



THOMAZ AURELIO BASTOS

**MODELAGEM DA PRODUTIVIDADE PELA GARRA
TRAÇADORA NO PROCESSAMENTO DE MADEIRA**

**LAVRAS - MG
2019**

THOMAZ AURELIO BASTOS

**MODELAGEM DA PRODUTIVIDADE PELA GARRA TRAÇADORA NO
PROCESSAMENTO DE MADEIRA**

Relatório de estágio apresentado à
Universidade Federal de Lavras, como parte
das exigências do Curso de Engenharia
Florestal, para a obtenção do título de
Bacharel.

Prof. Dr. Lucas Rezende Gomide
Orientador

Msc. Isáira Leite e Lopes
Coorientadora

**LAVRAS – MG
2019**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha
Catalográfica da Biblioteca Universitária da UFLA, com dados
informados pelo(a) próprio(a) autor(a).**

Bastos, Thomaz Aurelio.

Modelagem da produtividade pela garra traçadora no
processamento de madeira / Thomaz Aurelio Bastos. - 2019.
23 p.

Orientador(a): Lucas Rezende Gomide.

Relatório de Estágio (graduação) - Universidade Federal de
Lavras, 2019.
Bibliografia.

1. Garra Traçadora. 2. Planejamento florestal. 3. Aprendizado
de Máquina. I. Gomide, Lucas Rezende. II. Título.

THOMAZ AURELIO BASTOS

**MODELAGEM DA PRODUTIVIDADE PELA GARRA TRAÇADORA NO
PROCESSAMENTO DE MADEIRA**

Relatório de estágio apresentado à Universidade Federal de Lavras, como parte das exigências do Curso de Engenharia Florestal, para a obtenção do título de Bacharel.

APROVADO em 13 de Junho de 2019.

Lucas Rezende Gomide	UFLA
Isáira Leite e Lopes	UFLA
Gustavo Pereira Castro	KLABIN SA

Prof. Dr. Lucas Rezende Gomide
Orientador

Msc. Isáira Leite e Lopes
Coorientadora

**LAVRAS – MG
2019**

AGRADECIMENTOS

À Deus por todo apoio e companhia pelas etapas que passaram e estão por vir.

À Universidade Federal de Lavras e ao Departamento de Ciências Florestais pelas oportunidades, aprendizados e experiência vivenciadas.

Aos grandes amigos conquistados nesta caminhada, em especial ao Professor Paulo Trugilho, Professor Lucas Gomide, laboratório de Biomateriais e GOPLAN pelo auxílio durante a graduação, paciência e disponibilidade em compartilhar conhecimento.

Aos membros da banca Lucas Gomide, Isáira Leite e Lopes e Gustavo Castro pela participação e disponibilidade em contribuir com o trabalho feito.

Em especial a minha coorientadora Isáira Leite e Lopes que me ajudou de forma excelente, tanto para realização deste trabalho quanto ao meu crescimento profissional e pessoal. (muito obrigado!)

À minha mãe Clélia Damas Bastos por todo amor e por nunca medir esforços para a minha formação pessoal e profissional.

Ao meu pai Caio Márcio Bastos, minha irmã Gesane Damas Bastos e meu irmão Túlio Márcio Bastos pelo apoio durante a caminhada.

Aos meus sobrinhos Miguel Bastos e Gabriel Bastos por me alegrarem mesmo que distantes. Enfim, de modo geral minha família, que considero base para minha vida.

À todos os amigos de Cana Verde que sempre estiveram por perto torcendo por mim.

Meus sinceros OBRIGADO a todos.

“Por menor que seja o projeto que você está trabalhando, e o que quer que seja, ponha nele seu coração, sua alma e sua responsabilidade.” (Frank Gehry)

RESUMO

A colheita florestal é uma das atividades que mais influenciam no custo total das operações florestais. Essa atividade demanda análise criteriosa das variáveis que influenciam a produtividade do corte florestal, visando sua otimização. O presente trabalho teve como objetivo avaliar a influência de variáveis na estimativa da produtividade do corte florestal com uso da garra traçadora, bem como a comparação entre o *random forest* e sua combinação com o algoritmo genético. Foram avaliadas variáveis referentes ao Inventário florestal (espécie, idade do talhão, volume médio individual das árvores), clima (temperatura máxima, temperatura mínima e precipitação), solo (tipo de solo e textura de solo) e registros de produção do operador (turno, horas efetivas de trabalho e experiência do operador). Para isto, os dados foram divididos aleatoriamente para treinamento (80%) e validação (20%). Os métodos utilizados foram o *Random Forest* (RF) e a sua combinação com o algoritmo genético (AG+RF), para a avaliação das variáveis preditoras na estimativa da produtividade na colheita florestal. Assim, diante da complexidade de modelagem da produtividade de corte florestal, observou-se que a seleção das variáveis resultante do AG+RF alcançou resultados estatísticos satisfatórios para a validação com melhoria de 1,77% no RMSE em comparação com o modelo RF, com apenas 4 variáveis selecionadas: experiência do operador, volume médio individual das árvores, espécie e turno. Portanto, essas variáveis podem dar suporte aos gestores florestais na adoção de melhorias para o controle da produtividade, evidenciando um amplo campo para oportunidades de otimização.

