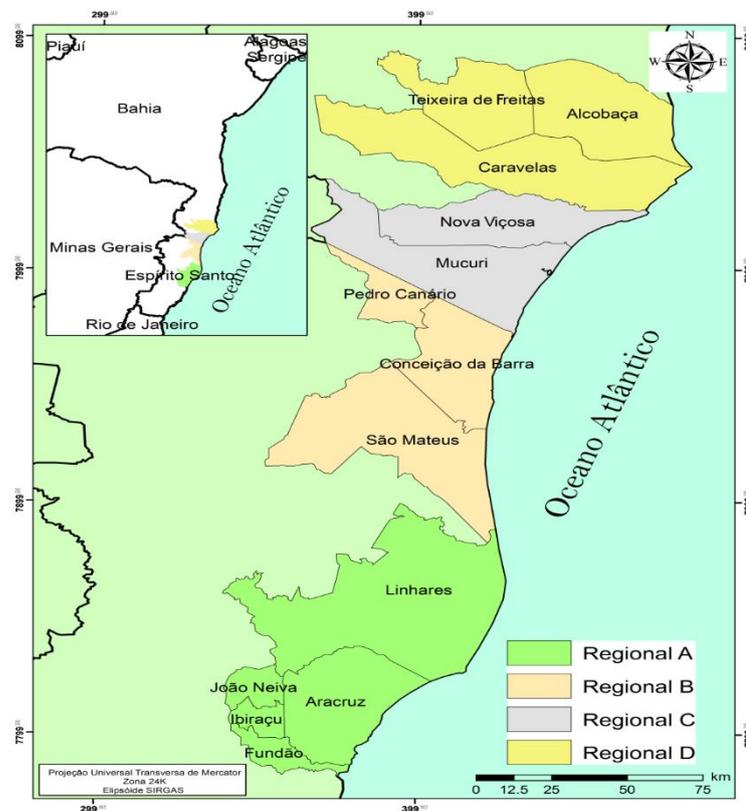
3. MATERIAL E MÉTODOS

3.1. Descrição dos dados

O banco de dados utilizados neste estudo foi formado por: registro de produção dos operadores nas atividades de colheita florestal; dados cadastrais dos talhões e dados de inventário pré-corte. O período de registro de produção, a nível de talhão, dos operadores da atividade de corte florestal mecanizada compreendeu o período de 1 de janeiro de 2014 à 31 de dezembro de 2016, durante os três turnos de trabalho de 312 operadores e 82 máquinas de corte florestal (*harvester*).

Foram analisadas as operações dos módulos (equipe de trabalho) de colheita florestal mecanizada em 4.941 talhões, das áreas operacionais das regionais B, C e D de uma empresa florestal nos estados da Bahia e Espírito Santo (Figura 3). Todas as equipes trabalhavam com maquinários próprios operados por funcionários da empresa.

Figura 3. Localização dos municípios de atuação dos módulos de colheita mecanizada.



Fonte: Lacerda (2014).

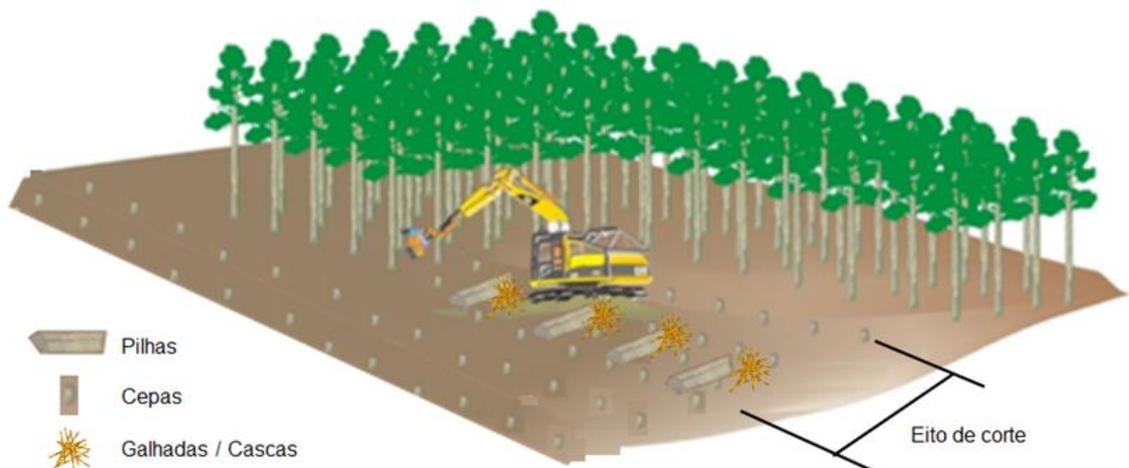
3.2 Sistema de colheita

O sistema de colheita utilizado pela empresa é o de toras curtas (*cut-to-length*), com operações mecanizadas de derrubada, processamento e extração. Para o corte (derrubada e processamento) a empresa utiliza um colhedor florestal do tipo *harvester*. Tal máquina realizou as seguintes operações:

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

O colhedor florestal (*harvester*) executou as atividades de derrubada e processamento em toras de 6,0 m de comprimento. O eito de trabalho foi constituído por quatro fileiras de árvores em que as toras eram depositadas em bandeiras entre a primeira e segunda linha do eito de corte (Figura 4).

Figura 4. Sequência operacional do *harvester* na atividade de corte.



Fonte: Lacerda (2014).

A produtividade do *harvester* em metros cúbicos por hora efetiva ($m^3 \cdot h^{-1}$) foi determinada pelo volume de madeira derrubada e processada no interior do talhão pelas horas de trabalho efetivo.

3.3. Descrição dos fatores que influenciam no corte com *harvester*

As variáveis quantitativas e qualitativas consideradas neste estudo para a modelagem da produtividade do corte mecanizado com *harvester* foram: volume médio individual das árvores (VMI), volume de madeira do talhão (VM), idade de corte (I), espaçamento (E), experiência do operador (O) e regime de manejo (M). Todas as variáveis foram extraídas dos dados de inventário pré-corte e do cadastro dos operadores, relacionadas com o registro de produção dos operadores na operação de corte dos talhões da empresa.

Na Tabela 1 é apresentado a análise descritiva das variáveis numéricas utilizadas na modelagem da produtividade do corte com *harvester* dos talhões avaliados.

Tabela 1. Análise descritiva das variáveis numéricas

Variável	Mín.	Máx.	Méd.	Desvio Padrão
VMI (m ³)	0,0132	0,3798	0,1206	±0,0448
VM (m ³)	7,8	12384	2101	±1883
I (meses)	36	120	67	±11

Mín = menor valor da variável; Máx = maior valor da variável; Méd = valor médio da variável.

As variáveis categóricas utilizadas para modelagem da produtividade do *harvester* são apresentadas na Tabela 2. O número de classes dessas variáveis categóricas foi 3, 3, e 2, respectivamente.

Tabela 2. Variáveis categóricas.

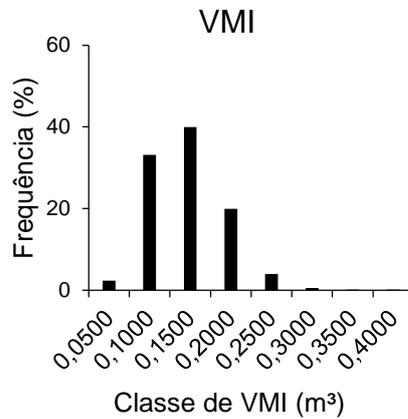
Variável	Classes
Espaçamento (E)	3x2; 3x2,5; 3x3
Experiência do operador (O)	Inexperiente e Experiente
Regime de manejo (M)	Implantação; Condução; Reforma

3.3.1. Volume médio individual (VMI)

O VMI do povoamento tem uma relação direta com a produtividade do corte florestal com o *harvester*, à medida que aumenta o volume médio individual das árvores, maior será a produtividade da máquina. Por se tratar de povoamentos de madeira de eucalipto para produção de celulose, o VMI dos talhões colhidos foi baixo,

não ultrapassou o valor de 0,4000 m³ (Tabela 1). A amplitude dos valores de VMI dos talhões avaliados pode ser observada na Figura 5.

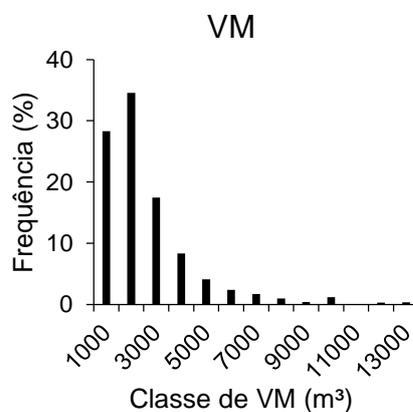
Figura 5. Histograma de frequência dos valores de VMI dos talhões colhidos 2014 a 2016 na empresa.



