

OUOROU GANNI MARIEL GUERA

**MODELOS MATEMÁTICOS PARA AUXÍLIO À TOMADA DE DECISÃO NO
PROCESSO PRODUTIVO DE *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. NA
EMPRESA FLORESTAL INTEGRAL MACURIJE, PINAR DEL RÍO, CUBA**

**RECIFE
Pernambuco - Brasil
Julho - 2017**

OUOROU GANNI MARIEL GUERA

**MODELOS MATEMÁTICOS PARA AUXÍLIO À TOMADA DE DECISÃO NO
PROCESSO PRODUTIVO DE *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. NA
EMPRESA FLORESTAL INTEGRAL MACURIJE, PINAR DEL RÍO, CUBA**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Ciências Florestais da Universidade Federal Rural de Pernambuco, em cumprimento às exigências para obtenção do título de Doutor em Ciências Florestais.

Prof. PhD. José Antônio Aleixo da Silva
ORIENTADOR

Prof. Dr. Rinaldo Luiz Caraciolo Ferreira
CO-ORIENTADOR

Prof. Dr. Daniel Alberto Álvarez Lazo
CO-ORIENTADOR

RECIFE
Pernambuco - Brasil
Julho - 2017

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema Integrado de Bibliotecas da UFRPE
Biblioteca Central, Recife-PE, Brasil

G929m Guera, Ouorou Ganni Mariel

Modelos matemáticos para auxílio à tomada de decisão no processo produtivo de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na empresa florestal integral Macurije, Pinar Del Río, Cuba / Ouorou Ganni Mariel Guera. – 2017.
262 f. : il.

Orientador: José Antônio Aleixo da Silva.

Coorientadores: Rinaldo Luiz Caraciolo Ferreira; Daniel Alberto Álvarez Lazo.

Tese (Doutorado) – Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Ciências Florestais, Recife, BR-PE, 2017.

Inclui referências, apêndice(s) e anexo(s).

1. Empresa Florestal 2. Técnicas multivariadas 3. Programação por Metas Lexicográfica 4. Redes Neurais Artificiais I. Silva, José Antônio Aleixo da, orient. II. Ferreira, Rinaldo Luiz Caraciolo, coorient. III. Lazo, Daniel Alberto Álvarez, coorient. IV. Título

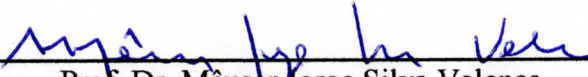
CDD 634.9

OUOROU GANNI MARIEL GUERA

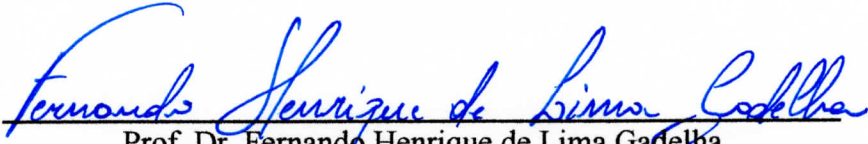
**MODELOS MATEMÁTICOS PARA AUXÍLIO À TOMADA DE DECISÃO NO
PROCESSO PRODUTIVO DE *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. NA
EMPRESA FLORESTAL INTEGRAL MACURIJE, PINAR DEL RÍO, CUBA**

Aprovada em: 06/07/2017

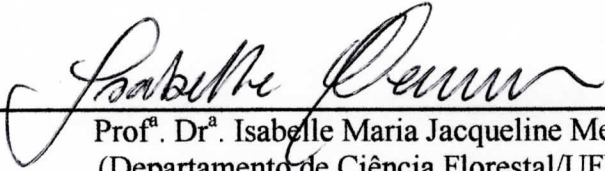
Banca Examinadora:



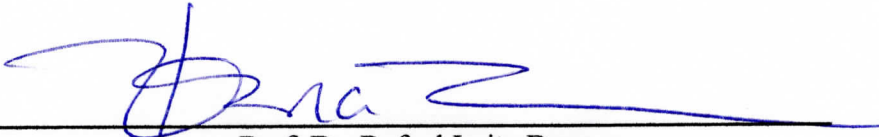
Prof. Dr. Mêuser Jorge Silva Valença
(Departamento de sistemas computacionais –DSC- UPE)



Prof. Dr. Fernando Henrique de Lima Gadelha
(Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco/IFPE)

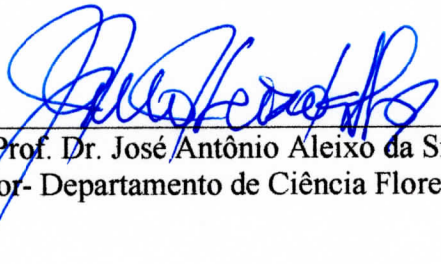


Prof.ª Dr.ª Isabelle Maria Jacqueline Meunier
(Departamento de Ciência Florestal/UFRPE)



Prof. Dr. Rafael Leite Braz
(Departamento de Ciência Florestal/UFRPE)

Orientador:



Prof. Dr. José Antônio Aleixo da Silva
(Orientador- Departamento de Ciência Florestal/UFRPE)

*Á meu pai GUERA Sabi Broussi Célestin (In memorian), minha mãe SEGLA Angèle, meus tios Bio TAFE e
ZIME Chabi Amadou e suas famílias e minha esposa Mariam Valdés Friol.*

Dedico.

AGRADECIMENTOS

O agradecimento sendo a memória do coração, meus maiores e sinceros agradecimentos para pessoas e instituições cujas contribuições foram imprescindíveis e valiosas na realização desta tese vão para:

- Meu Deus, pela minha vida e porque posso dizer “EBENÉZER! - Até aqui nos ajudou o Senhor!” I Samuel 7.12.
- Meu orientador e amigo, José Antônio Aleixo da Silva por uma orientação marcada por valiosos ensinamentos, conselhos, apoio, ajuda e amizade durante todo o processo. Obrigado por tudo professor !!!
- Meu co-orientador e amigo, Rinaldo Luiz Caraciolo Ferreira cuja disposição, colaboração e ajuda foi determinante para meu ingresso ao PPGCF e pela paciência, sugestões e valiosos ensinamentos e contribuições durante todas as etapas do desenvolvimento do trabalho. Obrigado por tudo professor !!!
- Meu co-orientador que também foi meu orientador nos trabalhos de conclusão de curso e de dissertação em Cuba, Daniel Alberto Álvarez Lazo pelo apoio ao longo da pesquisa, ensinamentos, pela amizade e por ter me recomendado o PPGCF/UFRPE para a realização dos meus estudos doutorais. Gracias por todo profesor !!!
- A Universidade Federal Rural de Pernambuco (UFRPE), em especial ao Programa de Pós-Graduação em Ciências Florestais (PPGCF) pela oportunidade concedida para realizar o doutorado e a todos seus professores pelos valiosos ensinamentos passados.
- Aos professores Luiz Carlos Marangon e Ana Lícia Patriota Feliciano, pelos ensinamentos passados nas disciplinas e pelo apoio toda vez que precisei na coordenação do programa.
- Aos secretários Douglas Menezes e Juliana Ferreira pelo excelente atendimento na secretaria do programa toda vez que precisei.
- A Cléia Lima da Biblioteca Central da UFRPE, pelas correções das referências bibliográficas.
- Aos professores Isabelle Maria Jacqueline Meunier, Rute Berger, José de Lima Albuquerque, Regis Villanova Longhi e Mêuser Jorge Silva Valença que fizeram parte das minhas bancas de projeto, qualificação e/ou resultados parciais. Obrigado pelas suas valiosas contribuições.

- O Programa de Estudantes-Convênio de Pós-Graduação (PEC-PG) da Coordenação de Aperfeiçoamento de Pessoal de Ensino Superior (CAPES) do Ministério da Educação, pela concessão da bolsa de estudos.
- A Universidade de Pinar del Río “Hermanos Saíz Montes de Oca” (UPR-CUBA), em especial ao Departamento Florestal pela parceria e apoio institucional na fase de coleta de dados na Empresa Florestal Integral (EFI) Macurije.
- A EFI Macurije por disponibilizar suas áreas e bases de dados para a realização da pesquisa e pelo apoio técnico e logístico em todas as etapas do desenvolvimento da mesma.
- Aos funcionários, técnicos, operários e motoristas da EFI Macurije pela sua ótima colaboração e paciência no desenvolvimento do experimento de colheita florestal.
- Aos engenheiros florestais responsáveis do ordenamento florestal da Empresa Macurije, José Luís Romero (Lara) e Mario Puentes Gomez, por disponibilizar as bases de dados da empresa e por toda colaboração no desenvolvimento da pesquisa.
- Minha mãe SEGLA Angèle. Merci de m’avoit donné la vie. Malgré ton état, je sais que tu me portes au plus profond de ton cœur comme je te porte et te porterai toujours au fond du mien durant ma traversée sur cette terre.
- Minha esposa Mariam Valdés Friol pelo companheirismo, incentivo, apoio, dedicação e amor na nossa caminhada.
- Meu tio BIO Tabe, sua esposa Ouorou Yérina Juliette e meus irmãos Mischael, Milca e Mirlande. Merci pour votre soutien durant toutes ces années et pour avoir constitué une famille pour moi.
- Meu tio ZIME Chabi Amadou e sua família. Merci pour tout cher oncle.
- Meu tio SEKE Cyrille e sua esposa. Merci tonton et tanti pour votre soutien.
- Meu tio SEKE Toussaint e sua família. Merci tonton pour votre soutien.
- Meu tio OROU GUIWA Bio Toro, embaixador de Benim em Marrocos. Papa, Merci pour votre soutien !!!
- Minha irmã AKOBETO Sylvie e sua família. Grande sœur, merci d’avoit pris soin de notre mère durant toutes ces années que j’ai dédié aux études !!!
- Meu professor e amigo, Héctor Barrero Medel, sua esposa Yatsunaris Alonso Torrens, seu filho Fabián pela amizade, apoio constante, ensinamentos e proporcionar valiosos dados e informações da Empresa Florestal Integral Macurije.

- Minha professora, Madelén Caridad Garófalo Novo pelo seu apoio incondicional e por despertar em mim, o interesse pela pesquisa operacional desde o quinto período da graduação.
- Ao professor Mêuser Jorge Silva Valença pelos valiosos ensinamentos recebidos na disciplina de Redes Neurais Artificiais na Universidade de Pernambuco (UPE) e pelo incentivo a aplicar essas técnicas para auxílio a tomada de decisões.
- Ao meu professor e amigo Fernando Domínguez Goizueta (*In memoriam*). Maestro, gracias por todo!
- Meus sogros Casimiro e Maria Julia por seu apoio e orações. Que Dios los bendiga abundantemente. Gracias por su apoyo y sus oraciones !!!
- Meu primo BANDIRI Sabi Yari Moïse e sua esposa Syntia Regina, pelo seu apoio. Família, obrigado por tudo !!!
- Minha prima Orou Guiwa Charlotte, pelo seu apoio mesmo na distância. Merci pour tout !
- As valiosas amizades realizadas durante esses anos aqui na pós-graduação entre elas: Fernando Gadelha e sua esposa Letícia, Diego e Samara, Juvenal, a Beth e sua família, Tibério e Lyanne, Damares e Wildson, Robson e Cinthia, Joselane, Rubeni, Marília, Penha, Célio, Pedro e demais companheiros da pós-graduação pela amizade durante esses anos no doutorado.
- Ao meu compatriota Kuessi Bertrand pela sua amizade desde que cheguei na UFRPE.
- Aos meus irmãos na FE, Paulo e Kelly, Jefson e Glaucia, Mesias e Priscila.
- A todas as pessoas que de uma forma ou de outra me levaram a este sucesso.

Agradeço !!!

"Toda decisão acertada é proveniente de experiência e toda experiência é proveniente de uma decisão não acertada"

Albert Einstein.

BIOGRAFIA

Nascido o dia 19 de dezembro de 1984 em Cotonou (Benim), Ouorou Ganni Mariel Guera é natural do estado de Kerou (Departamento de Atacora, República do Benin), filho de Guera Sabi Broussi Célestin e Sègla Angèle.

Culminou o ensino médio no final do ano 2005 no Colégio de Ensino Geral I (CEG I) de Djougou (Norte de Benin) e em 2006 iniciou o curso de Medicina na Universidade de Parakou (UNIPAR/BENIN). Após um ano no curso de medicina, passou no processo seletivo da Direção de Bolsas e Auxílios Universitários de Benim (DBSU da sua sigla em francês) para cursar a graduação em Engenharia Florestal na Universidade de Pinar del Río “Hermanos Saiz Montes de Oca” em Cuba.

Realizou um ano de curso preparatório de Espanhol na Universidade de Matanzas Camilo Cienfuegos (UMCC/CUBA) durante o ano escolar 2006-2007 e iniciou o curso de Engenharia Florestal em 2007 na Universidade de Pinar del Río “Hermanos Saiz Montes de Oca”. Em 2012, concluiu o curso com votos de louvor pelo desempenho acadêmico, ganhando como prêmio uma bolsa integral para cursar o mestrado no Programa de Pós-graduação em Ciências Florestais da mesma Universidade.

Após a conclusão do mestrado em 2013, iniciou em agosto do mesmo ano, o doutorado em Ciências Florestais (Linha de Pesquisa: Biometria e Manejo Florestal) no Programa de Pós-graduação em Ciências Florestais da Universidade Federal Rural de Pernambuco (PPGCF/UFRPE-BRASIL) como bolsista do Programa de Estudantes-Convênio de Pós-Graduação (PEC-PG) da CAPES.

Submeteu-se a defesa pública da presente tese no Auditório Professor Álvaro Antônio Magalhães Lêdo do DCFL/UFRPE em julho de 2017.

SUMÁRIO

| | CONTEÚDO | PÁG. |
|------------|--|------|
| | LISTA DE FIGURAS | |
| | LISTA DE TABELAS | |
| | LISTA DE ABREVIATURAS, NOMENCLATURAS E SÍMBOLOS | |
| | RESUMO GERAL | 24 |
| | GENERAL ABSTRACT | 25 |
| | RÉSUMÉ GÉNÉRAL | 26 |
| I. | INTRODUÇÃO GERAL | 27 |
| II. | REFERENCIAL TEÓRICO | 32 |
| 2.1 | Processo Produtivo Florestal (PPF) e níveis de planejamento | 32 |
| 2.2 | Generalidades sobre a espécie objeto de estudo: <i>Pinus caribaea</i> Morelet | 34 |
| 2.2.1 | Estudos sobre o <i>Pinus caribaea</i> Morelet..... | 35 |
| 2.2.2 | Florestas plantadas de <i>Pinus caribaea</i> var. <i>caribaea</i> em Cuba..... | 35 |
| 2.3 | Estudos de crescimento e produção florestal | 36 |
| 2.3.1 | Classificação da capacidade produtiva de sítios florestais..... | 36 |
| 2.3.2 | Estudos de crescimento e produção florestal e sua classificação..... | 37 |
| 2.3.3 | Elementos dos avanços na modelagem do crescimento e produção florestal..... | 40 |
| 2.3.4 | Modelos compatíveis de crescimento e produção florestal..... | 40 |
| 2.3.5 | A sobrevivência/mortalidade florestal: outro componente do crescimento e produção florestal..... | 41 |
| 2.3.6 | Estudos de crescimento e produção do <i>Pinus caribaea</i> var. <i>caribaea</i> em Cuba..... | 42 |
| 2.4 | Colheita florestal | 43 |
| 2.4.1 | Extração florestal..... | 43 |
| 2.4.2 | Transporte florestal..... | 44 |
| 2.4.3 | Estudos de tempo e movimentos na extração e transporte florestal..... | 45 |
| 2.5 | Rendimento e qualidade na transformação primária da madeira | 46 |
| 2.6 | Métodos quantitativos para auxílio à tomada de decisão no gerenciamento florestal | 47 |
| 2.6.1 | Estatística experimental para auxílio à tomada de decisão no gerenciamento florestal..... | 47 |
| 2.6.1.1 | Técnicas multivariadas para auxílio a tomada de decisão no gerenciamento florestal..... | 47 |
| 2.6.1.2 | Análise de variância univariada versus Análise de variância multivariada..... | 48 |

| | | |
|-----------|--|----|
| 2.6.2. | Métodos de programação matemática para auxílio ao gerenciamento florestal..... | 50 |
| 2.6.2.1 | Abordagem monocritério: Programação Linear (PL)..... | 50 |
| 2.6.2.2 | Abordagem multicritério: Programação por Metas..... | 51 |
| 2.6.3 | Técnicas de Redes Neurais Artificiais..... | 53 |
| 2.6.3.1 | Breve histórico..... | 54 |
| 2.6.3.2 | Arquiteturas ou tipos de Redes Neurais Artificiais (RNAs)..... | 55 |
| 2.6.3.2.1 | Redes Perceptron Multicamadas (MLP)..... | 55 |
| 2.6.3.2.2 | Redes de Funções de Base Radial (RBF)..... | 56 |
| 2.6.3.2.3 | Redes MLP versus Redes RBF..... | 57 |
| 2.6.3.3 | Treinamento das Redes Neurais Artificiais (RNAs)..... | 58 |
| 2.6.3.4 | RNAs para auxílio a tomada de decisão na mensuração e indústria florestal..... | 60 |

CAPÍTULO I

AVALIAÇÃO DE CAPACIDADE PRODUTIVA E PROGNÓSE DE CRESCIMENTO E PRODUÇÃO PARA *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

| | | |
|-----------|---|----|
| | RESUMO | 82 |
| | ABSTRACT | 83 |
| | RÉSUMÉ | 84 |
| 1. | INTRODUÇÃO | 85 |
| 2. | MATERIAL E MÉTODOS | 88 |
| 2.1 | Localização da área de estudo..... | 88 |
| 2.2 | Fontes de dados e análise de suficiência amostral..... | 88 |
| 2.3 | Modelos para predição e prognose da produção de <i>Pinus caribaea</i> var. <i>caribaea</i> | 89 |
| 2.3.1 | Modelos de predição do crescimento de <i>Pinus caribaea</i> var. <i>caribaea</i> | 89 |
| 2.3.2 | Classificação da capacidade produtiva para <i>Pinus caribaea</i> var. <i>caribaea</i> | 90 |
| 2.3.3 | Prognose de produção e sobrevivência para <i>Pinus caribaea</i> var. <i>caribaea</i> | 91 |
| 2.3.3.1 | Modelos de prognose de crescimento e produção para <i>P. caribaea</i> var. <i>caribaea</i> | 91 |
| 2.3.3.2 | Modelos de prognose da sobrevivência em plantios de <i>Pinus caribaea</i> var. <i>caribaea</i> na EFI Macurije..... | 91 |
| 2.4 | Treinamentos de Redes Neurais Artificiais para prognose de produção e sobrevivência de <i>Pinus caribaea</i> var. <i>caribaea</i> | 92 |
| 2.5 | Estimativa dos parâmetros, critérios de avaliação e de escolha dos modelos..... | 93 |
| 3. | RESULTADOS E DISCUSSÃO | 96 |
| 3.1 | Estimativas dos parâmetros dos modelos de crescimento e produção..... | 96 |
| 3.2 | Curvas de índice de sítio polimórficas para <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf. na empresa florestal Macurije..... | 99 |

| | | |
|-----------|---|-----|
| 3.3 | Equações para a prognose da produção do <i>Pinus caribaea</i> var. <i>caribaea</i> | 101 |
| 3.4 | Modelos de prognose de sobrevivência futura em plantios de <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf..... | 105 |
| 3.5 | Redes Neurais Artificiais para prognose de produção e sobrevivência do <i>Pinus caribaea</i> var. <i>caribaea</i> Barr. & Golf..... | 107 |
| 3.5.1 | Predição e prognose do crescimento e produção do <i>Pinus caribaea</i> var. <i>caribaea</i> ... | 108 |
| 3.5.2 | Prognose de sobrevivência do <i>Pinus caribaea</i> var. <i>caribaea</i> | 112 |
| 4. | CONCLUSÕES | 114 |
| 5. | REFERÊNCIAS | 115 |

CAPÍTULO II

ABORDAGEM MULTIVARIADA EM EXPERIMENTO DE COLHEITA DA MADEIRA EM PLANTIOS DE *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

| | | |
|-----------|---|-----|
| | RESUMO | 122 |
| | ABSTRACT | 123 |
| | RÉSUMÉ | 124 |
| 1. | INTRODUÇÃO | 125 |
| 2. | MATERIAIS E MÉTODOS | 127 |
| 2.1 | Caracterização da área de estudo..... | 127 |
| 2.2 | Características das máquinas de extração e transporte de madeira..... | 128 |
| 2.3 | Coleta de dados experimentais e cálculo de custos e produtividades..... | 130 |
| 2.4 | Análise de suficiência amostral..... | 131 |
| 2.5 | Sistemas de colheita avaliados e indicadores de desempenho..... | 131 |
| 2.6 | Análise estatística..... | 131 |
| 2.6.1 | Experimento fatorial univariado..... | 132 |
| 2.6.2 | Experimento fatorial multivariado..... | 133 |
| 3. | RESULTADOS E DISCUSSÃO | 135 |
| 3.1 | Suficiência amostral e resultados de estudos de tempos e movimentos na extração e transporte de madeira..... | 135 |
| 3.2 | Produtividades e custos de extração e transporte de madeira em florestas plantadas de <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf. na EFI Macurije..... | 137 |
| 3.3 | Experimentos fatoriais univariadas e multivariadas..... | 140 |
| 3.3.1 | Normalidade e homocedasticidade univariada e multivariada..... | 140 |
| 3.3.2 | Experimento fatorial univariado para custo e para produtividade..... | 140 |
| 3.3.3 | Experimento fatorial multivariado combinando “produtividade” e “custo”..... | 143 |

| | | |
|-----------|--|-----|
| 3.3.3.1 | Teste T2 de Hotelling para vetores de médias na interação MxD..... | 144 |
| 4. | CONCLUSÕES | 146 |
| 5. | REFERÊNCIAS | 147 |

CAPÍTULO III

MODELO DE PROGRAMAÇÃO POR METAS LEXICOGRÁFICA PARA O PLANEJAMENTO DA EXTRAÇÃO E TRANSPORTE DE MADEIRA NA EMPRESA FLORESTAL INTEGRAL MACURIJE

| | | |
|------------|---|-----|
| | RESUMO | 151 |
| | ABSTRACT | 152 |
| | RÉSUMÉ | 153 |
| 1. | INTRODUÇÃO | 154 |
| 2. | MATERIAIS E MÉTODOS | 158 |
| 2.1 | Caracterização da área de estudo..... | 158 |
| 2.2 | Caraterização de colheita e transporte de madeira na EFI Macurije..... | 158 |
| 2.3 | Metodologia..... | 159 |
| 2.3.1 | Modelo de Programação por Metas Lexicográfica de transbordo proposto..... | 161 |
| 2.3.1.1 | Definição das metas e ordem lexicográfica..... | 161 |
| 2.3.1.2 | Proposta de um modelo de programação por metas lexicográfica para transbordo (extração e transporte) de madeira..... | 162 |
| 2.3.1.2.1 | Especificação dos conjuntos, parâmetros e variáveis de decisão..... | 162 |
| 2.3.1.2.2. | Formulação matemática do modelo genérico..... | 164 |
| 2.3.2 | Implementação do modelo de programação por metas lexicográfica proposto..... | 167 |
| 3. | RESULTADOS E DISCUSSÃO | 169 |
| 3.1 | Solução do problema de transbordo de madeira por meio do modelo de programação por metas lexicográficas proposto..... | 169 |
| 3.2 | Análise da sensibilidade do modelo a variação dos recursos..... | 170 |
| 4. | CONCLUSÕES | 173 |
| 5. | REFERÊNCIAS | 174 |

CAPÍTULO IV

MODELOS DE REGRESSÃO E REDES NEURAIIS ARTIFICIAIS PARA PREDIÇÃO DO RENDIMENTO EM MADEIRA SERRADA DE *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

| | | |
|-----------|---------------------------------|-----|
| | RESUMO | 178 |
| | ABSTRACT | 179 |
| | RÉSUMÉ | 180 |
| 1. | INTRODUÇÃO | 181 |
| 2. | MATERIAL E MÉTODOS | 184 |

| | | |
|-----------|---|------------|
| 2.1 | Características do local de estudo..... | 184 |
| 2.2 | Coleta de dados e suficiência amostral..... | 184 |
| 2.3 | Variáveis envolvidas no estudo de rendimento em madeira serrada..... | 185 |
| 2.4 | Análise estatística..... | 187 |
| 2.5 | Modelos clássicos de predição do rendimento em madeira serrada..... | 187 |
| 2.6 | Modelo de regressão stepwise para a predição do rendimento em madeira serrada..... | 187 |
| 2.7 | Modelos de regressão baseados em Equações Diferenciais Ordinárias (EDOs)..... | 188 |
| 2.8 | Treinamentos de RNAs para a predição do rendimento em madeira serrada..... | 188 |
| 2.9 | Critérios de avaliação dos modelos de regressão e das RNAs..... | 190 |
| 3. | RESULTADOS E DISCUSSÃO | 191 |
| 3.1 | Rendimento em madeira serrada de <i>Pinus caribaea</i> na serraria Combate de Tenerías..... | 191 |
| 3.2 | Influência das classes de diâmetros e conicidade no rendimento em madeira serrada..... | 191 |
| 3.3 | Modelos de regressão tradicionais para a predição do rendimento em madeira serrada..... | 192 |
| 3.4 | Modelo de regressão stepwise para a predição do rendimento em madeira serrada..... | 195 |
| 3.5 | Modelos baseados em Equações Diferenciais Ordinárias e seus ajustes..... | 196 |
| 3.6 | Redes Neurais Artificiais para a predição do rendimento em madeira serrada..... | 197 |
| 3.7 | Comparação e validação dos modelos de regressão e das RNAs..... | 201 |
| 4. | CONCLUSÕES | 202 |
| 5. | REFERÊNCIAS | 203 |

CAPÍTULO V

REGRESSÃO LOGÍSTICA ORDINAL E REDES NEURAIS ARTIFICIAIS PARA A CLASSIFICAÇÃO DE MADEIRA SERRADA DE *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

| | | |
|-----------|--|------------|
| | RESUMO | 208 |
| | ABSTRACT | 209 |
| | RÉSUMÉ | 210 |
| 1. | INTRODUÇÃO | 211 |
| 2. | MATERIAL E MÉTODOS | 214 |
| 2.1 | Localização e características do local de estudo..... | 214 |
| 2.2 | Coleta de dados..... | 214 |
| 2.3 | Modelo de regressão logística politômica ordinal (RLPO)..... | 215 |

| | | |
|-----------|---|------------|
| 2.3.1 | Teste da significância do modelo de regressão logístico ordinal..... | 216 |
| 2.3.2 | Teste de Wald para cada coeficiente..... | 217 |
| 2.4 | Análise fatorial com as variáveis preditoras da qualidade de madeira serrada do classificador de madeira serrada proposto por García (2006)..... | 217 |
| 2.5 | Redes Neurais Artificiais para a classificação de madeira serrada..... | 218 |
| 2.5.1 | Características do treinamento das Redes Neurais Artificiais..... | 218 |
| 2.5.2 | Análise de sensibilidade..... | 218 |
| 2.6 | Crterios de avaliação e seleção dos modelos de regressão e das RNAs..... | 219 |
| 3. | RESULTADOS E DISCUSSÃO | 220 |
| 3.1 | Modelo de regressão logística ordinal para a classificação da madeira serrada de <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf..... | 220 |
| 3.2 | Análise fatorial para a redução da dimensionalidade das variáveis preditivas da qualidade da madeira serrada..... | 221 |
| 3.3 | Modelo de regressão logística ordinal baseado nos fatores..... | 223 |
| 3.4 | Redes Neurais Artificiais para a classificação da madeira serrada de <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf..... | 225 |
| 4. | CONCLUSÕES | 228 |
| 5. | REFERÊNCIAS | 229 |
| | CONSIDERAÇÕES FINAIS | 232 |
| | CONCLUSÕES GERAIS | 234 |
| | ANEXOS & APÊNDICES | 236 |

LISTA DE FIGURAS

| | PÁG. |
|---|------|
| REFERENCIAL TEÓRICO | |
| 1 Componentes do Processo de Produção Florestal (Fonte: GUNNARSSON, 2007)..... | 32 |
| 2 Área de distribuição natural do <i>Pinus caribaea</i> (Fonte: CRITCHFIELD; LITTLE, 1966)..... | 34 |
| 3 Classificação de modelos de crescimento e produção florestal. Fonte: Elaborada com base a classificação de Davis & Johnson (1987)..... | 38 |
| 4 Modelo matemático de um neurônio artificial (Fonte: HAYKIN, 2001)..... | 54 |
| 5 Taxonomia das arquiteturas de Redes Neurais Artificiais (Fonte: JAIN; MAO; MOHIUDDIN, 1996)..... | 55 |
| 6 Estrutura de uma rede neural MLP (COELHO; SANTOS; COSTA Jr., 2008)..... | 56 |
| 7 Estrutura de uma rede neural RBF (COELHO; SANTOS; COSTA Jr, 2008)..... | 57 |
| CAPÍTULO I | |
| 1 Localização geográfica da EFI Macurije, Pinar del Río, Cuba (Fonte: RODRÍGUEZ, 2012)..... | 88 |
| 2 Etapas de treinamento de Redes Neurais Artificiais para predição e prognose de produção para <i>Pinus caribaea</i> var. <i>caribaea</i> . Fonte: Elaborada com base a Valença (2010)..... | 92 |
| 3 Distribuição dos resíduos dos modelos de crescimento e produção ajustados..... | 98 |
| 4 Idades de Rotação Técnicas (IRT) para <i>Pinus caribaea</i> var. <i>caribaea</i> | 99 |
| 5 Curvas de índice de sítio polimórficas para <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf., Pinar del Rio, Cuba..... | 100 |
| 6 Idade vs. índice de sítio nas parcelas permanentes de <i>Pinus caribaea</i> var. <i>caribaea</i> var. <i>caribaea</i> na empresa florestal integral Macurije..... | 101 |
| 7 Distribuição dos resíduos dos modelos de prognose para <i>Pinus caribaea</i> var. <i>caribaea</i> | 104 |
| 8 Projeção da produção de <i>P. caribaea</i> var. <i>caribaea</i> por capacidade produtiva na Empresa Florestal Integral Macurije, Pinar del Río, Cuba..... | 105 |
| 9 Distribuição dos resíduos dos modelos de predição de sobrevivência do <i>Pinus caribaea</i> var. <i>caribaea</i> na empresa Macurije..... | 107 |
| 10 Prognose de sobrevivências (a) e taxas de mortalidade (b) para diferentes densidades iniciais em plantios de <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> | 107 |
| 11 Distribuição dos resíduos das RNAs treinadas para predição e prognose da produção em povoamentos de <i>Pinus caribaea</i> var. <i>caribaea</i> | 110 |

| | | |
|----|--|-----|
| 12 | Distribuição dos resíduos das RNAs e do sistema de equações de B.M.S. et al. (2006) na prognose do volume e da Área Basal em povoamentos de <i>Pinus caribaea</i> var. <i>caribaea</i> | 111 |
| 13 | Distribuição dos resíduos das RNAs treinadas para prognose de sobrevivência em povoamentos de <i>Pinus caribaea</i> var. <i>caribaea</i> | 112 |
| 14 | Distribuição dos resíduos das RNAs e do modelo de Pienaar e Shiver (1981) na prognose da sobrevivência em povoamentos de <i>Pinus caribaea</i> var. <i>caribaea</i> | 113 |