Palavras-chave: Garra Traçadora, Planejamento florestal, Aprendizado de Máquina.

Modeling of productivity by grapple saw in wood processing

ABSTRACT

The forest harvesting is one of the activities that most influences the total cost of the wood delivery at the paper and pulp mill. This activity requires a detailed analysis in the variables that influence the forest cutting productivity, aiming at its optimization. The objective of this study was to evaluate the influence of variables on the productivity estimation using a grapple saw cutting trees on roadside. Variables related to forest inventory (species, field age, individual average volume of trees), climate (maximum temperature, minimum temperature and precipitation), soil (soil type and soil texture) and operator production records (shift, effective working hours and operator experience) were evaluated. For this, the data were randomly divided in training (80%) and validation (20%). The methods used were Random Forest (RF) and its combination with Genetic Algorithm (AG + RF), for the evaluation of the predictive variables in the estimation of productivity in the forest harvest. Therefore, given the complexity of modeling forest productivity, it was observed that the selection of the variables resulting from the GA + RF achieved satisfactory statistical results with a 1.77% improvement in RMSE in comparison to the RF model, with only 4 variables selected: worker experience, individual average volume of trees, species and shift. Therefore, these variables can support the forest managers in the adoption of improvements to the productivity control, evidencing a wide field for optimization opportunities.

Keywords: Grapple Saw, Forestry planning, Machine learning.

SUMÁRIO

1	INTRODUÇÃO	9
2	MATERIAL E MÉTODOS.....	11
2.1	Descrição da área de estudo	11
2.2	Base de dados.....	11
2.3	Modelagem e seleção de variáveis para a predição da produtividade do corte.....	12
2.4	Avaliação dos métodos de predição	13
3	RESULTADOS E DISCUSSÃO	15
4	CONCLUSÃO	20
	REFERÊNCIAS	21

1 INTRODUÇÃO

A colheita florestal é considerada muito importante dentro da cadeia produtiva pois, aliada a melhoria de métodos silviculturais e ao melhoramento florestal possibilitou o crescimento do setor florestal, tornando-o competitivo frente a outros mercados. A execução das operações de colheita florestal é complexa, demandando assim conhecimento e planejamento com a finalidade de tornar esta atividade economicamente viável, ambientalmente correta, segura e principalmente produtiva (SHE; CHUNG; KIM, 2018). Devido aos fatos expostos, as empresas estão atentas às novas máquinas florestais que surgem no mercado, refletindo em suas operações florestais com elevado nível tecnológico. Esse cenário permite grandes inovações no processo produtivo, possibilitando a geração de dados, monitoramento e controle das atividades que acontecem no campo, auxiliando na melhor condução da empresa (NASCIMENTO et al., 2011).

Os dados coletados em campo têm sido amplamente utilizados para a extração de conhecimento sobre a produtividade de máquinas (STRANDGARD; MITCHELL; ACUNA, 2016), que consiste em uma tarefa desafiadora, visto que a mesma varia em função de diferentes variáveis, como exemplo, espécie, terreno, características do maquinário, tamanho da árvore e treinamento do operador (SILAYO; MIGUNGA, 2014). Entretanto, o elevado número de variáveis disponíveis pode demandar técnicas robustas para sua análise. Além disso, os mesmos podem conter ruídos ou características não lineares, exigindo uma seleção prévia para assegurar boa capacidade preditiva dos modelos que serão gerados (BURGEL; ANZANELLO, 2018). A etapa de seleção de variáveis é considerada pouco explorada na modelagem da produtividade de máquinas florestais, logo esforços são necessários para abordagem da mesma, uma vez que pode permitir um aumento no poder de predição dos futuros modelos.

Diante do exposto, uma alternativa promissora é a adoção de métodos de *Machine learning* que permite análise de dados e automatiza a construção de modelos estatísticos, dentre estes métodos destaca-se o *Random Forest* (RF), que fundamenta-se na construção de um grande número de árvores de decisão descorrelacionadas para a melhoria da acurácia da predição que é obtida pela média dos valores preditos por todas as árvores (REDDY; GEBRESLASIE; ISMAIL, 2017). Esse vem sendo amplamente aplicado em diversas áreas, por apresentar altos desempenhos preditivos quando comparado com outras metodologias e também pela sua capacidade em obter as variáveis mais importantes (LAHSSINI et al., 2015; MUTANGA; ADAM; CHO, 2012). Além disso, em busca de melhores soluções, como um conjunto ideal de variáveis com boa capacidade de predição pode-se combinar o RF com o

Algoritmo Genético (AG). O AG possibilita a simplificação de soluções de problemas de otimização quando envolve um grande número de variáveis. A vantagem da combinação de duas técnicas reflete na obtenção de um sistema capaz de reduzir erros e melhorar a predição dos modelos (COSTA et al., 2018).

Neste sentido, o objetivo deste estudo foi avaliar a influência das variáveis do Inventário florestal, climáticas, solo e registros de produção do operador na estimativa da produtividade do corte florestal com uso da garra traçadora, bem como a comparação entre o *random forest* e sua combinação com o algoritmo genético.

