

UNIVERSIDADE FEDERAL DO PARANÁ

UBIRAJARA COELHO MACHADO

REDES NEURAS ARTIFICIAIS PARA RENDIMENTO DO HARVESTER E
FORWARDER EM COLHEITA DE EUCALIPTO NA REGIÃO VALE DO RIO
DOCE EM MINAS GERAIS

CURITIBA

2016

UBIRAJARA COELHO MACHADO

**REDES NEURAS ARTIFICIAIS PARA RENDIMENTO DO HARVESTER E
FORWARDER EM COLHEITA DE EUCALIPTO NA REGIÃO VALE DO RIO
DOCE EM MINAS GERAIS**

Trabalho apresentado como requisito parcial à obtenção do grau de MBA em Gestão Florestal no curso de pós-graduação em Gestão Florestal, Departamento de Economia Rural e Extensão, Setor de Ciências Agrárias da Universidade Federal do Paraná.

Orientadora: Dra. Aline Edwiges Mazon Alcântara

CURITIBA

2016

AGRADECIMENTOS

À Deus, pela vida, presença e cuidado em minha vida.

À Universidade Federal do Paraná por meio do Programa de Educação Continuada em Ciências Agrárias, pela oportunidade concedida.

À parceira de trabalho e amiga Aline Mazon, pela orientação neste trabalho, disposição, dedicação e ensinamentos.

Aos meus gestores, José Márcio e Mauro Werneburg pelo apoio e confiança.

À Paula Ventura pelas dicas e materiais de apoio.

Aos colegas da CENIBRA, Bruno Ricardo e Luciano Gusmão pela contribuição e fornecimento de dados.

Em especial, à Deise, Mariana e Lucas, amores da minha vida, pelo carinho, torcida, incentivo, e compreensão nos momentos ausentes.

À todos aqueles, que de alguma maneira, contribuíram para realização deste trabalho.

RESUMO

O objetivo deste estudo foi utilizar a metodologia das Redes Neurais Artificiais (RNA) para estimar os rendimentos médios nas operações de colheita florestal utilizando equipamentos *harvester* e *forwarder*. Os dados utilizados foram provenientes de registros diários de derrubada, processamento e baldeio em plantios florestais de clones de eucalipto de uma empresa de celulose situada na região do Vale do Rio Doce, no leste de Minas Gerais. O percentual de dados para treinamento e generalização das redes foi de 80% e 20% respectivamente. Foram treinadas redes do tipo *Multilayer Perceptron (MLP)* e o algoritmo de treinamento foi o *Resilient Propagation (RPROP)*. Por meio da avaliação constatou-se uma boa correlação entre os valores observados e estimados pelas RNA. Conclui-se que as RNA apresentaram resultados satisfatórios na estimação de rendimentos operacionais para os distintos sistemas de colheita em plantios florestais de clones de eucalipto.

Palavras-chave: Redes neurais artificiais. Colheita de eucalipto. Rendimentos operacionais.

ABSTRACT

The objective of this study was to use the Artificial Neural Networks (ANN) methodology to estimate the average yields in the harvesting operations using harvester and forwarder equipment. The used data came from daily records of cutting down, processing and yarding the wood in forest plantations of eucalyptus clones from a pulp company located in the Vale do Rio Doce region, in the east of Minas Gerais. The percentage of data for training and generalization of the networks was 80% and 20%, respectively. Multilayer Perceptron (MLP) networks were trained and the training algorithm was the Resilient Propagation (RPROP). Through the evaluation, a good correlation between the values observed and estimated by ANN was verified. It was concluded that ANN presented satisfactory results in the estimation of operational yields for the different harvesting systems in forest plantations of eucalyptus clones.

Keywords: Artificial neural networks. Eucalyptus harvest. Operating yields.

LISTA DE FIGURAS

FIGURA 1 – PRODUTIVIDADE FLORESTAL NO BRASIL VERSUS OUTROS PAÍSES DESTAQUES NO SETOR FLORESTAL.....	1
FIGURA 2 – ESTRUTURA DE UM EXEMPLO DE REDE NEURAL ARTIFICIAL.....	4
FIGURA 3 – HARVESTER 6X6 JOHN DEERE.....	6
FIGURA 4 – FORWARDER 8X8 JOHN DEERE.....	7
FIGURA 5 – MECANIZAÇÃO DA COLHEITA POR GRAU DE INCLINAÇÃO DO TERRENO	7
FIGURA 6 – GUINCHO PARA TRAÇÃO EM TERRENOS COM INCLINAÇÃO ENTRE 27° E 35°.....	8
FIGURA 7 – RESULTADOS RNA HARVESTER	13
FIGURA 8 – RESULTADOS RNA FORWARDER.....	14

LISTA DE TABELAS

TABELA 1 – DADOS UTILIZADOS PARA PROCESSAMENTO DAS RNA.	9
TABELA 2 – VARIÁVEIS UTILIZADAS NA RNA POR EQUIPAMENTO.	10
TABELA 3 – RAIZ QUADRADA DO ERRO QUADRÁTICO MÉDIO (RQME) E CORRELAÇÃO ENTRE OS RENDIMENTOS OBSERVADOS E ESTIMADOS (R Y_I, \hat{Y}_I).....	12

LISTA DE ABREVIATURAS E/OU SIGLAS

RNA: Redes Neurais Artificiais.