CAPÍTULO II

| | | |
|---|---|-----|
| 1 | Localização da unidade de produção florestal “las cañas” da EFI Macurije..... | 127 |
| 2 | Climograma de Walter-Lieth para o período 2002-2012 (a) e diagrama de balanço hídrico para uma capacidade de campo de 100 mm/m (b)..... | 128 |
| 3 | Maquinaria de colheita e transporte florestal na EFI Macurije: A) Extração da madeira com o Skidder americano “John Deere 548E”; B) Skidder Chinês “J-80A”. C) Junta de bois; D) Caminhão autocarregável KRAZ- 257; E) Caminhão URAL- 4320; F) Caminhão KAMAZ-4310; G) Carregador frontal “VOLVO BM L90B”; H) O carregador frontal “VOLVO BM L90B” carregando um caminhão URAL- 4320..... | 130 |
| 4 | Porcentagens de tempos dos componentes dos ciclos operacionais de extração de madeira de <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf..... | 136 |
| 5 | Porcentagens de tempos dos componentes dos ciclos operacionais de transporte de madeira de <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf..... | 136 |
| 6 | Porcentagens de tempos dos componentes dos ciclos operacionais do Volvo BM L90B no carregamento e descarregamento dos caminhões na EFI Macurije..... | 137 |
| 7 | Componentes dos custos (fixos-Cf, variáveis- Cv, mão de obra-Cmo; Cem = Cf + Cv + Cmo) de extração de madeira de <i>P. caribaea</i> var. <i>caribaea</i> , Pinar Del Rio, Cuba..... | 138 |
| 8 | Componentes dos custos (propriedade-Cp, operacionais- Cop, mão de obra-Cmo; Cem = Cp + Cop + Cmo) de transporte da madeira em plantações de <i>P. caribaea</i> var. <i>caribaea</i> , EFI Macurije, Pinar Del Rio, Cuba..... | 138 |

CAPÍTULO III

| | | |
|---|--|-----|
| 1 | Localização da empresa florestal Macurije, Pinar Del Rio, Cuba..... | 158 |
| 2 | Fluxo de transbordo de madeira na Empresa Florestal Integral (EFI) Macurije..... | 159 |
| 3 | Analogia entre o algoritmo de transbordo e a extração - transporte de madeira..... | 160 |
| 4 | Fluxograma de abordagem do problema de transbordo de madeira..... | 161 |
| 5 | Diagrama de Pareto (80/20) para as atividades de colheita florestal na EFI Macurije..... | 162 |
| 6 | Volumes de madeira disponíveis e extraídos..... | 171 |
| 7 | Relação entre as demandas e os volumes de madeira recebida nos destinos..... | 171 |

CAPÍTULO IV

| | | |
|---|--|-----|
| 1 | Localização geográfica da serraria Combate de Tenerías da EFI Macurije..... | 184 |
| 2 | Distribuição dos resíduos das equações tradicionais de estimativa do rendimento em madeira serrada do <i>P. caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf. na EFI Macurije, Cuba..... | 194 |
| 3 | Distribuição dos resíduos da equação de regressão stepwise para estimativa do rendimento de madeira serrada do <i>P. caribaea</i> Morelet var. <i>caribaea</i> na EFI Macurije, Cuba..... | 195 |
| 4 | Distribuição dos resíduos das equações baseadas nas EDOs para a estimativa do rendimento em madeira serrada do <i>Pinus caribaea</i> var. <i>caribaea</i> na EFI Macurije, Cuba..... | 197 |
| 5 | Distribuição dos resíduos das RNAs na predição do rendimento em madeira serrada do <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf. na EFI Macurije, Cuba..... | 199 |
| 6 | Variação do rendimento observado e estimado pela RNA MLP 12-8-1..... | 200 |
| 7 | Importância das variáveis independentes nas RNAs treinadas para a predição do rendimento em madeira serrada do <i>P. caribaea</i> var. <i>caribaea</i> na EFI Macurije, Cuba..... | 200 |
| 8 | Desempenhos das RNAs e dos modelos de regressão no processo de validação..... | 201 |

CAPÍTULO V

| | | |
|---|---|-----|
| 1 | Localização geográfica da serraria “Combate de Tenerías” na EFI Macurije..... | 214 |
| 2 | Scree plot dos autovalores antes (a) e depois (b) da rotação varimax..... | 221 |
| 3 | Desempenhos dos diferentes modelos na classificação de madeira serrada de <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf. na serraria Combate de Tenerías..... | 227 |

LISTA DE TABELAS

| | PÁG. |
|---|-------------|
| REFERENCIAL TEÓRICO | |
| 1 Multilayer Perceptron (MLP) versus Radial Basis Function (RBF). Fonte: Elaborada com base a Kriesel (2007)..... | 57 |
| 2 Tipos de funções de ativação de neurônios nas RNAs MLP & RBF..... | 59 |
| 3 Proporções aplicadas na partição da base de dados no treinamento das RNAs..... | 60 |
| CAPÍTULO I | |
| 1 Distribuição das parcelas permanentes nas unidades básicas de produção florestal da empresa florestal integral macurije, Pinar del Río, Cuba..... | 89 |
| 2 Análise descritiva das variáveis coletadas nos plantios de <i>P. caribaea</i> var. <i>caribaea</i> | 89 |
| 3 Modelos de predição de crescimento ajustados para plantios de <i>Pinus caribaea</i> var. <i>caribaea</i> , Pinar del Rio, Cuba..... | 90 |
| 4 Modelos de prognose de produção em plantios de <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf..... | 91 |
| 5 Modelos de prognose de sobrevivência em plantios de <i>Pinus caribaea</i> var. <i>caribaea</i> | 92 |
| 6 Características dos treinamentos das RNAs para predição de crescimento e prognose de produção e sobrevivência..... | 93 |
| 7 Estimativas dos parâmetros dos modelos de predição de crescimento e produção do <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> | 96 |
| 8 Estimativas dos parâmetros dos modelos de prognose da área basal e do volume de <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf, em Pinar del Rio, Cuba..... | 102 |
| 9 Estimativas dos parâmetros dos modelos de prognose da sobrevivência em plantios de <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf..... | 105 |
| 10 Resultados dos treinamentos das RNAs para predição e prognose de crescimento e produção em plantios de <i>Pinus caribaea</i> var. <i>caribaea</i> , Pinar Del Rio, Cuba..... | 108 |
| 11 Testes <i>t-pareado</i> e T^2 de <i>Hotteling</i> entre os valores observados e estimados pelo modelo de B.M.S. et al. (2006) e as RNAs..... | 111 |
| 12 Resultados dos treinamentos das RNAs para a projeção da sobrevivência em plantios de <i>P. caribaea</i> var. <i>caribaea</i> , Pinar Del Rio, Cuba..... | 112 |
| 13 Teste <i>t-pareado</i> entre as sobrevivências observadas e as estimadas pelo modelo de Pienaar & Shiver (1981) e a RNA MLP 13-10-1..... | 113 |
| CAPÍTULO II | |
| 1 Características dos plantios de <i>P. caribaea</i> na empresa Macurije, Cuba..... | 127 |
| 2 Tamanhos mínimos de amostragem e erros de amostragem correspondentes..... | 135 |

| | | |
|----|--|-----|
| 3 | Produtividades e custos da extração e transporte da madeira em florestas plantadas de <i>Pinus caribaea</i> Morelet var. <i>caribaea</i> Barr. & Golf., Pinar Del Rio, Cuba..... | 139 |
| 4 | Análise de variância para o arranjo fatorial univariado 3x3x2..... | 141 |
| 5 | Teste de Tukey para a interação MxD para a variável produtividade..... | 142 |
| 6 | Teste de Tukey para a interação MxD para a variável custo..... | 143 |
| 7 | Efeito dos fatores maquinaria, declividade e sistema de colheita sobre o conjunto produtividade-custo na extração da madeira de <i>P. caribaea</i> var. <i>caribaea</i> | 143 |
| 8 | Efeito das interações MxD, MxS e DxS sobre o conjunto produtividade-custo..... | 144 |
| 9 | Efeito da interação MxDxS sobre o conjunto produtividade – custo..... | 144 |
| 10 | Teste T ² de Hotelling entre os pares de vetores de médias de custo e produtividade para a interação MxD | 145 |

CAPÍTULO III

| | | |
|---|---|-----|
| 1 | Distâncias entre origens e destinos e ofertas e demandas de madeira..... | 168 |
| 2 | Resultados da resolução do problema de transbordo planteado..... | 169 |
| 3 | Valores das variáveis de desvio nos diferentes níveis..... | 170 |
| 4 | Distribuição da madeira por maquinaria e sistema de colheita no transbordo de madeira.. | 170 |
| 5 | Resultados da análise da sensibilidade do modelo a variação dos recursos..... | 172 |

CAPÍTULO IV

| | | |
|----|---|-----|
| 1 | Distribuição da amostra de <i>Pinus caribaea</i> por classes de DAP e REND..... | 186 |
| 2 | Distribuição da amostra de <i>Pinus caribaea</i> por classes de D e REND..... | 186 |
| 3 | Distribuição da amostra de <i>Pinus caribaea</i> por as classes de Con. e REND..... | 186 |
| 4 | Modelos testados para a determinação da melhor equação de predição de rendimento de madeira serrada de <i>P. caribaea</i> var. <i>caribaea</i> na EFI Macurije, Cuba..... | 187 |
| 5 | Comparações múltiplas nas classes de DAP, D e Con. pelo Teste de Tukey..... | 192 |
| 6 | Resultados dos ajustes dos modelos tradicionais de predição do rendimento em madeira serrada de <i>Pinus caribaea</i> var. <i>caribaea</i> na serraria <i>Combate de Tenerías</i> | 192 |
| 7 | Valor de Inflação da Variância (VIF) e Tolerância das variáveis independentes de cada um dos modelos tradicionais..... | 194 |
| 8 | Correlação de Pearson entre as variáveis dos modelos..... | 195 |
| 9 | Resultados dos ajustes dos modelos (EDOs) de predição do rendimento em madeira serrada de <i>Pinus caribaea</i> var. <i>caribaea</i> na serraria <i>Combate de Tenerías</i> | 196 |
| 10 | Resultados dos treinamentos das Redes Neurais Artificiais (RNAs) para a predição do rendimento em madeira serrada de <i>Pinus caribaea</i> var. <i>caribaea</i> | 198 |
| 11 | Estatísticas das diferentes abordagens na validação..... | 201 |

CAPÍTULO V

| | | |
|----|--|-----|
| 1 | Variáveis preditoras das classes de qualidade de madeira serrada de coníferas..... | 215 |
| 2 | Estatísticas do ajuste do modelo de regressão logística politômica ordinal..... | 220 |
| 3 | Teste da significância dos parâmetros do modelo Logit ordinal..... | 220 |
| 4 | Validação do modelo de regressão logística ordinal usando as 22 variáveis..... | 221 |
| 5 | Matriz de cargas fatoriais rotacionadas para as 24 variáveis preditoras da qualidade da madeira serrada de <i>Pinus caribaea</i> var. <i>caribaea</i> | 222 |
| 6 | Nomenclatura dos fatores e variáveis explicativas associadas..... | 223 |
| 7 | Estatísticas da qualidade de ajuste da regressão logit-ordinal baseada nos fatores..... | 223 |
| 8 | Teste da hipótese nula no modelo de regressão logística ordinal baseada nos fatores..... | 223 |
| 9 | Significância dos fatores (análise do tipo II) | 224 |
| 10 | Estimativas de parâmetros do modelo de regressão logit-ordinal baseado nos fatores..... | 224 |
| 11 | Validação do modelo de regressão logística ordinal usando como inputs os fatores..... | 225 |
| 12 | Estatísticas dos ajustes e características das Redes Neurais Artificiais (RNAs) para a classificação da madeira serrada de <i>Pinus caribaea</i> var. <i>caribaea</i> considerando como input as 24 variáveis determinantes da qualidade da madeira serrada..... | 225 |
| 13 | Resultados de treinamento, teste e validação da RNA RBF 24-8-4 na classificação da madeira serrada de <i>Pinus caribaea</i> var. <i>caribaea</i> | 226 |

LISTA DE ABREVIATURAS, NOMENCLATURAS E SÍMBOLOS.

| | |
|--------------------|--|
| % | Percentual |
| ANOVA | Análise de Variância Univariada |
| B.M.S. | Buckman Modificado por Silva |
| cm | Centímetro |
| D | Diâmetro menor da tora |
| DAP | Diâmetro a Altura do Peito |
| DCFL | Departamento de Ciência Florestal |
| EDOs | Equações Diferenciais Ordinárias |
| EFI | Empresa Florestal Integral |
| h | Hora |
| ha | Hectare |
| Ht | Altura total |
| IRT | Idade de Rotação Técnica |
| LINDO | Linear, Interactive, and Discrete Optimizer |
| LISREL | Linear Structural Relationships (programa estatístico) |
| m | Metro |
| m ² /ha | Metro quadrado por hectare |
| m ³ /ha | Metro cúbico por hectare |
| MANOVA | Análise de Variância Multivariada |
| MCDA | Multi-Criteria Decision Analysis |
| MINAGRI | Ministerio de la Agricultura |
| MINAGRI | Ministerio de Agricultura |
| MLP | Multi-Layer Perceptron |
| ° C | Graus Celsius |
| PIB | Produto Interno Bruto |
| PML | Programação Por Metas Lexicográficas |
| PO | Pesquisa Operacional |
| PPF | Processo Produtivo Florestal |
| PPGCL | Programa de Pós-Graduação em Ciências Florestais |
| PROCLI | Programa para análise de dados climáticos (confecção de climogramas) |
| RBF | Radial Basis Function |
| REND | Rendimento de madeira serrada |
| RLPO | Modelo de regressão logística politômica ordinal |
| RNAs | Redes Neurais Artificiais |
| S | Sobrevivência (Número de árvores por hectare - Árv. /ha) |
| SAS | Statistical Analysis Software (programa estatístico) |
| SPSS | Statistical Package for the Social Sciences (programa estatístico) |
| UBPF | Unidad Básica de Producción Forestal |
| UPR | Universidad de Pinar del Río “Hermanos Saiz Montes de Oca” |
| US | Unidad Silvícola (Conjunto de UBPF) |
| VIF | Valor de Inflação da Variância |
| XLSTAT | Programa estatístico implementado no excel |
| \sum | Somatória |

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, julho 2017. **Modelos matemáticos para auxílio à tomada de decisão no processo produtivo de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na Empresa Florestal Integral Macurije, Pinar del Río, Cuba.** Orientador: Prof. Dr. José Antônio Aleixo da Silva. Co-orientadores: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira e Prof. Dr. Daniel Alberto Álvarez Lazo.

RESUMO GERAL

Objetivou-se no presente estudo, propor modelos que auxiliem na tomada de decisões no processo produtivo de *Pinus caribaea* var. *caribaea* Barr. & Golf. por meio da aplicação de técnicas multivariadas, análise de regressão, técnicas de análise de decisão multicritério (MCDA) e Redes Neurais Artificiais (RNAs) em diferentes etapas do referido processo. As três etapas do processo produtivo florestal (PPF) envolvidas no presente estudo foram: (1) a fase de crescimento, produção e sobrevivência florestal; (2) a fase de extração e transporte florestal e (3) a fase de transformação primária da madeira. A modelagem de crescimento, produção e sobrevivência da espécie requereu de dados provenientes de parcelas temporárias e permanentes circulares de 500 m² de plantios de *Pinus caribaea* var. *caribaea* da Empresa Florestal Integral Macurije, nas quais foram medidas as variáveis: Diâmetro à Altura de Peito–DAP (cm), altura total – H (m) e sobrevivência - (árv./ha). Nessa etapa, foi realizada a classificação da capacidade produtiva da espécie, foram treinadas Redes Neurais Artificiais (RNAs) e foram ajustados modelos de regressão para a predição e prognose de sobrevivência e crescimento e produção florestal. Na etapa de extração e transporte florestal, avaliou-se o desempenho de diferentes meios e sistemas de extração de madeira por meio de experimentos fatoriais univariados e multivariados sendo *custo* e *produtividade* as variáveis dependentes obtidas por estudos de tempo e movimento. Na mesma etapa, se propôs um modelo de programação por metas lexicográficas para auxiliar a tomada de decisão na extração e transporte florestal. Na etapa de transformação primária da madeira na serraria Combate de Tenerías, foram ajustados modelos de regressão e foram treinadas RNAs, tanto para a predição do rendimento em madeira serrada como para a classificação da mesma. A qualidade de madeira serrada sendo uma variável discreta ordinal, a regressão logística ordinal foi utilizada para sua modelagem. A base de dados requerida para a modelagem do rendimento em madeira serrada foi composta pelas variáveis Diâmetro a Altura do Peito (DAP), Diâmetro menor da tora (D) e conicidade (Con.) obtidas do acompanhamento em tempo real do desdobro da madeira na serraria Combate de Tenerías. As 24 variáveis preditoras da qualidade de madeira serrada foram mensuradas em peças obtidas ao final do processo de desdobro na mesma serraria. Os resultados obtidos ao longo da pesquisa indicaram que as técnicas multivariadas, multicritérios e as Redes Neurais Artificiais são eficientes no auxílio à tomada de decisão nas etapas do PPF consideradas. Os modelos de RNAs apresentaram desempenhos similares ou superiores aos modelos tradicionais de regressão tanto na predição (crescimento volumétrico; rendimento em madeira serrada) ou prognose (sobrevivência; crescimento e produção florestal) como na classificação da madeira serrada. Através dos resultados obtidos ao longo da pesquisa, concluiu-se que não é prudente assumir a superioridade absoluta das RNAs e que optar pela complementaridade de ambas as abordagens em vez do uso exclusivo das RNAs, como a maioria das pesquisas comparativas tendem a sugerir, é bem mais argucioso. A avaliação multivariada dos desempenhos dos meios de extração de madeira e o modelo de programação por metas lexicográfica proposto para o planejamento de extração e transporte de madeira proporcionaram um apoio multicritério traduzido em soluções com maior praticidade e funcionalidade.

Palavras-Chave: Empresa Florestal, técnicas multivariadas, Programação por Metas Lexicográfica, Redes Neurais Artificiais.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, July 2017. **Mathematical models to aid decision making in the productive process of *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. at Macurije Integral Forest Company, Pinar del Río, Cuba.** Adviser: Prof. PhD. José Antônio Aleixo da Silva. Co-advisers: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira and Prof. Dr. Daniel Alberto Álvarez Lazo.

GENERAL ABSTRACT

The objective of this study was to propose models that aid decision making in productive process of *Pinus caribaea* var. *caribaea* Barr. & Golf. through the application of multivariate techniques, regression analysis, multicriteria decision analysis techniques (MCDA) and Artificial Neural Networks (ANNs) in different stages of said process. The three stages of the forest production process (PPF) involved in the present study were: (1) growth, yield and forest survival stage; (2) wood extraction and transport stage, and (3) wood primary transformation stage. *Pinus caribaea* var. *caribaea* growth, yield and survival modeling required data from temporary and permanent circular plots of 500 m² of the Macurije Integral Forest Company, in which the following variables were measured: : Diameter at Breast Height - DBH (cm), total height - H (m) and survival - (num. of trees/ha). At this stage, the specie productive capacity classification was carried, Artificial Neural Networks (ANNs) were trained and regression models were adjusted for growth prediction and yield and survival prognosis. At wood extraction and transport stage, the performance of different wood extraction systems and means was evaluated through univariate and multivariate factorial experiments, being cost and productivity the dependent variables obtained by time and movement studies. At the same stage, a Lexicographic Goals Programming model was proposed to assist decision making in harvesting and forest transport planning. At the stage of wood primary transformation in Combate de Tenerías sawmill, regression models were adjusted and ANNs were trained, both for lumber recovery factor prediction and lumber classification. Lumber quality being a discrete ordinal variable, ordinal logistic regression was used for its modeling. The database required for lumber recovery factor modeling was composed by the variables Diameter at Breast Height (DBH), Smallest log diameter (D) and conicity (Con.) obtained from real-time monitoring of wood sawing at the sawmill *Combate de Tenerías*. The 24 variables predicting lumber quality were measured in pieces obtained at the end the end of sawing process in the same sawmill. The results obtained during the research indicated that multivariate, multicriteria and Artificial Neural Networks techniques are efficient in assisting decision-making in FPP stages considered. ANNs models presented similar or superior performances to the traditional regression models both in prediction (volumetric growth, lumber recovery factor) or prognosis (survival, growth and yield) and in lumber grading. From the results, it was concluded that it is not prudent to assume absolute superiority of ANNs and that opting for the complementarity of both approaches rather than the exclusive use of ANNs, as most comparative research tends to suggest, is far more prudent. Multivariate evaluation of wood extraction machineries performances and the Lexicographic Goal Programming model proposed for timber extraction and transport planning provided a multicriteria support translated into solutions with greater practicality and functionality.

Keywords: Forest company, multivariate techniques, Lexicographic Goal Programming, Artificial Neural Networks (ANNs).

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, juillet 2017. **Modèles mathématiques d'aide à la prise de décision dans le processus de production du *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. dans l'Entreprise Forestière Intégrale Macurije, Pinar del Río, Cuba.** Directeur de Thèse: Prof. Dr. José Antônio Aleixo da Silva. Co-directeurs de Thèse: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira et Prof. Dr. Daniel Alberto Álvarez Lazo.

RÉSUMÉ GENERAL

L'objectif de la présente étude a été de proposer des modèles d'appui à la prise de décision dans le processus productif du *Pinus caribaea* var. *caribaea* Barr. & Golf., par l'application de techniques multivariées, d'analyse de régression, de méthodes d'aide multicritère à la décision (AMCD) et des Réseaux de Neurones Artificiels (RNAs) à divers stades dudit processus. Les trois étapes, du processus de production forestière (PPF), impliquées ont été: (1) croissance, production et survie forestière; (2) l'étape d'extraction et transport du bois et (3) la phase primaire de la transformation du bois. La modélisation de la croissance, production et survie de l'espèce requies de données issues de placettes temporaires et permanentes circulaires de 500 m² implantées dans des plantations de *Pinus caribaea* var. *caribaea* de l'entreprise Macurije, dans lesquelles les variables suivantes ont été mesurées: diamètre à hauteur de poitrine (DHP), hauteur totale (Ht) et survie (Arbres/ha). A cette étape de la recherche, une classification de la capacité productive de l'espèce et des entraînements de RNAs et ajustements de modèles de régression pour la prédiction de la croissance et projection de la production ont été réalisés. Dans la phase d'extraction et transport du bois durant laquelle les performances de différents moyens et systèmes d'extraction de bois ont été évalués au moyen d'expériences factorielles univariées et multivariées. Dans ces expériences, les variables dépendantes furent « coût » et « rendement » obtenus d'études de temps et de mouvements. Ensuite, un modèle de programmation par buts (procédure lexicographique) a été proposé pour aider à la prise de décision dans le transport forestier dans l'entreprise. Dans l'étape de transformation primaire du bois dans la scierie « Combate de Tenerías », des modèles de régression ont été ajustés et des RNAs entraînés pour la prédiction du rendement en bois d'œuvre ainsi que sa classification. La qualité du bois d'œuvre étant une variable discrète ordinale, la régression logistique ordinale a été utilisée pour sa modélisation. La base de données requies pour la modélisation du rendement en bois d'œuvre a été obtenue en temps réel durant le sciage du bois et est composée par les variables suivantes: le diamètre à hauteur de poitrine (DHP), le diamètre inférieur de la grume (D) et la conicité de la grume (Con.). Les 24 variables de prédiction de la qualité du bois d'œuvre ont été mesurées dans des échantillons obtenus à la fin du processus de sciage. Les résultats obtenus au cours de la recherche indiquèrent que les techniques multivariées, multicritères et les RNAs sont efficaces pour l'aide à la prise de décision à différentes étapes du PPF. Les performances des RNAs dans les tâches de prédiction (croissance forestière, rendement du bois d'œuvre), projection (production et survie forestière) et classification (qualité du bois sciés) furent similaires ou supérieures à celles des modèles de régression. En se basant sur les résultats obtenus au cours de la recherche, il a été conclu qu'il n'est pas prudent de supposer une supériorité absolue des RNAs et qu'opter pour la complémentarité des deux approches au lieu de l'usage exclusif des RNAs, comme la plupart des études comparatives suggèrent, est beaucoup plus intelligent. L'évaluation multivariée de la performance des moyens d'exploitation forestière et le modèle de programmation par buts proposé pour la planification de l'extraction et transport du bois ont fournis un soutien multicritère traduit par des solutions d'une praticité et fonctionnalité majeure.

Mots-clés: Entreprise forestière, techniques multivariées, Programmation par Buts Lexicographique, Réseaux de Neurones Artificiels.

I. INTRODUÇÃO GERAL

As contribuições monetárias do setor florestal para as economias nacionais dos países em desenvolvimento excedem os 250 bilhões de dólares, cifra significativamente superior aos fundos destinados anualmente para subsidiar o desenvolvimento e superior à produção global anual de ouro e prata (AGRAWAL et al. 2013). No entanto, em numerosos países, esse setor tem sido pouco aditivo às respectivas economias nacionais. Tal é o caso do setor florestal cubano, que apesar de ter registrado uma admirável recuperação desde 1959, após o processo revolucionário, contribui em apenas 0,2% do Produto Interno Bruto (PIB) da Ilha (FAO, 2015).

Uma das antigas, mas também atuais alternativas para remediar este problema, é a produção a grande escala de florestas plantadas para satisfazer as necessidades em produtos madeireiros e não madeireiros e por consequência incrementar a contribuição do setor. Há previsões de aumento da importância das florestas plantadas e das suas contribuições nas metas de desenvolvimento para as próximas décadas (OSTADHASHEMI et al., 2014). As florestas plantadas, quando são gerenciadas de forma eficiente, constituem a alternativa mais viável dentre dos esforços realizados para a valorização do setor florestal.

A necessidade de conservação da biodiversidade e o rigor da legislação voltada para a preservação das florestas nativas ampliam constantemente as oportunidades de negócios com madeira oriunda das florestas plantadas (SILVA et al., 2014). Em escala mundial, as florestas plantadas representam um ativo econômico importante, ocupando uma área estimada em 264 milhões de hectares correspondentes a 6,6 % da área total do globo terrestre (BORGES et al., 2014). Porém, registros constantes e significativos de exploração ilegal de florestas naturais constituem evidências de que a madeira oriunda de florestas plantadas e de cortes regulatórios legais de florestas nativas não satisfazem as demandas locais e globais em recursos florestais. Essa escassez de recursos, neste caso de recursos florestais, é uma constante no atendimento das necessidades humanas e independe dos sistemas econômicos e políticos das nações (FILGUEIRAS, 1997) e se tratando de um setor de tão significativo potencial de contribuição ao PIB, uma gestão racional e sustentável é imperativa.

Por razões de produção em grande escala para comercialização, as empresas florestais se consagraram como as principais entidades condutoras dos processos produtivos florestais. Essas empresas, para um melhor aproveitamento das oportunidades de negócio com florestas plantadas, observam uma filosofia de planejamento otimizante caracterizada por uma gestão mais inovadora; gestão na qual a tomada de decisões consiste em selecionar a melhor linha de ação em complexos cenários caracterizados por recursos limitados.

Frente a esses desafios contemporâneos e objetivando uma melhor rentabilidade, a indústria florestal se preocupa com uma série de tomadas de decisões que envolvem desde as práticas silviculturais, colheita e transporte, armazenamento correto das toras, adequação de estoque, escolha de equipamentos e toras (matéria prima) a serem serrados, e um bom planejamento nas técnicas de desdobro (NOVAK; SILVA, 2009). Essa imperativa necessidade de tomar decisões adequadas nesses cenários e a de quantificar as respostas de tais decisões são indicadores da importância da aplicação de métodos de gerenciamento na gestão da produção florestal (DYKSTRA, 1984). Essa gestão, definida como a arte e a ciência de tomar decisões com respeito ao planejamento, uso e conservação das florestas e os recursos relacionados (BUONGIORNO & GILLESS, 2003), requer de uma atenção especial para garantir o alcance dos objetivos empresariais predefinidos na alta cúpula da empresa, os quais precisam estar em concordância com as grandes linhas do setor florestal do País em questão. O longo alcance temporal das decisões tomadas, devido aos compridos horizontes de planejamento, determinados pela própria natureza do processo de produção florestal, incrementa a atenção que deve ser dada ao processo decisório. As decisões tomadas, segundo Kangas et al. (2015), devem ser capazes de garantir a sustentabilidade econômica, ecológica e social das florestas.

Inicialmente, como tem acontecido na maioria das atividades econômicas, as decisões eram tomadas de forma instantânea e intuitiva e sem necessidade de observação de princípios de racionalidade, fato atribuído principalmente à remota abundância de recursos. A observação de uma irracionalidade prolongada no consumo dos recursos florestais levou a uma mudança de cenário, passando do, acima citado, quadro de abundância de recursos a um quadro de escassez que fez apelo à observação dos conhecidos princípios de racionalidade e sustentabilidade.

Frente a esses desafios, o processo decisório empresarial deve ser um processo estruturado e não intuitivo (SILVA, 2006), auxiliado por métodos estatísticos e métodos de programação matemática como os de programação linear e programação dinâmica (BETTINGER et al. 2009).

Os modelos monocritérios de programação linear, apesar da sua grande utilidade, robustez e popularidade, têm sido geralmente irrealistas (DIAZ-BALTEIRO; GONZÁLEZ-PACHÓN e ROMERO, 2013; ALDEA et al., 2014) devido principalmente as limitações apresentadas na hora de representar de forma fidedigna, os sistemas reais em estudo (LEUSCHNER, 1990; ROMERO, 1993). Nesses problemas reais da gestão florestal, os centros decisores não se baseiam apenas em um critério único como é realizado no paradigma

tradicional decisional (ROMERO, 1993). A multi-objetividade é então característica da gestão florestal contemporânea (OSTADHASHEMI et al., 2014) e os objetivos ou metas envolvidas se encontram muitas vezes em conflito (UHDE et al., 2015).

As técnicas de análise de decisão multicritério (MCDA), principalmente os modelos de programação por metas, tornaram-se então as técnicas alternativas mais utilizadas para auxílio a tomada de decisão na gestão florestal (ROMERO, 1991; DIAZ-BALTEIRO; GONZÁLEZ-PACHÓN e ROMERO, 2013; CHEN; CHANG, 2014; COLAPINTO; JAYARAMAN e MARSIGLIO, 2015). Das variantes desta técnica, as mais utilizadas na gestão florestal são: a programação por metas ponderadas e a programação por metas lexicográfica (DIAZ-BALTEIRO; ROMERO, 2008). Diaz-Balteiro, González-Pachón e Romero (2013) atribuem a popularidade dessas técnicas à três aspectos essenciais: (1) sua alta flexibilidade que permite a inclusão de inúmeros critérios de diferente natureza envolvidos na maioria das decisões tomadas na gestão dos recursos florestais; (2) a flexibilização das restrições “rígidas” para restrições “fracas” recorrendo ao conceito de meta e (3) por oferecer um quadro eficaz para a filosofia de satisfação de Simon, invalidando assim a filosofia de otimização da abordagem tradicional de programação linear.