2 MATERIAL E MÉTODOS

2.1 Descrição da área de estudo

A empresa Klabin S.A. possui no total de suas áreas 229 mil hectares plantados com pinus e eucalipto e 214 mil hectares de matas nativas preservadas. No estado do Paraná, a empresa possui destaque no setor de empresas de base florestal com maior área de reflorestamento próprio (ALMEIDA; SILVA; ANGELO, 2012). O estudo foi realizado na Fazenda Monte Alegre de propriedade da empresa, localizado nas coordenadas 24°13'19" Sul e 50°32'33" Oeste, com a maior parte de suas terras pertencente ao município de Telêmaco Borba – PR (SOUZA et al., 2018). Segundo a classificação de Köppen, este local possui clima do tipo Cfa/Cfb, subtropical úmido transicional para clima oceânico, com temperatura média anual no mês mais frio inferior a 18°C e temperatura média do mês mais quente acima de 22°C, apresenta verões quentes (ALVARES et al., 2014).

2.2 Base de dados

Os dados foram provenientes de uma área de estudo que compreende em torno de 65 talhões com diferentes espécies de *Eucalyptus* (*E. dunnii*, *E. grandis*, *E. saligna* e *E. grandis* x *E. urophylla*) plantados para a produção de celulose. Variáveis qualitativas também foram coletadas como os 2 turnos de trabalho (manhã/tarde e tarde/noite de 10 horas por dia), tipo de solo (cambissolo háplico, latossolo vermelho, neossolo litólico, neossolo quartzarênico), textura do solo (arenosa, argilosa, muito argilosa, média e siltosa).

A produtividade da garra traçadora, equipamento florestal utilizado como objeto de estudo, foi determinada por meio do volume médio individual das árvores fornecido pelo inventário da empresa, cujo valor foi multiplicado pelo número de árvores traçadas no turno de trabalho e dividido pelas horas efetivamente trabalhadas, conforme a expressão utilizada por Burgin, Lopes e Rodrigues (2017).

$$P = \frac{V}{He}$$

Em que: P = produtividade da máquina (m³/He); V = volume total de madeira processada (m³); He = hora efetiva de trabalho (horas).

O período de coleta dos dados ocorreu entre os meses de fevereiro a outubro/2018, sendo descritos na Tabela 1. Após a consolidação dos dados, este passou por um processo de validação e identificação de erros, gerando 301 observações.

Tabela 1 - Estatística descritiva da produtividade e das variáveis quantitativas.

Variável	Mínimo	Média	Máximo	CV (%)
Prod ($\text{m}^3.\text{he}^{-1}$)	38.2	97.56	183.6	30.82
Tmax ($^{\circ}\text{C}$)	13.26	22.90	31.15	17,61
Tmin ($^{\circ}\text{C}$)	3.93	14.34	22.4	26,91
P (mm)	0	2.53	43.6	259,59
I (anos)	6	9	29	36.06
Exp (dias)	0	112.84	242	56,30
He (h)	1	5.86	9	34,61
VMI (m^3)	0.23	0.39	0.80	28,68

Em que: Prod = produtividade de corte ($\text{m}^3.\text{he}^{-1}$), Tmax = temperatura máxima; Tmin = temperatura mínima; P = precipitação; I = idade; Exp = experiência do operador; He= horas efetivas; VMI= volume médio individual e CV = coeficiente de variação.

Since: Prod = cutting productivity ($\text{m}^3.\text{h}^{-1}$), Tmax = maximum temperature; Tmin = minimum temperature; P= precipitation; I = age; Exp = operator experience; He = effective hours; VMI = individual average volume and CV = Coefficient of variation.

Fonte: Do autor (2019).

2.3 Modelagem e seleção de variáveis para a predição da produtividade do corte

O número de variáveis preditoras que influenciam a produtividade do corte florestal pode gerar uma complexidade em sua modelagem, sendo necessária a seleção das principais que explicam seu comportamento, que podem auxiliar no processo de gestão da atividade no campo, sendo justificável essa etapa. Assim, o grande desafio é a identificação dessas variáveis que melhor explicam a produtividade do corte florestal, para isto, a base de dados foi dividida aleatoriamente em dois conjuntos com 80% (treino) e 20% (validação).

O primeiro método testado foi a aplicação do *Random Forest* (RF) na sua forma pura, sendo utilizado todas as 11 variáveis (qualitativas e quantitativas) disponíveis. Esse método baseia-se na combinação de árvores preditoras, em que cada árvore é construída a partir de uma seleção aleatória de amostras e variáveis (BREIMAN, 2001). Os parâmetros consistiram em: número de árvores de regressão (ntree) igual a 500, número de variáveis preditoras amostradas aleatoriamente a cada divisão (mtry) igual a 2 e o número mínimo de amostras dentro dos nós terminais (nodesize) igual a 4. O processamento foi realizado em linguagem R com uso do pacote randomforest (LIAW; WIENER, 2002). O segundo método testado foi um híbrido entre o Algoritmo Genético (AG) e o *Random Forest* (RF), conforme desenvolvido por Carvalho (2019). A meta-heurística implementada no R foi adicionada para a seleção das melhores

combinações de variáveis, que explicam a produtividade do corte florestal. Na sequência, cada indivíduo da população executava o *Random Forest*, retornando como fitness o erro quadrático médio (MSE). A partir de testes prévios, adotou-se os seguintes parâmetros iniciais: a) tamanho da população igual a 100; b) número de gerações igual a 10; c) taxa de seleção igual a 0,5 e d) taxa de mutação igual a 0,1. O operador de seleção torneio foi adotado para o *crossover*, com trocas ponto a ponto.