VMI: Volume Médio Individual.

PD: Colheita Padrão – Terreno com inclinação entre 0° e 27°.

GW: Colheita com Guincho *Work* – Terreno com inclinação entre 28° e 35°.

SC: Sem Casca.

CC: Com Casca.

IBA: Indústria Brasileira de Árvores.

CENIBRA: Celulose Nipo-Brasileira S.A.

SUMÁRIO

1. INTRODUÇÃO.....	1
2. MATERIAL E MÉTODOS	6
2.1 Equipamentos <i>Harvester</i> e <i>Forwarder</i>	6
2.2 Dados.....	9
2.3 Variáveis, treinamento e generalização das RNA	9
2.4 Avaliação das estimativas	11
3. RESULTADOS	12
4. DISCUSSÃO.....	15
5. CONCLUSÕES.....	16
6. REFERÊNCIAS BIBLIOGRÁFICAS	17

1. INTRODUÇÃO

Um dos fatores do sucesso dos empreendimentos florestais no Brasil é resultado da produtividade das árvores plantadas no país. A figura 1 compara as produtividades médias dos países destaques em produção de florestas plantadas de no ano de 2014.

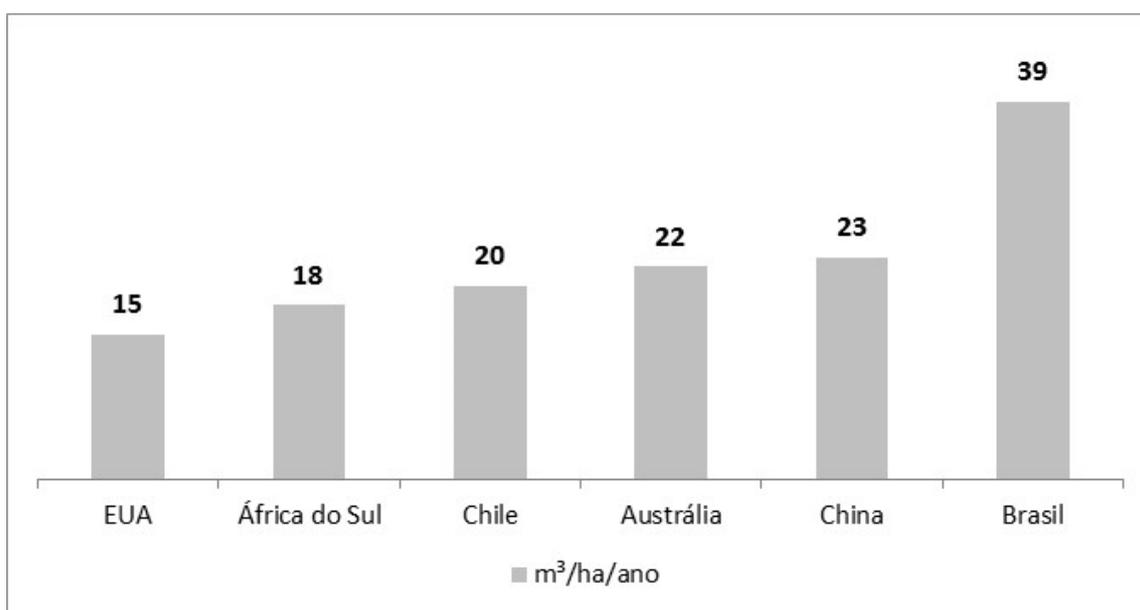


FIGURA 1 – PRODUTIVIDADE FLORESTAL NO BRASIL VERSUS OUTROS PAÍSES DESTAQUES NO SETOR FLORESTAL.

FONTE (IBÁ, 2015).

De acordo com SILVA (1996), a posição privilegiada que o Brasil ocupa em termos de florestas plantadas, com relação a outros países, é devida a uma série de vantagens comparativas, a saber:

- o país possui grande extensão territorial, com disponibilidade de terras para reflorestamentos.
- as condições de solo e clima são favoráveis ao cultivo de espécies florestais;
- as árvores atingem a idade de corte mais rapidamente do que nos países de clima temperado ou frio; e

- o país já possui, em determinados segmentos, por exemplo no de celulose e papel, tecnologia adequada e competitiva, bem como infraestrutura desenvolvida.

Diante de toda demanda existente e das potencialidades territoriais do Brasil, a cobertura florestal de eucalipto atingiu 5,6 milhões de hectares de florestas plantadas de eucalipto em 2014 (IBÁ, 2015), sendo o estado de Minas Gerais com maior participação, 1,4 milhões de hectares representando 25%.

O crescimento da demanda de produtos florestais incentivou o planejamento dos processos produtivos nas empresas, valorizando o grau de competitividade nas mesmas. Dentro deste setor, uma das atividades considerada mais importante é a colheita florestal, visto ser a mais onerosa em termos de custo de produção (FREITAS, 2005).