3.3.2. Volume de madeira do talhão

O volume de madeira do talhão possui uma relação natural com o VMI do talhão. Normalmente talhões com maior volume conferem maior produtividade as máquinas de corte. A variabilidade do volume de madeira dos talhões foi alta, de 7,8 até 12.384 m³ (Tabela 1). Observa-se na Figura 6 a frequência dos volumes dos talhões analisado neste estudo.

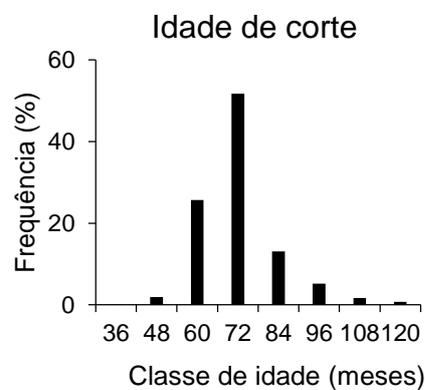
Figura 6. Histograma de frequência dos valores de VM dos talhões colhidos 2014 a 2016 na empresa.



3.3.3. Idade de corte

A idade de corte tem uma relação com o VMI das árvores. Normalmente quanto maior for a idade do talhão, maior será o VMI dessas árvores, conseqüentemente maior será a produtividade das máquinas. A idade de corte dos povoamentos variou de 36 a 120 meses, essa faixa de idade é conferida a finalidade da empresa que trabalha com madeira para celulose. Na figura 7, observa-se o histograma das idades de corte dos povoamentos avaliados.

Figura 7. Histograma de frequência da idade de corte (meses) dos talhões colhidos 2014 a 2016 na empresa.



3.3.4. Espaçamento

O espaçamento influencia no tempo de deslocamento da máquina de corte dentro do talhão, influenciando na produtividade operação. Os espaçamentos dos povoamentos colhidos foram divididos em três classes: 3x2, 3x2,5 e 3x3.

3.3.5 Experiência do operador

A experiência do operador tem influência direta sobre a produtividade da máquina de corte florestal. Os operadores foram agrupados em duas classes, uma denominada de inexperientes e outra de experientes, de acordo com a quantidade de horas operadas no *harvester*.

3.3.6. Regime de manejo

O regime de manejo tem relação direta com volume de madeira do talhão, em povoamentos de condução normalmente apresentam menor volume de madeira devido à perda de volume da cepa (cortada na colheita anterior) e trabalho com matéria genético antigo. Essa variável foi agrupada conforme os três tipos de regime utilizados pela empresa: implantação, reforma e condução.

3.4. Modelagem com Redes Neurais Artificiais (RNA)

As RNA consideram variáveis quantitativas e qualitativas na solução de problemas. Para cada variável quantitativa há um único neurônio na camada de entrada da rede, enquanto que o número de neurônios na camada de entrada para uma variável qualitativa, depende do número de classes desta variável, sendo necessário um neurônio para cada classe. Uma classe é determinada pelo seu respectivo neurônio com valor 1 (um) e os demais neurônios (das outras classes da variável qualitativa) com o valor 0 (zero).

Os dados, englobando todos os talhões colhidos nos anos de 2014 a 2016, foram separados aleatoriamente em dois conjuntos, um para o treinamento das redes (26.179 linhas de boletins de registro das atividades de *harvester*) e outro para avaliar a generalização das redes treinadas (12.008 linhas de registro), com uma proporção de cerca de 70% dos dados para treinamento e 30% para generalização.

3.4.1. Treinamento e generalização das redes neurais artificiais

O treinamento de uma RNA e o processo de ajuste de seus pesos através de um algoritmo de aprendizagem, que extrai características dos dados fornecidos tem por objetivo gerar uma rede que desempenhe a tarefa de interesse.

Foram treinadas redes para projetar a produtividade do *harvester*. No Statistica 13.2 foram treinadas 20 redes através da ferramenta *Neural nets* sendo selecionadas as 5 melhores RNA. As RNA selecionadas foram as que apresentaram maior coeficiente de correlação e menor erro % para os valores estimados de produtividade. Nesse software foi feito o treinamento da arquitetura de rede do tipo *Multilayer Perceptron* (MLP), com número mínimo de 4 e máximo 13 neurônios na camada

oculta. Os algoritmos de treino usados foram o *Conjugate gradiente*, *BFGS* e *conjugate gradiente*, todos com critério de parada de 1000 ciclos.

A generalização (validação) corresponde à aplicação da RNA em um conjunto de dados que não estavam presentes no treinamento da rede, ou seja, em um conjunto de dados independente e desconhecido. A validação das RNA tem o objetivo de testar a capacidade das redes treinadas em produzir saídas adequadas. Para validação das RNA foram utilizados um conjunto de dados aleatórios restantes, composto por 30% dos dados.

3.5. Influência das variáveis de entrada

A fim de verificar a influência de cada variável na produtividade do *harvester*, realizou-se treinamento das redes com combinações das variáveis de entrada (numérica e categóricas), sempre procurando retirar a variável de entrada que conferia a RNA de menor correlação entre os valores estimados e observados ($r_{y\hat{y}}$), da produtividade do *harvester* e maior raiz do erro quadrado médio (RMSE%).

3.6. Modelagem com regressão linear

O método tradicional empregado para modelar a produtividade das operações de colheita florestal utiliza modelos de regressão linear simples, com base nas variáveis independentes “x” para estimar a variável dependente “y”. Segue o modelo:

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

Em que:

Y_i = produtividade observada do *harvester* em $m^3.he^{-1}$

$X_{i1} + X_{i2} + \dots + X_{ik}$ = variáveis influenciam na produtividade do *harvester*

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

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

Foi avaliado se as variáveis (X), VMI, VM, I, E, O, e M, do estudo apresentavam correlação linear significativa, com a produtividade das máquinas *harvester* de corte florestal e entre as mesmas variáveis independentes. Para isso, foi obtido o grau de associação, efetuando-se a análise da matriz de coeficiente da correlação (r) de Pearson, pelo teste t a 5% e 1% de probabilidade. Assim, as variáveis que apresentaram associação linear com a produtividade da máquina foram adicionadas ao modelo 1.

3.7. Avaliação das estimativas

A avaliação das estimativas geradas pelas redes neurais e pelos modelos de regressão foi feita por meio de estatísticas e análise gráfica dos resíduos. As estatísticas empregadas foram a correlação entre os valores estimados e observados, da produtividade do *harvester*, e a raiz do erro quadrado médio (RMSE%). A análise gráfica consistiu na inspeção estatística da dispersão dos erros (resíduos) percentuais em relação aos valores observados (equação 2):

$$erro\% = \frac{(\tilde{Y} - Y)}{Y} \times 100 \quad (2)$$

Em que:

Y = é o valor observado (produtividade $m^3.he^{-1}$) nos boletins de corte mecanizado com *harvester*;

\tilde{Y} = é o valor estimado (produtividade $m^3.he^{-1}$) pela RNA ou regressão.

A correlação entre os valores observados e estimados ($r_{y\hat{y}}$) (equação 3) indica a força e a direção da relação entre as duas variáveis. Embora não permita inferir diretamente sobre igualdade entre valores observados e estimados (CAMPOS; LEITE, 2009), a correlação indica o grau de associação entre valores observados e estimados e, juntamente com a análise de resíduos, permite inferir sobre a qualidade da estimação.

$$r_{y\hat{y}} = \frac{cov(Y, \tilde{Y})}{\sqrt{s^2(Y)s^2(\tilde{Y})}} \quad (3)$$

Em que:

cov = covariância

s^2 = variância.

A correlação assume valores entre 0 e 1, sendo que quanto maior for o coeficiente de correlação (próximo de 1), maior é a precisão das estimativas. O coeficiente de correlação pode ser interpretado qualitativamente da seguinte forma (SHIMAKURA, 2006): de 0,9 a 1,0, existe uma correlação muito forte; de 0,7 a 0,89, indica uma correlação forte; de 0,4 a 0,69 há uma correlação moderada.

A raiz do erro quadrado médio (RMSE) (equação 4) avalia a diferença quadrática média entre os valores observados e os valores estimados. Quanto menor o RMSE, melhor a precisão da estimativa (MEHTÄTALO et al., 2006), sendo:

$$RMSE (\%) = 100 \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} / \bar{Y} \quad (4)$$

Em que:

\bar{Y} = média dos valores observados;

n = número total de observações.