Uma medida da importância das variáveis preditoras foi utilizada, denominada de *Increment in Mean Square Error* (%IncMSE). Esta avalia a redução do poder preditivo do modelo em termos de aumento do erro quadrático médio, quando os valores das amostras (*Out-of-bag* – OOB) são permutados para cada variável preditora, enquanto as outras permanecem fixas. Assim, as variáveis com alto valor de %IncMSE são consideradas as mais importantes. Esses valores foram gerados para cada método testado.

2.4 Avaliação dos métodos de predição

A avaliação das estimativas (Tabela 2) resultantes da aplicação do RF e AG+RF para os conjuntos de treinamento e validação foi efetuada por meio das estatísticas, coeficiente de determinação (R^2), *bias* (%) e a raiz do erro quadrado médio percentual (*Root Mean Square Error* – RMSE%), como ainda, uma análise gráfica dos resíduos (gráfico de correlação e dispersão do erro). Uma validação cruzada foi implementada, para avaliar a estabilidade do erro ou comportamento do modelo pelos métodos (NUNES; GORGENS, 2016). Nesse sentido, adotou-se o método *k-folds* com 10 repetições (HONG et al., 2018) e 500 interações (NUNES; GORGENS, 2016). Logo, um total de 5 mil modelos com uso do RF e AG+RF foram gerados. Tabela 2- Estatísticas de avaliação dos modelos *Random Forest* – RF e Algoritmo Genético associado com *Random Forest* – AG+RF.

Tabela 2 - Estatísticas de avaliação dos modelos *Random Forest* – RF e Algoritmo Genético associado com *Random Forest* – AG+RF.

Estatística	Fórmula
Coeficiente de determinação - R^2	$R^2 = 1 - \frac{\sum_i^n (Y_i - \hat{Y}_i)^2}{\sum_i^n (Y_i - \bar{Y})^2}$
Bias (%)	$B(\%) = \frac{100}{\bar{Y}} \cdot \frac{\sum_{i=1}^n Y_i - \sum_{i=1}^n \hat{Y}_i}{n}$
Raiz do erro quadrado médio (%)	$RMSE(\%) = \frac{100}{\bar{Y}} \cdot \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}$

Em que: Y_i = observado; \hat{Y}_i = estimada; \bar{Y} = média observada; e n = número de observações.

Since: Y_i = observed; \hat{Y}_i = estimated; \bar{Y} = observed average; and n = number of observations.

Fonte: Do autor (2019).

3 RESULTADOS E DISCUSSÃO

Na Tabela 3 estão apresentadas as análises estatísticas dos modelos utilizados, visto que para a validação cruzada os resultados para cada técnica utilizada consistiram na média de todos os modelos gerados. Observa-se que os valores de RMSE (%), B(%) e R^2 apresentaram resultados muito próximos, porém o modelo AG+RF conseguiu reduzir o RMSE (%) da validação e aumentou o valor do R^2 da validação, indicando assim uma melhora na qualidade de ajuste e uma maior concordância entre os valores estimados e observados. A avaliação estatística dos melhores modelos selecionados confirma o desempenho levemente superior do modelo AG+RF na validação. Sendo, portanto, o modelo utilizado para avaliação das variáveis preditoras na estimativa da produtividade de corte florestal com uso da garra traçadora.

Diversos estudos tem demonstrado êxito na modelagem de variáveis como, altura (FERRAZ FILHO et al., 2018), volume (KOHLENER et al., 2012) e afilamento de árvores (MENDONÇA et al., 2014) com R^2 acima de 0,9. Portanto, comparada a estas, a estimação da produtividade do corte florestal ainda é uma tarefa desafiadora, o que corrobora com os resultados deste estudo, em que o maior R^2 alcançado foi de 0,41 com o AG+RF. Gonçalves (2017) atribui a dificuldade de modelagem desta variável devido aos dados serem de difícil mensuração e apresentarem relações complexas.

Tabela 3 – Estatísticas de avaliação da validação cruzada para os modelos *Random Forest* – RF e Algoritmo Genético associado com *Random Forest* – AG+RF. Estatísticas de avaliação para os modelos selecionados de *Random Forest* – RF e Algoritmo Genético associado com *Random Forest* – AG+RF.