Situações nas quais se procura saber a existência ou não de diferença significativa entre diferentes grupos ou tratamentos são comuns na gestão dos recursos florestais e as técnicas mais utilizadas são as técnicas de estatística univariada, principalmente a análise de variância univariada (ANOVA). Mais, as comparações nem sempre estão baseadas em apenas uma variável e de fato, a maioria delas precisam ser realizadas se baseando na maior quantidade de critério (variável) possível para obter resultados mais acurados, no intuito de tomar decisões acertadas. Essa multiplicidade de variáveis dependentes para análises mais criteriosas e multidimensionais, assim como a correlação existente entre as mesmas justificam a utilização e popularização das técnicas de estatística multivariada (HUBERTY; MORRIS, 1989; ANDERSON, 2003). Estas técnicas, segundo Hair Jr et al. (2014), são as únicas que possibilitam o adequado exame das múltiplas relações existentes entre variáveis dependentes para uma compreensão mais realista na tomada de decisões.

As decisões na área florestal envolvem diversas situações nas quais é essencial ter informações referentes, ao estoque futuro dos povoamentos (NASCIMENTO et al., 2015) e ao rendimento e qualidade de madeira serrada. Essas informações são geralmente obtidas por meio de equações resultantes de modelagens baseadas na técnica de análise de regressão.

Porém, uma técnica em auge na gestão florestal e cujo interesse tem crescido significativamente nos últimos anos é a de Redes Neurais Artificiais – RNAs (ÖZÇELİK et al., 2010; KUMAR, AGGARWAL e SHARMA, 2015). Se a geração e utilização dessa técnica têm se mostrado extremamente atrativa para as empresas florestais nas últimas décadas (BINOTI, 2015), não é o caso das empresas florestais cubanas nas quais não há registros da utilização da mesma.

As RNAs têm como metáfora o funcionamento do cérebro humano com suas redes neurais biológicas (VALENÇA, 2010). Considerada como uma das técnicas mais modernas no auxílio à tomada de decisão (LEAL et al. 2015), a RNA é geralmente utilizada como alternativa ao procedimento de análise de regressão (KUMAR; AGGARWAL e SHARMA, 2015) e tem apresentado, em diferentes áreas da Engenharia Florestal, resultados equivalentes ou superiores as técnicas usuais (LEITE et al., 2016a).

Entre as numerosas vantagens que motivam ao uso das RNAs, estão a sua robustez a ruídos e dados incompletos, seu alto poder computacional, o paralelismo da sua estrutura, a capacidade de modelagem de relações não-lineares (VALENÇA, 2005; ÖZÇELİK, et al., 2010; HANRAHAN, 2011), a não exigência de pressupostos específicos sobre as características de distribuição das variáveis, o que faz dela uma técnica não-paramétrica (DIAMANTOPOULOU, 2005; VIRIYAMETANONT, 2008; GIAM; OLDEN, 2015) e sua capacidade de obter bons ajustes com a introdução de variáveis categóricas (HAYKIN, 2001).

Outro aspecto que está favorecendo a popularização das RNAs nas últimas décadas é a sua utilização juntamente com a lógica fuzzy para tomar decisões em situações em que a incerteza é um fator significativo (SHAO; REYNOLDS, 2006). Contudo, as RNAs não são panacéias (WASSERMAN, 1989 apud SHAO; REYNOLDS, 2006), mas suas principais desvantagens como treinamentos demorados (horas ou mesmo dias dependendo do volume de dados), frequentes resultados sem consistência biológica que requerem a experiência do pesquisador e o fenômeno de caixa-preta que impossibilita a interpretação de determinado resultados, não conseguiram impedir o contínuo crescimento do seu uso em inúmeras áreas.

A característica univariada ou monocritério das ferramentas (modelos) que auxiliam nas tomadas de decisões nas diferentes etapas do processo produtivo florestal (produção florestal, colheita e transporte florestal e transformação primária da madeira) nas empresas florestais em geral e na EFI Macurije em particular, pode ser responsável pelas discrepâncias existentes entre os resultados esperados e a realidade observada após a tomada de determinadas decisões ou

escolha de determinadas alternativas, erroneamente consideradas mais adequadas por se basear apenas em uma única variável ou critério.

Diante do exposto, o **objetivo geral** da presente tese foi propor sistemas ou modelos matemáticos para auxílio nas tomadas de decisões em determinadas etapas do processo produtivo de *Pinus caribaea* var. *caribaea* na Empresa Florestal Integral (EFI) Macurije por meio da aplicação de técnicas multivariadas, multicritérios e Redes Neurais Artificiais.

O alcance deste objetivo geral dependeu do alcance dos seguintes **objetivos específicos**:

- ❖ Obter sistemas aperfeiçoados de predição e/ou prognose de crescimento, produção e sobrevivência de *Pinus caribaea* var. *caribaea* por meio de ajustes de modelos clássicos de regressão não linear e treinamentos de Redes Neurais Artificiais (Capítulo I);
- ❖ Avaliar tecnicamente e economicamente, por meio de experimentos fatoriais univariados e multivariados, os desempenhos das máquinas de extração e transporte de madeira em diferentes cenários identificados nas florestas plantadas de *Pinus caribaea* var. *caribaea* da empresa florestal integral Macurije (Capítulo II);
- ❖ Propor um modelo de programação por metas lexicográfica para auxiliar o planejamento de extração e transporte de madeira na Empresa Florestal Integral Macurije (Capítulo III);
- ❖ Obter sistemas de predição de rendimento em madeira serrada de *Pinus caribaea* var. *caribaea* na serraria Combate de Tenerías por meio de ajustes de modelos de regressão e treinamentos de Redes Neurais Artificiais (Capítulo IV);
- ❖ Obter sistemas de auxílio a classificação de madeira serrada de *Pinus caribaea* var. *caribaea* na serraria Combate de Tenerías da Empresa Florestal Integral (EFI) Macurije, por meio de ajustes de modelos de Regressão Logística Ordinal e treinamentos de Redes Neurais Artificiais (Capítulo V).

II. REFERENCIAL TEÓRICO

2.1. Processo Produtivo Florestal (PPF) e níveis de planejamento

O processo produtivo, também conhecido como cadeia de abastecimento, começa com o fornecimento de matérias-primas, passa por uma ou várias etapas de fabricação, armazenamento e distribuição, e termina nos produtos finais (GUNNARSSON, 2007; BETTINGER et al., 2009; VAHID, 2011). Seu análogo na produção florestal, conhecido como Processo Produtivo Florestal (PPF), pode ser visto como um sistema de operações que começa a partir da etapa de produção florestal (plantios), a derrubada das árvores para obter as toras, seu envio para as unidades de transformação primárias tais como serrarias, fábricas de celulose ou plantas para produção de outros produtos, para então obter produtos como toras, madeira serrada, celulose, papel e resíduos florestais entre outros produtos (MITCHELL, 1992; EPSTEIN et al., 2007; GUNNARSSON, 2007). As unidades de transformação primária são muito diversificadas e dependem da gama de produtos produzidos na empresa em questão. Adicionalmente às unidades acima citadas, Weintraub (2002) faz referência as fábricas de compensados se a produção da madeira compensada está contemplada dentre dos produtos.

Na gestão de recursos naturais, o Processo Produtivo Florestal (PPF) pode ser descrito por cinco funções (BETTINGER et al., 2009): a coleta de dados, a estimativa de demanda, planejamento, execução e elaboração de relatórios. Essas funções são observadas ao longo das diferentes fases do PPF que são basicamente: (1) a fase de produção de matéria prima (madeira), (2) a de colheita e transporte dessa matéria prima em diversas formas (toras para serraria, para celulose e resíduos) para as unidades de transformação primária (serrarias, fábrica de celulose, planta de aquecimento) e secundária (fábrica de papel) e (3) a de transporte dos respectivos produtos para os consumidores (Figura 1).

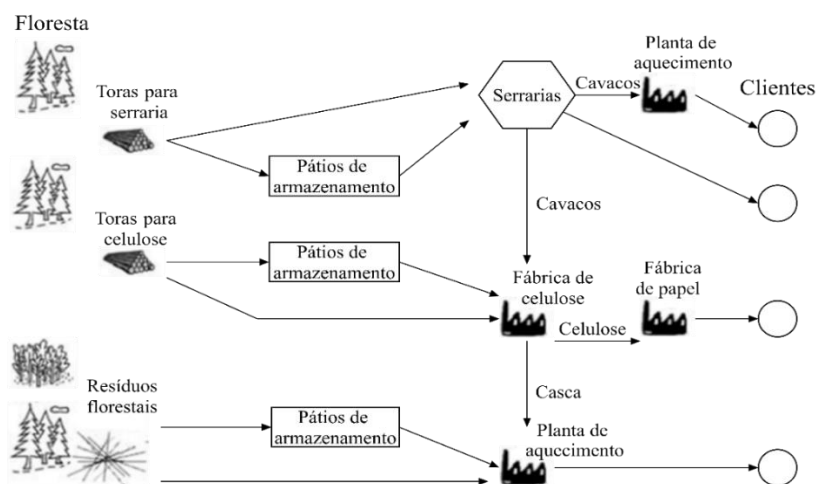


Figura 1 – Componentes do Processo de Produção Florestal

(Fonte: GUNNARSSON, 2007)

O planejamento do processo produtivo florestal pode ser dividido em três níveis: estratégico, tático e operacional. O nível estratégico é constituído principalmente pelo planejamento de investimentos e de infraestruturas (GUNNARSSON, 2007). Este nível inclui também a estimação da colheita pela predição e/ou prognose da produção, determinação da idade de rotação de determinada espécie submetida a determinado regime de manejo e o planejamento e avaliação de alternativas de extração e transporte da madeira. Subsequente a este nível de planejamento está o planejamento tático que se diferencia principalmente do anterior pela base de dados utilizados. Contrariamente aos planos estratégicos que se caracterizam por longos horizontes de planejamento, os planos táticos têm um horizonte de planejamento mais reduzido com um cumprimento que varia de 1 à 1,5 vezes a idade de rotação da espécie. É uma fase chave do planejamento cuja eficiência é auxiliada por modelos de pesquisa operacional já que os principais objetivos desta fase estão relacionados com a especificação de alternativas ou prescrições que minimizem os custos globais ou maximizem os retornos. Na fase operacional, as informações fornecidas pelo planejamento tático são utilizadas para definir especificidades e cronogramas de execução de atividades no PPF.

O objetivo final do PPF é a de executar os planos com o máximo de eficiência e atender todas as exigências de cada uma das etapas ao longo de todo o processo. Para o mesmo, os gestores de recursos naturais devem estar cientes da influência das suas decisões sobre a rentabilidade dos seus negócios, bem como sobre os negócios dependentes da madeira colhida (BETTINGER et al., 2009). Segundo Hall e Potts (2003), a significativa redução dos custos e aumento da eficiência do sistema de produção como um todo passa necessariamente pela integração dos processos de tomada de decisão entre os referidos componentes do PPF. Neste sentido, o conceito de empresa verticalmente integrada virtualmente, desenvolvido por Zielke e Pohl (1996), tem dado resultados satisfatórios na rotura das fronteiras organizacionais para uma maior integração e eficiência na produção.

Há muitas decisões a serem tomadas ao longo de uma cadeia de produção e técnicas de modelagem podem, direta ou indiretamente, ajudar os decisores revelando as consequências das ações e estratégias propostas (VAHID, 2011). Esse apoio à tomada de decisões, nos níveis estratégicos, táticos e operacionais nas diferentes etapas do processo produtivo florestal, é realizado por um conjunto de sistemas baseados em modelos matemáticos dentre dos quais os de pesquisa operacional destacam-se (WEINTRAUB, 2002). Embora esses modelos de pesquisa operacional (Programação Linear, Programação Linear Inteira, Métodos de Análise de Decisão Multicritério, etc....) sejam formulados geralmente sobre uma base estratégica,

determinadas restrições podem possibilitar o seu uso para a tomada de decisões nos níveis táticos e operacionais (GUNNARSSON, 2007).

Adicionalmente às técnicas supracitadas, outras técnicas que auxiliam nas tomadas de decisões no PPF são os modelos de crescimento e produção florestal que tem um papel fundamental no planejamento estratégico (BETTINGER et al., 2009).

2.2. Generalidades sobre a espécie objeto de estudo: *Pinus caribaea* Morelet

O gênero *Pinus*, com mais de 100 espécies reconhecidas, é o mais amplo dentro das coníferas (PRICE et al., 1998). É um dos gêneros mais plantados nas regiões tropicais (LAMB, 1973 apud KELLMAN; HUDSON, 1982), sendo seu rápido crescimento e/ou sua grande tolerância a solos pobres e condições relativamente áridas, segundo Price et al. (1998), as principais razões da sua popularidade nos planos de reflorestamentos. Além disto, Le Maitre (1998) atribui a referida popularidade ao seu alto valor econômico.

Originária da América Central (desde as latitudes de 12°13' N em Nicarágua a 27°25' N nas Ilhas Bahamas e longitude de 71°40' W a 89°25' W (Figura 2), a espécie *Pinus caribaea*, identificada como por Little Jr. e Dorman (1952) e foi classificada em três variedades por Barret e Golfari (1962): as variedades *caribaea*, *bahamensis* e *hondurensis* (ZHENG; ENNOS, 1999). A variedade *hondurensis* se encontra naturalmente distribuída da península de Yucatán do México até Nicarágua e a *bahamensis* nas ilhas do Bahamas e nos Caicos (ROJAS; ORTIZ, 1990). A variedade *caribaea*, endêmica de Cuba e objeto de estudo do presente trabalho, tem uma área de distribuição restringida à Pinar del Río. Existem também relatos da sua ocorrência natural na região central de Cuba e na *Isla de la Juventud*.

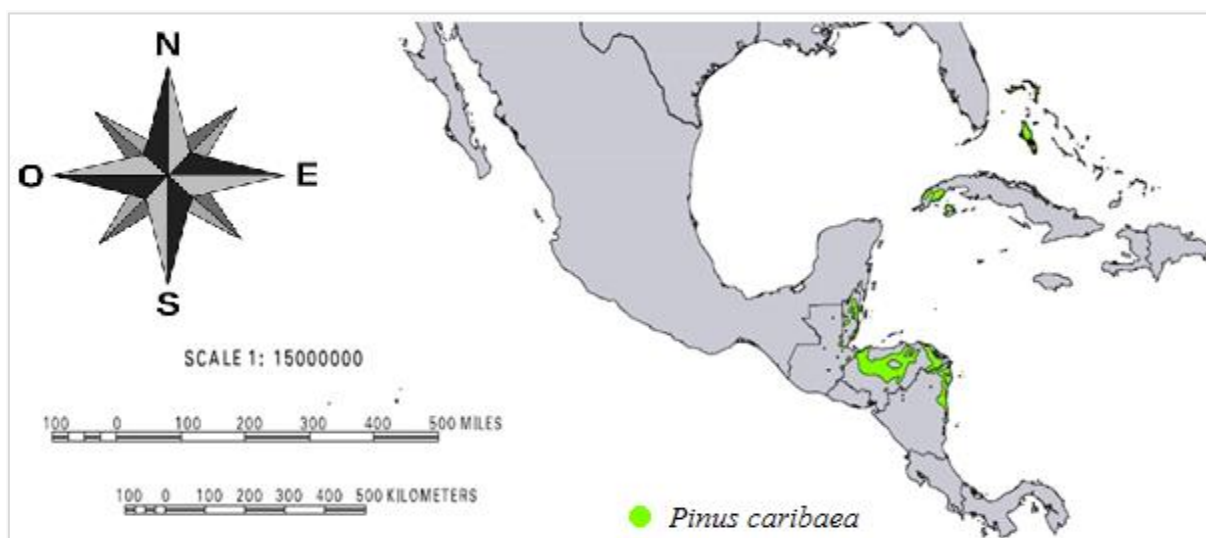


Figura 2 -Área de distribuição natural do *Pinus caribaea*

(Fonte: Adaptado de CRITCHFIELD; LITTLE, 1966).

2.2.1. Estudos sobre o *Pinus caribaea* Morelet

A literatura florestal evidencia o grande interesse que muitos pesquisadores têm demonstrado para esta espécie por meio de numerosos estudos realizados em diferentes condições (naturais e plantadas) e regiões do mundo. Por área de estudos, pode-se citar: estudos nutricionais em condições naturais (KELLMAN; HUDSON, 1982; KELLMAN; MIYANISHI; HIEBERT, 1987; KADEBA, 1991) e em plantações (LILIENFEIN et al. 2000); estudos de sobrevivência em caso de ataque por pragas e doenças (IVORY; MUNGA, 1983; GBADEGESIN, 1993); estudos sobre sua utilização na restauração de áreas degradadas (ASHTON et al., 1997); estudos de melhoramento genético (SILVA, 2005) e estudos de crescimento na África (ADEGBEHIN et al., 1988), Ásia (WANG; MALCOLM; FLETCHER, 1999) e na América (HERRERO, 1985; GRÁ, 1990; GARCÍA; ALDANA; ZALDÍVAR, 2004a; ALDANA et al., 2009; BARRERO, 2010; ALDANA; PADILLA; RODRÍGUEZ, 2011; BARRERO et al., 2011). A diversidade dos resultados encontrados em dependência das condições e a localidade indica a forte influência do ambiente no fenótipo da espécie, verificando-se a fórmula genética segundo a qual o FENÓTIPO = GENÓTIPO + AMBIENTE.

2.2.2. Florestas plantadas de *Pinus caribaea* var. *caribaea* em Cuba

Depois do alto desmatamento sofrido no período pré-revolucionário que deixou a cobertura florestal em aproximadamente 14%, uma paulatina recuperação foi observada a partir de 1959. As porcentagens registradas nos últimos anos foram: 27,6 % em 2010, 28% em 2011, 28,7 % em 2012 e 29% em 2013 (ONEI, 2014). Essa cobertura florestal está constituída, principalmente, por quatro espécies de *Pinus*: o *Pinus caribaea* var. *caribaea* e o *Pinus tropicalis* Morelet na parte ocidental e na parte oriental o *Pinus cubensis* Griseb e o *Pinus maestrensis* Bisse (BETANCOURT, 1987). O *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. por ocupar 91,1% da cobertura florestal de coníferas da Província de Pinar del Río e pela qualidade e diversidade de uso da sua madeira, tornou-se a espécie mais utilizada nos planos de produção e de reflorestamento (EGAS, 1998; MINAGRI, 2001). A última atualização do ordenamento florestal da EFI Macurije realizada por Aldana, Puentes e Romero (2006) revelou que o patrimônio florestal da empresa representa 17,8% (495.348,9 ha) dos recursos florestais da província, predominando o *Pinus* spp. com 47,6% da área total. Dados mais atuais indicam que a empresa tem um patrimônio florestal de 98.000 hectares, dos quais a metade é constituída por florestas nativas e plantadas de *Pinus* spp. (DOMÍNGUEZ, 2016).

A preferência do *Pinus caribaea* não só se atribui ao fato dela ser endêmica da região ocidental do país, mas também a aspectos fundamentais como:

- Um rápido crescimento e a classificação da sua madeira como moderadamente pesada ou pesada segundo Forest Products Laboratory (FPL);
- Uma grande versatilidade por ser fonte de produtos como madeira serrada para construção, celulose para papel, resina, madeira para postes elétricos, lâminas de compensados, lenha, artesanato, móveis e carvão, etc.... (CHUDNOFF, 1984; BETANCOURT, 1987);
- Uma plasticidade ecológica adquirida pela sua tolerância a uma grande variabilidade de solos, incluindo solos pouco férteis e degradados.

2.3. Estudos de crescimento e produção florestal

2.3.1. Classificação da capacidade produtiva de sítios florestais

A classificação da capacidade produtiva é a primeira etapa de estudos de crescimento e produção de florestas plantadas. Também conhecida como qualidade do local ou índice de sítio, pode ser definida como o potencial para produção de madeira em determinado lugar para determinada espécie ou clone (CAMPOS; LEITE, 2017). Nesta mesma ordem de ideias, autores como Clutter et al. (1983) e Skovsgaard e Vanclay (2008) a definiram como a produção esperada em um determinado local com um dado genótipo (espécie) e um regime de manejo específico.

Os métodos de determinação da capacidade produtiva se classificam em dois grupos: os métodos diretos baseados no histórico de produtividade, no volume e na altura; e os métodos indiretos baseados no histórico de relações interespecíficas, nas características da vegetação e em fatores climáticos, edáficos e fisiográficos (CLUTTER et al., 1983).

Embora existam todos esses métodos, o mais utilizado é o índice de sítio (ORTEGA; MONTERO, 1988) definido como a altura dominante média do povoamento na idade índice (CAMPOS; LEITE, 2017). Desde os primeiros trabalhos, as variáveis utilizadas juntamente com a idade para a determinação do índice do local têm mudado muito. As mais encontradas na literatura são: a altura média correspondente à média aritmética das alturas de todas as árvores da amostra considerada e, principalmente, a altura dominante cuja definição mais usual a considera como a altura média das 100 árvores de maior diâmetro em um hectare (ASSMANN, 1961). Esta última variável dentrométrica é a mais utilizada por ser considerada a mais adequada, devido à pouca influência dos desbastes por baixo e da densidade do povoamento nela.

Os principais métodos de construção de curvas de índice de sítio são: os métodos da curva-guia e de Hammer que geram curvas anamórficas (com dados de parcelas permanentes e temporárias), os métodos de atribuição preliminar de índices de local, o método da equação das

diferenças e o método da predição de parâmetros (com dados de parcelas permanentes ou de análise completa de tronco) (CLUTTER et al., 1983; CAMPOS; LEITE, 2017).

2.3.2. Estudos de crescimento e produção florestal e sua classificação

As origens dos modelos de produção florestal remontam ao final do século XVIII na Alemanha com o desenvolvimento das tabelas de volume (VUOKILA, 1965). Na atualidade, as prognoses de crescimento e produção são realizadas com equações ou sistemas de equações matemáticas inter-relacionadas e não como tabelas de volume. Uma das causas dessa mudança é a popularização dos computadores que permitiram a passagem de métodos gráficos que eram utilizados para a construção das tabelas de volume a métodos analíticos a partir de 1940 (ALDANA, 2010). Devido a maior precisão, menor subjetividade e a possibilidade de fazer prognoses em quaisquer cenários, esses métodos causaram o desuso dos métodos gráficos.

O crescimento refere-se ao acréscimo nas dimensões de um sistema orgânico (árvores individuais ou povoamentos) enquanto a produção é relacionada ao seu tamanho final após um período definido de observação (VANCLAY, 1994; OLIVEIRA; MACHADO, 1995; SPATHELF; NUTTO, 2000; BURKHART; TOMÉ, 2012). Esta relação é matematicamente expressa da seguinte maneira: o crescimento é a derivada da produção e a função de produção é a integral da função de crescimento (VANCLAY, 1994; BURKHART; TOMÉ, 2012).

Um modelo matemático é uma formulação matemática baseada em hipóteses, que tenta representar fenômenos físicos ou biológicos, com a finalidade de gerar uma equação que possa estimar quantitativamente tal (is) fenômeno (s) a um determinado nível de probabilidade (SILVA, 2015). A aplicação da modelagem matemática ao crescimento e produção das florestas, sejam elas plantadas ou nativas, dão resultados amplamente conhecidos na literatura florestal por modelagem de crescimento e produção florestal, que tem como resultados os úteis modelos de crescimento e produção florestal. Esses modelos auxiliam pesquisadores e gestores florestais, principalmente com a predição ou prognose dos rendimentos futuros das florestas, com a finalidade de selecionar melhores opções de manejo, alternativas silviculturais mais adequadas ou planejar frequências e sequências da colheita florestal (VANCLEY, 1994; BURKHART; TOMÉ, 2012).

A gama de modelos de crescimento varia de simples modelos estatísticos ao nível de povoamento até complexos modelos elaborados para a descrição de processos fisiológicos da árvore individual (ADLARD, 1995). Na literatura florestal, encontram-se numerosas propostas de classificação dos modelos de crescimento e produção florestal. A proposta por Clutter et al.

(1983) é uma das mais relevantes ou populares na literatura florestal. Essa classificação é feita atendendo à diversas características:

1. Tipo de floresta: os modelos se classificam em modelos equiâneos e modelos inequiâneos ou em modelos com desbaste e modelos sem desbaste.
2. Em relação à complexidade matemática, os modelos se classificam em: tabela de volume e modelo em forma de equações ou sistemas de equações (predições por unidade de área e realizadas por equações, por classes de árvores ou equações de árvores individuais).

Uma classificação mais completa é a proposta por Davis e Johnson (1987) (Figura 3). Desta classificação, os modelos ao nível de povoamento são os mais susceptíveis de servir as necessidades de gestão das florestas nas últimas décadas (ADLARD, 1995).

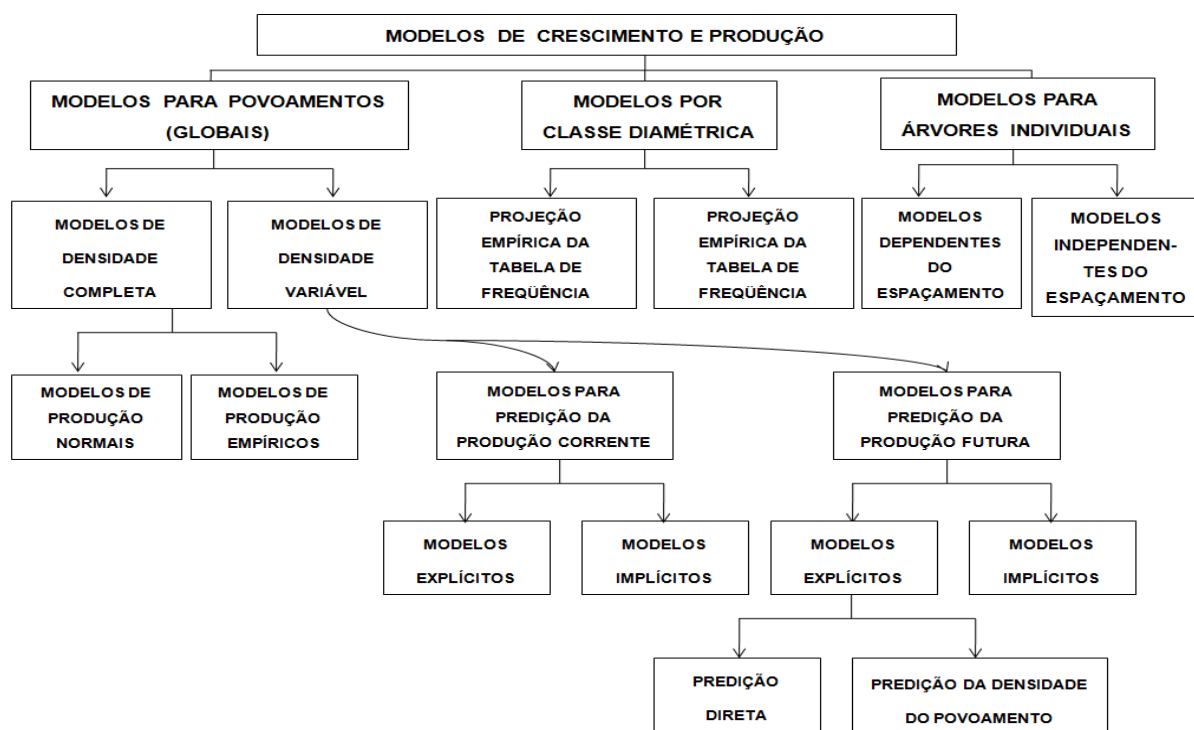


Figura 3 - Classificação de modelos de crescimento e produção florestal
(Fonte: Adaptado de Davis e Johnson, 1987)

Uma classificação simples e muito adotada é a que divide os modelos de crescimento em **modelos empíricos** nos quais não são consideradas as causas do fenômeno modelado e **mecanísticos** ou **teóricos** que objetivam o estudo dos fenômenos para entendimento dos processos (VANCLAY, 1994; SPATHELF; NUTTO, 2000; BURKHART; TOMÉ, 2012). Na modelagem de fenômenos biológicos incluindo o crescimento florestal, os modelos teóricos são geralmente conhecidos como modelos biológicos. Por isso, essa classificação é encontrada com nomenclaturas diferentes classificando os modelos em modelos **empíricos** ou **matemáticos** e

modelos **biológicos** ou **teóricos** (SILVA, 2015). Os modelos matemáticos são modelos cujas expressões matemáticas expressam apenas uma relação entre um grupo de variáveis e os modelos biológicos são os elaborados com base a hipóteses baseadas no realismo do fenômeno modelado, neste caso, o crescimento florestal.

Entre os modelos biológicos utilizados para a modelagem de crescimento florestal, se destaca o modelo de Chapman-Richards (1959), o qual é uma generalização do modelo de Von Bertalanffy (1938) derivado de estudos das então chamadas relações alométricas entre elementos dimensionais de um organismo (SILVA, 2015).

Um modelo generalizado de crescimento do qual derivam a maioria dos modelos crescimento é o de Schnute (1981) (Expressão 4). Esse modelo, desenvolvido em pesquisas pesqueiras, foi baseado em duas equações diferenciais ordinárias de primeira ordem (Expressões 1 e 2). A expressão 1 indica que o crescimento é uma função de tamanho, Y , e a taxa de crescimento, z e a expressão 2 indica que a mudança na taxa de crescimento, z , é uma função linear de Z . A combinação de ambas as equações diferenciais de primeira ordem geram uma equação diferencial ordinária de segunda ordem que descreve a aceleração do crescimento (Expressão 3).

$$\frac{dY}{dt} = zY \quad (1)$$

$$\frac{dZ}{dt} = -(\alpha + \beta z) \quad (2)$$

$$\frac{d^2Y}{dt^2} = \frac{dY}{dt} [-(\alpha + \beta z)] \quad (3)$$

$$Y(t) = \left[Y_1^\beta + (Y_2^\beta - Y_1^\beta) \frac{1 - e^{-\alpha(t-t_1)}}{1 - e^{-\alpha(t_2-t_1)}} \right]^{1/\beta} + \varepsilon; \quad (\alpha \neq 0, \beta \neq 0) \quad (4)$$

Em que: $Y(t)$ = tamanho do organismo no tempo t ; Y_1 e Y_2 = tamanho do organismo nos tempos t_1 e t_2 (a ser estimado através de regressão); z = taxa de crescimento; α , β = parâmetros a serem estimados por regressão.

Para determinados valores de parâmetros, o modelo geral de Schnute gera 10 modelos de crescimento, incluindo não apenas funções de crescimento sigmoidais com tamanho final assintótico, mas também modelos lineares e exponenciais (Anexo 2.0).

O modelo de Chapman-Richards, caso específico do modelo generalizado de crescimento de Schnute (1981) para $\alpha > 0$, $\beta < 0$, é o mais utilizado para a modelagem de crescimento florestal (LEI; ZHANG, 2004). Esse modelo de Chapman-Richards, para valores específicos do parâmetro “ m ” associado a localização do ponto de inflexão, geram os modelos

de Von Bertalanffy ($m= 2/3$), Gompertz ($m=1$), Logística ($m=2$) e Monomolecular ($m=0$). O modelo Monomolecular ou de Mitscherlich, embora tenham bases biológicas, não tem um ponto de inflexão e nem uma forma sigmoide (FEKEDULEGN; MAC SIURTAİN; COLBERT, 1999). Outros modelos de crescimento biológicos/sigmoidais utilizados com resultados satisfatórios na modelagem do crescimento florestal, são os de Schumacher, Silva-Bailey, Brody, Lundqvist-Korf (Anexo 1.0).