4. RESULTADOS E DISCUSSÃO

4.1. Modelagem da produtividade do corte florestal por meio de RNA

As RNA selecionadas no treinamento e validação para a estimativa da produtividade do *harvester*, apresentaram valores de coeficiente de correlação acima de 0,89 e RMSE% menores que 11,91, indicando forte correlação e alta exatidão entre as estimativas e os valores observados (Tabela 3). Sendo que a RNA 2, apresentou os melhores resultados de $r_{y\hat{y}}$ (0,90 e 0,89) e RMSE(%) (11,55 e 11,66), no treinamento e na validação respectivamente. Estas redes foram do tipo MLP e utilizaram todas as variáveis de entrada disponíveis, categóricas e numéricas.

Tabela 3. Características e precisão das redes neurais artificiais selecionadas para estimar a produtividade do *harvester*.

RNA	Arquitetura*	Entradas numéricas	Entradas categóricas	Treinamento		Validação	
				$r_{y\hat{y}}$	RMSE%	$r_{y\hat{y}}$	RMSE%
1	11-10-1	VMI, VM, I	E, O, M	0,89	11,66	0,8888	11,80
2	11-11-1	VMI, VM, I	E, O, M	0,90	11,55	0,8920	11,66
3	11-9-1	VMI, VM, I	E, O, M	0,89	11,77	0,8909	11,76
4	11-7-1	VMI, VM, I	E, O, M	0,89	11,88	0,8890	11,91
5	11-11-1	VMI, VM, I	E, O, M	0,89	11,63	0,8915	11,70

* Número de neurônios em cada camada. VMI = volume médio individual das árvores, VM = volume de madeira do talhão, I = idade de corte, E = espaçamento, O = experiência do operador, M = regime de manejo.

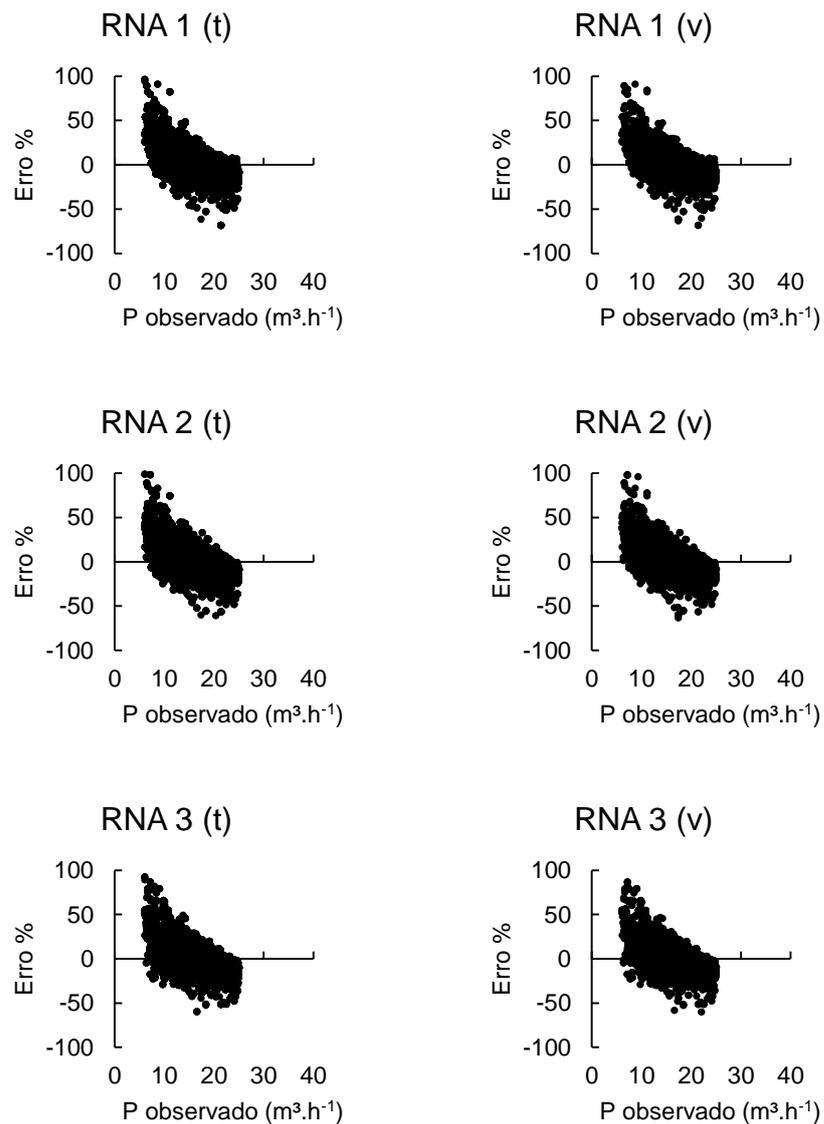
Binoti (2010), encontrou nas redes do tipo *Multilayer Perceptron* (MLP), os melhores resultados de treinamento e generalização para projeção da área basal e do volume em povoamentos de clones de eucalipto. O autor afirma que esse tipo de rede é capaz de desempenhar a tarefa de aproximação de funções. Silva (2015), aplicando redes neurais para estimar a produtividade do *forwarder* na extração de madeira, também encontrou melhores desempenhos das RNA do tipo MLP.

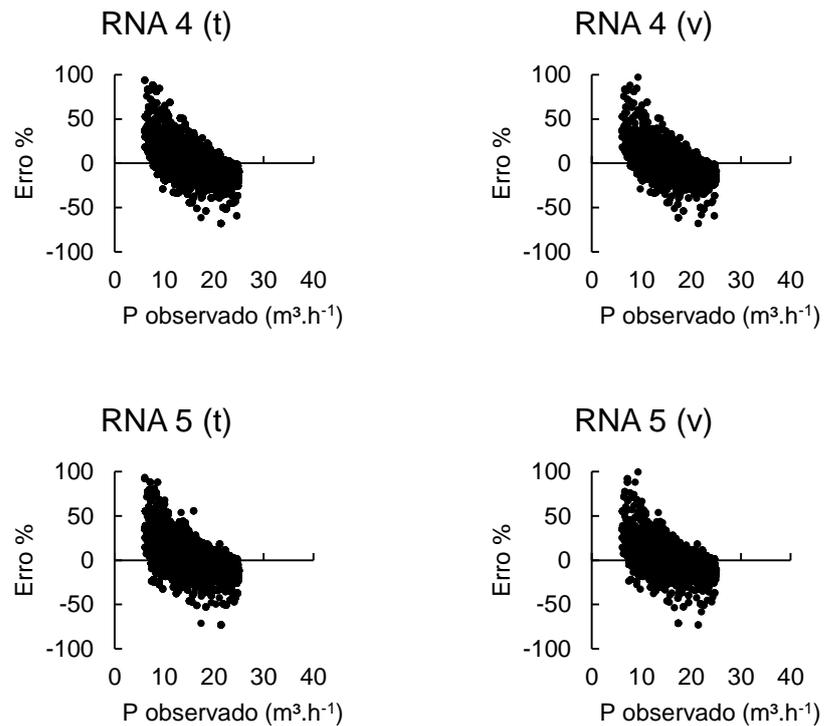
Segundo Binoti (2010), não é suficiente uma rede apenas bem treinada, pois uma boa validação é essencial para a aplicação da mesma a novos dados. A validação ou generalização de todas as redes selecionadas foi precisa para gerar estimativas da produtividade do *harvester*, mostrando a eficiência do método durante o

treinamento. Silva (2015) trabalhando com redes neurais artificiais para estimação da produtividade da extração de madeira com forwarder também encontrou bons resultados das redes de treinamento e generalização das RNA.

Na Figura 8 é apresentado os erros (%) das estimativas de produtividade do *harvester* ($m^3.he^{-1}$) para cada RNA no treinamento e validação.