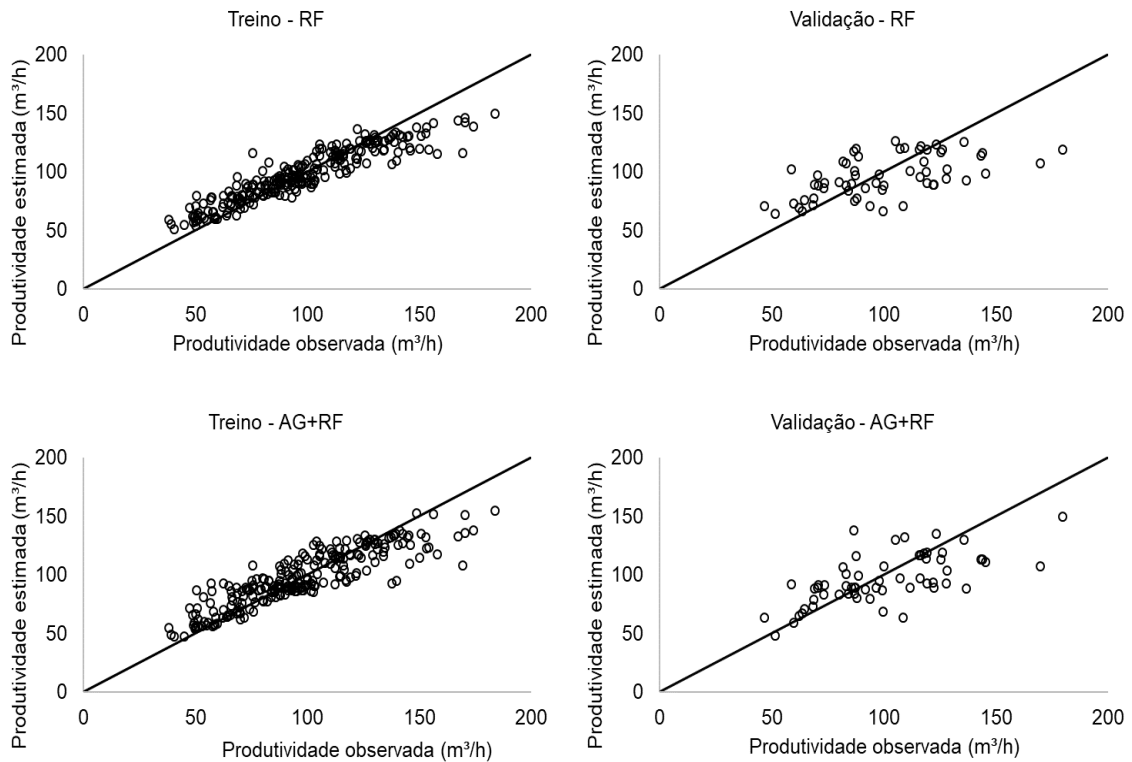
Modelo	Estatística	validação cruzada		Melhores	
		Treino	Validação	Treino	Validação
RF	RMSE (%)	13.30	24.76	13.22	23.60
	BIAS (%)	-0.16	0.28	-0.13	3.49
	R^2	0.81	0.37	0.82	0.31
AG+RF	RMSE (%)	14.82	23.41	14.98	21.83
	BIAS (%)	-0.16	-0.27	-0.09	3.65
	R^2	0.77	0.43	0.77	0.41

Fonte: Do autor (2019).

As análises gráficas de correlação entre as produtividades observadas e estimadas pelo RF e AG+RF e distribuição de erros percentuais para o treino e validação estão dispostas na Figura 1. Para os dados de treino, o gráfico de correlação entre as produtividades observadas e estimadas destacou-se ao apresentar os dados próximos à linha de 45° para ambos os modelos.

Já, os dados de validação revelam que o modelo AG+RF obteve pontos mais próximos da linha de 45°, o que evidencia uma correlação maior quando comparado com a validação do RF.