2.3.3. Elementos dos avanços na modelagem de crescimento e produção florestal

Nas últimas décadas, o nível geral de sofisticação desses modelos tem crescido devido a muitos fatores como a disponibilidade de técnicas estatísticas mais refinadas, de bases de dados em expansão, de melhor compreensão da dinâmica da floresta, e do poder crescente e disponibilidade de computadores (SHAO; REYNOLDS, 2006). Dentre as últimas pesquisas inovadoras, pode-se citar as de: Cao (2014) que usa o método da desagregação que permitiu a melhora das predições de crescimento e produção; por outra parte, o caráter empírico da maioria dos modelos usados (exclusivamente utilizáveis nas condições nas que foram desenvolvidas) levou Ashraf (2015) a propor uma nova abordagem para a previsão do crescimento e produção sob alterações climáticas; Hagihara (2014) estudou a trajetória da densidade no crescimento das florestas plantadas conciliando as leis de desbaste e auto-desbastes; Castro et al., (2015) avaliou a eficiência e aplicabilidade de diferentes métodos de determinação do índice do local na modelagem do crescimento e da produção de povoamentos comerciais de *Eucalyptus*.

Uma das técnicas que se encontram em pleno auge não por ser recente mais pela sua recente aplicação na gestão florestal e pelos satisfatórios resultados obtidos é a técnica de Inteligência Artificial conhecida sob o nome de Redes Neurais Artificiais (RNAs). Entre os trabalhos mais relevantes nas últimas décadas, pode-se citar os de Gordon (1998), Higgins (2011), Binoti (2012), Ashraf et al. (2013), Castro et al. (2013a e 2013b); Özçelik et al. (2014) que utilizam essas técnicas de RNAs para estudos de crescimento e produção em florestas plantadas; os trabalhos de Porras (2007) e Lima (2014) que abordam seu uso na modelagem do crescimento em florestas nativas.

2.3.4. Modelos compatíveis de crescimento e produção florestal

Compatibilidade, consistência e flexibilidade são três características básicas desejáveis em todo modelo de crescimento e produção florestal (GORGENS et al., 2007). Até 1962, os modelos de crescimento eram desenvolvidos de forma separada aos de produção (CLUTTER et al., 1983). A ausência do depois conhecido como princípio de compatibilidade constituía uma enorme limitação para esses modelos já que a soma das estimativas de sucessivos

incrementos era diferente do volume predito pela equação de produção (OLIVEIRA; MACHADO, 1995). A compatibilidade matemática e biológica se tornou então uma propriedade altamente desejável nos modelos de crescimento e produção florestal e o problema foi abordado pela primeira vez pelos modelos de crescimento e produção compatíveis de Buckman e Clutter (BUCKMAN, 1962; CLUTTER, 1963) que foram reconhecidos como os pioneiros desses estudos. Nesses modelos, a produção é obtida por integração do modelo de crescimento e esse último obtido pela derivada do modelo de produção (CLUTTER, 1963).

2.3.5. A sobrevivência/mortalidade florestal: outro componente do crescimento e produção florestal

A mortalidade de árvores é um dos principais elementos da dinâmica florestal (BIGLER; BUGMANN, 2003); variável complementar da sobrevivência que pode ser definida como a redução da densidade da floresta ocasionada por fatores naturais (SANQUETTA, 1990). Segundo Campos e Leite (2017), a mortalidade não deve ser confundida com as falhas de plantio que ocorrem na etapa inicial do estabelecimento dos plantios. Negligenciar este fenômeno, como acontece geralmente, é aceitável apenas em plantações florestais industriais intensamente manejadas (VANCLAY, 1991), principalmente se desbastes periódicos estão incluídos dentro dos tratamentos silviculturais aplicados (CAMPOS; LEITE, 2017).

Embora a mortalidade ou sobrevivência seja implícita nos modelos de prognose de crescimento e produção florestal, a sua modelagem é realizada de forma explícita para obter equações de auxílio a toma de decisões relacionadas com as densidades dos povoamentos. Em dependência da fonte dos fatores naturais ao que faz referência Sanquetta (1990), dois tipos de mortalidade são identificados na literatura florestal (CAMPOS; LEITE, 2017): a mortalidade regular característica de povoamentos superestocados e atribuída a fatores intrínsecos às árvores como a senescência, a genética e a alta competição por recursos naturais limitados; e a mortalidade irregular causada por fatores não intrínsecos às árvores como incêndios, doenças e pragas, ventos e danos mecânicos. A complexidade da previsão dos fatores causadores da mortalidade irregular dificulta a sua projeção e por isso a maioria dos estudos focam na mortalidade regular.

Numerosos métodos de prognose de mortalidade regular foram desenvolvidos para florestas monoespecíficas (VANCLAY, 1991). A sobrevivência florestal é geralmente modelada ao nível de povoamento ou de árvore individual (THAPA, 2014). Os modelos ao nível de povoamento se baseiam na idade e densidade do povoamento e os desenvolvidos ao

nível de árvore individual se baseiam geralmente na probabilidade de mortalidade de cada árvore ou grupo de árvores.

As principais variáveis dependentes desses modelos são: o número de árvores por hectare (N/ha) como nos modelos desenvolvidos por Clutter e Jones (1980), Pienaar e Shiver (1981) e Silva (1986) que projetam a sobrevivência; a probabilidade de mortalidade das árvores como na abordagem proposta por Hamilton (1974).

Dentre os numerosos modelos, geralmente não lineares, propostos para a modelagem da sobrevivência (ou mortalidade) ao nível de povoamento, podem-se destacar os de Clutter e Jones (1980), Pienaar e Shiver (1981) e Silva (1986) que têm se mostrado adequados e eficientes para a análise do fenômeno em numerosos estudos. Segundo Clutter et al. (1983), os modelos adequados para a prognose de mortalidade devem possuir as seguintes propriedades:

- Se I_2 é igual a I_1 , N_2 deve ser igual a N_1 ;
- Para povoamentos equiâneos, quando I_2 é muito avançada N_2 deve se aproximar de zero;
- Se o modelo é utilizado para projetar N_2 na idade I_2 , e I_2 e N_2 são utilizados para projetar N_3 numa idade I_3 ($I_3 > I_2 > I_1$), o resultado deve ser igual à projeção única de I_1 a I_3 .

Em relação ao nível de árvore individual, o modelo proposto por Hamilton (1974) foi o pioneiro de numerosos modelos posteriormente desenvolvidos.

A importância da predição precisa da mortalidade nos sistemas de crescimento e produção florestal é incontestável, porém, este continua sendo um dos componentes menos compreendidos devido à complexidade dos ecossistemas florestais (HAMILTON, 1986). Em função disso, é o componente do crescimento mais difícil e menos confiável de se estimar (GLOVER; HOLL, 1979).

2.3.6. Estudos de crescimento e produção do *Pinus caribaea* var. *caribaea* em Cuba

O crescimento do *Pinus caribaea* é mais condicionado pela umidade do solo do que pela fertilidade e pode tolerar até seis meses de seca assim como inundações esporádicas (ROJAS; ORTIZ, 1990; NIETO; RODRIGUES, 2003). Essa pouca exigência contribuiu para sua expansão e utilização nos planos de reflorestamento e na produção madeireira (WANG; MALCOLM; FLETCHER, 1999; ZHENG; ENNOS, 1999).

A sua ocorrência natural em Cuba e o sucesso do estabelecimento das plantações do gênero *Pinus* é principalmente atribuído a condições edáficas. Geralmente os povoamentos se encontram em solos ácidos, com baixa capacidade de retenção de água, como são os solos limoníticos e arenosos. Essa ocorrência e estabelecimento em condições tão desfavoráveis é atribuída a simbiose com fungos em forma de micorrizas ectotrofas que permitem que elas

adquiram a capacidade de obter nutrientes e substâncias alimentícias suficientes para manter um crescimento relativamente rápido e atingir o porte arbóreo (GÓMEZ, 1976). Essa associação simbiótica é uma característica importante do gênero que ocorre naturalmente ainda em solos de alta fertilidade nos que aparentemente não é necessária sua presença (LEÓN; SUAREZ, 1998).

Os estudos de crescimento e produção para as variedades *hondurensis* e *bahamensis* são numerosos na literatura florestal, mas não é o caso da variedade *caribaea*. Em Cuba, tais estudos foram restritos a elaboração de tabelas de produção de espécies florestais de maior participação nos planos de reflorestamento e produção nacionais (BARRERO et al., 2011).

A autoria dos primeiros trabalhos de modelação de crescimento realizados na ilha, embora sejam extraoficiais, é atribuída à Löschau (1974) e foram precisamente desenvolvidos em florestas plantadas de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. (BARRERO et al., 2011). Depois, surgiram os primeiros trabalhos com caráter oficial de De Nacimiento et al. (1983) que tiveram como resultados, as tabelas de produção de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. para a província de Pinar Del Río. Esses trabalhos foram os pioneiros de importantes pesquisas em plantios de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. como as de García (1983), Grá et al. (1990), García, Aldana e Zaldívar (2004a,b), Barrero (2010), Aldana et. al (2009) e Aldan, Padilla e Rodríguez (2011).

2.4. Colheita florestal

A colheita florestal é um conjunto de operações realizadas no maciço florestal, objetivando preparar e transportar a madeira até seu local de utilização (SIMÕES, 2008; MACHADO, 2014). A mesma se divide nas seguintes fases: corte, pré-extração, extração, carregamento e descarregamento da madeira (TANAKA, 1986). A tecnologia utilizada depende da produtividade necessária e do orçamento disponível. Em Cuba, segundo Cándano (1998), a tecnologia de colheita florestal é considerada, pelo seu nível de mecanização, como intermediária. Segundo o autor, este nível de mecanização tem que ser melhorado ou pelo menos mantido para satisfazer as demandas existentes no mercado interno.

2.4.1. Extração florestal

A extração florestal, etapa subsequente à de corte, refere-se à movimentação da madeira desde o local de derrubada até o pátio intermediário de estocagem ou borda das estradas secundárias de onde esta será transportada para o seu destino final (DYKSTRA; HEINRICH, 1996; LEITE; SOUSA, 2001; CÁNDANO, 2003; SIMÕES, 2008; MACHADO, 2014).

Os principais sistemas de colheita florestal são: a) Sistemas de toras curtas (*cut to length, short Wood* ou *log length*); b) Sistemas de toras longas ou fuste (*tree length*); c) Sistemas de árvores inteiras (*full tree*); d) Sistemas de árvores completas (*Whole tree*) e e) Sistemas de cavaqueamento (*Chipping*) (MACHADO et al., 2014). Cada empresa adota o sistema de extração em função de suas características ou limitações como, por exemplo, a topografia, a disponibilidade de capital, mecanização, entre outros (SANT'ANNA, 1992).

Nas empresas cubanas, segundo Cándano (2003), a colheita florestal é realizada com sistemas ou métodos que variam desde os mais rudimentares como a extração manual utilizada para madeira com dimensões pequenas; a extração animal para situações de alta declividade ou cortes seletivos e aos métodos semi-mecanizados como os tratores arrastadores.

As variáveis que mais influenciam a extração florestal podem se classificar em variáveis de identificação direta e variáveis de identificação indireta. As variáveis de identificação direta são: o tamanho da área explorada, os volumes a serem extraídos, as características dos fustes, os diâmetros e porcentagem dos galhos, a topografia do local, a natureza e distribuição geográfica dos solos, a malha viária, a distância de arraste de toras, a intensidade e distribuição pluviométrica e a necessidade de sortimentos diversos. As de identificação indireta são: estabilidade de áreas declivosas podendo ser agregada a erodibilidade e compactação dos solos, o fator mão de obra com relação, a qualidade, habilidade e sua disponibilidade, a necessidades impostas pelo manejo florestal e variações climáticas que impõem limitações, mais ou menos severas, a aplicação dos sistemas de colheita de madeira (MALINOVSKI et al., 2006).

2.4.2. Transporte florestal

O transporte florestal pode ser definido como o carregamento de madeira desde as margens das estradas, deslocamento do veículo carregado até o destino (local de consumo), descarregamento da madeira e retorno do caminhão descarregado para novo carregamento (SILVA et al. 2007; STEIN; CARASCHI; GUERREIRO, 2013). Das modalidades de transportes existentes, o transporte rodoviário se apresenta como o de menores custos fixos e custos variáveis médios (NAZÁRIO; WANKE; FLEURY, 2005), o que justifica a sua viabilidade econômica além da sua praticidade e acessibilidade amplamente conhecidas. O transporte terrestre com caminhões constitui o principal método de transporte florestal (DYKSTRA; HEINRICH, 1996) e segundo a realidade cubana descrita por Cándano (1998), Cuba não faz exceção.

2.4.3. Estudos de tempo e movimentos na extração e transporte florestal

A realização de estudos sobre as variáveis que influenciam a produtividade de colheita de madeira é obrigatória para a minimização dos custos e a otimização operacional (SIMÕES; FENNER, 2010). Uma das técnicas utilizadas no planejamento e na otimização das operações de colheita florestal é o estudo de tempos e movimentos (ANDRADE, 1998; MOREIRA, 2000; MOUSAVI, 2009). Os estudos de tempo e os de movimentos embora sejam quase inseparáveis na atualidade, nem sempre foram estudados juntos. A fusão destes dois métodos, segundo Silva (1997, apud GONÇALVES, 2011), proporcionou ganhos incalculáveis para grandes empresas incluindo as empresas florestais.

O estudo de tempo e movimento pode ser definido como a análise dos métodos, materiais, ferramentas e equipamentos utilizados no processo de produção (GONZÁLEZ, 2005). Manter as condições reais de trabalho é uma das importantes premissas para o sucesso desses estudos. Segundo Mousavi (2009), essas condições devem ser semelhantes aos de trabalho normal na floresta. O mesmo autor afirma que nesses estudos, não só se trata de medir apenas o tempo e a produção, mas também identificar categorias de tempo de acordo com as fases que compõe a atividade avaliada.

Segundo Barnes (1968), existe três métodos de cronometragem nos estudos de tempos e movimentos: o método de tempo contínuo ou método indireto no qual o tempo é medido e registrado sem detenção do cronômetro, sendo os tempos dos diferentes elementos do ciclo calculado por subtração do tempo total; o método de tempo individual no qual o tempo é determinado diretamente para cada elemento e o cronômetro volta à zero antes da realização da seguinte medição e o método multimomento no qual a variável de interesse não é a duração de cada um dos elementos do ciclo, mas a frequência de ocorrência dos mesmos. Este último método é o mais adequado no estudo do tempo das atividades de colheita florestal (SARIKHANI, 2001) e uma das suas maiores vantagens é a possibilidade de estudar vários trabalhadores ou máquinas simultaneamente (GONZÁLEZ, 2005).

Os estudos de tempo e movimento podem ser realizados com diferentes enfoques: correlativo e comparativo. Os estudos de correlação objetivam descrever a relação entre o desempenho e os fatores que influenciam o trabalho (BERGSTRAND, 1991; NURMINEN; KORPUNEN; UUSITALO, 2006), enquanto os estudos comparativos permitem comparar o consumo de tempo ou produtividade para equipamentos ou diferentes métodos utilizados para executar a mesma tarefa trabalho. A instrução de base em estudos comparativos de tempo é que o consumo de tempo relativo usando diferentes métodos e condições de trabalho são constantes

e independentes do trabalhador. Nesses últimos estudos, os mesmos trabalhadores são empregados para eliminar a influência do desempenho do trabalhador (HARSTELA, 1993). Os estudos de colheita florestal mais relevantes no contexto cubano, principalmente na parte ocidental da ilha incluindo a EFI Macurije, foram os realizados por Cándano (1998) na sua tese de doutorado. Esses estudos serão considerados como pontos de partida e/ou de referência para os estudos de colheita realizados no presente trabalho.

2.5. Rendimento e qualidade na transformação primária da madeira

Nos últimos anos, o comércio da madeira, o mais importante dos recursos oriundos das florestas, tem enfrentado grandes desafios. De 2012 a 2013, a produção mundial de toras industriais passou de 1, 71 milhões de m³ para 1, 74 milhões de m³, ou seja, um aumento de 1,6% (FAOSTAT, 2014). Esse aumento representou uma das luzes no fundo do longo túnel das crises que o setor industrial madeireiro vinha passando desde 2009, ano no qual foi registrado a sua produção mais baixa (1, 51 milhões de m³).

Uma das principais formas de comercialização da madeira é em forma de madeira serrada. A madeira serrada é obtida pela transformação de toras em vários produtos com diferentes formatos e dimensões entre os quais se destacam: tábuas, pranchas, pontaletes, sarrafos, ripas, caibros, dormentes, perfis e vigas (BUAINAIN; BATALHA, 2007). A produção e comercialização da madeira serrada durante a crise seguiu a tendência da produção e comercialização das toras acima descrita.

O rendimento em madeira serrada, também conhecido como porcentagem de aproveitamento, pode ser definido como a relação entre o volume de madeira serrada e o volume das toras antes do desdobro, expresso em porcentagem (ROCHA, 2002; VALÉRIO et al., 2007; MARCHESAN, 2012). Segundo Chies (2005), tanto o rendimento como a qualidade de madeira serrada, são influenciados por características como o diâmetro, comprimento, conicidade, tortuosidade e outros defeitos.

Devido à peculiaridade de cada serraria, as variáveis que influem no rendimento poucas vezes são as mesmas (STEELE, 1984 apud NÁJERA et al., 2012). No entanto numerosos fatores se destacaram ao longo das pesquisas e entre os mesmos se podem citar fatores como: características da espécie, produtos, maquinário, mão de obra e, principalmente, diâmetro das toras (MURARA Jr.; ROCHA; TIMOFEICZYK, 2005). O rendimento em madeira serrada varia entre 45% a 55% para folhosas e entre 55% a 65% para as coníferas (ROCHA, 2002).

A indústria de madeira serrada é praticamente a única indústria florestal existente em Cuba (CABALLERO et al. 2006). Na atualidade, a Ilha conta com 572 serrarias, distribuídas

em 13 entidades da economia nacional, incluindo o setor privado (MINAGRI, 2004). A primeira serraria de Cuba data de 1757, e é conhecida como “Arsenal de La Habana” (GARCÍA et al., 2002). É, atualmente, a maior da capital da ilha e segunda ao nível nacional depois da serraria Combate de Tenerías da Empresa Macurije. Até 2005, 73,3% das serrarias do país, funcionavam com tecnologias antigas adquiridas antes de 1960 (SÁNCHEZ, 2005). Isso causou uma redução progressiva e significativa dos rendimentos de madeira serrada nas maiores serrarias do país.

2.6. Métodos quantitativos para auxílio à tomada de decisão no gerenciamento florestal

2.6.1. Estatística experimental para auxílio à tomada de decisão no gerenciamento florestal

A estatística pode ser definida como a matemática aplicada aos dados de observação (FISHER, 1951). Um ramo da estatística que tem auxiliado significativamente as tomadas de decisões na gestão de florestas plantadas é a estatística experimental cujas ideias e princípios fundamentais foram desenvolvidas por Sir Ronald A. Fisher nas décadas de 1920 e 1930, enquanto trabalhava na Estação Experimental Agrícola de Rothamsted, na Inglaterra (TAMHANE, 2009; CHENG, 2014). Segundo Pimentel-Gomes (2009), é o ramo da estatística que estuda os experimentos, seu planejamento, sua execução e análise.

Neste ramo da estatística, alternativas, grupos ou tratamentos são comparados em um ambiente nos quais todas as demais fontes de variação são controladas. Os principais experimentos utilizados em pesquisas são: experimentos inteiramente casualizados, experimentos casualizados em blocos, experimentos em quadrados latinos e experimentos em parcelas subdivididas. Esses experimentos por considerar vários fatores podem ser organizados em arranjos fatoriais. O teste básico para análise de variância é o teste z de Fisher, geralmente substituído pelo teste F de Snedecor que compara as estimativas de variâncias (PIMENTEL-GOMES, 2009). A existência de diferença significativa em experimentos com mais de dois tratamentos leva a realização de comparações de médias com testes como os de Tukey, Duncan, SNK, Scheffé e Scott-Knott...entre outros.

2.6.1.1. Técnicas multivariadas para auxílio a tomada de decisão no gerenciamento florestal

A estatística multivariada consiste em um conjunto de técnicas estatísticas utilizadas em situações nas quais diversas variáveis são medidas simultaneamente, em cada elemento amostral (MINGOTI, 2005). Um dos alvos principais dessas técnicas é a correlação existente entre essas variáveis dependentes (ANDERSON, 2003).

As técnicas de estatística multivariada se dividem em dois grupos (MINGOTI, 2005): um primeiro grupo constituído por métodos exploratórios de redução da estrutura de variabilidade dos dados como a análise de componentes principais, análise fatorial, análise de correlações canônicas, análise de agrupamentos, análise discriminante e análise de correspondência; e um segundo constituído por métodos de inferência estatística como métodos de estimação de parâmetros, testes de hipótese, análise de variância (MANOVA), de covariância e de regressão multivariada.

O uso dessas técnicas como alternativas as técnicas univariadas, quando mais de uma variável dependente é usada, tem sido amplamente questionado. Em situações nas quais as análises a serem realizadas são exclusivamente da capacidade das técnicas multivariadas, o problema não se apresenta. A dificuldade surge quando as técnicas têm análogas e a escolha se torna uma decisão difícil de tomar. Porém, a literatura aborda amplamente essas questões e propõe dicas a serem seguidas de forma consensual. Um dos métodos objetos de discussões é a análise de variância cujas análogas univariadas e multivariadas podem ser utilizadas segundo a quantidade de variáveis dependentes envolvidas e a relação existente entre as mesmas.

2.6.1.2. Análise de variância univariada versus Análise de variância multivariada

Situações nas quais se procura saber a existência ou não de diferença significativa entre diferentes grupos ou tratamentos que geram resultados estocásticos são comuns em todas as áreas de conhecimento, incluindo as ciências florestais. Em dependência do número de variáveis sobre as quais as decisões são baseadas, as técnicas utilizadas podem ser univariadas ou multivariadas.

Se o objetivo da análise de variância univariada é examinar as diferenças entre as médias de diferentes grupos se baseando em uma única variável, o da análise de variância multivariada (MANOVA) é examinar as diferenças de média em combinações lineares de múltiplas variáveis quantitativas (GRICE; IWASAKI, 2007). Os métodos estatísticos multivariados, extensões das técnicas univariadas (TABACHNICK; FIDELL, 2013), proporcionam a possibilidade de realizar análises baseadas simultaneamente em inúmeras variáveis dependentes tanto em estudos amostrais como experimentais. Seu uso tem aumentado significativamente nas últimas décadas (GRICE; IWASAKI, 2007). Segundo Tabachnick e Fidell (2013), esta crescente popularidade não é acidental e é paralela à complexidade das pesquisas contemporâneas. Em áreas como “Consultoria e Psicologia Clínica” e “Personalidade e Psicologia Social”, o número de artigos que utilizaram pelo menos uma técnica de estatística multivariada cresceu de 356% a 744% no período de 1976 a 1992 (GRIMM; YARNOLD, 1995 apud TINSLEY; BROWN,

2000) e a unanimidade da importância desses métodos tem levado à sua oferta na maioria dos cursos de pós-graduação. Apesar dessa popularidade, esses métodos nem sempre têm tido o uso adequado. Segundo Huberty e Morris (1989), as técnicas de análise de variância multivariada foram consideradas por muito tempo apenas como técnicas de análise preliminar antes da realização de múltiplas ANOVAs. Uma questão muito recorrente nas abordagens comparativas entre a ANOVA e a MANOVA é: por que realizar uma MANOVA e não várias ANOVAs? O uso da MANOVA tem vantagens que facilitaram a sua preferência a múltiplas ANOVAs e a minimização do erro de tipo I crescente por cada ANOVA realizada é uma das principais razões (LEARY; ALTMAIER, 1980).

Herberty e Morris (1989) identificaram quatro situações nas quais a aplicação de múltiplas ANOVAs é mais apropriada que a aplicação da MANOVA:

- (1) As variáveis respostas são conceitualmente independentes;
- (2) Trata-se de estudos meramente exploratórios e se tem interesse em relações bivariadas entre fator e variável resposta;
- (3) Pretende-se reexaminar as relações bivariadas dentro de um contexto multivariado
- (4) Objetiva-se selecionar um grupo de comparação na concepção de um estudo.

Em complexos estudos empíricos, é difícil encontrar ou se assegurar da independência conceitual entre as variáveis respostas, o que leva a violação da primeira das condições acima enumeradas. Entre as vantagens de aplicação das técnicas multivariadas, pode-se citar (SNIJDERS; BOSKER, 2012; FROST, 2014):

- A possibilidade de tirar conclusões sobre a correlação entre as variáveis dependentes;
- Aumento de potência: se as variáveis respostas são altamente correlacionadas, a MANOVA pode detectar diferenças muito pequenas não identificáveis pelas análises de variâncias individuais (ANOVA), o que o faz mais robusto. Essa robustez adicional é insignificante se as variáveis dependentes são fracamente correlacionadas e neste caso, conforme a Herberty e Morris (1989), a realização de múltiplas ANOVAs é mais adequada;
- Detectar padrões de resposta multivariados: os fatores podem influenciar a relação existente entre as variáveis respostas em vez de afetar cada variável de forma individualizada;
- Controlar a taxa de erro: a probabilidade de rejeitar incorretamente a hipótese nula aumenta com cada ANOVA sucessiva. Executando uma MANOVA considerando todas as variáveis de resposta, simultaneamente, a taxa de erro é mantida igual ao nível de significância alfa.

É de suma importância salientar que a MANOVA funciona bem em situações em que existem correlações moderadas entre as variáveis dependentes. Quando as variáveis

dependentes são muito correlacionadas, não há variância suficiente após a primeira variável dependente e quando as variáveis dependentes não estão correlacionadas, o teste multivariado perde robustez (FRENCH et al., 2008).

Independentemente das vantagens da análise multivariada supracitadas, Snijders e Bosker (2012) recomendam que sejam realizadas a priori análises exploratórias univariadas e estudos das relações existentes entre as variáveis dependentes antes de escolher uma alternativa.

2.6.2. Métodos de programação matemática para auxílio ao gerenciamento florestal

Um ramo da matemática que trata de técnicas que objetivam maximizar ou minimizar uma função objetivo sujeita a restrições lineares, não lineares e inteiras é a programação matemática (DANTZIG; THAPA, 1997). Os problemas de programação matemática são abordados com ferramentas de Pesquisa Operacional (PO). Winston (2003) define a PO como uma abordagem científica para a tomada de decisões, que envolve um ou mais modelos matemáticos e visa entender e operar melhor um sistema, geralmente sob alocação de recursos escassos.

Atendendo ao número de objetivos a atingir na abordagem do modelo, os métodos de pesquisa operacional podem ser classificados em dois grupos: os métodos monocritérios (programação linear) e os métodos de tomada de decisão multicritérios que agrupa todos os métodos que envolvem múltiplos critérios ou objetivos. A mais conhecida desses últimos métodos é a Programação por Metas (*Goal Programming*).

2.6.2.1. Abordagem monocritério: Programação Linear (PL)

A programação linear (PL) é uma das numerosas técnicas de programação matemática e de fato a mais difundida e aplicada na tomada de decisão quando a função objetivo e as restrições são lineares (LEUSCHNER, 1984; DANTZIG; THAPA, 1997). Segundo Buongiorno e Gilles (2003), a PL é uma das primeiras ferramentas práticas utilizadas para enfrentar problemas de tomada de decisões na administração, na indústria e na agricultura. Segundo os mesmos autores, esta técnica pode ser definida como uma técnica de alocação ótima de recursos limitados entre atividades que competem entre si. A sua formulação matemática pode ser apresentada na seguinte forma genérica (VANDERBEI, 2014):

Função Objetivo:

$$\text{Max ou Min : } Z = \sum_{j=1}^n C_j X_j$$

Sujeito a:

$$\sum_{j=1}^n a_{ij}X_j \leq b_i \quad (i = 1, 2, \dots, m)$$

$$X_j \geq 0 \quad (j = 1, 2, \dots, n)$$

Em que: m = número de restrições; n = número de variáveis X_j ; C_j = coeficientes econômicos; a_{ij} = coeficientes tecnológicos; b_i = coeficientes relacionado aos recursos.

2.6.2.2. Abordagem multicritério: Programação por Metas (PM)

A programação linear abordada na seção anterior, mesmo no seu máximo nível de sofisticação, aborda apenas a otimização de um objetivo único. Na vida real, a tomada de decisões sendo dependentes de múltiplos critérios (objetivos) geralmente em conflitos, a abordagem monocritério começou a cair em desuso, deixando lugar à abordagem multicritério cuja técnica mais utilizada é a programação por metas (COLAPINTO; JAYARAMAN; MARSIGLIO, 2015).

A ideia original da programação por metas (PM) aparece num artigo de Charnes, Cooper e Ferguson publicado em 1955 na revista *Management Science* (ROMERO, 2005). Naquele momento, os resultados atingidos por esses autores, que hoje são considerados como os pioneiros da PM, só foram registrados como um caso de factibilidade da programação linear. Mais tarde, Ignizio (1963), utilizando o conceito de PM, conseguiu construir um enfoque que permitisse resolver problemas de programação multiobjetivos. Este tipo de programação minimiza o desvio de múltiplas metas, ou objetivos, sujeitos a algumas restrições que são metas determinadas e outras que são restrições físicas (DYKSTRA, 1984; LEE, KANG; CHANG, 2009).

Esse método multiobjetivo, proposto para atender limitações da programação linear (BUONGIORNO; GILLES, 2003), exige poucas informações do tomador de decisão em relação à priorização dos objetivos e permite a interação do analista com o produtor por meio da construção de vários cenários de análise, que aproximam o modelo ao mundo real do produtor. Romero (2005) define de forma mais conceituada a PM como um marco analítico desenhado para analisar problemas complexos de análises de decisão, onde o centro de decisão atribui níveis de aspiração a todos os atributos relevantes para o problema em questão.

Considerando a função de lucros, a programação por metas pode ser classificada em três grupos principais: a programação por metas ponderadas, a programação por metas lexicográfica e a programação por metas minmax (ROMERO, 1993).

O modelo de programação por metas ponderadas minimiza a soma ponderada das variáveis de desvio não desejadas. A sua formulação analítica segue a continuação (IGNIZIO, 1976):

$$\text{Min } \sum_{i=1}^q \alpha_i d_i^- + \beta_i d_i^+$$

Sujeita a:

$$f_i(x) + d_i^- - d_i^+ = g_i \quad i \in \{1, \dots, q\}$$

$$d_i^- \cdot d_i^+ = 0$$

$$d_i^- \geq 0; d_i^+ \geq 0$$

Em que: $\alpha_i = w_i/k_i$ se a variável de desvio negativo d_i^- é não desejada, caso contrário $\alpha_i = 0$; $\beta_i = w_i/k_i$ se a variável de desvio positivo d_i^+ é não desejada, caso contrário $\beta_i = 0$; w_i e k_i são os parâmetros utilizados respectivamente para o estabelecimento da importância (pesos) e para a normalização da i-ésima meta; g_i é o nível designado para a i-ésima meta; x é o vetor de variáveis de decisão e f o conjunto de restrições.