Figura 8. Dispersão dos erros percentuais em relação aos valores observados de produtividade do *harvester* (P observado) no treinamento (t) e validação (v) das RNA

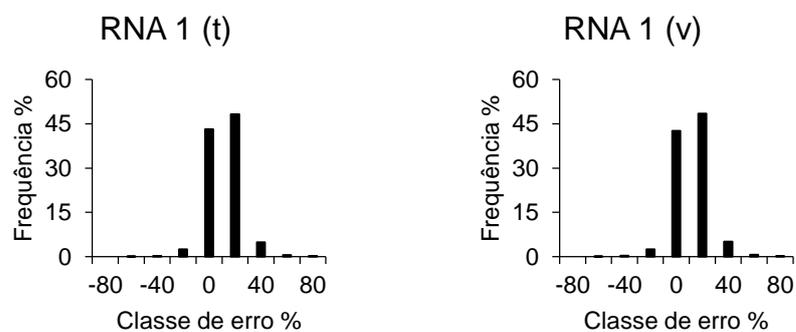


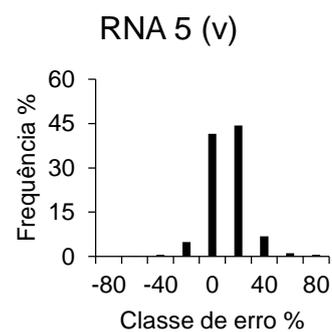
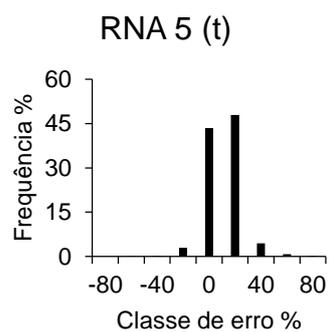
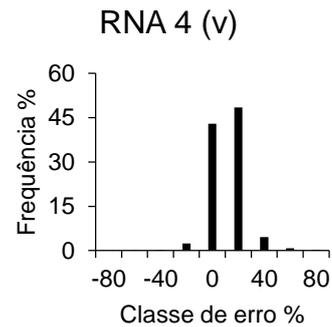
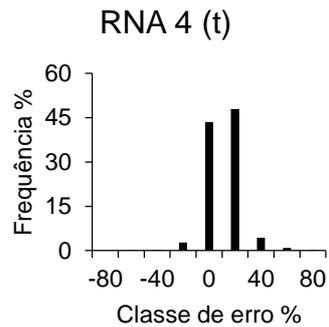
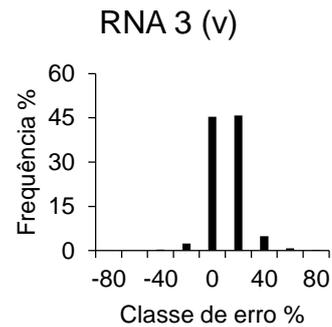
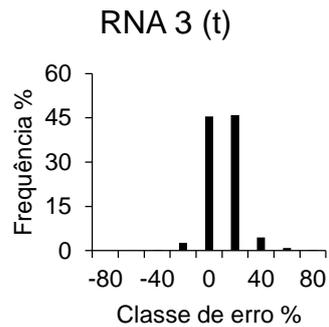
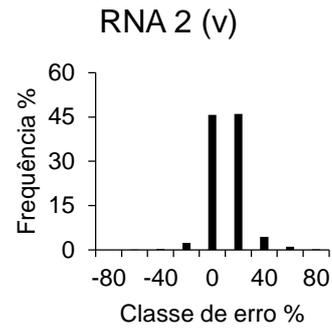
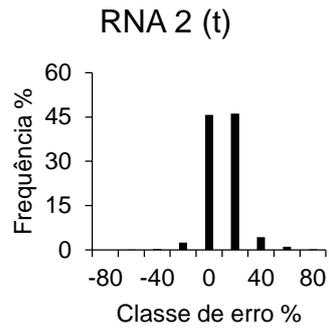


Verifica-se na Figura 8 que as redes tiveram uma leve tendência de superestimar a produtividade do *harvester* nos valores menores que $15 \text{ m}^3 \cdot \text{h}^{-1}$ e subestimar em valores maiores. Silva (2015), também observou uma leve tendência das RNA de superestimar a produtividade do *forwarder* na extração de madeira nos valores de produtividade inferiores a $18 \text{ m}^3 \cdot \text{h}^{-1}$ e subestimar em valores maiores que $40 \text{ m}^3 \cdot \text{h}^{-1}$.

A frequência dos erros (%) das estimativas de produtividade do *harvester* para cada RNA no treinamento e validação é apresentado na Figura 9.

Figura 9. Frequência dos erros percentuais das estimativas de produtividade do *harvester* ($\text{m}^3 \cdot \text{h}^{-1}$), no treinamento (t) e validação (v) das RNA





Observa-se que a classe -10 a 30 concentraram mais de 90% dos erros percentuais para treinamento e validação das RNA. Esse resultado mostra que as redes foram precisas na modelagem da produtividade do harvester.

Vieira (2015) avaliou o desempenho de redes neurais artificiais na projeção do crescimento em DAP e altura total e também verificou que as redes apresentaram boa

precisão para estimar o crescimento em DAP e altura total de árvores de eucalipto. Binoti (2010), a utilizaram RNA do tipo RBF e MLP para estimar o volume de árvores, os resultados mostraram que o método pode ser recomendado para previsão volumétrica da produção de florestas plantadas.

A aplicação e avaliação da técnica de rede neural artificial pra estimar a produtividade do *harvester* em função de algumas variáveis que interferem na colheita florestal, VMI, volume de madeira do talhão, idade de corte, espaçamento, experiência do operador e regime de manejo mostrou-se eficiente, uma vez que todas as redes apresentaram alta correlação e baixo RMSE%, no treinamento e validação, sendo precisas na geração das estimativas da produtividade do *harvester* (Tabela 3, Figuras 8 e 9).

4.2. Combinações de variáveis de entrada na estimação da produtividade do *harvester*

A descrição das RNA obtidas a partir das diferentes combinações de variáveis de entrada e as respectivas estatísticas do treinamento e da validação são apresentadas na Tabela 4.

Tabela 4. Características e precisão das diferentes combinações de variáveis de entrada na RNA selecionadas para estimar a produtividade do *harvester*.

RNA	Arquitetura*	Entradas numéricas	Entradas categóricas	Treinamento		Validação	
				$r_{\hat{y}y}$	RMSE%	$r_{\hat{y}y}$	RMSE%
6	MLP	11-11-1	VMI, VM, I	E, O, M	0,9002	11,55	0,8920
7	MLP	8-11-1	VMI, VM, I	O, M	0,8980	11,89	0,8971
8	MLP	5-8-1	VMI, VM, I	M	0,8920	12,20	0,8937
9	MLP	3-6-1	VMI, VM, I	-	0,8759	13,80	0,8718
10	MLP	2-8-1	VMI, VM,	-	0,8549	14,32	0,8508
11	MLP	1-3-1	VMI	-	0,8420	14,89	0,8498

* Tipo de RNA: MLP = *Multilayer Perceptron*, ** Número de neurônios em cada camada. VMI = volume médio individual das árvores, VM = volume de madeira do talhão, I = idade de corte, E = espaçamento, O = experiência do operador e M = regime de manejo.

Observa-se que a RNA 6 obteve a maior correlação e o menor erro, tanto para os dados de treinamento quanto de validação. Tal fato demonstra que a rede estimada com mais variáveis de entrada (variáveis que influenciam a operação de

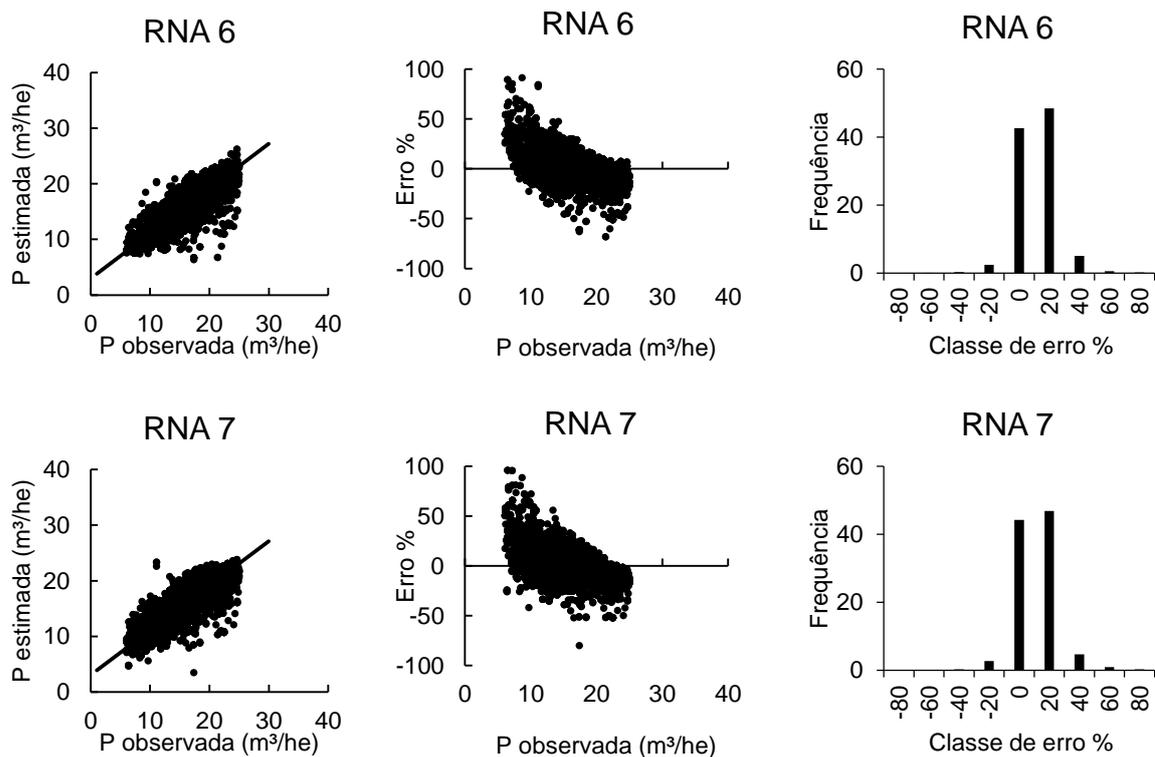
corte) apresentou maior precisão e exatidão na modelagem da produtividade do *harvester*.