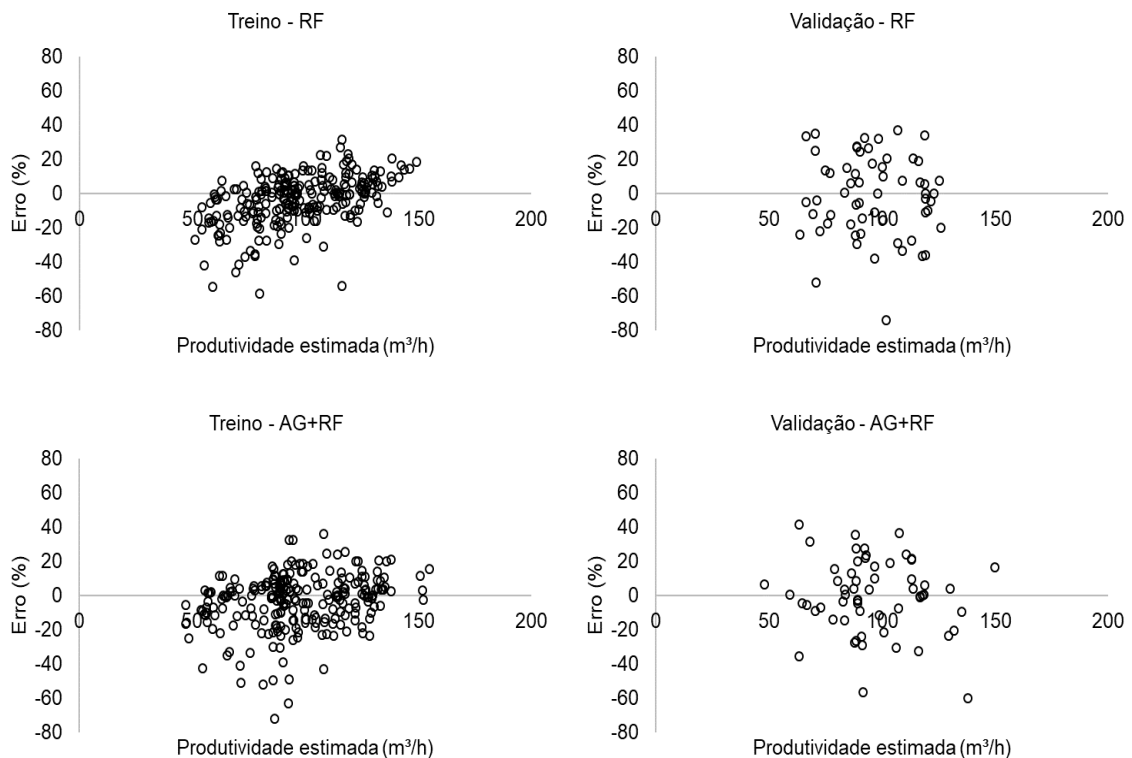
Figura 1 - Produtividade estimada versus produtividade observada, obtidas por *Random Forest* (RF) e Algoritmo Genético + *Random Forest* (AG+RF), para os dados de treino e validação.



Fonte: Do autor (2019).

Para os dados de treino de ambos os modelos conforme Figura 2, verifica-se no gráfico de dispersão do erro que houve uma dispersão mais homogênea próxima ao eixo zero, mas com tendência em superestimar os valores mais baixos de produtividade, diferente da validação que demonstrou maior dispersão do erro.


Figura 2 - Distribuição dos erros percentuais das estimativas de produtividade, obtidas por *Random Forest* (RF) e Algoritmo Genético + *Random Forest* (AG+RF), para os dados de treino e validação.



Fonte: Do autor (2019).

As variáveis quantitativas consideradas para este estudo possuem fator de impacto e influência importante na produtividade final do equipamento, sendo o mesmo comportamento observado para as variáveis qualitativas. Estudos mostram que a experiência do operador, otimização das horas efetivas, condições ambientais de trabalho (temperaturas e precipitação) e volume médio individual das árvores interferem diretamente na produtividade (ALVES et al., 2015; RODRIGUES et al., 2018; ROSSIT et al., 2019; SIMÕES; FENNER; ESPERANCINI, 2014). Vários autores afirmam que a iluminação natural durante o trabalho, capacidade operacional dos equipamentos, variedade genética, possuem influência na produtividade final (ALVES et al., 2015; ROCHA et al., 2009; ROSSIT et al., 2019). A partir do ranqueamento das variáveis conforme a importância (%IncMSE), verificou-se que a experiência do operador, o volume médio individual das árvores, a idade do talhão e a espécie foram as que mais influenciaram na produtividade do corte florestal (Figura 3) pelo RF, o que corrobora com os demais trabalhos. Já considerando o AG+RF a experiência do operador, volume médio individual das árvores, espécie e turno, foram as mais influentes do conjunto.

Figura 3 - Importância das variáveis predictoras utilizando o modelo RF, em que: Exp= experiência do operador; VMI= volume médio individual; I= idade; Esp= espécie; Tmax = temperatura máxima; Tmin = temperatura mínima; Text. Solo= textura do solo; Ts= tipo de solo; He= hora efetiva e P= precipitação.



Fonte: Do autor (2019).

A relevância da experiência do operador é evidenciada neste estudo. Para Rossit et al. (2019), a mesma é considerada um fator de impacto importante na produtividade e que quanto mais experiente o operador, maior será sua produtividade. Purfust (2010), analisou o impacto do treinamento na capacidade produtiva dos trabalhadores, indicando que ao final do treinamento sua capacidade de produção atual era bastante superior a capacidade de produção inicial.

O volume médio individual das árvores, conforme os estudos realizados por Rodrigues et al. (2018) e Simões, Fenner e Esperancini (2014) possuem relação direta com a produtividade e o desempenho operacional das máquinas florestais. Estas afirmações coincidem diretamente com nosso estudo. Gonçalves et al. (2017) em seu estudo apresenta que o volume de madeira aumentou de acordo com a idade, sendo uma variável importante para decisão da rotação econômica, visando aproveitar o máximo volume da floresta.

Rossit et al. (2019) considerou em seu estudo a espécie como uma variável capaz de exercer influência na produtividade, pois em todos os testes realizados em seu estudo ela aparece como uma variável importante, sendo compatível com nossos resultados tais afirmações. Alves et al. (2015) considerou que o turno de trabalho dos operadores possui influência na produtividade das máquinas florestais sendo que a velocidade de operação, planejamento de trabalho e análise do ambiente circundante são influenciadas pela iluminação natural que possibilita aos trabalhadores uma velocidade maior de processamento, indo de encontro com nosso resultado.