A colheita florestal sempre foi de grande atenção por parte das empresas consumidoras de madeira devido a alta representatividade nos custos da produção e a elevada demanda de mão de obra, e também pela natureza desgastante do trabalho juntamente com o elevado nível de risco de acidentes. Com a abertura das importações, a mecanização da colheita se intensificou no final da década de 90. Com isso, verificaram-se ganhos expressivos na utilização de mão de obra além da redução da frequência e gravidade dos acidentes de trabalho, resultando no contínuo aumento do grau de mecanização da colheita (BRAMUCCI, 2001)

Nas últimas décadas o setor florestal brasileiro vem se destacando devido ao avanço tecnológico empregado nos processos da cadeia de produção madeireira.

A intensificação da mecanização no processo de colheita tem proporcionado às empresas florestais oportunidades, tais como: o aumento de produtividade, a redução de mão de obra, do custo de colheita e de acidentes de trabalho. Por outro lado, empresas florestais possuem grandes desafios para manter o lucro, uma vez que estas não têm influência no preço de venda do produto e, além disso, necessitam constantemente buscar inovações tecnológicas para neutralizar o efeito crescente dos aumentos inflacionais nos custos das atividades.

Machado e Lopes (2002) define Sistema de Colheita Florestal como “um conjunto de atividades, integradas entre si, que permitem o fluxo constante de

madeira, evitando-se os pontos de estrangulamento, levando os equipamentos à sua máxima utilização”.

Os sistemas de colheita podem variar de acordo com vários fatores, dentre eles topografia do terreno, rendimento volumétrico do povoamento, tipo de floresta, uso final de madeira, máquinas, equipamentos e recursos disponíveis (MACHADO, 2002).

No Brasil, o sistema de toras curtas (*cut-to-length*) é largamente utilizado na colheita do gênero *Eucalyptus*. Segundo Malinovski *et. al.* (2002), neste sistema a árvore é processada no local de derrubada, sendo extraída para a margem da estrada ou para o pátio temporário em forma de pequenas toras, ou seja, com até 6 metros de comprimento.

A colheita florestal em áreas acidentadas ou em condições topográficas desfavoráveis exige um alto nível de planejamento e detalhamento. Também é necessário o desenvolvimento de máquinas e equipamentos específicos para essas condições, com o objetivo de minimizar os custos, diminuir a necessidade de mão de obra e aumentar a produtividade (LIMA e LEITE, 2002).

Para subsidiar o processo de planejamento de produção das empresas florestais é necessário conhecer os rendimentos operacionais, os quais são elementos fundamentais para a gestão dos custos e atividades. Considerando que existem diversas variáveis de influência que interferem diretamente na capacidade operacional dos equipamentos e, por consequência, no resultado final da produção de madeira, a estimativa das produtividades torna-se fundamental para o processo de planejamento florestal.

A utilização de técnicas computacionais, como Redes Neurais Artificiais, tem sido amplamente empregada no processo florestal devido as oportunidades nos aspectos de estimativa de resultados e tomada de decisões, bem como redução de custos operacionais.

O conceito de RNA definido por BULLINARIA (2014) e citado por ALCÂNTARA (2015), é um sistema computacional paralelo constituído de várias unidades de processamento simples conectadas entre si de uma maneira específica para desempenhar uma determinada tarefa. A figura 2 ilustra as redes de neurônios artificiais.

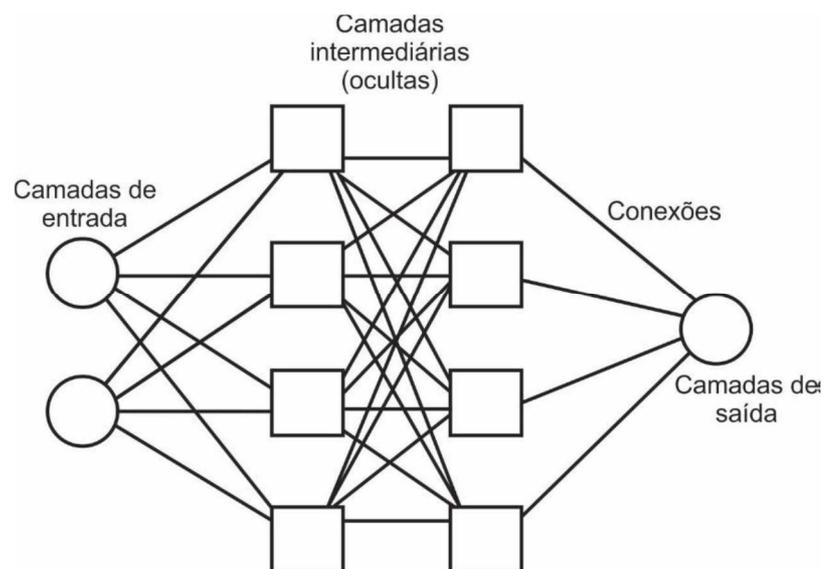


FIGURA 2 – ESTRUTURA DE UM EXEMPLO DE REDE NEURAL ARTIFICIAL.

FONTE: Binoti (2010).