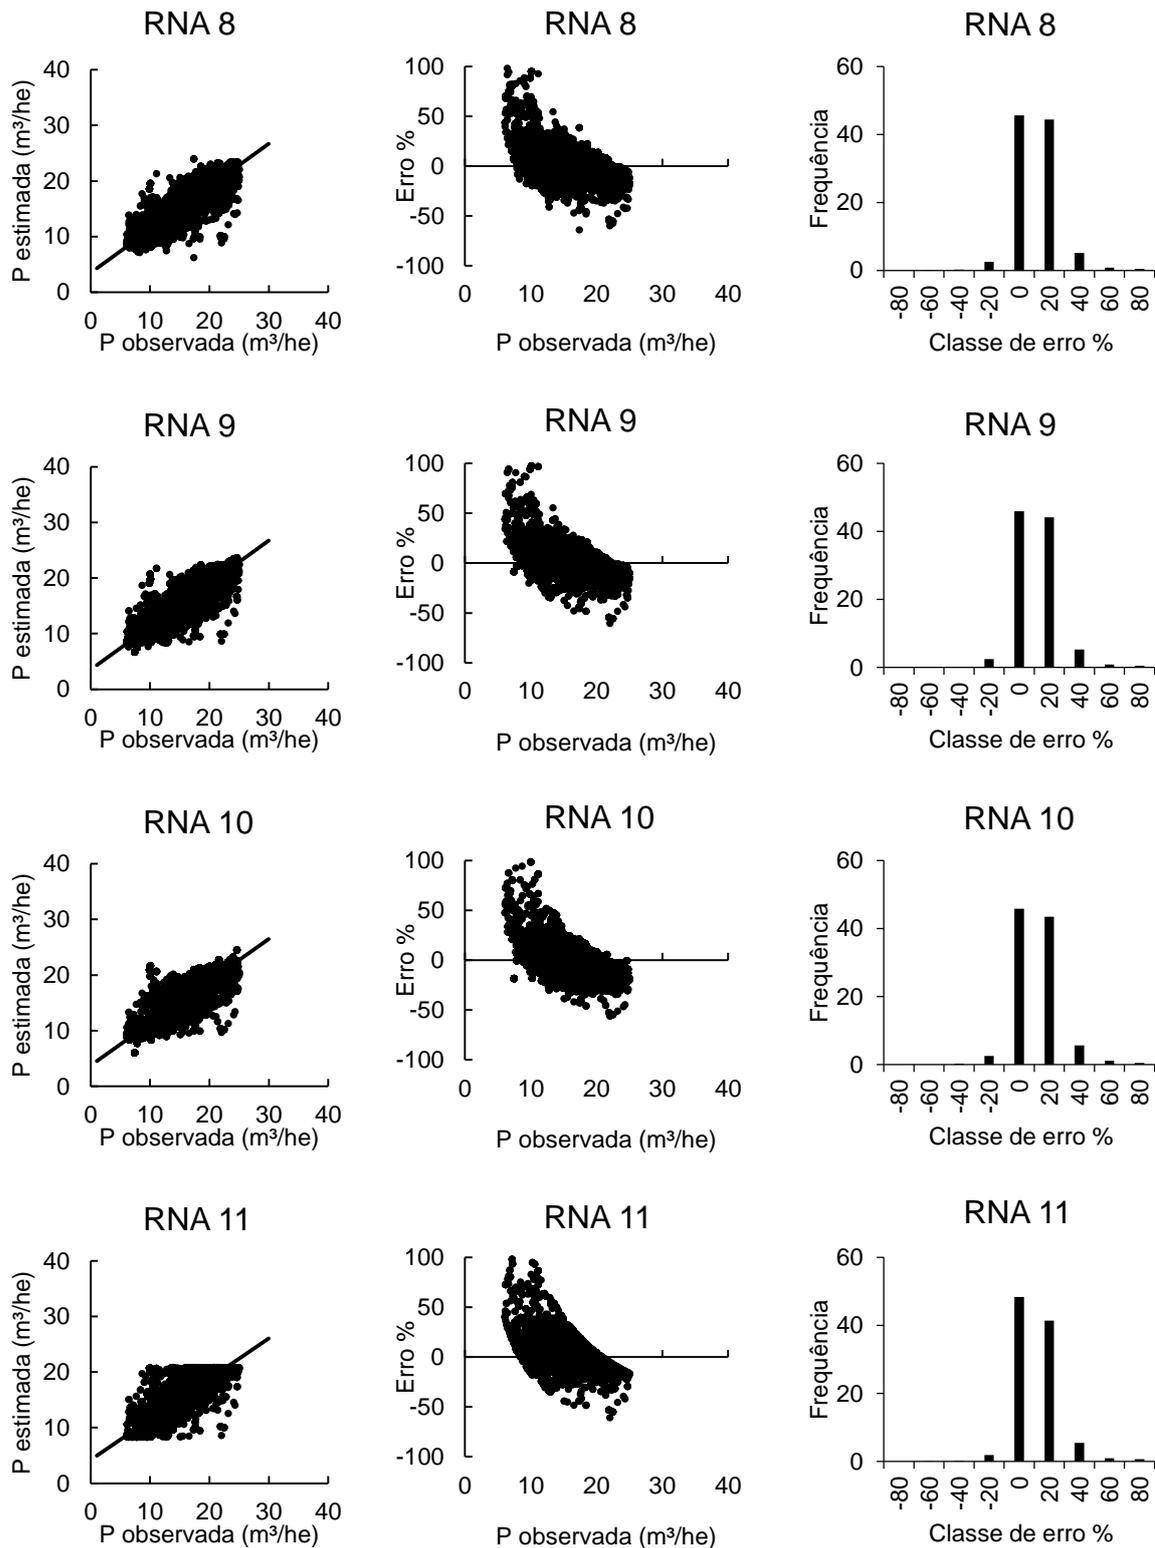
As RNA 6 e 7 apresentaram pouca diferença nos valores de coeficiente de correlação e RMSE% para treinamento e validação. Esse resultado demonstra que a retirada das variáveis espaçamento (E) e experiência do operador (O) da entrada da rede, não influenciou a precisão da estimação da produtividade do *harvester* neste estudo.

A RNA 11 apresentou $r_{y\hat{y}}$ 0,8420, 0,8498 e RMSE% 14,89 e 14,92 para dados de treinamento e validação, respectivamente. Esse fato confirma que dentre as variáveis avaliadas no estudo, o VMI foi a que mais influenciou na estimação da produtividade do *harvester*. Corroborando com esses resultados, Richardson e Makkonen (1994) estudaram o desempenho de *harvesters* e que o VMI era o fator que mais afetava a capacidade produtiva da mesma. Burla (2008) afirma que o volume médio individual é o principal fator de influência na produtividade de um *harvester*.

A análise gráfica dos erros percentuais e a correlação entre valores observados e estimados das combinações das redes é apresentado na Figura 10.

Figura 10. Produtividade estimada e observada, dispersão e histograma de frequência dos erros percentuais da RNA em função das diferentes combinações de variáveis de entrada rede para estimar produtividade do *harvester*.





É possível verificar que a RNA 11 (menor quantidade de variáveis de entrada) apresentaram maior dispersão e frequência dos erros percentuais da produtividade observada e estimada do *harvester*. Esse resultado demonstra menor precisão das estimativas das redes na modelagem da produtividade do *harvester* à medida que se diminuiu a quantidade de variáveis de entrada.