A programação por metas lexicográfica também tem o objetivo de minimizar os desvios entre o nível de ganho de cada meta e seu correspondente nível de aspiração. Assim, o centro decisor ordena suas metas por ordem de prioridade e a satisfação de uma meta é condicionada à satisfação da meta do nível superior. Este tipo de ordenação recebe o nome de Lexicográfica por analogia com a ordenação de palavras no léxico ou dicionário. Essas metas são hierarquizadas pelo tomador de decisão, ordenando-as em uma ordem decrescente de prioridade. A estrutura de um modelo matemático de programação por meta lexicográfica é (IGNIZIO, 1976):

$$\text{Lex Min } a = \left[\sum_{i \in h_1} (\alpha_i d_i^- + \beta_i d_i^+), \dots, \sum_{i \in h_r} (\alpha_i d_i^- + \beta_i d_i^+), \dots, \sum_{i \in h_Q} (\alpha_i d_i^- + \beta_i d_i^+) \right]$$

Sujeito a:

$$f_i(x) + d_i^- - d_i^+ = g_i \quad i \in \{1, \dots, q\} \quad i \in h_r \quad r \in \{1, \dots, Q\}$$

$$x \in F, d_i^- \geq 0; d_i^+ \geq 0$$

Em que: h_r representa o índice do conjunto de objetivos colocados no r-ésimo nível de prioridade.

A tomada de decisão pelo método de PM, tem-se mostrado como uma alternativa viável para a solução de problemas com vários objetivos, mesmo conflitantes e/ou incomensuráveis, ou

seja, com unidades de medidas diferentes (PINHO; COELHO, 2010).

A programação por metas minimax, proposta por Flavell (1976), objetiva a minimização do máximo desvio entre todos os desvios possíveis. A sua estrutura matemática é a seguinte (ROMERO, 1993):

Min D

Sujeito a:

$$\alpha_i d_i^- + \beta_i d_i^+ \leq D$$

$$f_i(x) + d_i^- - d_i^+ = g_i, \quad i \in \{1, \dots, q\}$$

$$x \in F, \quad d_i^- \geq 0; \quad d_i^+ \geq 0$$

Em que: D é o máximo desvio; α_i e β_i são os coeficientes normalizadores e indicadores das preferências relativas; $\alpha_i = w_i/k_i$ se a variável de desvio negativo d_i^- é não desejado, caso contrário $\alpha_i = 0$; $\beta_i = w_i/k_i$ se a variável de desvio positivo d_i^+ é não desejado, caso contrário $\beta_i = 0$; w_i e k_i são os parâmetros utilizados respectivamente para o estabelecimento da importância (pesos) e para a normalização da i -ésima meta.

Dos três modelos clássicos de programação por metas acima citados, os envolvidos na presente pesquisa são os modelos programação por metas ponderadas e os de programação por metas Lexicográfica.

2.6.3. Técnicas de Redes Neurais Artificiais

Pelas abordagens e filosofias utilizadas na sua idealização, os modelos matemáticos podem ser classificados em modelos tradicionais e modelos originados de técnicas de Inteligência Artificial, principalmente as Redes Neurais Artificiais baseadas na inteligência humana e classificadas como método não paramétrico (VIRIYAMETANONT, 2008).

O ser humano é a única espécie viva do gênero *Homo* e seu nome *Homo sapiens* significa em latim “homem sábio” ou “homem que pensa”, nome que está em perfeita sintonia com a nossa espécie cujas características essenciais são a autoconsciência, a racionalidade e a sapiência (MACINTYRE, 1999; FLANAGAN, 2007). Baseada principalmente nessa inteligência humana reconhecida como a melhor inteligência natural existente, a Inteligência Artificial, definida por McCarthy (2007) como a ciência e engenharia de fazer máquinas inteligentes e programas de computador inteligentes, tem desenvolvido numerosas técnicas cuja a mais popular é a técnica de Redes Neurais Artificiais (RNAs). A unidade básica de uma rede neural artificial é o neurônio artificial cujo modelo matemático se encontra na Figura 4.




Figura 4 - Modelo matemático de um neurônio artificial

(Fonte: HAYKIN, 2001)

2.6.3.1. Breve histórico

As Redes Neurais Artificiais são processadores constituídos de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso (HAYKIN, 2001). Valença (2010), de uma forma mais simples, as define como sendo modelos matemáticos que tem como metáfora, o funcionamento do cérebro humano com suas redes neurais biológicas.

Levando em consideração o aspecto estrutural, as RNAs são definidas por Segall (1995) como um grafo orientado composto de neurônios como nós e sinapses ou nervos como os arcos com um algoritmo que descreve como os impulsos são conduzidos através da rede. Haykin (2001) define as RNAs como sistemas computacionais não lineares, constituídos por neurônios artificiais conectadas entre si para desempenhar determinada tarefa. Sua similaridade com o cérebro se centra em dois pontos (HAYKIN, 1994): (1) a aquisição de conhecimento por aprendizagem; (2) a utilização dos pesos das conexões entre neurônios para memorizar o conhecimento. Embora sejam consideradas antigas por serem propostas desde 1943, por McCulloch e Pitts, e sua regra de aprendizagem proposta por Hebb em 1949, as RNAs, segundo Arce-Medina e Paz-Paredes (2007), só se tornaram populares a partir dos anos 80, após a popularização, por Rumelhart et al. (1986), do algoritmo de treinamento backpropagation anteriormente proposto por Werbos (1974). Esta popularização foi também impulsionada e acelerada pelo surgimento de computadores pessoais e softwares (SCHIAVO et al., 2004).

Na última década, essa técnica conheceu uma verdadeira explosão por sua aplicação nas mais diferentes áreas (VALENÇA, 2009), para resolver problemas de predição, classificação, categorização, otimização, reconhecimento de padrão e memória associativa (DREW; MONSON, 2000).

2.6.3.2. Arquiteturas ou tipos de Redes Neurais Artificiais (RNAs)

O maior critério de classificação das RNAs é a direção de propagação dos sinais e atendendo a este critério, dois tipos de RNAs são identificados (JAIN; MAO; MOHIUDDIN, 1996) (Figura 5):

- As redes recorrentes (*Feedback*) nas quais os sinais são multidirecionais, contando com ao menos um ciclo.
- As redes diretas (*Feedforward*) nas quais a propagação dos sinais é unidirecional: a camada de entrada recebe os sinais de excitação nos neurônios e os resultados depois do treinamento são enviados para a camada de saída. São as redes mais estudadas pela comunidade científica e os mais utilizados em diversos campos de aplicação (SALAS, 2004). Exemplos delas são as redes Multi Layer Perceptron (MLP) e Radial Basis Function (RBF) utilizadas amplamente em tarefas de predição, classificação, reconhecimento de padrões, etc.

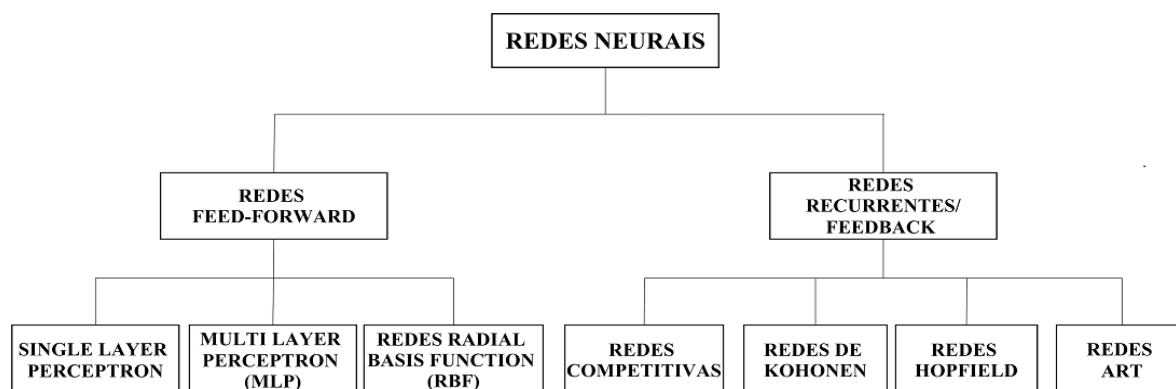


Figura 5 – Taxonomia das arquiteturas de Redes Neurais Artificiais

(Fonte: JAIN; MAO; MOHIUDDIN, 1996).

2.6.3.2.1. Redes Perceptron Multicamadas (MLP)

Uma rede MLP é uma generalização da rede Perceptron simples pela adição de pelo menos uma camada intermediária e dotada de uma estrutura composta por um conjunto de neurônios artificiais interconectadas, tendo cada unidade de processamento uma função de ativação específica (VALENÇA, 2010). Três pontos caracterizam basicamente as redes MLP (HAYKIN, 2009): uma função de ativação não-linear incluída no modelo de cada neurônio da rede; a existência de uma ou mais camadas intermediárias ou escondidas; e um elevado grau de ligação, a qual é determinada pelos pesos sinápticos.

As redes MLP são mais populares (OZÇELIK et al., 2010) e utilizadas em problemas de aproximação de funções nas tarefas de predição e classificação (SILVA, 1998; VIRIYAMETANONT, 2008; OULMANE, 2014). No plano estrutural (Figura 6), esse tipo de

rede está composto de uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída (VALENÇA, 2010; SOARES et al., 2011). A camada de entrada está constituída pelas variáveis de entrada em forma de neurônios e a de saída pela ou pelas variáveis a serem estimadas. A camada intermediária, componente que diferencia as redes MLP das redes Perceptron simples, a confere a capacidade de aproximar funções ou relações não lineares. A saída de uma rede neural MLP pode ser descrita com a expressão a (COELHO; SANTOS; COSTA Jr., 2008):

$$y_{t+h} = w_0 Z_t + \sum_{i=1}^n w_{1i} g(Z_t) + \varepsilon_{t+h} \quad (a)$$

Em que: n_1 = neurônios intermediários; $g(x) = \frac{1}{(1+e^x)}$; $Z_t = (1, y_t, y_{t-1}, \dots, y_{t-n-1})$;

y = variável dependente; w = pesos sinápticos.

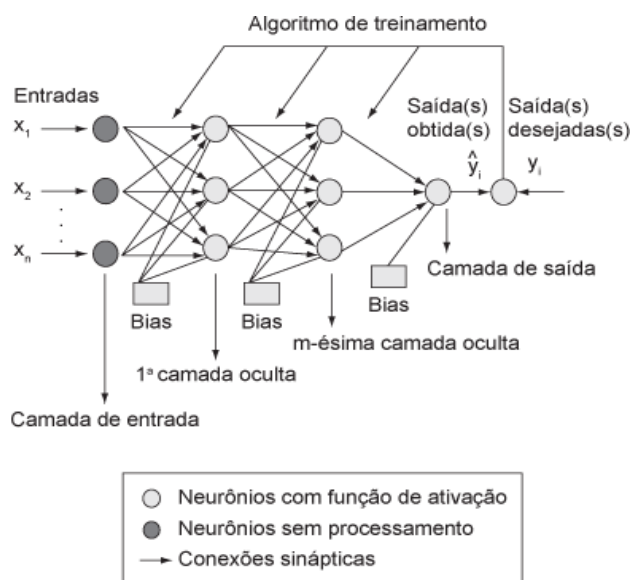


Figura 6 – Estrutura de uma rede neural MLP
(Fonte: COELHO; SANTOS; COSTA Jr., 2008)

2.6.3.2.2. Redes de Funções de Base Radial (RBF)

As redes RBF surgiram em 1988 como possíveis alternativas as redes MLP (VALENÇA, 2010). Embora sua estrutura (Figura 7) seja semelhante à das redes MLP, existe uma diferença. Essa estrutura é constituída por uma única camada intermediária com unidades não lineares, seguida por uma camada de saída com unidades lineares (YEGNANARAYANA, 2005). Essas redes se popularizaram pelo seu alto desempenho nos problemas de aproximação de funções, ajuste de curvas, previsão de séries temporais, controle e classificação (KURBAN; BEŞDOK, 2009).

A forma geral de uma rede RBF pode ser representada pela expressão b (COELHO; SANTOS; COSTA Jr., 2008):

$$y_{t+h} = \sum_{i=0}^m \omega_i \varphi(\|Z_t - c_i\|) \tag{b}$$

Em que: $\varphi(\cdot)$ é a função de base radial não linear com o centro em c_i ; $\|Z_t - c_i\|$ representa a distância do centro c_i até Z_t ; ω_i são os pesos.

As redes RBF são aproximadores universais de função tal quais as redes MLP (VALENÇA, 2010). Essas redes adquirem a capacidade de aproximar funções não lineares se as funções de base podem se mover ou mudar de tamanho ou se houver mais do que uma camada intermediária (ORR, 1996).

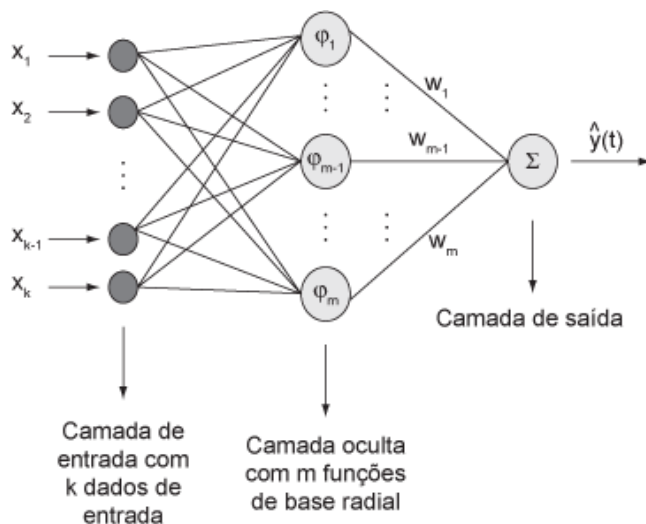


Figura 7 – Estrutura de uma rede neural RBF

(Fonte: COELHO; SANTOS; COSTA Jr, 2008)

2.6.3.2.3. Redes MLP versus Redes RBF

Apesar de apresentarem semelhanças do ponto de vista estrutural, existem numerosas diferenças funcionais entre as redes MLP e RBF. Baseado em Kriesel (2007), essas diferenças se resumem na Tabela 1.

Tabela 1– Multilayer Perceptron (MLP) versus Radial Basis Function (RBF)

| ASPECTOS | MLP | RBF |
|---------------------|--|--|
| Dimensão da entrada | Causa menos problemas, porque o número de neurônios não cresce exponencialmente com a dimensão de entrada. | Em espaços funcionais de alta dimensão essas redes requer uma memória de armazenamento enorme e de maior esforço computacional. |
| Seleção do centro | Não há ocorrência de tais problemas | A seleção dos centros “c” ainda é um grande problema que requer a aplicação de qualquer conhecimento prévio antes de aplicá-las. |

| | | |
|---------------------|--|---|
| Dimensão da saída | Um processo de aprendizagem, tais como retropropagação é muito demorado quando a dimensão da saída da rede é alta. | O treinamento não é muito influenciado quando a dimensão da saída da rede é alta |
| Extrapolação | Esta rede é capaz de usar o valor "0" para nos dizer "eu não sei", o que poderia ser uma vantagem. | Na extrapolação, essa rede retorna o resultado "0" longe dos centros de camada RBF. |
| Tolerância a falhas | A saída de uma rede MLP é pouco afetada pela ausência de um peso ou um neurônio. | A saída de uma rede RBF é significativamente afetada pela ausência de um peso ou um neurônio. |
| Expansão | Por ser mais antiga e pelo seu ótimo funcionamento, as redes MLP são mais usadas | O ótimo funcionamento das redes MLP não favoreceu a sua expansão |

Fonte: Elaborada com base em Kriesel (2007)

2.6.3.3. Treinamento das Redes Neurais Artificiais (RNAs)

A aquisição da capacidade computacional por meio de aprendizado e generalização é o principal atrativo das RNAs (BRAGA; CARVALHO; LUDEMIR, 2000). O treinamento é o ajuste dos pesos de maneira a minimizar os erros entre os valores estimados com a RNA e os valores observados. Durante esse processo, a rede aprende de duas formas: o aprendizado supervisionado ou com professor (conhecimento prévio do valor esperado ou desejado) é o mais usado por ser o utilizado no treinamento das redes Perceptron, MLP, GMDH e NSRBN (VALENÇA, 2010); aprendizado não supervisionado nos quais os algoritmos de treinamento não precisam das saídas e dos valores desejados (ou professor).

O algoritmo de aprendizado retropropagação ou backpropagation é o mais utilizado até agora (VIRIYAMETANONT, 2008), por ter provado sua utilidade no treinamento supervisionado de redes multicamadas (SILVA, 1998). Na prática, duas características desfavorecem esse algoritmo: a sua sensibilidade à presença de mínimos locais (VIRIYAMETANONT, 2008; VALENÇA, 2010) e sua lentidão na convergência (BISHOP, 1995; SILVA, 1998), confirmada por Prechelt (1997) que não o recomenda para grandes conjuntos de treinamento. Para superar essas limitações, principalmente o da velocidade de convergência, algoritmos de otimização mais sofisticados foram desenvolvidos. Entre eles podem se citar (SILVA, 1998): Broyden-Fletcher-Goldfarb-Shanno (BFGS) baseado no método de quase-Newton; Levenberg-Maquardt (LM); Algoritmo padrão (BP); Método do gradiente (GRAD); Gradiente conjugado (GC); Fletcher-Reeves (FR); Polak-Ribière (PR); Gradiente conjugado escalonado de MOLLER (1993) (SCG); Newton (MN); Davidon-Fletcher-Powell (DFP); BATTITI (1992) One-step Secant (OSS); Quickprop de FAHLMAN (1988) (QUICK).

No treinamento, o processamento em cada neurônio se dá por uma função associada a cada neurônio conhecida como função de ativação. As mais populares se encontram resumidas na Tabela 2.

Tabela 2 - Tipos de funções de ativação de neurônios nas RNAs MLP & RBF

| REDES | FUNÇÕES DE ATIVAÇÃO | EXPRESSÕES MATEMÁTICAS |
|-------|---|--|
| | Função linear | $\phi_i(x) = x$ |
| | Função degrau | $\phi_i(x) = \begin{cases} 1, & \text{se } x \geq 0 \\ 0, & \text{se } x < 0 \end{cases}$ |
| MLP | Função logística | $\phi_i(x) = \frac{1}{1 + e^{-\beta x}}$ |
| | Função tangente Hiperbólica | $\phi_i(x) = \frac{1 - e^{-\beta x}}{1 + e^{-\beta x}}$ |
| | Função de base gaussiana | $\phi_i(x) = \exp\left(-\frac{\ x_j - \mu_i\ ^2}{2\sigma_i^2}\right)$ |
| RBF | Função de base Multi-quadrática | $\phi_i(x) = \sqrt{\ x_j - \mu_i\ ^2 + \sigma_i^2}$ |
| | Função de base Multi-quadrática inversa | $\phi_i(x) = \frac{1}{\sqrt{\ x_j - \mu_i\ ^2 + \sigma_i^2}}$ |
| | Função de base Lâmina Spline fina | $\phi_i(x) = \frac{\ x_j - \mu_i\ }{\sigma_i^2} \log\left(\frac{\ x_j - \mu_i\ }{\sigma_i}\right)$ |

x_j são os exemplos de entrada; μ_i e σ_i são respectivamente o centro e a largura (dispersão) da i -ésima função de base radial (Fonte: VALENÇA, 2010).

As RNAs sendo comparáveis aos modelos de regressão, suas capacidades de predição são também limitadas (VIRIYAMETANONT, 2008). Partindo-se da base de que as RNAs são modelos empíricos, uma base de dados adequada, tanto quantitativamente como qualitativamente, é uma condição sine qua non para a obtenção de resultados satisfatórios.

Para garantir a capacidade de generalização das RNAs, aspecto que permite a avaliação do desempenho das mesmas, é recomendado que a base de dados seja dividida em três partes: a base de treinamento, a base de validação cruzada e a base de verificação ou teste (VALENÇA, 2005). Em relação a esses conjuntos, não existe um consenso em quanto as proporções a serem usadas, embora todas as fontes consultadas coincidam na atribuição da maior proporção ao conjunto de treinamento. As proporções encontradas na literatura estão resumidas na Tabela 3.

Tabela 3 – Proporções aplicadas na partição da base de dados no treinamento das RNAs

| Autores | Proporções (%) | | |
|------------------------|----------------|-------------------|---------------|
| | Treinamento | Validação Cruzada | Teste |
| Valença (2010) | 50 | 25 | 25 |
| Viriyametantont (2008) | 66,66 | 16,67 | 16,67 |
| Silva (2005) | Entre 50 e 80 | Entre 10 e 25 | Entre 10 e 25 |
| Haykin (1994) | 50 | 25 | 25 |
| Prechelt (1997) | 50 | 25 | 25 |

Tetko e Villa (1997) propõem uma subdivisão da base de dados em sub-bases com o aprendizado não-supervisionado. O resultado a ser retido será a média dos resultados dos treinamentos supervisionados aplicados a cada uma das sub-bases.

2.6.3.4. RNAs para auxílio a tomada de decisão na mensuração e indústria florestal

As empresas florestais, cujo principal objetivo é a produção de recursos florestais, investem geralmente poucos recursos e tempo para atividades de pesquisa, que embora não gerem lucros diretos para as mesmas, culminam na obtenção de ferramentas de auxílio a tomada de decisões em seus mais importantes e diversos processos produtivos. Por isto, é frequente nas poucas pesquisas desenvolvidas em numerosas empresas, fazer frente ao desafio de elaborar ferramentas de auxílio a tomada de decisão em um cenário de limitação de recursos, principalmente a limitação de dados.

Nas últimas décadas, procurando estimativas mais precisas, técnicas como as Redes Neurais Artificiais (RNAs) foram introduzidas em diferentes áreas da Engenharia Florestal, com resultados equivalentes ou superiores aos modelos usuais (LEITE et al., 2016a). Esse bom desempenho e a preferência das RNAs são geralmente atribuída a determinadas vantagens que as mesmas apresentam sobre os métodos estatísticos tradicionais.

As principais características de não-linearidade, adaptatividade, aprendizagem, modelagem de sistemas complexos, processamento paralelo, tolerância e falhas e capacidade de generalização das RNAs (VALENÇA, 2005) as tornam capazes de identificar e modelar as complexas relações não lineares multivariadas (VIRIYAMETANONT, 2008).

Um das principais vantagens radicam na não exigência de pressupostos estatísticos por parte das redes neurais e na sua capacidade de proporcionar modelos de precisão equivalente com menos dados experimentais ou a de criar modelos mais precisos com o mesmo tamanho amostral (DREYFUS et al., 2004; LEMMOU; BELLAKHDAR; LEDJEDEL, 2011). Porém, é imprescindível deixar claro que as RNAs, por serem modelos estatísticos e

aprenderem em base a observações, têm tendência a apresentar melhores desempenhos com maiores bases de dados. Em situações de limitação de dados, Yuan e Fine (1998) alertam que é preciso ter destreza na etapa de treinamento, principalmente na validação cruzada, e ser parcimonioso na construção das arquiteturas das RNAs para evitar o sobre-treinamento (em inglês *overtraining*) e assim obter redes neurais com boas capacidades de generalização. Desmet (1996) reporta uma maior utilidade e destaque das RNAs quando o número de variáveis preditivas e a complexidade do sistema modelado crescem. Segundo Dreyfus et al. (2008), uma quantidade de variáveis preditivas maior ou igual a três é preferível, principalmente em RNAs que tem a função sigmoide como função de ativação. Outra razão da preferência das RNAs é sua maior parcimônia e sua capacidade de separar os efeitos combinados (multicolinearidade) entre as variáveis de entrada (VIRIYAMETANONT, 2008).

Inúmeras pesquisas são evidências da ampla aplicação das Redes Neurais Artificiais nas mais diversas áreas da Engenharia Florestal nas últimas décadas. Exemplos das mesmas são as pesquisas de Leite et al. (2016a) para classificação de sítios florestais, Gordon (1998), Diamantopoulou (2005), Özçelik et al. (2010), Castro et al. (2013a, b), Leal et al. (2015), Souza (2015) e Miguel et al. (2016) para estimação de volume, BINOTI et al. (2015) e LIMA et al. (2017) para prognose de produção florestal, Martins et al. (2016) para estimação do afilamento do fuste de árvores, Leite et al. (2016b) para a estimação da densidade básica da madeira, Jensen e Qiu (1999) para estimação da idade de florestas e Özçelik et al. (2017) para estimação da biomassa, Leite et al. (2011) e Kitikidou et al. (2012) para a estimação de diâmetro sem casca, Yuan, Dong e Hai (2011) para identificação de defeitos de madeira serrada e Thomas (2017) para sua classificação em tempo real.

REFERÊNCIAS

ADEGBEHIN, J.O. et al. Trials and growth of *P. caribaea* in northern Nigeria. **Pakistan Journal of Forestry**, v. 38, n. 1, p. 1-13, 1988.

ADLARD, P.G. Myth and reality in growth estimation. **Forest Ecology and Management**, v.71, n. 3, p. 171-176, 1995.

AGRAWAL, A. et al. **Economic contributions of forests**. United Nations Forum of Forests, 2013. 132p. Consultado o dia 26/08/2016 e disponível em: <http://www.un.org/esa/forests/pdf/session_documents/unff10/EcoContrForests.pdf>

ALDANA E, P. et al. **Análisis de diferentes edades para establecer el turno de tala en plantaciones de *Pinus caribaea* en la EFI Viñales**. In: CD Memorias del IV Taller internacional de Desarrollo Forestal Sostenible; La Habana; Cuba; 2009.

ALDANA, E. P.; PADILLA, T.G.; RODRÍGUEZ, P. J. Turno de corta eficiente para la obtención de mayores productos maderables en plantaciones de *Pinus caribaea* de la Empresa Forestal Integral Viñales. **Revista Forestal Baracoa**, v. 30, n. 1, p. 29-35, 2011.

ALDANA, E.; PUENTES, M.; ROMERO, J.L. **Proyecto de Ordenación EFI Macurije**. La Habana: Ministerio de la Agricultura; 2006. 101 p.

ALDANA, E.P. **Medición forestal**. La Habana: Editorial Felix Varela, 2010. 266p.

ALDEA, J. et al. Participatory Goal Programming in Forest Management: An Application Integrating Several Ecosystem Services. **Forests**, v. 5, n. 12, p. 3352-3371, 2014.

ANDERSON, T. W. **An introduction to multivariate statistics**. New York: Wiley-Interscience, 3 ed., 2003. 752p.

ANDRADE, S. C. **Avaliação técnica, social, econômica e ambiental de dois subsistemas de colheita florestal no litoral norte da Bahia**. 1998. 125f. Dissertação (Mestrado em Ciência Florestal) -Universidade Federal de Viçosa, Viçosa.

ARCE-MEDINA, E.; PAZ-PAREDES, J.I. Artificial neural network modeling techniques applied to the hydrodesulfurization process. **Mathematical and Computer Modelling**, v. 49, n. 2, p. 207-214, 2009.

ASHRAF, M. I. et al. A Novel Modelling Approach for Predicting Forest Growth and Yield under Climate Change. **PLoS One**, v. 10, n. 7, p. 1-18, 2015.

ASHRAF, M. I. et al. Integrating biophysical controls in forest growth and yield predictions with artificial intelligence technology. **Canadian Journal of Forest Research**, v. 43, n. 12, p. 1162–1171, 2013.

ASHTON, P.M.S. et al. Restoration of a Sri-Lankan rainforest: Using Caribbean Pine *Pinus caribaea* as a nurse for establishing late-successional tree species. **Journal of Applied Ecology**, v. 34, n. 4, p. 915-925, 1997.

ASSMANN, E. **Waldertragskunde**. Muenchen: Verlagsgessellschaft, 1961. 435p.

BARNES, R.M. **Motion and time study: design and measurement of work**. 6 ed. New York: John Wiley and Sons, 1968. 799 p.

BARRERO, H. **Modelo integral de crecimiento, perfil de fuste, grosor de corteza y densidad de la madera de *Pinus caribaea* Morelet var. *caribaea* Barret y Golfari: Estudio de caso EFI Macurije**. 2010. 101f. Tesis (Doctorado en ciencia forestal) - Universidad de Pinar del Río, Pinar del Río.

BARRERO, M. H. et al. Determinación del Turno de Corta para *Pinus caribaea* var. *caribaea* en la Empresa Forestal Integral “Macurije”. **Floresta e Ambiente**, v. 18, n. 1, p. 109-116, 2011.

BARRET, H.G.; GOLFARI, L. Descripción de dos nuevas variedades del “Pinus del Caribe” (*Pinus caribaea* Mor). **Caribbean Forester**, v. 23, n. 2, p. 59-71, 1962.

BENTIL, D.E.; OSEI, B.M.; ELLINGWOOD, C.D.; HOFFMANN, J.P. Analysis of a Schnute postulate-based unified growth mode for model selection in evolutionary computations. **Biosystems**, v. 90, n. 2, p. 467–474, 2007.

BERGSTRAND, K. **Planning and analysis of forestry operation studies**, Skogsarbeten Bulletin n. 17, 1991.63p.

BETANCOURT, A. **Silvicultura especial de árboles maderables tropicales**. La Habana: Editorial Científico Técnica, 1987. 427 p.

BETTINGER, P. et al. **Forest management and planning**. New York: Elsevier, 2009.331 p.

BIGLER, C.; BUGMANN, H. Growth-dependent tree mortality models based on tree rings. **Canadian Journal of Forest Research**, v. 33, n. 2, p. 210-221, 2003.

BINOTI, D.H.B. Redes neurais artificiais e imagens de satélite são ferramentas utilizadas para medir sustentabilidade da Fibria. **Celulose Online**, 2015. Acesso no dia 24-05-2017 e

disponível em: <<http://celuloseonline.com.br/excluviso-redes-neurais-artificiais-e-imagens-de-satelite-sao-ferramentas-utilizadas-para-medir-sustentabilidade-da-fibria-entenda/#content-anchor>>

BINOTI, M.L.M.S. et al. Prognose em nível de povoamento de clones de eucalipto empregando Redes Neurais Artificiais. **Cerne**, v. 21, n. 1, p. 97-105, 2015.

BINOTI, M.L.M.S. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. 2012. 130 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa.

BISHOP, C. **Neural Networks for Pattern Recognition**. Oxford: University Press, 1995. 482p.

BORGES, L.J.G. et al. **The Management of Industrial Forest Plantations: Theoretical Foundations and Applications**. Managing Forest Ecosystems 33, Springer Science Business MEDIA DORDRECHT, 2014. 544 p.

BRAGA, A.P.; CARVALHO, A.C.P.L.F.; LUDEMIR, T.B. **Redes Neurais Artificiais: teoria e aplicações**. 1 ed. Rio de Janeiro: LTC, 2000. 250 p.

BUAINAIN, A.M.; BATALHA, M.O. **Cadeia Produtiva de Madeira**. Brasília: IICA: MAPA/SPA, Série agronegócios, v. 6, 2007, 84 p.

BUCKMAN, R. E. **Growth and yield of red pine in Minnesota**. Tech. Bull. 1272. Washington, DC: U.S. Department of Agriculture, 1962. 50 p.

BUONGIORNO, J.; GILLESS, K.J. **Decision methods for forest resources management**. Academic Press, 2003. 439p.

BURKHART, H.E.; TOME, M. **Modeling forest trees and stands**. Springer, Dordrecht, The Netherlands, 2012. 132p.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 5ª ed. Editora UFV, Viçosa: UFV, 2017. 636 p.

CÁNDANO, F. **Aprovechamiento Forestal**. Pinar del Rio, Cuba: Editorial Científico Técnica, 2003. 111 p.

CÁNDANO, F. **Propuesta para el perfeccionamiento de la tecnología de aprovechamiento de madera en rodales de *Pinus caribaea* en la provincia de Pinar del Río.** 1998. 117 f. Tesis (Doctorado en Ciencias Forestales) – Universidad de Pinar del Rio, Cuba.

CAO, Q. V. Linking individual-tree and whole-stand models for forest growth and yield prediction. **Forest Ecosystems**, v.1, n. 18, p. 1-8, 2014.