Segundo Haykin (2001), uma rede neural artificial é uma máquina projetada para modelar, semelhante ao cérebro, uma tarefa ou função de interesse, com capacidade de armazenar conhecimento experimental e torná-lo disponível para uso. O bom desempenho de uma RNA se deve à interligação de suas unidades de processamento (neurônio artificiais).

As Redes Neurais Artificiais podem ser classificadas quanto ao número de camadas: rede de camada única (apresentam apenas uma camada de neurônios de processamento) e rede de múltiplas camadas (apresentam uma ou mais camadas de neurônios intermediárias, ou seja, camadas que se encontram entre a camada de entrada e a camada de saída). Quanto ao tipo de conexões: rede do tipo *feedforward* (redes acíclicas) ou feedback (cíclicas, ou seja, possuem pelo menos uma conexão de realimentação). E quanto à conectividade: rede totalmente conectada (cada neurônio de uma camada está conectado a todos os neurônios da camada seguinte) e rede parcialmente conectada (falta alguma conexão na rede) (BULLINARIA, 2014).

Os principais modelos de RNA utilizados para fins de previsão de variáveis contínuas são as redes MPL (*Multilayer Perceptron*) (HAYKIN, 2001). Um Perceptron de múltiplas camadas possui uma ou mais camadas ocultas (intermediárias), além da camada de entrada e de saída. Os sinais de entrada

propagam para frente através da rede, camada por camada, ou seja, são classificadas como *feedforward*.

O treinamento é do tipo supervisionado com o algoritmo de retropropagação do erro (*ErrorBackPropagation*), com base na regra de aprendizagem por correção do erro.

Segundo Heaton (2011), o algoritmo de retropropagação é o mais usado em aprendizagem supervisionada em Redes Neurais Artificiais de múltiplas camadas. A ideia básica desse algoritmo é a repetição da aplicação de uma cadeia de regras para calcular a influência de cada peso da rede com respeito à arbitrariedade da função de erro. Algoritmos tais como o de retropropagação utilizam a “descida do gradiente” para ajustar os parâmetros das redes para melhor adaptar um conjunto de treinamento de pares entrada e saída.

Vários outros algoritmos de adaptação da aprendizagem foram desenvolvidos para lidar com o problema de calcular o valor apropriado dos pesos, um desses algoritmos é o *Resilient Propagation* (RPROP), o qual efetua a adaptação direta do peso, baseado na informação do gradiente local, não sendo esta adaptação influenciada pelo comportamento do gradiente. Ele apresenta um desempenho melhor do que o algoritmo de retropropagação do erro, pois necessita de um número menor de iterações para convergir para uma solução com uma determinada taxa de erro (HEATON, 2011).

Os estudos na área de RNA se justificam por diversas propriedades úteis e capacidades das redes como: não linearidade (propriedade importante, principalmente se o mecanismo físico responsável pela geração do sinal de entrada for inerentemente não linear), adaptabilidade (uma rede treinada para operar em um ambiente específico pode ser retreinada para lidar com modificações, e atuando em ambiente não estacionário, uma rede pode ser projetada para modificar seus pesos em tempo real), tolerância a falhas e ruídos, aprendizagem e generalização a partir de dados de treinamento, paralelismo que as tornam muito eficientes, uniformidade de análise e projeto e analogia neurobiológica (HAYKIN, 2001; BRAGA; CARVALHO; LUDEMIR, 2007; BULLINARIA, 2014).

Desta forma, o objetivo deste trabalho foi estimar o rendimento médio do *harvester* e do *forwarder*, em plantios florestais de clones de eucalipto, aplicando a metodologia de RNA.

2. MATERIAL E MÉTODOS

2.1 Equipamentos *Harvester* e *Forwarder*

O presente estudo contempla a análise das produções de 19 tratores florestais utilizados no processo de colheita de eucalipto, sendo 11 *harvester* e 8 *forwarder*, ambos fabricados pela empresa estadunidense John Deere.

Os equipamentos *harvester* utilizados pela empresa é de 19 toneladas com tração 6x6 que utiliza um cabeçote processador para realizar o corte, a derrubada, o descascamento, o desgalhamento e o traçamento da árvore em toretes de comprimentos pré-determinados. Possui sistema de nivelamento na grua e na cabine bem como acompanhamento automático da grua pela cabine (Figura 3).



FIGURA 3 – HARVESTER 6X6 JOHN DEERE.

FONTE: CENIBRA.

O modelo dos equipamentos *forwarder* utilizado na operação possuem tração 8x8 que utiliza uma grua e caixa de carga para realizar o baldeio de dentro do talhão para a borda da estrada, empilhando os toretes para futuro

carregamento e transporte. Possui sistema de giro e nivelamento na cabine e acompanhamento automático da grua pela cabine (Figura 4).



FIGURA 4 – FORWARDER 8X8 JOHN DEERE.

FONTE: CENIBRA.

Em função da característica de inclinação do terreno em que as florestas da empresa em estudo estão implantadas, a operação de colheita é realizada considerando duas modalidades, Colheita padrão (PD) de 0 a 27° e Colheita Guincho *Work* (GW) de 28 a 35° (Figura 5).