Oliveira et al. (2006) nos diz que a precipitação e o clima são fatores ambientais que possuem influência em toda a atividade florestal. Porém a máquina em estudo neste trabalho

possui elevada tecnologia visando a segurança do operador e que a operação ocorra normalmente independente das condições ambientais. As condições climáticas analisadas neste estudo são bem controladas devido a tecnologia existente que permite ao operador o controle da temperatura dentro de sua cabine para que não interfira em sua jornada de trabalho. No período dos dados analisados houve uma seca na região de estudo, explicando assim a quase nulidade de importância da variável precipitação.

As variáveis tipo de solo e textura do solo tiveram baixa influência de importância devido ao maquinário em estudo realizar sua operação somente na beirada do talhão que na maioria das vezes é um local plano, firme e sem declividade.

As horas efetivas de trabalho possuem influência na produtividade sendo necessário sempre que possível maximizá-la, visando reduzir ao máximo o número de interrupções (LINHARES et al., 2012). A baixa influência na produtividade vista neste estudo pode ser explicada devido a estes dados serem informados pelos próprios operadores, podendo conter erros de marcação devido o entendimento ao conceito da definição de hora efetiva.

A abordagem de diversas variáveis para modelagem da produtividade do corte florestal conferiu um aspecto inovador a este estudo que permitiu a seleção das variáveis que mais impactam na produtividade, por meio do modelo AG+RF.

4 CONCLUSÃO

O modelo AG+RF mostrou-se eficiente na avaliação das diversas variáveis capazes de influenciar a produtividade do corte florestal com a garra traçadora, possibilitando a priorização das 4 variáveis que mais influenciaram, sendo: experiência do operador, volume médio individual das árvores, espécie e turno.

As técnicas utilizadas apresentaram desempenho similar, embora com uma melhoria de 1,77% no RMSE para a validação do modelo AG+RF, demonstrando um amplo campo de oportunidade de otimização e estudo.

REFERÊNCIAS

- ALMEIDA, A. N. de; SILVA, J. C. G. L. da; ANGELO, H. Influência da Klabin no mercado de madeira em tora do estado do Paraná. **Cerne**, Lavras, v. 18, n. 1, p. 153-158, jan./mar. 2012.
- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, Berlin, v. 22, n. 6, p. 711–728, Dec. 2014.
- ALVES E. G. et al. Efeito do turno de trabalho na produção e produtividade de máquinas de colheita de madeira. **Nativa**, Sinop, v. 3, n. 3, p. 201-204, jul./set. 2015.
- BREIMAN, L. Random forests. **Machine Learning**, Boston, v. 45, n. 1, p. 5–32, Oct. 2001.
- BURGEL, E.; ANZANELLO, M. J. Abordagem para seleção de variáveis preditivas no contexto de controle de inventários. **Revista Gestão Industrial**, Ponta Grossa, v. 14, n. 4, p. 154-195, out./dez. 2018.
- BURGIN, M. R. B.; LOPES, E. S.; RODRIGUES, C. K. Efeito do volume individual e declividade do terreno na produtividade do harvester no desbaste de pinus. **Agropecuária Científica no Semiárido**, Patos, v. 13, n. 4, p. 322-328, out./dez. 2017.
- CARVALHO, M. C. **Inteligência computacional na modelagem florestal: teor de carbonato e distribuição geográfica de espécies**. Tese (Doutorado em Ciências Florestais) - 2019. 149 p. Universidade Federal de Lavras, Lavras, 2019.
- COSTA F. M. da et al. Arquitetura meta-heurística híbrida aplicada ao problema do corte bidimensional guilhotinado. **Interdisciplinary Scientific Journal**, Rio de Janeiro, v. 5, n. 2, p. 100-111, abr./jun. 2018.
- DUAILIBE, P. R. M. et al. Impact of the objective function on the construction of internal grids of wind farms using genetic algorithm. **Open Journal of Civil Engineering**, Reston, v. 6, n. 5, p. 705-721, Dec. 2016.
- FERRAZ FILHO, A. C. et al. Height-diameter models for Eucalyptus sp. plantations in Brazil. **Cerne**, Lavras, v. 24, n. 1, p. 9-17, jan./mar. 2018.
- FIEDLER, N. C.; ROCHA, E. B. da; LOPES, E. da S. Análise da produtividade de um sistema de colheita de árvores inteiras no norte do estado de Goiás. **Floresta**, Curitiba, v. 38, n. 4, p. 577-586, out./dez. 2008.
- GONÇALVES, J. C. et al. Análise econômica da rotação florestal de povoamentos de eucalipto utilizando a simulação de Monte Carlo. **Ciência Florestal**, Santa Maria, v. 27, n. 4, p. 1339-1347, out./dez. 2017.
- GONÇALVES, S. B. **Modelagem matemática da produtividade do corte florestal mecanizado**. 2017. 62 p. Tese (Doutorado em Ciências Florestais) - Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2017.

GOUVEIA, J. F. et al. Modelos volumétricos mistos em clones de *Eucalyptus* no Polo Gesseiro do Araripe, Pernambuco. **Floresta**, Curitiba, v. 45, n. 3, p. 587-598, jul./set. 2015.