CASTRO, R.V.O. et al. Crescimento e produção de plantios comerciais de eucalipto estimados por duas categorias de modelos. **Pesq. agropec. bras.** Brasília, v. 48, n. 3, p.287-295, 2013a.

CASTRO, R.V.O. et al. Individual Growth Model for *Eucalyptus* Stands in Brazil Using Artificial Neural Network. **Forestry**, v. 2013, p. 1-12, 2013b.

CASTRO, R.V.O. et al. Modelagem do crescimento e produção para um povoamento de *Eucalyptus* utilizando dois métodos para quantificação do índice de local. **Scientia Forestalis**, v. 43, n. 105, p. 83-90, 2015.

CHEN, Y.T.; CHANG, C.T. Multi-coefficient goal programming in thinning schedules to increase carbon sequestration and improve forest structure. **Annals of Forest Science, Springer Verlag/EDP Sciences**, v. 71, n. 8, p. 907-915, 2014.

CHENG, C.S. **Theory of Factorial Design Single- and Multi-Stratum Experiments.** CRC Press, Taylor & Francis Group, 2014, 403p.

CHIES, D. **Influência do espaçamento sobre a qualidade e o rendimento da madeira serrada de *Pinus taeda* L.** 2005. 123 f. Dissertação (Mestrado em Engenharia Florestal). Universidade Federal do Paraná, Curitiba.

CHUDNOFF, M. Tropical Timbers of the World. **Agriculture Handbook**, Washington: USDA Forest Service, n. 607, 1984.466p.

CLUTTER, J.L. Compatible growth and yield models for loblolly pine. **Forest Science**, v.9, n.3, p.354-371, 1963.

CLUTTER, J.L. et al. **Timber management: a quantitative approach.** 1sted. New York: John Wiley & Sons, 1983. 333p.

CLUTTER, J.L.; JONES, E.P. **Prediction of growth after thinning in old-field slash pine plantation.** Res. Pap. SE-217. Asheville, NC: U.S. Dept. of Agriculture, Forest Service, Southeastern Forest Experiment Station, 1980, 14 p.

COELHO, L.S.; SANTOS, A.A.P.; COSTA Jr., N.C.A. Podemos prever a taxa de cambio brasileira? Evidência empírica utilizando inteligência computacional e modelos econométricos. **Gest. Prod.**, São Carlos, v. 15, n. 3, p. 635-647, 2008.

COLAPINTO, C.; JAYARAMAN, R.; MARSIGLIO, S. **Multi-criteria decision analysis with goal programming in engineering, management and social sciences: a state-of-the art review**, Annals of Operations Research, 2015, 1–34.

CRITCHFIELD, W.B.; LITTLE Jr., E.L. 1966, **Geographic distribution of the pines of the world**: U.S. Department of Agriculture Miscellaneous Publication 991, p. 1-97.

DANTZIG, G. B.; THAPA, M.N. **Linear Programming 1**: Introduction, Springer, 1997.435p.

DAVIS, L.S.; JOHNSON, K.N. **Forest management**. 3.ed. New York: McGraw-Hill, 1987. 789p.

DE NACIMIENTO, J. et al. Tabla preliminar de rendimiento para *Pinus caribaea*. Pinar del Río, **Revista Forestal Baracoa**, v. 13, p. 57-103, 1983.

DESMET, P. Comparaison de la prédictivité d'un réseau de neurones à rétropropagation avec celles des méthodes de régression linéaire, logistique et AID pour le calcul des scores en marketing. **Recherche et Applications en Marketing**, v.11, n.2, p. 17-27, 1996.

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

DIAZ-BALTEIRO, L.; GONZÁLEZ-PACHÓN, J.; ROMERO, C. Goal programming in forest management: customising models for the decision-maker's preferences. **Scandinavian Journal of Forest Research**, v. 28, n. 2, p. 166-173, 2013.

DIAZ-BALTEIRO, L.; ROMERO, C. Making forestry decisions with multiple criteria: A review and an assessment. **Forest Ecology and Management**, v. 255, n.8, p. 3222-3241, 2008.

DOMÍNGUEZ, G. A. Sector forestal cubano se inclina a la energía renovable (Opiniones recogidas por IPS-Cuba). 2016. Acesso em: 19/02/2017 e disponível em: <<http://www.ipscuba.net/economia/sector-forestal-cubano-se-inclina-a-la-energia-renovable/>>

DREW, P.; MONSON, J. Artificial neural networks. **Surgery**, v. 127, p. 3-11, 2000.

DREYFUS, G. et al. **Réseaux de neurones, Méthodologie et applications**. 2nd ed. France: Collection Algorithmes. Eyrolles; 2004. 417p.

DREYFUS, G.; MARTINEZ, J.M.; SAMUELIDES, M.; GORDON, M.B.; BADRAN, F.; THIRIA, S. *Apprentissage statistique*. Paris: Eyrolles, 3ème Editions. 2008, 471p.

DYKSTRA, D. P. **Mathematical programming for natural resource management**. New York: McGraw-Hill, 1984. 318 p.

DYKSTRA, D.P.; HEINRICH, R. **FAO model code of forest harvesting practice**. Rome, Italy, Rome, Food and Agriculture Organization. FAO, 1996. 85p.

EGAS, A.F. **Consideraciones para el incremento de la eficiencia de conversión de madera en rollo de *Pinus caribaea* Morelet var. *caribaea* en sierras de bandas**. 1998. 116f. Tesis (Doctorado en Ciencias Forestales) - Universidad de Pinar Del Río, Pinar del Río, Cuba.

EPSTEIN, R.; KARLSSON, J.; RÖNNQVIST, M.; WEINTRAUB, A. Harvest operational models in forestry. In: WEINTRAUB, A.; ROMERO, C.; BJØRNDAL, T.; EPSTEIN, R.; MIRANDA, J. **Handbook of operations research in natural resources**. USA: SPRINGER, 2007. Chap. 18, p. 365-377.

FAO. **La contribución del sector forestal a las economías nacionales, 1990-2011**, por A. Lebedys y Y. Li. Documento de trabajo sobre finanzas forestales. FSFM/ACC/09. FAO, Roma, 2015. 172p.

FAOSTAT - **Food and agriculture organization corporate statistical database**. 2014. Disponível em: <[http:// faostat.fao.org />](http://faostat.fao.org/). Acesso em: 08/05/2015.

FEKEDULEGN, D.; MAC SIURTAÍN, M. P.; COLBERT, J.J. Parameter estimation of nonlinear growth models in forestry, **Silva Fennica**, v. 33, n. 4, p. 327–336, 1999.

FILGUEIRAS, J. F. **Um modelo de substituição de equipamentos para minimizar custos operacionais em uma empresa florestal**. 1997. 54 f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa.

FISHER, R. A. **The design of experiments**. 6ª ed. Nova York: Hafner, 1951.

FLANAGAN, O. **The Really Hard Problem: Meaning in a Material World**. MIT Press, 2007, 288 p.

FLAVELL, R.B. A New Goal Programming Formulation, **Omega**, v. 4, n. 6, p. 731-732, 1976.

FRENCH, A. et al. Multivariate Analysis of Variance (MANOVA). 2008. Disponível em: <<http://online.sfsu.edu/efc/classes/biol710/manova/manovanewest.htm>>. Acesso em: 20/08/2016.

FROST, J. The Power of Multivariate ANOVA (MANOVA). 2014. Acesso em: 17/08/2016 e disponível em: <<http://blog.minitab.com/blog/adventures-in-statistics/the-power-of-multivariate-anova-manova>>

GARCÍA, C.I. **Investigaciones para la elaboración de una tabla de rendimiento preliminar para el *Pinus caribaea* var. *caribaea***. In: Memorias del II Foro Multisectorial de la ACC en Pinar del Río. 1983. CD.

GARCÍA, C.I.; ALDANA, P.E.; ZALDIVAR, S.A. Tabla de Producción para las plantaciones de *Pinus caribaea* var. *caribaea* de la Empresa Forestal Integral Macurije. 2004b. Disponível em: <<http://www.buscagro.com/biblioteca/PinardelRio/TabladeProduccion.pdf>> Acesso em: 10/09/2014.

GARCÍA, C.I.; ALDANA, P.E.; ZALDÍVAR, S.A. **Tablas de rendimiento y crecimiento para la EFI Macurije**. In: Memorias del III Simpósio sobre Manejo Sostenible de los Recursos Forestales - SIMFOR; Pinar del Río; Cuba. Pinar del Río: SIMFOR; 2004a. CD.

GARCÍA, E.L.; A. GUINDEO, C.; PERAZA, C. O.; DE PALACIOS, P. 2002. **La madera y su tecnología**. Ediciones Mundi-Prensa, AITIM, Madrid. 2002. 272p.

GBADEGESIN, R.A. Effect on the development of *Pinus caribaea* seedlings of certain plant-parasitic nematodes from the savanna area of Nigeria. **Forest Ecology and Management**, v. 60, p. 163-166, 1993.

GIAM, X.; OLDEN, J.D. A new R²-based metric to shed greater insight on variable importance in artificial neural networks. **Ecological Modelling**, v. 313, n.10, p. 307–313. 2015.

GLOVER, G.R.; HOLL, J.N. A basal area ratio predictor of loblolly pine plantation mortality. **Forest Science**, v. 25, n. 2, p. 275-282, 1979.

GÓMEZ, J. **Aspectos Geográficos y de las Formaciones Forestales de Cuba**. INDAF, La Habana, 1976. 35 p.

GONÇALVES, S.B. **Análise técnica das atividades de colheita semimecanizada em áreas declivosas no sul do espírito santo**. 2011. 23 f. Monografia (Engenharia Florestal) - Universidade Federal do Espírito Santo, Espírito Santo.

GONZÁLEZ, D.D.J. 2005. **A time study and description of the work methods for the field work in the National Inventory of Landscapes in Sweden**. Department of Forest Resource Management and Geomatics, SLU. Vol. 140.

GORDON, C. **Artificial Neural Network Modeling of Forest Tree Growth**. 1998. 87f. Dissertação (Mestrado em Ciências) - Universidade de Witwatersrand, Johannesburg.

GORGENS, E.B.; LEITE, H.G.; NOGUEIRA, G.S.; DIAS, A.N. Tendência de crescimento de povoamento de eucalipto após aplicação de desbaste. **Revista Árvore**, Viçosa, v. 31, n. 5, p. 879-885, 2007.

GRÁ, A. et al. **Tablas de Volumen y surtido y densidad del *Pinus caribaea* en plantaciones puras para Cuba**. Informe etapa 509-09. 1990. 24p.

GRICE, J.W.; IWASAKI, M. A truly multivariate approach to manova. **Appl Multivariate Res**, v. 12, n. 3, p. 199–226, 2007.

GUNNARSSON, H. **Supply chain optimization in the forest industry**. 2007. 40 f. Dissertation (PhD) - Linkoping University (Institute of Technology), Sweden.

HAGIHARA, A. Deriving the mean mass–density trajectory by reconciling the competition–density effect law with the self-thinning law in even-aged pure stands. **Journal Forest Research**, v. 19, p. 125–133, 2014.

HAIR Jr, J.F. et al. **Multivariate data analysis**. 7th edition, Harlow: Pearson Education Limited, 2014. 734p.

HALL, N.G.; POTTS, C.N. Supply chain scheduling: Batching and delivery. **Operations Research**, v.51, n. 4, p. 566–584, 2003.

HAMILTON, D.A. **Event probabilities estimated by regression**. U.S.D.A. For. Serv., Res. Paper INT-152. Intermountain Forest & Range Experiment Station, Forest Service, U.S. Dept. of Agriculture, 1974 – 18p.

HAMILTON, Jr., D. A. A logistic model of mortality in thinned and unthinned mixed conifer stands of Northern Idaho. **Forest Science**, v. 32, n. 4, p. 989–1000, 1986.

HANRAHAN, G. **Artificial neural network in biological and environmental analysis**. Taylor and Francis Group, CRC Press, USA. 2011.210p.

HARSTEL, A. P. **Work studies in forestry**. Silva Carelica 25, 1993. 131 p.

HAYKIN, S. **Neural Networks – A Comprehensive Foundation**. Macmillan College Publishing Inc., 1994.

HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. New Jersey: Prentice Hall, 2009. 906p.

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

HERRERO, J. **Manejo del *Pinus caribaea* var *caribaea* en las zonas de Alturas de Pizarra, provincia de Pinar del Río**. La Habana: Ministerio de la Agricultura (Boletín de Reseñas, Grupo de publicaciones CIDA, n. 3.; Centro de Investigaciones Forestales), 1985. 60p.

HIGGINS, J. **A neural network growth and yield model for Nova Scotia forests**. 2011. 108 f. Dissertação (Mestrado em ciências aplicadas) – Universidade de Dalhousie, Halifax, Nova Scotia.

HUBERTY, C. J.; MORRIS, J. D. Multivariate analysis versus multiple univariate analyses. **Psychological Bulletin**, v. 105, n. 2, p. 302-308, 1989.

IGNIZIO, J. P. **Goal programming and extensions**. Massachusetts: Lexington Books, 1976.

IGNIZIO, J. P. **S-II trajectory study and optimum antenna placement**: report SID-63. Downwy, CA: North American Aviation Corporation, 1963.

IVORY, M.H.; MUNGA, F.M. Growth and survival of container-grown *Pinus caribaea* infected with various ectomycorrhizal fungi. **Plant and Soil**, v. 71, p. 339-344, 1983.

JAIN, A.K.; MAO, J.; MOHIUDDIN, K.M. **Artificial neural networks – a tutorial**. Computer March, 1996. p. 31-44.

JENSEN, J.R.; QIU, F.; JI, M. Predictive modelling of coniferous forest age using statistical and artificial neural network approaches applied to remote sensor data. **Int. j. remote sensing**, v.20, n.14, p.2805 – 2822, 1999.

KADEBA, O. Above-ground biomass production and nutrient accumulation in an age sequence of *Pinus caribaea* stands. **Forest Ecology and Management**, v. 41, n. 3, p. 237-248, 1991.

KANGAS, A. et al. **Decision Support for Forest Management**. 2 ed. Springer, 2015. 307p.

KELLMAN, M.; HUDSON, J. Nutrition of *Pinus caribaea* in its native savanna habitat. **Plant and Soil**, v. 64, p. 381-391, 1982.

KELLMAN, M.; MIYANISHI, K.; HIEBERT, P. Nutrient Sequestering by the Understorey Strata of Natural *Pinus caribaea* Stands Subject to Prescription Burning. **Forest Ecology and Management**, v. 21, n. 1, p. 57-73, 1987.

KITIKIDOU, K.; MILIOS, E.; ILIADIS, L.; KAYMAKIS, M. Combination of M-Estimators and Neural Network Model to Analyze Inside/Outside Bark Tree Diameters. **AIAI 2012, IFIP AICT 381**, p. 11-18, 2012.

KRIESEL, D. **A Brief Introduction to Neural Networks**. Bonn: University of Bonn, 2007, 244 p.

KUMAR, R.; AGGARWAL R. K.; SHARMA, J. D. Comparison of regression and artificial neural network models for estimation of global solar radiations. **Renewable and Sustainable Energy Reviews**, v. 52, p. 1294–1299, 2015.

KURBAN, T.; BEŞDOK, E. A Comparison of RBF Neural Network Training Algorithms for Inertial Sensor Based Terrain Classification. **Sensors**, v. 9, n. 8, p. 6312-6329, 2009.

LE MAITRE, D. C. **Pines in cultivation: a global view**. In: M. D. Richardson (ed). **Ecology and Biogeography of Pinus**. Cambridge University Press. Cambridge, UK, 1998. p. 407-431.

LEAL, F.A. et al. Redes neurais artificiais na estimativa de volume em um plantio de eucalipto em função de fotografias hemisféricas e número de árvores. **Revista Brasileira de Biometria**, v.33, n.2, p.233-249, 2015.

LEARY, M. R.; ALTMAYER, E. M. Type I error in counseling research: A plea for multivariate analyses. **Journal of Counseling Psychology**, v. 27, p. 611-615, 1980.

LEE, A. H. I.; KANG, H.; CHANG, C. Fuzzy multiple goal programming applied to TFT-LCD supplier selection by downstream manufacturers. **Expert Systems with Applications**, v. 36, p. 6318-6325, 2009.

LEI, Y.C.; ZHANG, S.Y. Features and Partial Derivatives of Bertalanffy-Richards Growth Model in Forestry. **Nonlinear Analysis: Modelling and Control**, v. 9, n. 1, 2004, p.65–73.

LEITE, A.M.P.; SOUSA, R.T.M. **Exploração e Transporte Florestal**. 2001.113p. Disponível em: <http://www.academia.edu/3634993/Apostila_de_Colheita>. Acesso em: 23/12/2013.

LEITE, H.G. et al. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. Trees using artificial neural networks. **Eur. J. For. Res.**, v. 130, n. 2, p. 263-269, 2011.

LEITE, H.G. et al. Redes Neurais Artificiais para a estimação da densidade básica da madeira. **Sci. For.** Piracicaba, v. 44, n. 109, p. 149-154, 2016b.

LEITE, M.V.S. et al. Classificação de sítios florestais a partir de alturas dominantes estimadas com redes neurais artificiais. Anais do III Encontro Brasileiro de Mensuração Florestal, Piracicaba, SP, p. 41-45, 2016a.

LEMMOU, A. ; BELLAKHDAR, K. ; LEDJEDEL, A. **Identification et commande des systèmes non linéaires.** Université de M'Sila Algérie - Ingénieur en électronique, 2011.

LEÓN, S. T.; SUÁREZ, A. **Efecto de las plantaciones forestales sobre el suelo y agua.** CONIF, Santa Fe de Bogota, 1998.143p.

LEUSCHNER, W. A. **Forest regulation, harvest scheduling, and planning techniques.** New York: John Wiley & Sons, 1990. 281 p.

LEUSCHNER, W.A. **Introduction to forest resource management.** New York: J. Wiley, 1984. 298p.

LILIENFEIN, J. et al. Soil acidification in *Pinus caribaea* forests on Brazilian savanna Oxisols. **Forest Ecology and Management**, v.128, n.1, p.145-157, 2000.

LIMA, M.B.O.; JUNIOR, I.M.L.; OLIVEIRA, E.M.; FERREIRA, J.C.B.; SOARES, K.L.; MIGUEL, E.P. Artificial neural networks in whole-stand level modeling of Eucalyptus plants. **African Journal of Agricultural Research**, v.12, n.7, p.524-534, 2017.

LIMA, R.B. **Distribuição diamétrica e volumetria em vegetação de Caatinga arbustiva-arbórea, FLORESTA-PE.** 2014. 138fl. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal Rural de Pernambuco, Pernambuco, Recife.

LITTLE Jr., E.L.; DORMAN, K.W. Slash pine (*Pinus elliottii*), its nomenclature and varieties. **Journal of Forestry**, v. 50, n. 12, p. 918-923, 1952.

MACHADO, C. C. **Colheita florestal.** 2. Ed. Minas Gerais: Editora UFV, 2014. 543 p.

MACINTYRE, A. **Dependent Rational Animals: Why Human Beings Need the Virtues.** Chicago, Open Court Publishing, 1999, 172p.

MALINOVSKI, R. A. et al. 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. **Floresta**, v. 36, n.2, p. 166-182, 2006.

MARCHESAN, R. **Rendimento e qualidade de madeira serrada de três espécies tropicais**. 2012. 92 f. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal do Paraná, Curitiba.

MARTINS, E.R. et al. Configuração de redes neurais artificiais para estimação do afilamento do fuste de árvores de eucalipto. **Revista Brasileira de Ciências Agrárias**, v.11, n.1, p.33-38, 2016.

MCCARTHY, J. **What is Artificial Intelligence?** 2007. Acesso em: 23/12/2015 e disponível em: <<http://www-formal.stanford.edu/jmc/whatisai/whatisai.html>>

MIGUEL, E.P.; MOTA, F.C.M.; TÉO, S.J.; NASCIMENTO, R.G.M.; LEAL, F.A.; PEREIRA, R.S.; REZENDE, A.V. Artificial intelligence tools in predicting the volume of trees within a forest stand. **African Journal of Agricultural Research**, v. 11, n. 21, pp. 1914-1923, 2016.

MINAGRI: **Anteproyecto plan perspectiva de la Industria Forestal en Cuba hasta el año 2015 IIF**. Plan de Desarrollo Forestal hasta el 2015. 2004.

MINAGRI: **Dinámica Forestal**. Subdelegación forestal. Ministerio de la Agricultura. Pinar del Río. 2001.

MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada**. Belo Horizonte: Editora UFMG, 2005. 297p.

MITCHELL, C.P. Biomass supply from conventional forestry. **Biomass and Bioenergy**, v.2, n. (1-6), p. 97–104. 1992.

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 Ciência Florestal) – Universidade Federal de Viçosa, Viçosa.

MOUSAVI, R. **Comparison of productivity, cost and environmental impacts of two harvesting methods in Northern Iran: short-log vs. long-log**. 2009. 93 f. Dissertação (Forest Sciences) – University of Joensuu, Joensuu, Iran.

MURARA Jr., M.I.; ROCHA, M.P.; TIMOFEICZYK, J.R. Rendimento em madeira serrada de *Pinus taeda* para duas metodologias de desdobro. **Floresta**, Curitiba, PR, v. 35, n. 3, p. 473-483, 2005.

NÁJERA, L.J.A. et al. Rendimiento de la madera aserrada en dos aserraderos privados de El Salto, Durango, México. **Investigación y Ciencia de la Universidad Autónoma de Aguascalientes**, n. 55., p. 11-23, 2012.

NASCIMENTO, F.A.F. et al. Sistema de crescimento e produção para povoamentos de *Pinus taeda* na região norte de Santa Catarina. **Cerne**, v. 21, n. 2, p. 235-242, 2015.

NAZÁRIO, P.; WANKE, P.; FLEURY, P. F. **O Papel do Transporte na Estratégia Logística. Artigos CEL. COPPEAD. Centro de Estudos em Logística.** UFRJ. 2005. Disponível em: <www.cel.coppead.ufrj.br/fr_art_transporte.htm>. Acesso em: 13/09/2016.

NIETO, V.M.; RODRIGUES, J. ***Pinus caribaea* Morelet.** In: VOZZO, J.A. Tropical Tree Seed Manual. Part II. Species Descriptions, USDA Forest Service, 2003, p.609-611.

NOVAK, R.S.; SILVA, A.C.L. Um sistema de otimização aplicado ao desdobro de madeira. In: XLI SBPO 2009 - Pesquisa Operacional na Gestão do Conhecimento, Porto Seguro, Bahia, 2009, p. 3030-3040.

NURMINEN, T.; KORPUNEN, H.; UUSITALO, J. Time consumption analyses of the mechanized cut-to-length harvesting system. **Silva Fennica**, v. 40, n. 2, p. 335-363, 2006.

OLIVEIRA, C.G.; MACHADO, S.A. **Introdução ao estudo de modelos de crescimento e produção florestal.** 79p. 1995. (Serie Didática).

ONEI (Oficina Nacional de Estadística e Información). **Anuario estadístico de cuba 2014.** República de cuba, Ed. Medio ambiente, 2014. 53p.

ORR, M.J.L. **Introduction to Radial Basis Function Networks.** Centre for Cognitive Science, University of Edinburgh Press, Scotland, 1996. 67p.

ORTEGA, A.; MONTEIRO, G. Evaluación de la calidad de las estaciones forestales. Revision bibliografica. **Ecologia**, v.2, p.155-184, 1988.

OSTADHASHEMI, R. et al. Goal programming and analytical hierarchy process approaches for sustainable plantation. **Caspian J. Env. Sci.**, v. 12, n. 2, p. 233-244, 2014.

OULMANE, A. **Surveillance et diagnostic des défauts des machines tournantes dans le domaine temps-fréquences utilisant les réseaux de neurones et la logique floue.** 2014. 232 f. Thèse (Doctorat en Génie Mécanique). École Polytechnique de Montréal, Canada.

ÖZÇELİK, R. et al. Estimating tree bole volume using artificial neural network models for four species in Turkey. **Journal of Environmental Management**, v. 91, n.3, p. 742–753, 2010.

ÖZÇELİK, R.; DIAMANTOPOULOU, M. J.; BROOKS, J. R. 2014. The use of tree crown variables in over-bark diameter and volume prediction models. **iForest**, v. 7, n. 3, p. 132-139, 2014.

ÖZÇELİK, R.; DIAMANTOPOULOU, M. J.; EKER, M.; GURLEVIK, N. Artificial Neural Network Models: An Alternative Approach for Reliable Aboveground Pine Tree Biomass Prediction. **Forest Science**, v.63, p.1-12, 2017.

PEREZ, S. I. **Origen y evolución de los humanos. La historia de la divergencia de los primates.**, v. 22, n. 129, p. 22-30, 2012.

PIENAAR, L. V.; SHIVER, B. D. Survival functions for site prepared slash pine plantations in the flat woods of Georgia Northern Florida. **Southern Journal Forestry**, v.5, n.2, p.59-62, 1981.

PIMENTEL-GOMES, F. **Curso de estatística experimental**. 15 ed. Piracicaba: FEALQ, 2009. 451p.

PINHO, A.; COELHO, G. **Utilização da programação por metas como auxílio à tomada de decisão em transportes**. Espírito Santo: Universidade Federal do Espírito Santo, 2010, 11 p.

PORRAS, J. C. Growth Evaluation of a Conifer Forest (*Pinus Cooperi* Blanco) using a Neural Net Backpropagation Trained with Distance Independent Competition Measures. **Computación y Sistemas**, v. 10, n. 4, p. 415-427, 2007.

PRECHELT L. **Early Stopping - but when?** Technical Report, 1997. Disponível em: <http://page.mi.fu-berlin.de/prechelt/Biblio/stop_tricks1997.pdf> e acesso em: 22/12/2015.

PRICE, R. A.; GERNANDT, D.S.; LISTON, A. 1998. **Pine Trees**. Disponível em: <<http://www.tolweb.org/Pinus>> e acesso em: 07/09/2015.

ROCHA, M. P. **Técnicas e planejamentos de serrarias**. Série Didática FUPEF, 02/01. Curitiba: FUPEF, 2002. 121p.

ROJAS, F., ORTIZ, E. 1990. **Pino caribe (*Pinus caribaea*), especie de árbol de uso múltiple en América Central**. CATIE, Turrialba, Costa Rica. Serie Técnica, Informe Técnico No. 175. 59p.

ROMERO, C. Programación por metas (Goal Programming): pasado, presente y futuro. España: Toma de decisiones con criterios múltiples. **Serie Monografías Número 1**, p. 75-89, 2005.

ROMERO, C. **Economía de los recursos ambientales y naturales**. Madrid, España: Alianza Editorial S.A. 2d Ed., 1994. 216p.

ROMERO, C. **Handbook of Critical Issues in Goal Programming**. Oxford: Pergamon Press, 1991. 122 p.

ROMERO, C. **Teoría de la Decisión Multicriterio: Conceptos, Técnicas y aplicaciones**. Madrid: Alianza Editorial, 1993.195p.

RUMELHART, D.E.; MCCLELLAND, J.L.; WILLIAMS, R.J. Learning representations by backpropagation. **Nature**, v. 323, p. 533–536, 1986.

SALAS, R. Redes Neuronales artificiales. 2004. Acesso em: 18/09/2016 e disponível em: <<http://www.inf.utfsm.cl>>.

SÁNCHEZ, C.O. **Influencia de la tecnología de aserrado en la calidad de la madera aserrada de coníferas**. 2005. 113f. Tesis (Maestría en ciencias forestales)- Universidad de Pinar del Río, Pinar del Río.

SANQUETTA, C.R. **Predição da sobrevivência em reflorestamentos de *Pinus elliottii* Engelm.** 1990. 97f. Dissertação (Mestrado em Engenharia Florestal) – Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba.

SANT'ANNA, C. M. **Fatores humanos relacionados com a produtividade do operador de motosserra no corte florestal**. 1992. 145 f. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa.

SARIKHANI, N. **Forest utilization**. Tehran University Press, Tehran, 2001.728 p.

SCHIAVO, E.H.C. et al. **Estudo comparativo entre redes neurais artificiais e análise de regressão múltipla na avaliação de bens, para pequenas amostragens**. In: XXIV Encontro Nac. de Eng. de Produção - Florianópolis, SC, Brasil. 2004.

SEGALL, R.S. Some mathematical and computer modelling neural networks. **Applied Mathematical Modelling**, v. 19, n. 7, p. 386 – 399, 1995.

SHAO, G.; REYNOLDS, K.M. **Computer Applications in Sustainable Forest Management: Including Perspectives on Collaboration and Integration**. Netherlands: Springer, 2006. 267p.

SILVA, E.N. et al. **Florestas de produção**. 1. ed. Viçosa - MG: Suprema, 2014. v.1. 296p.

SILVA, J.A.A. da. **Dynamics of stand structure in fertilized slash pine plantations**. 1986. 136f. Dissertation (Doctor of Philosophy) - University of Georgia, Athens.

SILVA, J.A.A. da. Conceitos e princípios básicos de modelagem matemática em ciências florestais. **Anais da Academia Pernambucana de Ciência Agronômica**, Recife, v. 11/12, p.195-215, 2015.

SILVA, J.M. **Análises genéticas em progênies de *Pinus caribaea* Morelet var. *caribaea* por caracteres quantitativos e marcadores moleculares**. 2005. 129f. Dissertação (Mestrado) - Universidade Estadual Paulista, Faculdade de Engenharia de Ilha Solteira, São Paulo.

SILVA, L.N.C. **Análise e síntese de estratégias de aprendizado para redes neurais artificiais**. 1998. 225f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Estadual de Campinas, São Paulo.

SILVA, M. L. DA et al. Análise do custo e do raio econômico de transporte de madeira de reflorestamentos para diferentes tipos de veículos. **R. Árvore**, Viçosa-MG, v. 31, n.6, p.1073-1079, 2007.

SILVA, R.M. **Redes Neurais Artificiais aplicadas à Detecção de Intrusão em Redes TCP/IP**. 2005. 120 f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Católica do Rio de Janeiro, Rio de Janeiro.

SILVA, V.S.M. **Manejo de florestas nativas: planejamento, implantação e monitoramento**. Cuiabá: FENF/UFMT, 2006. 106p.

SIMÕES, D. **Avaliação econômica de dois sistemas de colheita florestal mecanizada de eucalipto**. 2008. 105 f. Dissertação (Mestrado em Agronomia/Energia na Agricultura) - Faculdade de Ciências Agrônomicas/Universidade Estadual Paulista, Botucatu-SP.

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

SKOVSGAARD, J.P.; VANCLAY, J.K. Forest site productivity: a review of the evolution of dendrometric concepts for even-aged stands. **Forestry**, v. 81, n. 1, p. 13-31, 2008.

SNIJDERS, T.A.B.; BOSKER, R. J. **Multilevel Analysis: An Introduction to Basic and Advanced Multilevel Modeling**. 2nd ed. London, Sage Publishers, 2012. 368p.

SOARES, F.A.A.M.N. et al. Recursive diameter prediction and volume calculation of eucalyptus trees using Multilayer Perceptron Networks. **Computers and Electronics in Agriculture**, Amsterdam, v. 78, p. 19–27, 2011.

SOUZA, S.R.R. **Uso de Redes Neurais na estimativa volumétrica de clones de *Eucalyptus spp.* no pólo gesseiro do Araripe, Pernambuco**. 2015. 66 f. Dissertação (Mestrado em Biometria e Estatística Aplicada) - Universidade Federal Rural de Pernambuco, Recife.