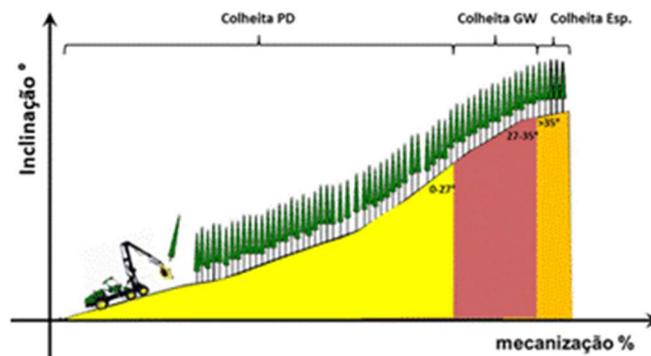


FIGURA 5 – MECANIZAÇÃO DA COLHEITA POR GRAU DE INCLINAÇÃO DO TERRENO

FONTE: CENIBRA.

Para as operações realizadas em terrenos com inclinação entre 28° e 35°, a empresa utiliza nos equipamentos *harvester* e *forwarder* um guincho de tração (figura 6) acoplado tendo como objetivo auxiliar a tração das máquinas.



FIGURA 6 – GUINCHO PARA TRAÇÃO EM TERRENOS COM INCLINAÇÃO ENTRE 27° E 35°.

FONTE: CENIBRA.

No caso da operação do *harvester* e *forwarder* com uso de guincho, estas máquinas estarão sobre o solo e sob ação das forças intervenientes eliminando o efeito de queda livre.

2.2 Dados

Os dados utilizados neste trabalho foram fornecidos por uma empresa de celulose situada na região do Vale do Rio Doce, em Minas Gerais, a qual utiliza o sistema de “toras curtas” (*cut-to-length*).

Os dados correspondem às medições diárias das operações de colheita em um período de 30 meses para o *harvester* e 6 meses para o *forwarder*, conforme resumo expressado na Tabela 1.

Equipamento	Sistema	Produto	Σ Volume (m ³)	Σ Horas
Harvester	PD	SC - 6,30 m	2.338.918	98.571
		CC - 3,30 m	136.505	5.542
	GW	SC - 6,30 m	319.544	17.856
Sub-total Harvester			2.794.967	121.969
Forwarder	PD	SC - 6,30 m	329.604	8.889
		CC - 3,30 m	39.401	1.705
	GW	SC - 6,30 m	56.904	2.022
Sub-total Forwarder			425.908	12.616
Total Geral			3.220.875	134.584

TABELA 1 – DADOS UTILIZADOS PARA PROCESSAMENTO DAS RNA.

FONTE: O AUTOR.

De posse da base de dados, foram determinados os estratos para construção e aplicação das RNA.

2.3 Variáveis, treinamento e generalização das RNA

Os dados foram agrupados por faixa de declividade, sortimento da madeira (com casca ou sem casca) e comprimento da tora para cada equipamento.

As variáveis quantitativas utilizadas para o treinamento das RNA foram o VMI (volume médio individual) para o *harvester* e a distância de baldeio para o *forwarder* (Tabela 2). Essas variáveis foram utilizadas por influenciarem

diretamente nas atividades no campo e conseqüentemente, terem maior relação com o rendimento.

Equipamento	Variáveis Qualitativas	Variáveis Quantitativas	Variável de saída
Harvester	Faixa de declividade; Comprimento da tora;	VMI (m ³ /arv)	Rendimento medio (m ³ /h)
Forwarder	Sortimento da madeira (com casca ou sem casca)	Distância de baldeio (metros)	

TABELA 2 – VARIÁVEIS UTILIZADAS NA RNA POR EQUIPAMENTO.

FONTE: O AUTOR.

O percentual de dados utilizados para o treinamento foi de 80% e o percentual de dados utilizados para generalização foi de 20% a partir de seleção aleatória. Por se tratar de uma base de dados grande e abrangente, a seleção aleatória não afeta a representatividade das amostras selecionadas.

O software utilizado para o treinamento e aplicação das redes foi o *Neuroforest*® (versão 3.3). Foram treinadas redes neurais artificiais para estimativa do rendimento médio, do tipo *Multilayer Perceptron (MLP)*, totalizando três camadas: uma de entrada; uma intermediária; e uma de saída. O algoritmo de treinamento utilizado foi o *Resilient propagation (RPROP+)*.

Quanto à definição da arquitetura das redes, o número de neurônios da camada de entrada variou de acordo com o número de variáveis consideradas em cada estudo. Foram utilizados 12 neurônios na camada intermediária e um neurônio na camada de saída. A função de ativação utilizada para as camadas oculta e de saída foi do tipo *sigmoidal*.

O critério de parada utilizado foi o erro médio ou o número de ciclos, ou seja, o treinamento da rede foi finalizado quando o primeiro parâmetro foi atingido. O limite de parada foi de 0,0001 para o erro médio e 3.000 para o número de ciclos.