HOLLAND, J. H. **Adaptation in natural and artificial systems**: An Introductory Analysis with applications to biology, control and artificial intelligence. Michigan: University of Michigan Press, 1975. 183 p.

HONG, H. et al. Applying genetic algorithms to set the optimal combination of forest fire related variables and model forest fire susceptibility based on data mining models. The case of Dayu County, China. **Science of the Total Environment**, Amsterdam, v. 630, p. 1044–1056, July 2018.

LAHSSINI, S. et al. Predicting cork oak suitability in maãmore forest using random forest algorithm. **Journal of Geographic Information System**, Essex, v. 7, n. 2, p. 202-210, Apr. 2015.

LIAW, A.; WIENER, M. Classification and regression by randomForest. **R-News**, New York, v. 2, n. 3, p. 18-22, 2002.

LINHARES, M. et al. Eficiência e desempenho operacional de máquinas harvester e forwarder na colheita florestal. **Pesquisa Agropecuária Tropical**, Goiânia, v. 42, n. 2, p. 212-219, abr./jun. 2012.

MENDONÇA, A. R. de et al. Modelagem da produção de sortimentos em povoamentos de eucalipto. **Cerne**, Lavras, v. 20, n. 4, p. 587-594, out./dez. 2014.

MUTANGA, O.; ADAM, E.; CHO, M. A. High density biomass estimation for wetland vegetation using WorldView-2 imagery and random forest regression algorithm. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 18, p. 399-406, Aug. 2012.

NASCIMENTO, A. C. et al. Avaliação técnica e econômica da colheita florestal com feller-buncher. **Cerne**, Lavras, v. 17, n. 1, p. 9-15, jan./mar. 2011.

NUNES, M. H.; GORGENS, E. B. Artificial intelligence procedures for tree taper estimation within a complex vegetation mosaic in Brazil. **Plos One**, San Francisco, v. 11, n. 5, p. e0154738, May 2016.

OLIVEIRA, R. J. de et al. Avaliação técnica e econômica da extração de madeira de eucalipto com “clambunk skidder”. **Revista Árvore**, Viçosa, v. 30, n. 2, p. 267-275, mar./abr. 2006.

PISANI JUNIOR, R.; CASTRO, M. C. A. A. de; COSTA, A. A. da. Desenvolvimento de correlação para estimativa da taxa de geração per capita de resíduos sólidos urbanos no estado de São Paulo: influências da população, renda per capita e consumo de energia elétrica. **Engenharia Sanitária e Ambiental**, Rio de Janeiro, v. 23, n. 2, p. 415-424, mar./abr. 2018.

PURFURST, F. T. Learning curves of harvester operators. **Croatian Journal of Forest Engineering**, [S.l.], v. 32, n. 2, p. 89–97, Dec. 2010.

- REDDY, N.; GEBRESLASIE, M.; ISMAIL, R. A hybrid partial least squares and random forest approach to modelling forest structural attributes using multispectral remote sensing data. **South African Journal of Geomatics**, [S.l.], v. 6, n. 3, p. 377-394, Oct. 2017.
- ROCHA, E. B. da et al. Produtividade e custos de um sistema de colheita de árvores inteiras. **Cerne**, Lavras, v. 15, n. 3, p. 372-381, set. 2009.
- RODRIGUES, C. K. et al. Influência do volume das árvores no desempenho do processador florestal harvester em povoamento de eucalipto. **BIOFIX Scientific Journal**, Paraná, v. 3, n. 2, p. 237-242, 2018.
- ROSSIT, D. A. et al. A Big Data approach to forestry harvesting productivity. **Computers and Electronics in Agriculture**, Amsterdam, v. 161, p. 29-52, June 2019.
- SHE, J.; CHUNG, W.; KIM, D. Discrete-event simulation of ground-based timber harvesting operations. **Forests**, Dordrecht, v. 9, n. 11, p. 683-702, Oct. 2018.
- SILAYO, S. A.; MINUNGA, G. A. Productivity and costs modeling for tree harvesting operations using chainsaws in plantation forests, Tanzania. **International Journal of Engineering & Technology**, Índia, v. 3, n. 4, p. 464 - 472, 2014.
- SIMÕES, D.; FENNER, P. T.; ESPERANCINI, M. S. T. Produtividade e custos do feller-buncher e processador florestal em povoamento de eucalipto de primeiro corte. **Ciência Florestal**, Santa Maria, v. 24, n. 3, p. 621-630, jul./set. 2014.
- SOUZA, J. L. M. de et al. Atributos físicos e balanço hídrico do solo com floresta ombrófila mista, em latossolo vermelho-amarelo, em Telêmaco Borba – PR. **Ciência Florestal**, Santa Maria, v. 28, n. 1, p. 90-101, jan./mar. 2018.
- STRANDGARD, M.; MITCHELL, R.; ACUNA, M. General productivity model for single grip harvesters in Australian eucalypt plantations. **Australian Forestry**, Queen Victoria, v. 79, n. 2, p. 108-113, Jan. 2016.