SPATHELF, P.; NUTTO, L. **Modelagem aplicada ao crescimento florestal**. Santa Maria: UFSM, 2000. 70 p.

STEIN, G.H.; CARASCHI, J.C.; GUERREIRO, E.D.R. Análise operacional de carregamento florestal. **Revista da madeira** - edição nº135 - 2013. Disponível em: <http://www.remade.com.br/br/revistadamadeira_materia.php?num=1674&subject=Transporte&title=An%20E1lise%20operacional%20de%20carregamento%20florestal> e acesso em: 15/11/2015.

TABACHNICK, B.G.; FIDELL, L.S. **Using Multivariate Statistics**. 6th edition. New York, NY: Pearson Education, 2013. 983 p.

TAMHANE, A.C. **Statistical Analysis of Designed Experiments. Theory and Applications**. John Wiley & Sons, Inc., Hoboken, New Jersey. 2009. 708p.

TANAKA, O.K. Exploração e transporte na cultura do eucalipto. **Informe Agropecuário**, v. 12, n. 141, p. 24-30, 1986.

TETKO I.V.; VILLA A.E.P. Efficient Partition of Learning Data Sets for Neural Network Training. **Neural Networks**, v. 10, n. 8, p. 1361-1374, 1997.

THAPA, R. **Modeling Mortality of Loblolly Pine (*Pinus taeda* L.) Plantations**. 2014. 187f. Dissertation (Philosophy in Forestry) - Virginia Polytechnic Institute and State University, Virginia.

THOMAS, E. An artificial neural network for real-time hardwood lumber grading. **Computers and Electronics in Agriculture**, n. 132, pp. 71–75, 2017.

TINSLEY, H.E.A.; BROWN, S.D. **Multivariate statistics and mathematical modeling**. San Diego: Academic Press, 2000.676p.

UHDE, B. et al. Hybrid MCDA Methods to Integrate Multiple Ecosystem Services in Forest Management Planning: A Critical Review. **Environmental Management**, v. 56, n. 2, p. 373-388, 2015.

VAHID, S. **An Agent-Based Supply Chain Model for Strategic Analysis in Forestry**. 2011.138 f. Thesis (PhD) - University of British Columbia, Canada.

VALENÇA, M. **Aplicando Redes Neurais: um guia completo**. 2a ed. Olinda, Pernambuco: Editora Livro Rápido, 2005. 284p.

VALENÇA, M. **Fundamentos das redes neurais: Exemplos em Java**. 2ª. Edição, Revisado e ampliado. Olinda-PE: Livro Rápido, 2010. 386p.

VALENÇA, M.; LUSERMIR, T. **Uma metodologia para correção do erro de defasagem durante o processo de previsão com redes neurais**. In: XVIII Simpósio Brasileiro de Recursos Hídricos. Campo Grande, MS. 2009.

VALÉRIO, A.F. et al. Quantificação de resíduos e rendimento no desdobro de *Araucaria angustifolia* (BERTOL.) O. Kuntze. **Floresta**, Curitiba, PR, v. 37, n. 3, p. 387-398, 2007.

VANCLAY, J. K. Mortality functions for north Queensland rain forests. *Journal of Tropical Forest Science*, Kuala, v. 4, n. 1, p. 15-36, 1991.

VANCLAY, J.K., **Modelling forest growth and yield: applications to mixed tropical forests**, CAB International, Wallingford, UK, 1994. 312p.

VANDERBEI, R.J. **Linear Programming: Foundations and Extensions**. Springer; 4th ed. 2014. 468 p.

VIRIYAMETANONT, K. **Reconnaissance physique et géométrique d'éléments en béton armé par radar et réseaux de neurones artificiels**. 2008. 248 f. Thèse (Doctorat en Génie Civil) - Institut National des Sciences Appliquées de Toulouse (INSA de Toulouse) de l'Université de Toulouse. France.

VUOKILA, Y., Functions for variable density yield tables of pine based on temporary sample plots. **Commun. Inst. For. Fenn.**, v. 60, n. 4, p. 1-86, 1965.

WANG, H.; MALCOLM, D.C.; FLETCHER, A.M. *Pinus caribaea* in China: introduction, genetic resources and future prospects. **Forest Ecology and Management**, Amsterdam, v.117, n. 1/3, p.1-15, 1999.

WEINTRAUB, A. The supply chain in the forest industry: models and linkages, In: GEUNES, J. et al. **Supply Chain Management: Models, Applications, and Research Directions**. Netherlands: Kluwer Academic Publishers, 2002. Cap. 13, p. 343-362.

WERBOS, P.J. **Beyond regression: New tools for prediction and analysis in behavioral sciences**. 1974. Thesis (PhD) - Harvard University, USA.

YEGNANARAYANA, B. **Artificial Neural Networks**. Prentice Hall of India Private Limited, New Delhi, 2005. 461 p.

YUAN, J.L.; FINE, T.L. Neural-Network Design for Small Training Sets of High Dimension. *IEEE Transactions on Neural Networks*, v. 9, n. 2, p. 266-280, 1998.

YUAN, N.S.; DONG, X.H.; HAI, W.L. Quantitative identification of defects in lumber based on modal frequencies and artificial neural network. **Advanced Materials Research**, v. 183-185, pp. 2279-2283, 2011.

ZHENG, Y.Q.; ENNOS, R.A. Genetic variability and structure of natural and domesticated populations of Caribbean pine (*Pinus caribaea* Morelet). **Theoretical and Applied Genetics**. Berlin, n. 98, p.765-771, 1999.

ZIELKE, A.; POHL, M. Virtual vertical integration: The key to success. **The McKinsey Quarterly**, v. 3, p. 160-163, 1996.

CAPÍTULO I

AVALIAÇÃO DE CAPACIDADE PRODUTIVA E PROGNÓSE DE PRODUÇÃO E SOBREVIVÊNCIA PARA *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, julho 2017. **Avaliação de capacidade produtiva e prognose de produção e sobrevivência para *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.** Orientador: Prof. Dr. José Antônio Aleixo da Silva. Co-orientadores: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira e Prof. Dr. Daniel Alberto Álvarez Lazo.

RESUMO

Objetivou-se, no presente capítulo, obter equações de regressão e Redes Neurais Artificiais (RNAs) para prognose de produção e sobrevivência de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na empresa forestal Macurije, província de Pinar Del Río – Cuba. Os dados usados para as modelagens provem da medição das variáveis sobrevivência (densidade - número de árvores/ha), diâmetro a altura do peito (DAP) e altura total (Ht) em 550 parcelas temporárias e 14 parcelas permanentes circulares de 500m² estabelecidas em plantios de *Pinus caribaea* var. *caribaea*, com idades entre 3 e 41 anos. O estudo foi dividido em seis etapas: i) Ajuste de modelos de predição de crescimento; ii) Classificação da capacidade produtiva com o método de predição de parâmetros; iii) Ajuste de modelos de prognose de crescimento e produção; iv) Ajuste de modelos de prognose de sobrevivência; v) Treinamentos de Redes Neurais Artificiais para predição e prognose de produção e sobrevivência utilizando o algoritmo BFGS e incluindo variáveis categóricas; vi) Comparação dos desempenhos das equações de regressão com os das RNAs tanto na prognose da produção como na da sobrevivência. Os melhores modelos foram seleccionados com base aos seguintes critérios: coeficiente de determinação - R_{aj}^2 (%), o erro padrão da estimativa - Syx (%), a Raiz Quadrada do Erro Médio Quadrático – RMSE (%) e análises de distribuição de resíduos. A avaliação da qualidade de ajuste dos modelos também considerou a significância dos Testes F e t aplicados para os modelos e seus respectivos parâmetros, a verificação dos pressupostos de normalidade, homocedasticidade e ausência de autocorrelação serial nos resíduos pelos Testes de Kolmogorov-Smirnov com correção de Lilliefors, White e Durbin-Watson, respectivamente. Os modelos de predição de Schumacher (1939) e Korf (1939) apresentaram a melhor aderência aos dados. Na prognose da área basal e do volume, o sistema de Buckman modificado por Silva et al. (2006) foi melhor que os demais modelos. Na prognose do volume, não houve diferença significativa entre as RNAs e a equação de Buckman modificado por Silva et al. (2006), mas em relação à prognose da área basal, observou-se a superioridade das Redes Neurais Artificiais treinadas. Na prognose da sobrevivência, o modelo de melhor ajuste foi o de Pienaar e Shiver (1981). A RNA de arquitetura MLP 13-10-1 foi a de melhor capacidade de generalização e apresentou um desempenho semelhante ao da equação obtida do ajuste do modelo de Pienaar e Shiver (1981). A diferença dos modelos de regressão tradicionais, as RNAs têm uma estrutura flexível que possibilitou a inclusão de variáveis categóricas que melhoraram significativamente suas capacidades de generalização, mantendo a consistência biológica das estimativas.

Palavras-Chave: Florestas plantadas, regressão não linear, Redes Neurais Artificiais.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, July 2017. **Evaluation of productive capacity and prognosis of yield and survival for *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.** Adviser: Prof. PhD. José Antônio Aleixo da Silva. Co-advisers: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira and Prof. Dr. Daniel Alberto Álvarez Lazo.

ABSTRACT

The objective of this chapter was to obtain regression equations and Artificial Neural Networks (ANNs) to prognose growth, yield and survival of *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. in forest company Macurije, province of Pinar Del Río - Cuba. The data used for the modeling come from measurement of variables survival (density - number of trees/ha), diameter at breast height (DBH) and total height (Ht) in 550 temporaries plots and 14 circular permanent plots of 500 m² established in *Pinus caribaea* var. *caribaea*, aged between 3 and 41 years. To achieve this objective, the study was divided into six stages: i) Adjustment of growth prediction models; ii) Classification of productive capacity with parameters prediction method; iii) Adjustment of growth and yield prognose models; iv) Adjustment of survival prognose models; v) ANNs training for prediction and prognosis of yield and survival using BFGS algorithm and including categorical variables; vi) Comparison of ANNs and regression models performances in both production and survival prognosis. The best models were selected based on the following criteria: coefficient of determination - R_{aj}^2 (%), standard error of estimate - Syx (%), Square Root of the Mean Square Error - RMSE (%) and residue distribution analysis. The evaluation of models fit quality also considered analysis of significance of F and t tests applied to the models and their respective parameters; verification of normality and homoscedasticity assumptions and analysis of serial autocorrelation by Kolmogorov-Smirnov (with Lilliefors correction), White and Durbin-Watson tests, respectively. Schumacher (1939) and Korf (1939) presented the best adherence to the data in growth prediction. In basal area and volume prognosis, the Buckman system modified by Silva et al. (2006) was better than the other models. In volume prognosis, there was no significant difference between ANNs and Buckman system modified by Silva et al. (2006) performances, but in relation to basal area prognosis, a superiority of Artificial Neural Networks was observed. In Survival prognosis, the best fit model was that of Pienaar and Shiver (1981). The ANN MLP 13-10-1 was the one with best generalization capacity and presented a similar performance to Pienaar and Shiver (1981) model. Unlike the traditional regression models, ANNs have a flexible structure that allowed the inclusion of categorical variables that significantly improved their generalization capacities while maintaining the biological consistency of the estimates.

Keywords: Forest plantations, nonlinear regression, Artificial Neural Networks (ANNs).

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, juillet 2017. **Évaluation de la capacité productive et pronostic de la production et survie du *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.** Directeur de Thèse: Prof. Dr. José Antônio Aleixo da Silva. Co-directeurs de Thèse: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira et Prof. Dr. Daniel Alberto Álvarez Lazo.

RÉSUMÉ

L'objectif de ce chapitre est d'obtenir des équations de régression et des réseaux de neurones artificiels (RNAs) pour la projection de la croissance, production et survie du *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. dans l'entreprise Macurije, Province de Pinar del Río - Cuba. Les données utilisées pour la modélisation proviennent de la mesure des variables survie (densité - nombre d'arbres/ha), diamètre à hauteur de poitrine (DHP) et hauteur totale (Ht) de 550 placettes temporaires et 14 placettes permanentes circulaires de 500 m² f implantées dans les plantations de *Pinus caribaea* var. *caribaea*, de l'entreprise Macurije, âgées entre 3 et 41 ans. Pour atteindre cet objectif, l'étude a été divisée en six étapes: i) Ajustement de modèles de prédiction de croissance; ii) Classification de la capacité productive de l'espèce avec la méthode de prédiction de paramètres; iii) Ajustement des modèles de pronostic de croissance et production; iv) ajustement de modèles de pronostic de survie; v) Entraînement de RNAs, en incluant des variables catégorielles, pour la prédiction et le pronostic de la production et survie en utilisant l'algorithme BFGS; vi) comparaison des performances des équations de régression avec celles des RNAs dans le pronostic de la production et de la survie. Les meilleurs modèles ont été sélectionnés sur la base des critères suivants: le coefficient de détermination ajusté $-R_{aj}^2$ (%), l'erreur type de l'estimation - Syx (%), la racine carrée de l'erreur quadratique moyenne - RMSE (%) et l'analyse de la distribution des résidus. L'évaluation de la qualité de l'ajustement des modèles inclue aussi l'analyse des résultats des tests F et t appliqués aux modèles et leurs paramètres respectifs; la vérification des postulats de normalité, homoscedasticité et absence d'autocorrélation sérielle des résidus par les tests de Kolmogorov-Smirnov (avec correction de Lilliefors), White et Durbin-Watson, respectivement. Les modèles de Schumacher (1939) et Korf (1939) ont présentés les meilleures adhérences aux données dans la prédiction de la croissance. Pour la projection de l'aire basale et du volume, le système Buckman modifié par Silva et al. (2006) a été meilleur que les autres modèles. Dans la projection du volume, il n'y a pas eu de différence significative entre les performances des équations du système Buckman modifié par Silva et al. (2006) et celles des RNAs, mais par rapport à celle de l'aire basale, la supériorité des réseaux de neurones artificiels a été observée. Pour la projection de la survie, le meilleur modèle a été celui de Pienaar et Shiver (1981). Le RNA d'architecture MLP 13-10-1 a présenté la meilleure capacité de généralisation et a montré une performance similaire à celle du modèle de Pienaar et Shiver (1981). Contrairement aux modèles traditionnels de régression, les RNAs ont une structure flexible qui a permis l'inclusion de variables catégorielles qui ont considérablement améliorées leurs capacités de généralisation tout en maintenant la cohérence biologique des estimations.

Mots-clés: Plantations forestières, régression non linéaire, les réseaux de neurones artificiels.

1. INTRODUÇÃO

Os estudos de crescimento e produção por meio de modelos não são novos na área florestal (BUONGIORNO; GILLES, 2003) e constituem uma das abordagens de maior importância no estudo da dinâmica florestal (BOTKIN, 1993). Nestes estudos, as estimativas presentes (predições) e futuras (prognose) realizadas com técnicas de modelagem, tanto ao nível de árvores como de povoamentos, constituem uma das etapas essenciais para viabilizar o planejamento da atividade florestal (PRODAN et al., 1997). A predição ou projeção desse crescimento e produção florestal, juntamente com a classificação da capacidade produtiva e as prescrições, são os principais elementos do manejo de florestas equiâneas (CAMPOS; LEITE, 2017).

A modelagem, segundo Rawlings, Pantula e Dickey (1998), se refere ao desenvolvimento ou ajuste de expressões matemáticas que descrevam o comportamento de uma variável aleatória de interesse. A análise de regressão, técnica estatística cujo nome é atribuído ao antropólogo britânico Francis Galton (DRAPER; SMITH, 1998), é a mais utilizada em pesquisas empíricas de modelagem, principalmente, quando o objetivo é descrever ou revelar uma relação existente, porém oculta, entre um conjunto de variáveis independentes e uma variável dependente (DRAPER; SMITH, 1998; PARDOE, 2012). As equações matemáticas, principais resultados da análise de regressão, auxiliam pesquisadores e gestores florestais de várias maneiras, sendo a principal, a projeção dos rendimentos futuros das florestas com a finalidade de selecionar melhores opções de manejo, alternativas silviculturais adequadas ou planejar frequências e sequências de colheita florestal (VANCLEY, 1994; BURKHART; TOMÉ, 2012).

Abordando a diferença existente entre os modelos de predição e os de prognose, salienta-se que as prognoses são realizadas por meio de modelos de regressão em forma de sistemas de equações que estimam os parâmetros da função para a projeção da produção para idades futuras (CASTRO et al., 2013a) e os modelos de predição podem ser definidos como funções que descrevem a mudança no tamanho de um indivíduo (árvore) ou de uma população (povoamento) ao longo do tempo (idade) (BURKHART; TOMÉ, 2012).

Desde a perspectiva dos componentes das variáveis de entradas dos modelos, Binoti et al. (2015) asseveram que a predição é realizada por meio de modelos que tem a idade como variável independente, enquanto que a prognose é realizada por meio de modelos nos quais a produção futura é projetada em função da produção atual dentre outras variáveis. Os erros associados a estes modelos de prognose crescem com o passar do tempo (KANGAS, 1997).

Realizar prognoses precisas se converteu no principal desafio das modelagens, já que a área florestal, diferente de outras áreas, requer longos horizontes de planejamento, os quais podem variar de 20 a 50 anos em florestas tropicais e chegar até 250 anos em florestas temperadas (SPATHELF; NUTTO, 2000).

Na literatura florestal, a modelagem do crescimento e produção de florestas plantadas por meio da análise de regressão foi abordada em inúmeras pesquisas dentre as quais se pode citar os destacados trabalhos de Schumacher (1939), Buckman (1962) e Clutter (1963). Tratando-se da análise de regressão aplicada ao crescimento e produção florestal, é válido destacar autores como Draper e Smith (1998) e Pardoe (2012) cujos trabalhos foram complementares a literatura específica florestal que aborda o tema.

A mortalidade de árvores, um dos principais elementos da dinâmica florestal (BIGLER; BUGMANN, 2003), é a redução da densidade da floresta ocasionada por fatores naturais (SANQUETTA, 1990) e segundo Campos e Leite (2017), a mesma não deve ser confundida com falha de plantio que ocorre na etapa inicial do estabelecimento das áreas plantadas. Embora a mortalidade seja implícita nos modelos de prognose de crescimento e produção florestal, acima abordado, a sua modelagem de forma explícita é de suma importância para obter equações de auxílio a toma de decisões relacionadas com as densidades dos povoamentos. Negligenciar este fenômeno, como acontece geralmente, é aceitável apenas em plantações florestais industriais intensamente manejadas (VANCLAY, 1991), principalmente se são plantações desbastados periodicamente (CAMPOS; LEITE, 2017).

Em povoamentos poucos manejados, como os que são objetos da presente pesquisa, a importância da predição precisa de mortalidade nos sistemas de crescimento e produção florestal é incontestável, porém, a mortalidade continua sendo um dos componentes menos compreendidos devido à complexidade dos ecossistemas florestais (HAMILTON, 1986). Devido ao mesmo, é o componente do crescimento mais difícil e menos confiável de se estimar (GLOVER; HOLL, 1979).

Nas últimas décadas, procurando estimativas mais precisas, técnicas como as Redes Neurais Artificiais estão sendo popularizadas na mensuração florestal devido a suas vantagens sobre os métodos estatísticos tradicionais. Devido a sua eficácia na compreensão de sistemas complexos, estas técnicas de modelagem são utilizadas como alternativas ao ajuste de modelos de regressão não-lineares tradicionais (ÖZÇELİK et al. 2017). A eficácia dessas técnicas, segundo Dreyfus et al. (2004), está na sua capacidade de proporcionar modelos de precisão equivalente com menos dados experimentais ou a de criar modelos mais precisos com o mesmo

tamanho amostral. As RNAs podem ser definidas como modelos matemáticos que tem como metáfora o funcionamento do cérebro humano com suas redes neurais biológicas (VALENÇA, 2010).

No intuito de um melhor entendimento da produção e mortalidade das árvores e desenvolvimento de modelos com melhores capacidades preditivas, numerosas pesquisas utilizaram as técnicas de RNAs tanto na modelagem da produção florestal (GORDON, 1998; HIGGINS, 2011; BINOTI, 2012; ASHRAF et al., 2013; CASTRO et al., 2013a, b; ÖZÇELIK, DIAMANTOPOULOU e BROOKS, 2014; BINOTI et al., 2015; LIMA et al., 2017) como na da mortalidade ou sobrevivência (GUAN; GERTNER, 1991a, b; KING; BENNETT e LIST, 2000).

Diante do exposto, o presente trabalho teve como objetivo, obter sistemas aperfeiçoados de predição e/ou prognose de crescimento, produção e sobrevivência de *Pinus caribaea* var. *caribaea* Barr. & Golf. na Empresa Florestal Integral (EFI) Macurije, Pinar del Rio, Cuba, por meio de ajustes de modelos de regressão não linear e treinamentos de Redes Neurais Artificiais.

Esse objetivo geral foi alcançado por meio dos seguintes objetivos específicos:

- Classificar a capacidade produtiva de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. em áreas da Empresa Florestal Integral (EFI) Macurije.
- Obter equações de predição de crescimento para *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na EFI Macurije.
- Obter modelos ajustados para a prognose precisa de produção e sobrevivência de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na EFI Macurije.
- Analisar a capacidade de Redes Neurais Artificiais na predição de crescimento e prognose de produção e sobrevivência de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. em áreas da EFI Macurije.
- Comparar os desempenhos das equações obtidas com os das RNAs treinadas para prognose de produção e sobrevivência de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na EFI Macurije.

2. MATERIAL E MÉTODOS

2.1. Localização da área de estudo

A presente pesquisa foi desenvolvida em plantações de *Pinus caribaea* var. *caribaea* da Empresa Florestal Integral (EFI) Macurije localizada aproximadamente entre as coordenadas geográficas 22° 06' a 22° 42' latitude Norte e 83° 48' a 84° 23' longitude oeste, na região mais ocidental da província de Pinar del Río, Cuba (Figura 1).

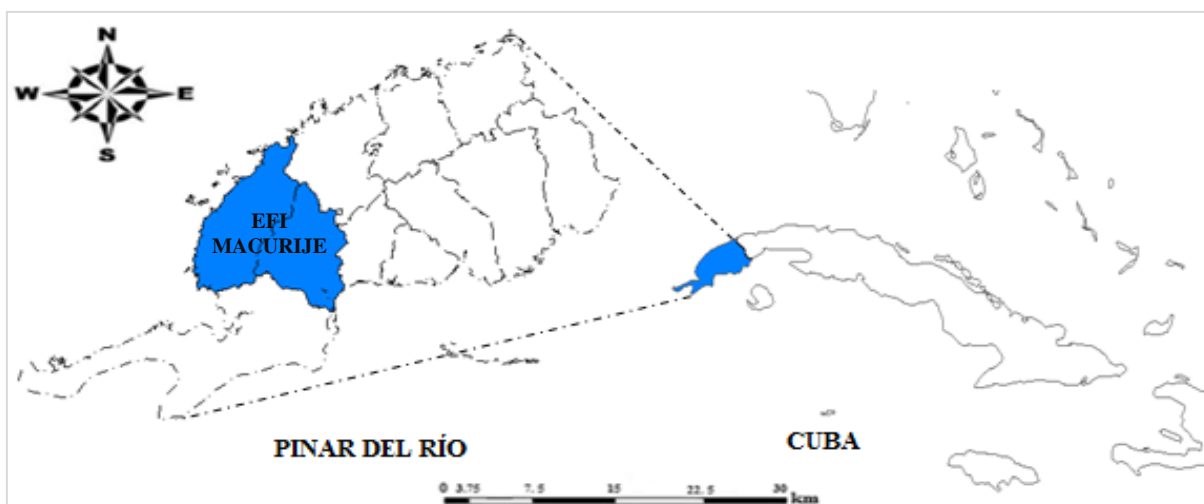


Figura 1- Localização geográfica da EFI Macurije, Pinar del Río, Cuba

(Fonte: RODRÍGUEZ, 2012)

2.2. Fontes de dados e análise de suficiência amostral

A base de dados foi constituída por 550 parcelas temporárias e 14 parcelas permanentes de 500 m² (r=12,615 m) estabelecidas em áreas da EFI Macurije. Segundo Campos e Leite (2013), a eficiência do modelo de prognose, utilizando parcelas permanentes, depende principalmente da localização das parcelas e do número de medições. As parcelas permanentes estão distribuídas nas duas unidades silvícolas (US) e cinco unidades básicas de produção florestal (UBPF) da empresa Macurije (Tabela 1) e contam com seis medições consecutivas realizadas sobre um período de 20 anos (1986-2006).

As parcelas temporárias foram levantadas seguindo uma amostragem inteiramente aleatória em toda a empresa para assegurar a representatividade das mesmas. A análise da suficiência amostral das parcelas temporárias foi realizada por meio do erro amostral, se baseando no procedimento de amostragem inteiramente aleatório em população infinita, com um erro admissível de 10% e um nível de probabilidade de 95%.

Tabela 1 – Distribuição das parcelas permanentes nas unidades básicas de produção florestal da empresa florestal integral macurije, Pinar del Río, Cuba.

| Unidades Silvícolas | UBPF | Quantidade de parcelas |
|---------------------|------------|------------------------|
| Guane | Los Ocujes | 3 |
| | Las cañas | 3 |
| | Sábalo | 3 |
| Mantua | Río Mantua | 2 |
| | Macurije | 3 |
| Total | | 14 |

Os talhões têm idades entre 3 e 41 anos e as variáveis mensuradas foram: diâmetro a altura do peito (DAP) e altura (H) imprescindíveis para a estimativa da produtividade do povoamento em determinada idade (I) e a sobrevivência (Tabela 2).

Tabela 2 - Análise descritiva das variáveis coletadas nos plantios de *P. caribaea* var. *caribaea*

| Variáveis | Mínimo | Máximo | Média | Desvio-Padrão |
|----------------------|--------|--------|--------|---------------|
| Sobrevivência (N/ha) | 425 | 1025 | 665,80 | 157,69 |
| DAP (cm) | 5,50 | 37,00 | 20,15 | 4,97 |
| Ht (m) | 5,00 | 23,00 | 14,40 | 3,21 |
| I (anos) | 3,00 | 41 | 24,43 | 8,79 |

DAP= diâmetro a altura do peito; Ht = altura total; I=idade.

2.3. Modelos para predição e prognose da produção de *Pinus caribaea* var. *caribaea*

2.3.1. Modelos de predição de crescimento em volume de *Pinus caribaea* var. *caribaea*

Os modelos de crescimento e produção seleccionados (Tabela 3) foram ajustados para o povoamento completo e o de melhor aderência foi ajustado por capacidade produtiva. A determinação da idade de rotação técnica (IRT) se baseou no critério de máxima produtividade ou máximo Incremento Médio Anual definido pela relação $ICA = IMA$ ou $dIMA/dt = 0$. Essa relação aplicada aos modelos de crescimento e produção seleccionados permitiram obter expressões de determinação das IRT (Tabela 3) cujas demonstrações se encontram nos apêndices 1.12, 1.13 e 1.14.

Tabela 3 – Modelos de predição de crescimento em volume ajustados para plantios de *Pinus caribaea* var. *caribaea*, Pinar del Rio, Cuba

| Nº | Autores | Expressões matemáticas | IRT |
|----|-----------------------------|--|--|
| 01 | Schumacher (1939) | $Y = e^{\beta_0 + \beta_1 \left(\frac{1}{I}\right)} + \varepsilon$ | $-b_1$ (*) |
| 02 | Korf (1939) | $Y = \beta_0 e^{-\beta_1 I^{-\beta_2}} + \varepsilon$ | $\left(\frac{1}{b_1 b_2}\right)^{\left(\frac{1}{-b_2}\right)}$ (**) |
| 03 | Chapman-Richards (1959) | $Y = \beta_0 (1 - e^{-\beta_1 I})^{\beta_2} + \varepsilon$ | $\frac{-b_2 * W_n \left(-\frac{e^{-\frac{1}{b_2}}}{b_2} \right) - 1}{b_1 * b_2}$ (**) |
| 04 | Logístico – Verhurst (1837) | $Y = \frac{\beta_0}{1 + \beta_1 e^{-\beta_2 I}} + \varepsilon$ | $-\frac{W_n \left(-\frac{e}{b_1} \right) - 1}{b_2}$ (*) |
| 05 | Silva-Bailey (1986) | $Y = \beta_0 e^{\beta_1 \beta_2 I} + \varepsilon$ | $\frac{W_n(1/b_1)}{\ln b_2}$ (**) |

Y: volume (m³/ha); I: Idade (anos); β_0 ; β_1 ; β_2 : parâmetros a estimar; ε : erro aleatório; (*) Fonte: Campos e Leite (2013); (**) Determinada na presente pesquisa (demonstrações nos apêndices 1.11, 1.12 e 1.13); IRT: Idade de Rotação Técnica; b_1 e b_2 : estimativas respectivas dos parâmetros β_1 e β_2 do modelo, obtidas após ajuste do mesmo e W_n : a função de Lambert.

2.3.2. Classificação da capacidade produtiva para *Pinus caribaea* var. *caribaea*

A classificação da capacidade produtiva, fase inicial da modelagem de crescimento e produção, foi realizada por meio de curvas de índice de sítio ajustadas pelo método da predição de parâmetros proposto por Clutter et al. (1983), considerado eficiente na construção de curvas polimórficas (CAMPOS; LEITE, 2017). Para o mesmo, considerou-se uma idade-índice (I_i) de 30 anos e cinco sítios: SI = 11,5; SII= 14,5; SIII= 17,5; SIV= 20,5 e SV = 23,5. Inicialmente, foi ajustado o modelo de Schumacher (1939) (Expressão 1) para cada parcela e depois substituída a idade pela idade-índice em cada uma das regressões visando encontrar a classe de sítio para cada parcela, obtendo-se a equação 2.

$$HD = e^{\left(\beta_0 + \frac{\beta_1}{I}\right)} + \varepsilon_i \tag{1}$$

$$S = e^{\left(b_0 + \frac{b_1}{I}\right)} \tag{2}$$

Em que: HD = altura dominante em metros; β_0 ; β_1 = parâmetros do modelo 1. b_0 , b_1 = estimativas de parâmetros; I = idade em anos; S = índice de sítio.

Posteriormente relacionou-se cada estimativa de parâmetro com os índices de sítio por meio de regressão linear (Expressões 3 e 4) e substituiu-se as equações obtidas desses modelos

no modelo na expressão 1 para obter as equações a serem utilizadas para a construção das curvas.

$$\beta_0 = \alpha_0 + \alpha_1 \cdot S + \alpha_2 \cdot S^2 + \varepsilon_i \tag{3}$$

$$\beta_1 = \alpha_3 + \alpha_4 \cdot S + \alpha_5 \cdot S^2 + \varepsilon_i \tag{4}$$

Em que: α_i = parâmetros a serem estimados; S = índice de sítio; ε_i = erro associado.

2.3.3. Prognose de produção e sobrevivência para *Pinus caribaea* var. *caribaea*

2.3.3.1. Modelos de prognose de crescimento e produção para *P. caribaea* var. *caribaea*

A literatura florestal conta com muitos modelos desenvolvidos para a prognose da produção em florestas plantadas. Dentre eles, os modelos da Tabela 4 foram selecionados e testados no presente estudo.