2.4 Avaliação das estimativas

A avaliação das estimativas das Redes Neurais Artificiais nas etapas de treinamento e validação foi feita por estatísticas e análises gráficas. As estatísticas utilizadas foram: a correlação entre os volumes estimados e observados; a raiz quadrada do erro quadrático médio (RQEM); e o erro médio percentual (erro%).

$$r(y_i, \hat{y}_i) = \frac{\text{cov}(y_i, \hat{y}_i)}{\sqrt{V(y_i) \cdot V(\hat{y}_i)}} \quad RQEM = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n - 1}} \quad \text{erro} (\%) = \frac{(\hat{y}_i - y_i)}{y_i} \cdot 100$$

Em que

y_i e \hat{y}_i = rendimentos observado e estimado da variável sob análise;

n = número de casos;

V = variância da amostra; e

cov = covariância.

A correlação entre os volumes observados e estimados indicam o grau de associação e a direção da relação entre as duas variáveis (CAMPOS; LEITE, 2013). Quanto mais próxima de 1, maior a correlação entre as variáveis.

A raiz quadrada do erro quadrático médio avalia o erro entre os volumes observados e os estimados, sendo que quanto menor o RQEM, maior a precisão da estimativa (MEHTÄTALO; MALTAMO; KANGAS, 2006). Quando o número de observações tende para o infinito, o RQEM pode ser interpretado como erro padrão residual.

A análise gráfica dos erros (resíduos) também foi utilizada na avaliação dos modelos de redes neurais, sendo construídos histogramas com a frequência de casos por classe de erro percentual e gráficos de rendimento observado *versus* rendimento estimado.

3. RESULTADOS

Na Tabela 3 são apresentadas as estimativas da raiz quadrada do erro quadrático médio (RQEM) e da correlação entre os rendimentos observados e estimados (r_{y_i, \hat{y}_i}) com base no percentual de treinamento e generalização.

Equipamento	Sistema	Produto	Treinamento (%)	Generalização (%)	Análise	RQEM (%)	r_{y_i, \hat{y}_i}
Harvester	PD	SC - 6,30 m	80	20	Treinamento	5,63	0,6152
					Generalização	5,88	0,5749
		CC - 3,30 m	80	20	Treinamento	6,12	0,4940
					Generalização	7,59	0,3502
	GW	SC - 6,30 m	80	20	Treinamento	7,25	0,3909
					Generalização	6,83	0,3823
Forwarder	PD	SC - 6,30 m	80	20	Treinamento	8,76	0,3919
					Generalização	8,20	0,3980
		CC - 3,30 m	80	20	Treinamento	5,22	0,5096
					Generalização	5,83	0,5208
	GW	SC - 6,30 m	80	20	Treinamento	9,32	0,1515
					Generalização	7,87	0,1899

TABELA 3 – RAIZ QUADRADA DO ERRO QUADRÁTICO MÉDIO (RQME) E CORRELAÇÃO ENTRE OS RENDIMENTOS OBSERVADOS E ESTIMADOS (R_{Y_i, \hat{Y}_i})

FONTE: O AUTOR.

Na figura 7 são apresentados os resultados para os equipamentos *harvester* por faixa de inclinação e sortimento da madeira, demonstrando os rendimentos observados e estimados *versus* VMI, bem como o gráfico da frequência percentual dos erros percentuais das estimativas de rendimento pelas Redes Neurais Artificiais em função das classes de erros percentuais. Os números em cada barra indicam os percentuais de casos por classe de erro (%).