Estudos de campo devem ser realizados a fim de se definir para cada conjunto de variável e máquina base a curva de relação entre as classes de variável e a produtividade da máquina. Pois estes estudos irão permitir além do conhecimento das correlações, uma priorização das variáveis que mais influenciam em cada situação de colheita (MALINOVSKI et al., 2006).

4.2. Modelagem da produtividade do corte florestal por meio de regressão linear

As variáveis VMI, VM, I e M apresentaram correlação linear significativa com a produtividade das máquinas de corte florestal (Tabela 5). As mesmas foram combinadas e incluídas nos modelos de regressão.

Na Tabela 6 é apresentado as equações de predição dos valores de produtividade do *harvester* (onde foram selecionadas apenas as variáveis significativas) levando-se em consideração o coeficiente da correlação ($r_{y\hat{y}}$) para as equações de predição ajustadas, em cada caso em particular, e a raiz do erro quadrado médio (RMSE%) entre os valores observados e estimados.

Tabela 6. Componentes das equações de predição e características de precisão da produtividade do corte mecanizado com *harvester* ($m^3 \cdot h^{-1}$), em função das variáveis influentes.

	Equação	$r_{y\hat{y}}$	RMSE%
1	$P = 73,914VMI + 6,536$	0,80	15,73
2	$P = 70,777VMI + 0,00026123VM + 6,369$	0,81	15,26
3	$P = 74,247VMI + 0,00027511VM - 0,044029I + 8,8496$	0,82	15,01
4	$P = 74,059VMI + 0,00034179VM - 0,040095I + 7,8448$ $IMP + 7,1799CON + 8,8572REF + 0,001$	0,83	14,5

P = produtividade observada do *harvester* em $m^3 \cdot h^{-1}$, VMI = volume médio individual, VM = volume de madeira do talhão, I = idade de corte, IMP = regime de manejo de implantação, CON = regime de manejo de condução e REF = regime de manejo de reforma.

A equação 4, obtida pela regressão linear múltipla, foi a que teve o melhor ajuste para a produtividade do *harvester*, coeficiente de correlação 0,83 e RMSE% 14,5. O melhor ajuste dessa equação pode ter sido em função da maior quantidade de variáveis que influenciam a produtividade do *harvester*, no modelo, o que denota a

importância de cada variável na predição da produtividade da máquina no corte florestal mecanizado.

Dentre as variáveis avaliadas no modelo, a que mais explica a produtividade estimada pela regressão linear é o volume médio individual, pois, observa-se na equação 1: $P = 73,914VMI + 6,536$, $r_{y\hat{y}} 0,80$ e $RMSE\% 15,73$, que essa variável sozinha apresentou bons valores de precisão na estimação da produtividade do *harvester*. Tal fato também foi encontrada na modelagem com rede (RNA 11). Silva et al. (2010b) afirmam que a variável VMI foi a que melhor explicou a produtividade final da máquina *harvester* no corte mecanizado de pinus.

As correlações entre a produtividade do *harvester* no corte florestal mecanizado e as variáveis que influenciam a atividade, espaçamento, idade de corte, volume de madeira do talhão, volume médio individual das árvores, experiência do operador e regime de manejo são apresentadas na Tabela 5.

Tabela 5. Matriz de correlação das variáveis influentes na produtividade do *harvester* no corte florestal e entre as mesmas.

	Prod	E	I	VM	VMI	O	M
Prod	1,00						
E	0,00	1,00					
I	-0,13	0,07	1,00				
VM	0,13	0,01	0,03	1,00			
VMI	0,77	-0,03	0,33	0,10	1,00		
O	-0,02	-0,02	0,04	-0,04	0,01	1,00	
M	0,15	0,11	0,07	0,01	-0,11	0,00	1,00

Prod = Produtividade do *harvester*, E = espaçamento; I = idade de corte; VM = volume de madeira do talhão VMI = volume médio individual das árvores, O = experiência do operador, M = regime de manejo.

A produtividade do *harvester* em relação ao espaçamento apresentou uma correlação não significativa e positiva, ou seja, a produtividade da máquina não variou em relação ao espaçamento do talhão (0,00). O espaçamento do talhão dá ideia de tempo de deslocamento da máquina de corte dentro do talhão, influenciando na produtividade operação, porém como neste estudo trabalhou-se com classes de espaçamentos semelhantes 3x2, 3x2,5 e 3x3 m, o que pode ser a razão da não alteração no desempenho operacional da máquina.

A correlação entre a produtividade do *harvester* e a idade de corte mostrou-se significativa e negativa, o que demonstra que a produtividade variou de forma inversa a idade de corte. Esperava-se que quanto maior fosse a idade do talhão, maior seria

o VMI dessas árvores, conseqüentemente maior a produtividade das máquinas. Mas tal relação não ocorreu neste estudo, pois, a maior idade dos talhões estudados não conferiu variação positiva na produtividade da máquina.

A associação entre a Prod e VM foi significativa e positiva (0,13), para a correlação entre produtividade e volume de madeira no talhão. O que indica que a produtividade do *harvester* varia diretamente ao aumento do volume de madeira do talhão.

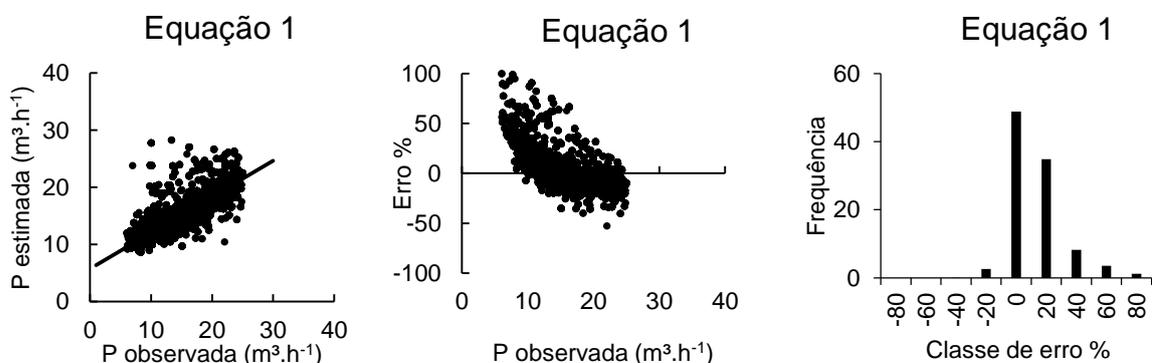
O volume médio individual apresentou correlação significativa, positiva e alta (0,77), o que denota um padrão geral de variação direta da produtividade do *harvester* com o VMI, um fator já esperado. À medida que aumenta o volume da árvore, aumenta-se a produtividade da máquina (MOREIRA, 2000; AKAY et al., 2004).