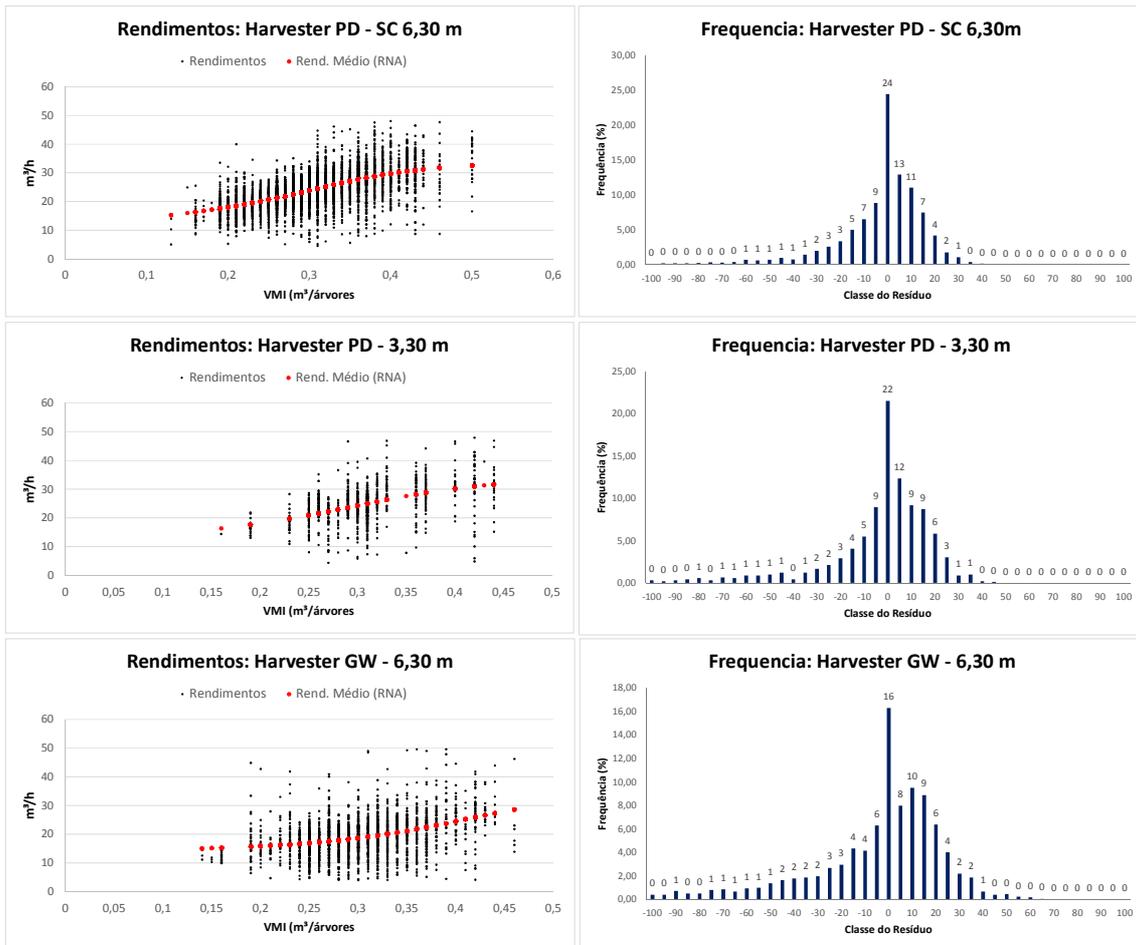


FIGURA 7 – RESULTADOS RNA HARVESTER

FONTE: O AUTOR.

A figura 8 apresenta os resultados para os equipamentos *forwarder* por faixa de inclinação e sortimento a madeira, demonstrando os rendimentos observados e estimados pela distância de baldeio, bem como o gráfico da frequência percentual dos erros percentuais das estimativas de rendimento pelas redes neurais artificiais em função das classes de erros percentuais. Os números em cada barra indicam os percentuais de casos por classe de erro (%).

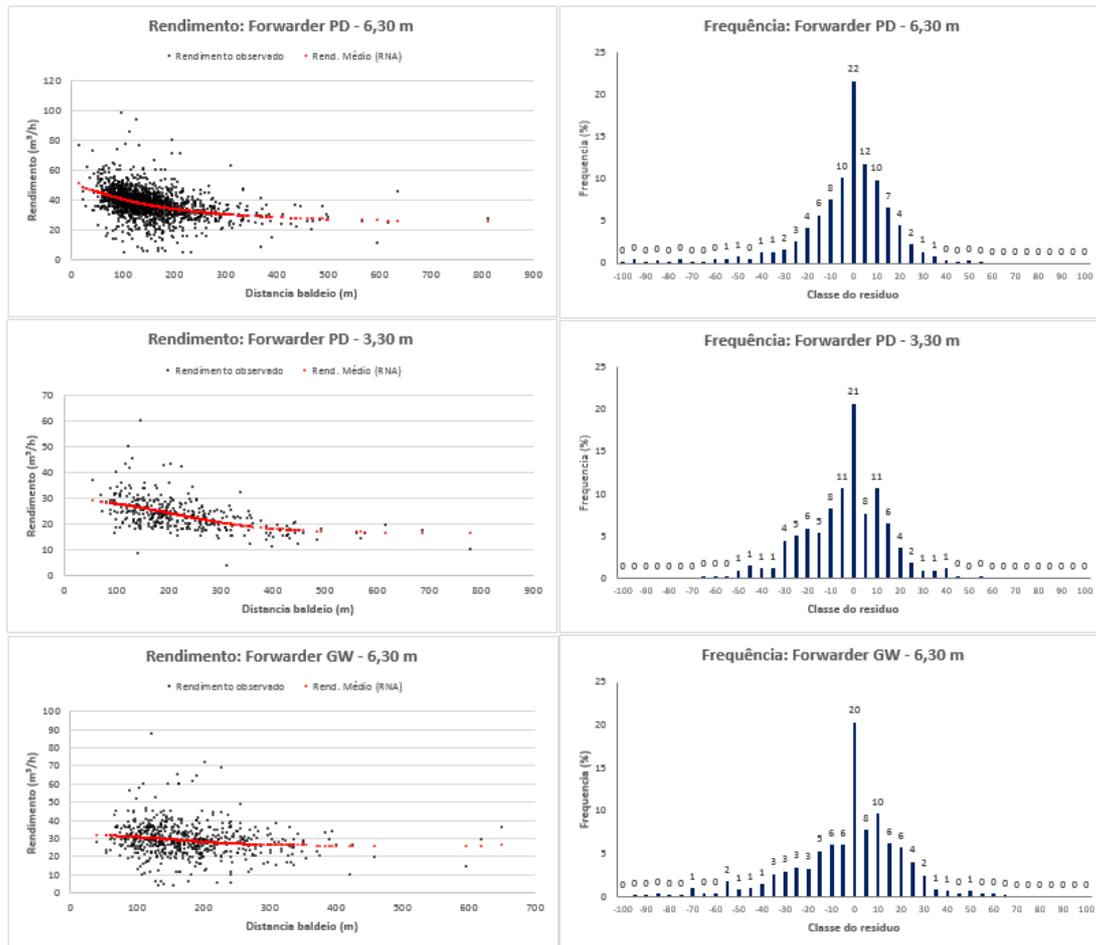


FIGURA 8 – RESULTADOS RNA FORWARDER.