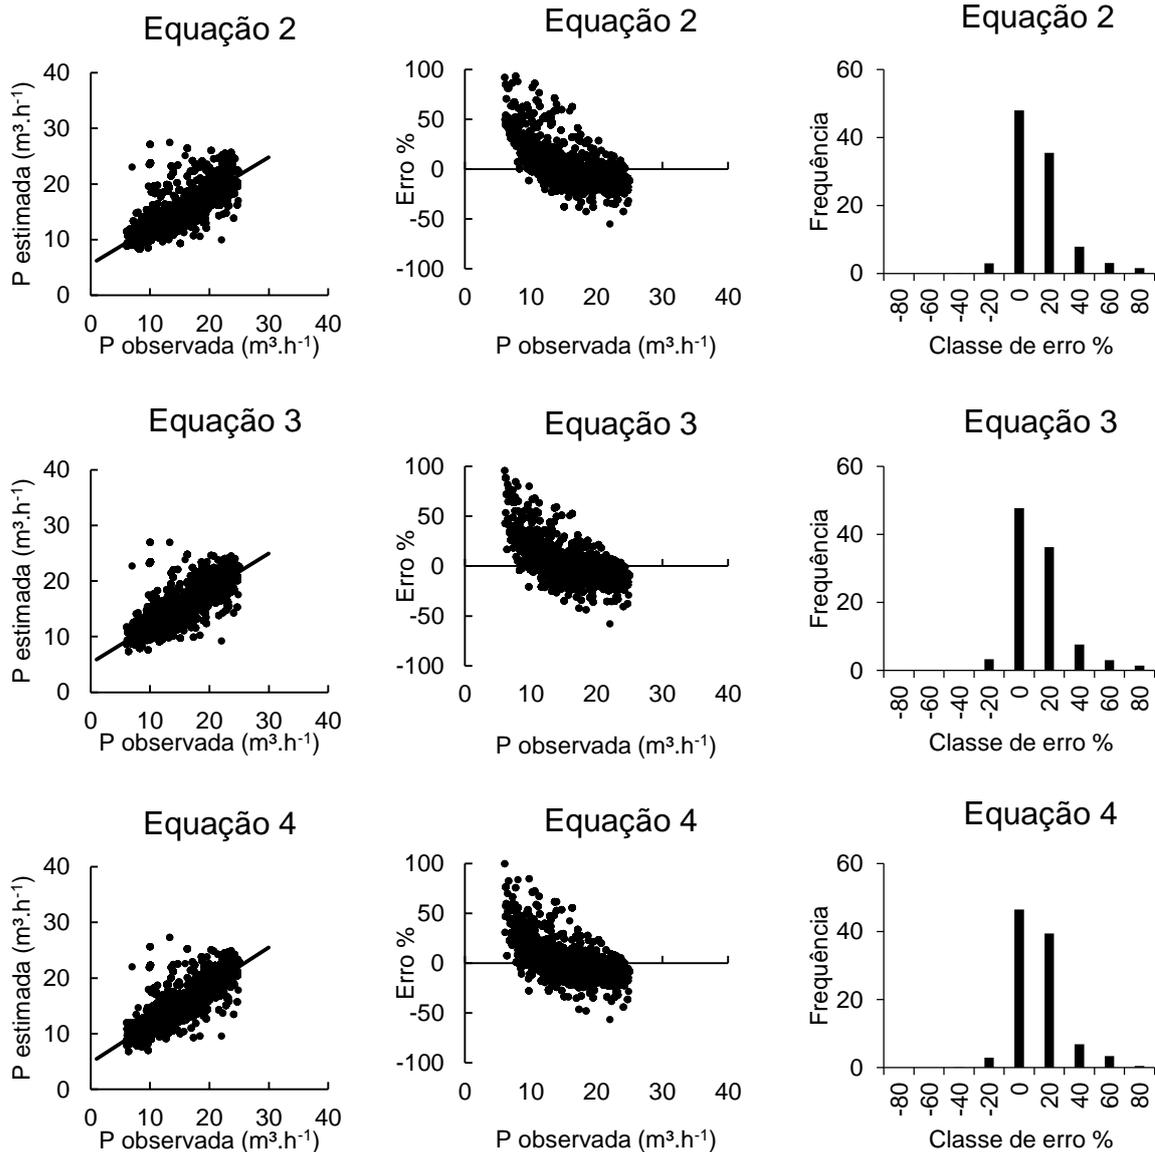
A produtividade e a experiência do operador foi não significativa e negativa (-0,02), o que indica que a produtividade não variou conforme o grau de experiência dos operadores avaliados no estudo. Esse resultado pode ter ocorrido devido aos operadores que compõem as classes inexperientes e experientes, não apresentarem diferença estatística nas médias de produtividades na operação de corte mecanizado.

Valores estatisticamente significativos para a associação da produtividade e regime de manejo foram encontrados (0,15) isso indica que a produtividade varia de forma direta em relação ao regime de manejo adotado no talhão, porém não é possível determinar qual tipo de regime mais influência na produtividade do *harvester*.

A avaliação das estimativas do modelo de regressão linear múltipla em função das variáveis de correlação significativa é apresentada na Figura 11.

Figura 11. Produtividade estimada e observada, dispersão e histograma de frequência dos erros percentuais da regressão em função das variáveis significativas





O modelo de regressão linear múltipla escolhido para a estimação das produtividades das máquinas em relação às variáveis do terreno, do povoamento e do planejamento operacional, em geral, ajustou-se bem aos dados, haja vista as estatísticas e análise gráfica dos resíduos das equações.

De maneira geral a modelagem com RNA, em função das seis variáveis que influenciam a operação de corte mecanizado, apresentou estimativas de produtividade do harvester mais precisas em comparação ao modelo de regressão linear múltipla, com base em 4 variáveis. Corroborando com os resultados encontrados neste estudo, Binoti (2012) e Silva (2015), ressaltam que a utilização de redes neurais artificiais tem se mostrado uma alternativa promissora em relação às técnicas de regressão para o manejo dos recursos florestais.

Diante do exposto esse estudo justificou-se pela modelagem da produtividade do corte florestal mecanizado (*harvester*) por meio de RNA e regressão linear, com base em variáveis do terreno, povoamento e planejamento operacional da colheita. Os modelos permitiram conhecer a correlação de cada variável com a produtividade da máquina e demonstraram a importância das mesmas na estimação da produtividade.

Com o modelo de previsão de corte florestal mecanizado e o conhecimento de correlação das variáveis com a produtividade da máquina, o gestor florestal pode executar um planejamento eficiente da colheita, no que diz respeito às estratégias e metas de produção de madeira para colheitas futuras, planejamento das operações ou ordens de produção, pois, tais fatores confere maior segurança no abastecimento de madeira na fábrica no curto, médio e longo prazos.

5. CONCLUSÕES

Os resultados deste estudo permitem concluir que:

- A técnica de RNA se mostrou eficiente na modelagem da produtividade do corte florestal mecanizado com *harvester* em função das variáveis relacionadas às características do terreno, do povoamento e do planejamento operacional.
- A variável que mais influenciou na predição da produtividade do *harvester*, foi o volume médio individual das árvores, seguida do volume de madeira do talhão, idade de corte e regime de manejo.
- O modelo de regressão linear múltipla foi capaz de realizar a predição da produtividade do corte mecanizado com *harvester* em função das variáveis de correlação significativas avaliadas no estudo
- A modelagem por meio de RNA é mais precisa e pode ser empregada, com vantagens, em substituição ao modelo de regressão linear múltipla testado.

6. REFERÊNCIAS BIBLIOGRÁFICAS

AKAY, A.E.; ERDA, O.; SESSIONS, J. Determining productivity of mechanized harvesting machines. **Journal of applied Sciences**, v. 4, n.1, p. 100-105, 2004.

AMABILINI, V.D. Utilização do *Harvester* na exploração florestal. In: Simpósio Brasileiro sobre Exploração e Transporte Florestal. Belo Horizonte. 1991. P.349-364.

ANDERSSON, D. **Approaches to Integrated Strategic/Tactical Forest Planning**. Licentiate thesis. Swedish University of Agricultural Sciences. Umeå, 2005.

ANDRADE, E.L. Introdução à pesquisa operacional - Métodos e modelos para a análise de decisão. **Rio de Janeiro. ed. Livros Técnicos e Científicos**, 1990.

ARCE, J.E.; MACDONAGH, P.; FRIEDL, R.A. Geração de padrões ótimos de corte através de algoritmos de traçamento aplicados a fustes individuais. **Revista Árvore**, v.28, n.2, p.383- 391, 2004.

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

ASSUMPÇÃO, J.F.P. **Gerenciamento de empreendimentos da construção civil: modelo para planejamento estratégico da produção de edifícios**. 207 f. Tese (Doutorado em Engenharia Civil) – Escola Politécnica, Universidade de São Paulo, São Paulo, 1996.

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

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

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

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

BRAMUCCI, M. **Determinação e quantificação de fatores de influência sobre a produtividade de “harvesters” na colheita de madeira**. 2001. 65f. Dissertação (Mestrado). Escola Superior de Agricultura Luiz de Queiroz - ESALQ, Piracicaba. 2001.

BRAMUCCI, M; SEIXAS, F. Determinação e quantificação de fatores de influência sobre a produtividade de “harvesters” na colheita florestal. **Revista Scientia Forestalis**, Piracicaba, 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: 11 de julho de 2017.

BURLA, E. R. **Avaliação técnica e econômica do harvester na colheita e processamento de madeira em diferentes condições de declividade e produtividade florestal**. 2008. 70 f. Dissertação (Mestrado em Engenharia Agrícola). UFV, Viçosa, 2008.

CAMARINHA FILHO, J. A. **Nota Metodológica sobre modelos lineares mistos**. Curitiba, 2003.

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

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

EVANS, J. **Plantation forestry in the tropics**. Oxford: Clarendon Press, 1992. 403p.

GARDNER, M.; DORLING, S. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. **Atmospheric Environment**, v. 32, n. 14-15, p. 2627–2636, ago. 1998.

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

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

GRAYBIL, F.A. **Theory and application of the linear model**. Duxbury, North State, Massachusetts, 1976.

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

HARTZELL, S. **Types of Planning**: Strategic, Tactical, Operational & Contingency Planning. 2015. Disponível em: < <http://study.com/academy/lesson/types-of-planning-strategic-tacticaloperational-contingency-planning.html> >. Acesso em: 16 de maio de 2015.

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

HOLTZSCHER, M.A.; LANFORD, B.L. Tree diameter effects on cost and productivity of cut-to-length systems. **Forest Products Journal**, v. 47, n. 3, p. 25-30, 1997.

IBÁ– Indústria Brasileira de Árvores. **Relatório 2017**: Ano base 2016. Brasília, 2017.

INSTITUTO DE PESQUISA E ESTUDOS FLORESTAIS – IPEF Silvicultura e Manejo. 2008. **Disponível em:** <<http://www.ipef.br/silvicultura/manejo.asp>>. Acesso em 18 de janeiro de 2017.

KLEIN, J.E.M; BORTOLAS, E.P; ASSIS, T.F; PERRANDO, E.R. Fatores operacionais que afetam a regeneração do Eucalyptus manejado por talhadia. **Série Técnica – IPEF** 1997; 11 (30): 95-104.

LACERDA, L.C. **Colheita florestal mecanizada em módulos próprios e terceirizados**. 2014. 58f. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Espírito Santo. Jerônimo Monteiro. 2014.

LAMPRECHT, H. **Silvicultura nos trópicos**. Eschborn: GTZ, 1990. 343p.

LEITE, E.S. **Modelagem técnica e econômica de um sistema de colheita florestal mecanizada de toras curtas**. 2012. 109 f. Tese (Doutorado em Engenharia Agrícola)- Universidade Federal de Viçosa, Viçosa, MG, 2012.

LEITE, H. G.; SILVA, M. L. M.; BINOTI, D. H. B.; FARDIN, L.; TAKIZAWA, F.H. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, v.130, n.2, p.263-269, 2011.

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

LIMA, J.S.S.; LEITE, Â.M.P. Mecanização. In: MACHADO, C. C. (Ed.). **Colheita Florestal**. 3ª Ed. Viçosa: Editora UFV, 2014. p.46-73.

MACHADO, C. C. **Colheita florestal**. 3ª ed. Viçosa: Editora UFV, 2014.

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

MALINOVSKI, J.R., CAMARGO, C.M.S. A Eucaliptocultura no contexto brasileiro, *Revista Madeira*, Brasília, n.59, 2001. Disponível em: . Acesso em: 15 jun. 2017.

MALINOVSKI, J.R.; MALINOVSKI, R. A. **Evolução dos sistemas de colheita de Pinus na Região Sul do Brasil**. Curitiba: Fundação de Pesquisas Florestais do Paraná - FUPEF, 1998. 138.

MALINOVSKI, R.A.; FENNER, P. T.; SCHACK-KIRCHNER, H.; MALINOVSKI, J. R.; MALINOVSKI, R.A. Otimização da distância de extração de madeira com forwarder. **Scientia Forestalis**, Piracicaba, v. 36, n. 79, p. 171-179, 2008.

MALINOVSKI, R.A.; MALINOVSKI, R. A.; MALINOVSKI, J.R.; YAMAJI, F. M. Análise das variáveis de influência na produtividade das máquinas de colheita de madeira em função das características físicas do terreno, do povoamento e do planejamento operacional florestal. **Revista Floresta**, v.36, n.2, p.166-182, 2006.

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

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

MEGGINSON, C.L., MOSLEY, C.D., PIETRI, H.P. **Administração: Conceitos e aplicações**. Harbra: 1986. 544p.

MEHTATALO, L.; MALTAMO, M.; KANGAS, A. The use of quantile trees in the prediction of the diameter distribution of a stand. **Silva Fennica**, v. 40, n. 3, p. 501-516, 2006.

MENDES, J. B. **Mercado Florestal Brasileiro – Contexto e Tendências**. 2010. Disponível em: < <http://www.ciflorestas.com.br/conteudo.php?id=3774> >. Acesso em: 10 de março de 2017.

MINETTE, L. J.; SILVA, E. N.; FREITAS, K. E.; SOUZA, A. P.; SILVA, E. P. Análise técnica e econômica da colheita florestal mecanizada em Niquelândia, Goiás. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 12, n. 6, p. 659-665, dez. 2008. ISSN 1415-4366.

MITCHELL, S.A. **Operational Forest Harvest Scheduling Optimisation – A mathematical model and solution strategy**. Auckland. 2004. 252f. Thesis. University of Auckland.2004.

MOREIRA, F.M.T. **Análise técnica e econômica de subsistemas de colheita de madeira de eucalipto em terceira rotação**. 2000. 148 f. Dissertação (Mestrado em Ciências Florestais). Universidade Federal de Viçosa – UFV. Viçosa. 2000.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística aplicada e probabilidade para engenheiros**. 2. Ed. Rio de Janeiro: LTC, 2003. 463 p.

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

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

NETER, J. KUTNER, M. H.; NACHTSHEIM, C. J.; LI, W. **Applied linear statistical models**. 5th ed. New York: Mc Graw-Hill/Irwin, 2005. 1396 p.

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

PEREIRA, A. L. C. **Avaliação de um sistema de colheita de Pinus taeda L. em diferentes produtividades do povoamento**. 2011. 93 f. Dissertação (Mestrado em Ciências Florestais) – Universidade Estadual do Centro-Oeste, Irati, PR, 2011.

PURFÜRST, F. T.; ERLER, J. The Human Influence on Productivity in *Harvester Operations*. **International Journal of Forest Engineering**, v.22, n.2, p. 15-22, 2011.

RAO, C.R. **Linear statistical inference and its applications** 2nd ed. New York, John Wiley & Sons, 1973.

REZENDE, J.; PEREIRA, A.; OLIVEIRA, D. Espaçamento ótimo para produção de madeira. **Revista Árvore**, Viçosa, v.7, n.1, p.30-43, 1983.

RIBEIRO, N.; MUSHOVE, P.; AWAM, A.; SIMANGO, S. Caracterização ecológica da floresta de galeria do Rio Mecuburi na Reserva Florestal de Mecuburi, Província de Nampula. **IUCN**. Maputo. 2002.

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

RODRIGUES, F.L. **Metaheurística e sistema de suporte à decisão no gerenciamento de recursos florestais**. 2001. 255f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2001.

SANT'ANNA, G. L. Corte. In: MACHADO, C. C. **Colheita Florestal**. Viçosa: UFV. 3^a ed. Viçosa: UFV, 2014. p. 66-96.

SANTOS, S.L.M.; MACHADO, C.C. Análise técnica-econômica do processamento de madeira de eucalipto em áreas planas, utilizando o processador. **Revista Árvore**, v. 19, n. 3, p. 346-357, 1995.

SCHNEIDER, P.R. **Manejo Florestal: Planejamento da Produção Florestal**. Santa Maria: CEPEF/FATEC/UFSM. 2009. 613p.

SCOLFORO, J. R. MAESTRI, R.; O manejo de florestas plantadas. In: SCOLFORO, J. R. S.; **Manejo Florestal**. Lavras: UFLA/FAEPE, 1998. 438 p.

SEARLE, S.R. **Linear models**. New York, John Wiley & Sons, 1971. 532p.

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

SHIMIZU, J. Y. **A Pesquisa na Evolução do Setor Florestal**. 1995. Disponível em:<<http://www.alice.cnptia.embrapa.br/alice/bitstream/doc/300609/1/PesquisaEvolucao0001.pdf>>. Acesso em: 10 de março de 2017.

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, 2010b.

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

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

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

SIMÕES, D.; FENNER, P.T. Influência do relevo na produtividade e custos do *harvester*. **Scientia Forestalis**, v.38, n.85, p.107-114, 2010.

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

SIMÕES, J. W. **Formação, manejo e exploração de florestas com espécies de rápido crescimento**. Brasília: IBDF, 1981. 131p.

STOONER, J.A.F., FREEMAN, R.E. **Administração**. Prentice-Hall: 1985. 538p.

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

TAVARES, M.C. **Planejamento estratégico. A opção entre sucesso e fracasso empresarial**. Ed. Harbra, São Paulo, 1991. 199p.

TURBAN, E; ARONSON, J.E. **Decision support systems and intelligent systems**. New Jersey: Prentice-Hall, 1998. 890p.

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

VIEIRA, G.C. **Prognose do diâmetro e da altura de árvores individuais utilizando inteligência artificial**. 2015. 52f. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Espírito Santo. Jerônimo Monteiro. 2015.

WADOUSKI, L. H. O planejamento operacional na exploração de florestas. In: SIMPÓSIO SOBRE EXPLORAÇÃO, TRANSPORTE, ERGONOMIA E SEGURANÇA EM REFLORESTAMENTOS, 1987, Curitiba. **Anais...** Curitiba: FUPEF, 1987. p.28 - 39.