FONTE: O AUTOR.

4. DISCUSSÃO

De acordo com a Tabela 3, a raiz quadrada do erro quadrático médio (RQEM) não apresentou grandes variações. Para ambos equipamentos, a baixa variação dos valores entre o treinamento e a generalização indicam que as redes podem ser aplicadas para novas bases de dados para esta região, estimando valores dentro desta faixa de variação de RQEM.

No caso do *harvester*, a RQEM variou entre 5,633 a 7,595, já a correlação variou entre 0,315 a 0,650. Para os dados do *forwarder*, a RQEM variou entre 5,225 a 9,321 e a correlação variou entre 0,151 a 0,398.

Existe uma grande dispersão dos dados observados quando comparados com os dados estimados (Figuras 7 e 8). Isso se deve ao fato de outras variáveis influenciarem no rendimento. Essa alta dispersão explica dos baixos valores de correlação (r_{y_i, \hat{y}_i}) apresentados na Tabela 3. Porém, apesar deste fato, as variáveis apresentam uma boa tendência dos dados e são eficientes para expressar curvas médias de rendimento, atendendo o objetivo proposto.

Os resíduos apresentam distribuição com tendência normal. Isso indica que não houve tendências em subestimar ou superestimar as estimativas das Redes Neurais Artificiais.

Considerando o intervalo 20 a -20% da frequência percentual dos erros percentuais das estimativas de rendimento, os resultados do *harvester* para o sistema Padrão SC foi de 83%, Padrão CC 79% e Guincho SC 66%. No mesmo critério avaliativo, os resultados do *forwarder* foi de 82% para o sistema Padrão SC, 79% para Padrão CC e 70% para Guincho SC. Estes valores indicam que as redes são capazes de fazer boas estimativas de curvas médias de rendimentos.

Devido a capacidade de generalização das RNA, uma única rede foi capaz de estimar rendimentos para diferentes sistemas em equipamentos distintos. Caso o rendimento fosse estimado com modelos matemáticos, o planejado deveria avaliar as estimativas ajustando 6 modelos diferentes.

5. CONCLUSÕES

Os resultados do estudo permitem concluir que:

- As RNA são eficientes para estimar curvas médias de rendimento na colheita de *harvester* e *forwarder* em plantios florestais de clones de eucaliptos na região do vale do Rio Doce e podem ser utilizadas para fins de manejo florestal.
- As RNA quando comparadas com modelos matemáticos podem promover maior agilidade ao planejador florestal no processamento das estimativas de rendimento, tornando o processo mais prático e menos oneroso.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ALCANTARA, A. E. M. Redes Neurais Artificiais para prognose do crescimento e da produção de povoamentos de eucalipto em Minas Gerais. 2015. 65 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2015.

BINOTI, M. L. M. S. **Rede neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54 f. Dissertação (Mestrado) – Universidade Federal de Viçosa, Viçosa, 2010.

BULLINARIA, J. A. Introduction to neural computation: notas de aula. 2014. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/inc.html>>.2014.

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Redes Neurais Artificiais**: Teoria e Aplicações. 2. ed. Rio de Janeiro: LTC, 2007.

BRAMUCCI, MARCELO – Determinação e quantificação de fatores de influência sobre a produtividade do “Harvester” na Colheita de madeira; Piracicaba, 2001.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal**: Perguntas e respostas. 4. ed. Viçosa: UFV, 2013. 605 p.

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

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

HEATON, J. **Introduction to the math of neural networks (Beta-1)**. St. Louis, 2011. 92 p.

IBÁ 2015, Anuário. **Indústria Brasileira de Árvores**, Brasília, 30p. 2015.

MACHADO, C. C.: LOPES, E. S. Planejamento. In: MACHADO, C. C. (Org.). **Colheita florestal**. Viçosa, MG: UFV, Imprensa Universitária, 2002. 468 p.

MALINOVSKI, J.R.; CAMARGO, C.M.S.; MALINOVSKI, R.A. Sistemas. In: MACHADO, C.C. (Org.). **Colheita florestal**. Viçosa: UFV / Imprensa Universitária, 2002. p.145-167.

MEHTÄTALO, 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.

LIMA, J.S.S.; LEITE, A.M.P. Mecanização. In: MACHADO, C.C. (Org). Colheita florestal. Viçosa: UFV / Imprensa Universitária, 2002. p.33-54.

SILVA, M.L. *Análise econométrica do mercado brasileiro de celulose e de papel e papelão*. Viçosa: UFV, 1996. 120p. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, 1996.