Tabela 4 – Modelos de prognose de produção em plantios de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

| Nº | AUTORES | EXPRESSÕES MATEMÁTICAS | FONTES |
|----|------------------------|---|------------------------|
| 1 | Clutter (1963) | $LnV_2 = \beta_0 + \beta_1/I_2 + \beta_2S + \beta_3LnG_2 + Ln\varepsilon$ $LnG_2 = LnG_1 \left(\frac{I_1}{I_2}\right) + \alpha_0 \left(1 - \frac{I_1}{I_2}\right) + \alpha_1 \left(1 - \frac{I_1}{I_2}\right)S + Ln\varepsilon$ | Campos e Leite (2017) |
| 2 | B.M.S. et al. (2006) | $LnV_2 = \beta_0 + \beta_1I_2^{-1} + \beta_2S_1 + \beta_3LnG_2 + Ln\varepsilon$ $LndG_2 = \beta_4 + \beta_5S_1 + \beta_6I_2^{-1} + \beta_7G_1 + \varepsilon$ | Campos e Leite (2017) |
| 3 | Silva e Bailey (1986) | $V_2 = V_1 * e^{\beta_0(\beta_1^{I_2} - \beta_1^{I_1})} + \varepsilon_i$ | Silva (1986) |
| 4 | Clutter e Jones (1980) | $V_2 = \left[V_1^{\beta_0} + \beta_1 \left(I_2^{\beta_2} - I_1^{\beta_2} \right) \right]^{\frac{1}{\beta_0}} + \varepsilon_i$ | Clutter e Jones (1980) |

Em que: V_2 = Produção (m³) esperada na idade I_2 ; V_1 = Produção atual (m³) na idade I_1 ; I_1 = Idade atual; I_2 = Idade futura; G_1 = Área Basal atual; G_2 = Área Basal futura; S_1 = Índice de sítio definido na idade atual; dG_2 = Incremento em área basal da idade I_1 a idade I_2 ; $\beta_0, \beta_1, \beta_2, \beta_3, \beta_4, \beta_5, \beta_6, \beta_7, \alpha_0, \alpha_1$ = Parâmetros a serem estimados; ε_i = Erro aleatório ~ NID (0, σ^2); Ln : Logaritmo neperiano.

2.3.3.2. Modelos de prognose da sobrevivência em plantios de *Pinus caribaea* var. *caribaea* na EFI Macurije.

Infinidades de modelos foram desenvolvidos para a prognose da sobrevivência/mortalidade em florestas plantadas. Dentre eles, foram selecionados e ajustados aqueles que foram reportados como de bons ajustes (Tabela 5).

Tabela 5 – Modelos de prognose de sobrevivência em plantios de *Pinus caribaea* var. *caribaea*

| Nº | AUTORES | EXPRESSÕES MATEMÁTICAS | FONTES |
|----|-------------------------|--|-----------------------|
| 1 | Clutter e Jones (1980) | $N_2 = \left[N_1^{\beta_0} + \beta_1 (I_2 - I_1^{\beta_2}) \right]^{\frac{1}{\beta_0}} + \varepsilon_i$ | Sanquetta (1990) |
| 2 | Silva e Bailey (1986) | $N_2 = N_1 e^{\beta_0 (\beta_1^{I_2} - \beta_1^{I_1})} + \varepsilon_i$ | Silva (1986) |
| 3 | Pienaar e Shiver (1981) | $N_2 = N_1 e^{-\beta_0 (I_2^{\beta_1} - I_1^{\beta_1})} + \varepsilon_i$ | Campos e Leite (2017) |
| 4 | Chapman-Richards (1959) | $N_2 = N_1 \left[\frac{1 - e^{\beta_0 I_2}}{1 - e^{\beta_0 I_1}} \right]^{\beta_1} + \varepsilon_i$ | Silva (2015) |
| 5 | Weibull | $N_2 = N_1 - \beta_0 \left[e^{-\beta_1 I_2^{\beta_2}} - e^{-\beta_1 I_1^{\beta_2}} \right] + \varepsilon_i$ | Silva (2015) |

Em que: N_2 = Número de árvores futuro; N_1 = Número de árvores presente; I_2 =Idade futura; I_1 = Idade presente; β_i = Parâmetros a serem estimados.

2.4. Treinamentos de Redes Neurais Artificiais para prognose de produção e sobrevivência de *Pinus caribaea* var. *caribaea*.

Tanto para predição de volume como para prognose de produção e sobrevivência, foram treinadas 100 RNAs dos tipos Multi Layer Perceptron (MLP) e Radial Basis Function (RBF) e as melhores retidas para análise. Os treinamentos seguiram as mesmas estruturas em relação às variáveis usadas nos modelos de regressão ajustados. As características dos treinamentos se encontram na Tabela 3 e as etapas seguidas nos mesmos descritos na Figura 2.

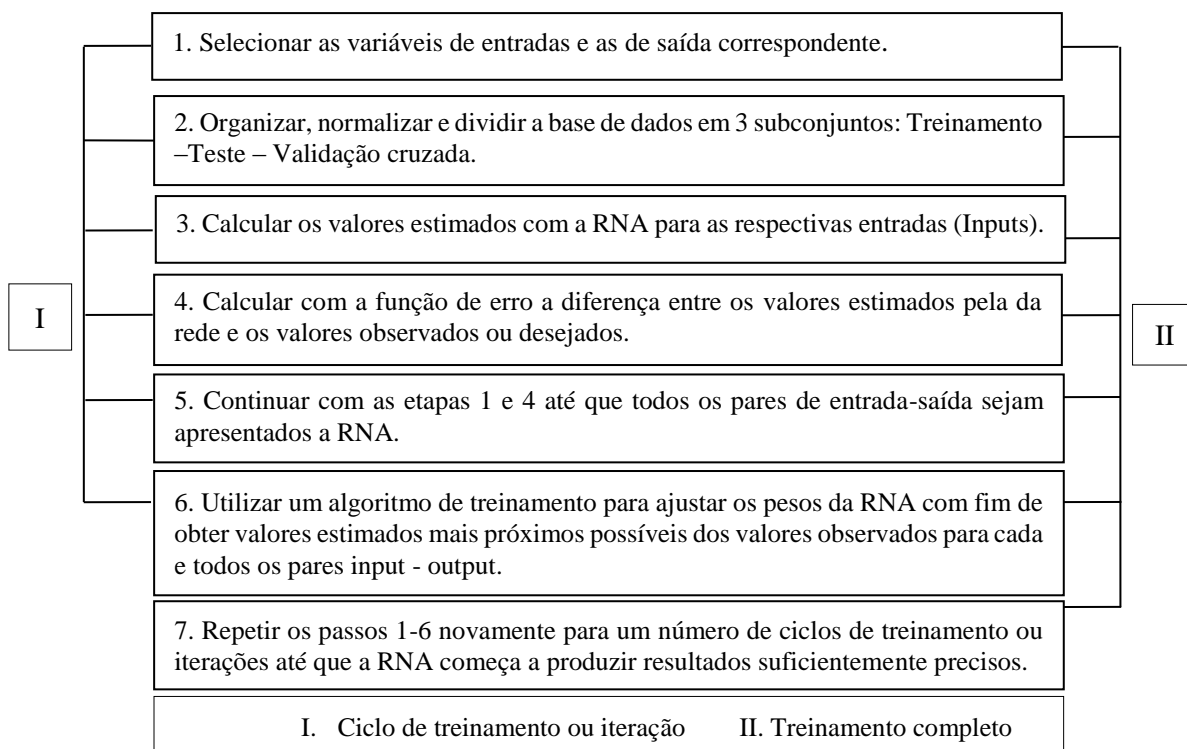


Figura 2 – Etapas de treinamento de Redes Neurais Artificiais para predição e prognose de produção para *Pinus caribaea* var. *caribaea*. Fonte: Elaborada com base em Valença (2010)

Nos treinamentos, o conjunto de dados foi dividido seguindo as proporções de Valença (2010): 50% para o treinamento, 25% para a avaliação do desempenho da rede (teste) e 25% para a validação cruzada, critério de parada do treinamento da rede. Para melhorar a eficiência (convergência estável dos pesos e desvios) do algoritmo de treinamento que pode ser afetada pela variação das escalas das variáveis, os dados foram normalizados nos intervalos [0,1] ou [-1,1] segundo a função de ativação, utilizando a transformação linear.

A escolha do algoritmo Broyden-Fletcher-Goldfarb-Shanno (BFGS) (Tabela 6) se baseou em Bishop (1995), quem recomenda o mesmo para treinamentos supervisionados devido a sua maior taxa de convergência e capacidade de pesquisa mais inteligente.

O uso de variáveis qualitativas ou categóricas sendo uma das grandes vantagens das RNAs (MARTINS et al. 2016), duas variáveis *dummies* foram incluídas nos treinamentos: a variável “índice de sítio” que conta com cinco categorias (SI, SII, SIII, SIV e SV) e a variável “UBPF” incluída para possibilitar a realização de prognose para cada unidade básica de produção florestal. As categorias dessa última variável são as cinco UBPFs da Tabela 1: Los Ocujes, Las cañas, Sábalo, Río Mantua, Macurije. Estas variáveis categóricas foram codificadas e normalizadas por meio do procedimento 1-de-N (GOLDSCHMIDT; PASSOS, 2005).

Tabela 6 – Características dos treinamentos das RNAs para predição de crescimento e prognose de produção e sobrevivência

| Finalidade | Variável Dependente | Variáveis Independentes | Tipo de RNAs | Algoritmo de Treinamento | Funções de ativação |
|---------------------------|---------------------|------------------------------|--------------|--------------------------|---|
| Predição | V | $I, S, UBPF$ | MLP RBF | BFGS | Seno, Identidade, Logística, Exponencial Tangente hiperbólica |
| Prognose da produção | V_2 | $I_1, I_2, S, G_1, G_2, V_1$ | | | |
| | G_2 | I_1, I_2, S, G_1 | | | |
| Prognose da sobrevivência | N_2 | N_1, I_1, I_2, S | | | |

2.5. Estimativa dos parâmetros, critérios de avaliação e de escolha dos modelos

Os ajustes dos modelos assim como os treinamentos das RNAs foram realizados com o software STATISTICA vers. 8 e SPSS vers. 20. Os modelos de Clutter (1963) e de Buckman modificado por Silva et al. (2006) sendo um sistema de equações simultâneas exatamente identificadas, seus parâmetros foram estimados com o Método de Mínimos Quadrados em dois Estágios (MQ2E). Os modelos de predição de crescimento (Tabela 3), os de prognose de

produção de Silva e Bailey (1986) e Clutter e Jones (1980) e os de sobrevivência (Tabela 5) foram ajustados por meio dos métodos iterativos de Levenberg-Marquardt, Gauss-Newton ou Newton-Raphson em dependência da convergência dos modelos.

Os ajustes foram realizados em três etapas: (1) Avaliação da qualidade de ajuste dos modelos mediante os seguintes critérios: coeficiente de determinação ajustado - R_{aj}^2 (Expressão 5). Para a comparação de modelos de diferentes naturezas, no lugar do R_{aj}^2 foi calculado o índice de Schlaegel (IA) (Expressão 6). Seus valores variam entre 0 e 1 e quanto maior seja, mais explicativo é o modelo; a Raiz Quadrada do Erro Médio Quadrático – RMSE (%) (Expressão 7) e Erro padrão da estimativa - Syx (%) (Expressão 8) nos quais valores pequenos são desejáveis, as análises de distribuição de resíduos (Expressão 9) e o bias (Expressão 10) para verificar possíveis tendências de estimativa nas equações obtidas; (2) Análise da significância do Teste F aplicado aos modelos e o Teste t aos seus respectivos parâmetros; (3) Verificação dos pressupostos de normalidade, homocedasticidade e ausência de autocorrelação serial nos resíduos pelos Testes de Kolmogorov-Smirnov (KOLMOGOROV, 1933; SMIRNOV, 1948) com correção de Lilliefors (LILLIEFORS, 1967), White (WHITE, 1980) e Durbin-Watson (DURBIN; WATSON, 1951), respectivamente.

$$R_{aj}^2 = R^2 - \left[\frac{N-1}{N-K} \right] * (1 - R^2) \quad (5)$$

Em que: R^2 = Coeficiente de determinação; K = número de parâmetros; N = número de observações.

$$IA = 1 - \left(\frac{n-1}{n-p-1} \right) \cdot \frac{SQres}{SQt} \quad (6)$$

Em que: p = número de parâmetros; n = número de observações; $SQres$ = soma dos quadrados dos resíduos; SQt = soma dos quadrados total.

$$RMSE(\%) = 100 \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} / \bar{Y} \quad (7)$$

Em que: Y : Volume observado (m³/ha); \hat{Y} : Volume estimado (m³/ha); \bar{Y} : média dos volumes observados (m³/ha); n : número de observação.

$$S_{yx}(\%) = \frac{S_{yx}}{\bar{Y}} \cdot 100 \quad (8)$$

Em que: S_{yx} = Erro padrão da estimativa determinada pela raiz quadrada do Quadrado Médio dos Resíduos (QMR); \bar{Y} = média aritmética da variável dependente.

$$E_i = \frac{(Y_i - \hat{Y}_i)}{Y_i} * 100 \quad (9)$$

Em que: E_i = Resíduo da i -ésima observação; Y_i = Variável dependente observada; \hat{Y}_i = Variável dependente estimada pela equação.

$$Bias = n^{-1} \sum_{i=1}^n (Y_i - \hat{Y}_i) \quad (10)$$

Em que: Y : Volume observado (m³/ha); \hat{Y} : Volume estimado (m³/ha); \bar{Y} : média dos volumes observados (m³/ha); n : número de observação.

As comparações univariadas e multivariadas do desempenho do modelo de melhor ajuste com o das RNAs selecionadas na prognose da produção foram realizadas com o Teste t para dados pareados, conforme adotado por Rezende et al. (2006), Rocha et al. (2015); e o Teste T^2 de Hotelling (HOTELLING, 1931), ao nível de 5% de significância (Expressões 11 e 12).

$$T^2 = (\bar{X} - \bar{Y})^T \left[S \left(\frac{1}{n_x} + \frac{1}{n_y} \right) \right]^{-1} (\bar{X} - \bar{Y}) \quad (11)$$

$$S = \frac{(n_x - 1)S_X + (n_y - 1)S_Y}{(n_x - 1) + (n_y - 1)} \quad (12)$$

Em que: S_X e S_Y são as matrizes de covariância de X e Y respectivamente; \bar{X} e \bar{Y} as médias de X e Y respectivamente; n_x e n_y são os tamanhos das variáveis X e Y , respectivamente.

As significâncias foram determinadas fazendo uma aproximação do teste F ao teste T^2 de Hotelling por meio da expressão 13.

$$F = \frac{n - k}{k(n - 1)} T^2 \sim F(k, n - k) \quad (13)$$

Em que: $n = n_x + n_y - 1$ = grau de liberdade e k = número de variáveis.

Como regras de decisão considerou-se que os melhores modelos e RNAs foram os que, além de apresentar maiores R_{aj}^2 , menores RMSE (%) ou S_{yx} (%) e uma dispersão dos resíduos sem tendenciosidade e entorno a zero, satisfaçam todos os pressupostos supracitados.

3. RESULTADOS E DISCUSSÃO

3.1. Estimativas dos parâmetros dos modelos de crescimento e produção

Os erros de amostragem de 2,19 % e 7,21% correspondentes as variáveis volume e sobrevivência, respectivamente, foram inferiores ao erro permissível de 10%, indicando que a amostra piloto foi suficiente para a realização das estimativas e modelagens.

Na Tabela 7 são apresentadas as estimativas dos parâmetros de cada um dos modelos após a realização dos ajustes.

Tabela 7 – Estimativas dos parâmetros dos modelos de predição de crescimento e produção do *Pinus caribaea* Morelet var. *caribaea*

| Modelos | Coeficientes | | | R^2_{aj} (%) | S_{yx} (%) | Sig. F | IRT |
|--------------------------------|-----------------|-----------------|-----------------|-------------------|-----------------|---------|-------|
| | $\hat{\beta}_0$ | $\hat{\beta}_1$ | $\hat{\beta}_2$ | | | | |
| Schumacher (1939) | 6,916* | -33,567* | - | 98,76 | 1,96 | <0,0001 | 33,57 |
| Korf (1939) | 1055,355* | 31,017* | 0,965* | 98,80 | 1,94 | <0,0001 | 33,86 |
| Chapman-Richards (1959) | 579,048* | 0,063* | 3,367* | 98,70 | 2,09 | <0,0001 | 33,02 |
| Logístico – Verhurst (1837) | 473,091* | 25,427* | 0,137* | 98,20 | 3,57 | <0,0001 | 32,73 |
| Silva-Bailey (1986) | 513,241* | -5,711* | 0,918* | 98,60 | 2,52 | <0,0001 | 32,21 |

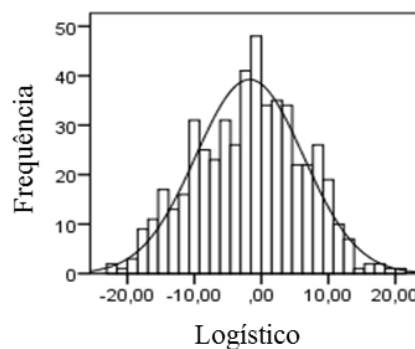

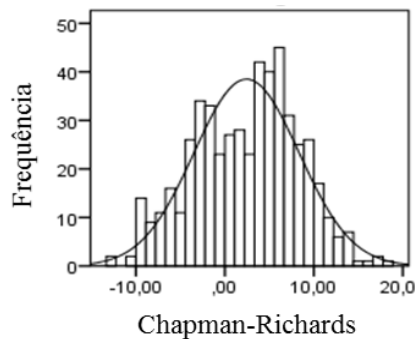

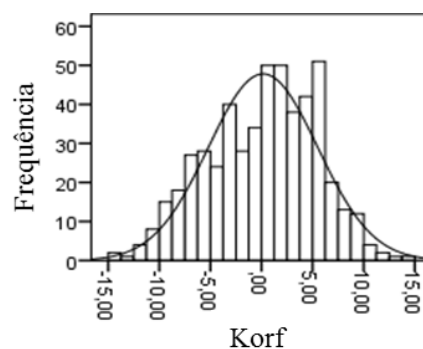

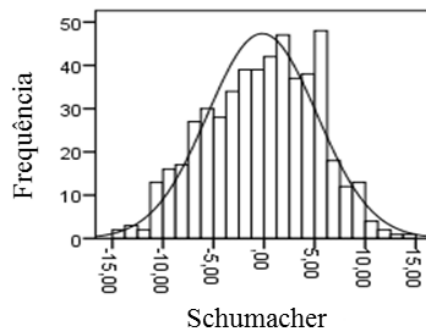

*Estimativa significativa a 99% de confiança pelo Teste t ; IRT=Idade de Rotação Técnica.

Os testes de Kolmogorov-Smirnov com correção de Lilliefors não sendo significativos apenas para os modelos de Schumacher, Logístico e Silva-Bailey (Apêndice 1.1), não se rejeita então a hipótese nula segundo a qual os resíduos seguem uma distribuição normal, condição necessária para a confiabilidade dos resultados dos testes paramétricos t e F utilizados para testar a significância dos parâmetros e dos modelos, respectivamente. Os valores do Teste de Durbin-Watson iguais (Apêndice 1.2) indicam que apenas o modelo de Schumacher apresentou resíduos não correlacionados. Os modelos de Chapman-Richards, Silva-Bailey e Logístico apresentaram autocorrelação serial negativa e o de Korf, uma autocorrelação positiva.

Em relação à homocedasticidade, os modelos que satisfizeram esse pressuposto foram os de Schumacher, Korf e Chapman-Richards (Apêndice 1.3), resultados estes confirmados pela distribuição dos resíduos (Figura 3). A distribuição periódica ou sinusoidal do modelo logístico evidencia sua inadequação para a base de dados.

Os resultados acima encontrados, somados aos altos coeficientes de determinação e menores erros padrões das estimativas (Tabela 7), favoreceram a seleção das equações obtidas dos modelos de Schumacher e Korf como as mais adequadas para a predição precisa do

crescimento e produção nas plantações de *Pinus caribaea* var. *caribaea* na empresa Macurije, Pinar del Rio, Cuba.



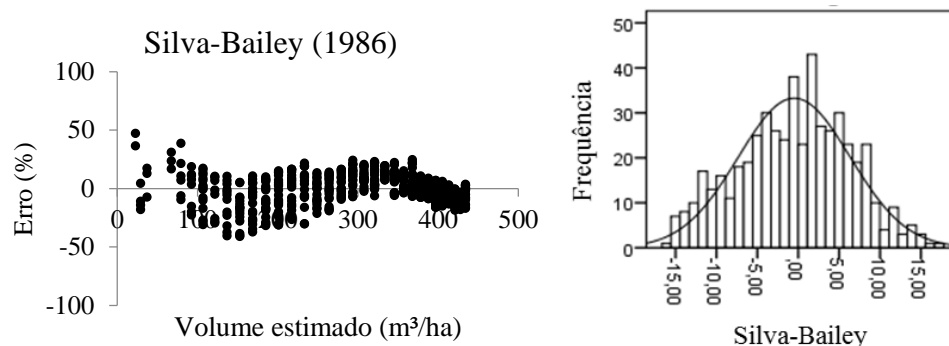


Figura 3 – Distribuição dos resíduos dos modelos de crescimento e produção ajustados

Com base a equação de Schumacher, os plantios apresentaram uma produção de 375,734 m³/ha correspondendo a um IMA de 11,051 m³/ha/ano. Este resultado é muito superior ao reportado por Aldana, Puentes e Romero (2006) para a espécie no plano de ordenamento da empresa (6,5 m³/ha/ano), mas está em consonância com os resultados de Barrero et al. (2011) que encontrou incrementos compreendidos entre 10 e 12 m³/ha/ano.

As equações resultantes dos ajustes indicam idades de rotação compreendidas entre 32 e 34 anos (Tabela 7) para a espécie na empresa. Este resultado está em consonância com as rotações encontradas por Alder, Drichi e Elungat (2003), Aldana, Padilla e Rodríguez (2011), Barrero et al. (2011) que foram 22-33 anos, 31 anos e de 30-35 anos, respectivamente. Estudos mais antigos encontraram resultados tantos superiores como inferiores aos encontrados no presente estudo. Dentre eles se pode citar os trabalhos de Herrero (1985) que encontrou rotações mais curtas entre 25 e 30 anos e os de Varona (1982), que encontrou para a espécie, rotações mais longas que variaram de 40 a 80 anos segundo a qualidade do sítio. Peraza (2011) encontrou uma idade de rotação técnica de 27 anos para a espécie.

As expressões dos modelos de Schumacher, Korf e Chapman-Richards indicaram rotações únicas (Figura 4). As expressões de IRT dos modelos Logístico e de Silva-Bailey indicaram duas idades de rotação. É comum que ao longo do crescimento da floresta, os ICAs e IMAs se igualem mais de uma vez. Isso acontece nas predições realizadas com certos modelos e fica evidente na sua expressão de determinação de IRT. A função de Lambert sendo uma função não injetiva, se seu argumento pertence ao intervalo $(-1/e; 0)$, dois valores serão obtidos e cada um desses valores permitirá obter uma determinada IRT.

No modelo de Silva-Bailey, o argumento da função de Lambert é $\frac{1}{b_1} = \frac{1}{-5,711} = -0,1751$. Esse valor pertencendo ao intervalo $(-1/e; 0)$, a função de Lambert tomou os valores -2,76 e -0,22 que proporcionam idades de rotação de 32,21 e 2,54 anos, respectivamente. O mesmo aconteceu na expressão do modelo Logístico na qual a função de Lambert tomou os

valores -3,48 e -0,12 que geraram as rotações de 32,72 e 8,18 respectivamente. A invalidez das menores rotações em ambos os modelos é evidente já que a madeira é produzida para serraria e a essas idades os povoamentos ainda não alcançaram as características dendrométricas exigidas. Os resultados alcançados pela presente abordagem analítica coincidem com os observados pelo método gráfico (Figura 4).

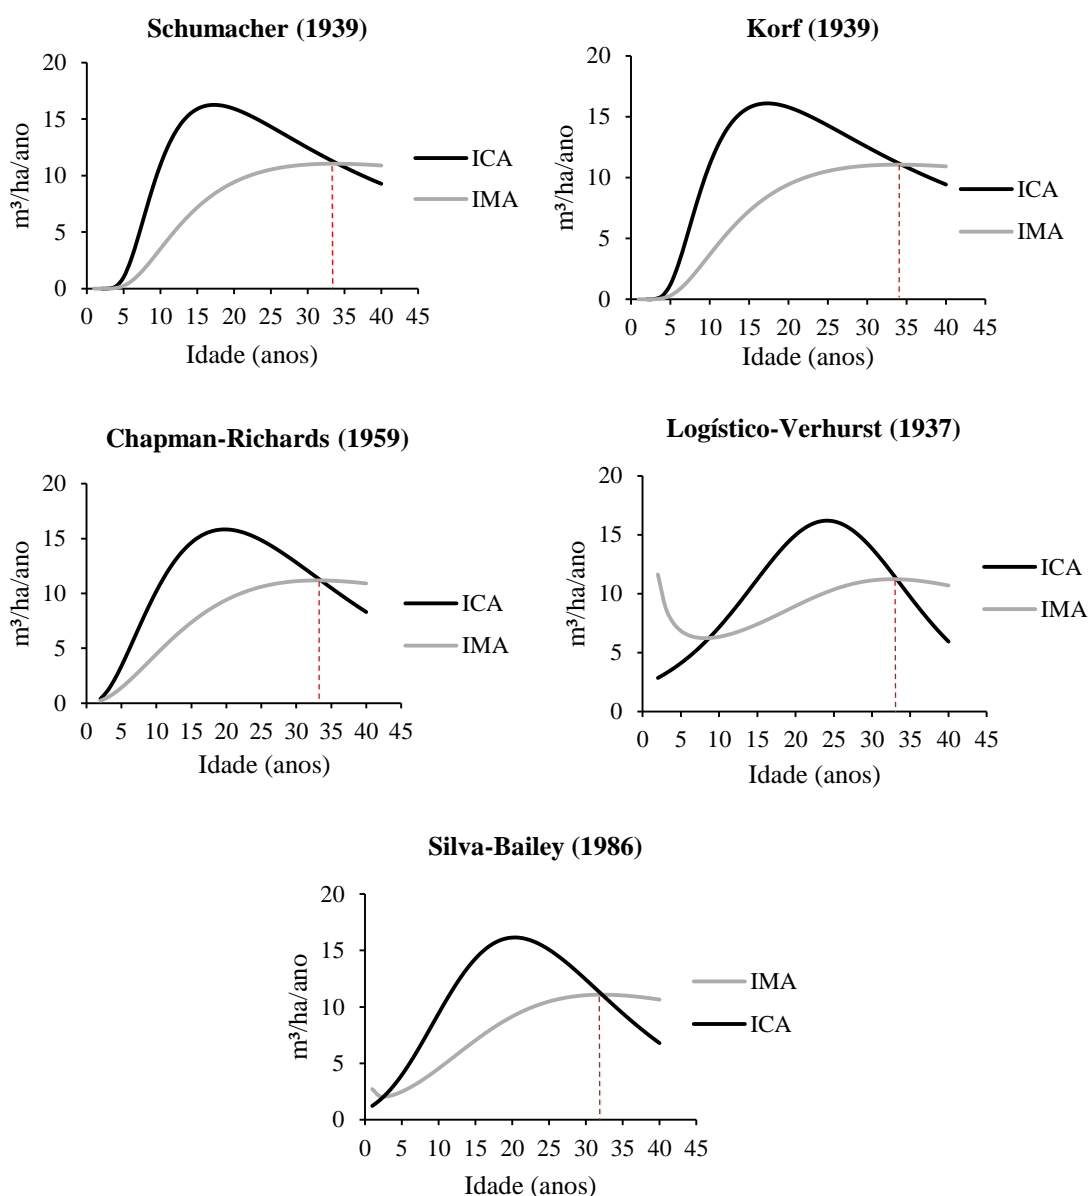


Figura 4 – Idades de Rotação Técnicas (IRT) para *Pinus caribaea* var. *caribaea*

3.2. Curvas de índice de sítio polimórficas para *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na empresa florestal Macurije

O ajuste da relação entre o índice de sítio S e as estimativas dos parâmetros β_0 e β_1 do modelo de Schumacher (1939) permitiu obter as equações 12 e 13.

$$b_0 = 6,115 + 1,108 * S + 0,0224 * S^2 \quad (R^2 = 75,64\%; S_{yx} = 10,84\%) \quad (12)$$

$$b_1 = -14,25 - 0,83 * S + 0,0365 * S^2 \quad (R^2 = 68,78\%; S_{yx} = 11,55\%) \quad (13)$$

Essas equações 12 e 13 substituídas no modelo inicial de Schumacher gerou a equação 14 para a construção das curvas de índice de sítio (Figura 5), bem como os limites de altura dominante em cada classe de sítio (Apêndice 1.4).

$$Hd = (6,115 + 1,108 * S + 0,0224 * S^2) e^{[(-14,25 - 0,83 * S + 0,0365 * S^2) * (\frac{1}{I_i})]} \quad (14)$$




Figura 5 - Curvas de índice de sítio polimórficas para *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf., Pinar del Rio, Cuba

Os resultados da análise de covariância (Apêndice 1.5), aplicada para comparar os crescimentos em altura dominante dos sítios, indicaram que a hipótese de similaridade entre as tendências de crescimento da altura dominante entre os sítios foi rejeitada a 95% de confiança.

O mesmo indica a não existência de paralelismo entre as curvas de índice de sítio e por consequência o polimorfismo das curvas.

3.3. Equações para a prognose da produção do *Pinus caribaea* var. *caribaea*

A Figura 6, conforme a Vanclay, Skovsgaard e Hansen (1995), apresenta a relação entre a idade e classes de sítio nas áreas amostradas pelas parcelas permanentes. A mesma indica que todas as classes de sítios e de idades estão representadas na base de dados, o que é incativo da representatividade dos dados com respeito as condições existentes nas áreas. Porém, a principal fraqueza perceptível na base de dados utilizada é a baixa representatividade das classes de sítios IV e V.




Figura 6 – Idade vs. índice de sítio nas parcelas permanentes de *Pinus caribaea* var. *caribaea* na empresa florestal integral Macurije.

Conforme os valores de RMSE (Tabela 8), os sistemas mais precisos na prognose de produção são os de Clutter (1963) e B.M.S. et al. (2006).

Os resultados do Teste de Kolmogorov-Smirnov (com correção de Lilliefors) indicaram que apenas os modelos de B.M.S. et al. (2006) na projeção do volume e da área basal e o modelo de Silva-Bailey (1986) atendeu ao pressuposto de normalidade (Apêndice 1.6).

Os resultados do Teste de Durbin-Watson indicaram que apenas os resíduos das equações de B.M.S et al. (2006) e Clutter e Jones estão livres de autocorrelação (Apêndice 1.7).

Em relação ao pressuposto de homocedasticidade, o Teste de White e a distribuição dos resíduos indicaram a satisfação desse pressuposto em todas as equações exceto na equação de Clutter para prognose de volume (Apêndice 1.8).

Tabela 8 – Estimativas dos parâmetros dos modelos de prognose da área basal e do volume de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf, em Pinar del Rio, Cuba

| MODELOS | VP. | Estimativas dos parâmetros | | | | R ² (%) | RMSE (%) | Sig. F | Bias |
|------------------------------|-------------------|----------------------------|-----------------------------|-----------|-----------|--------------------|----------|---------|-------|
| | | β_0 | β_1 | β_2 | β_3 | | | | |
| CLUTTER (1963) | $\text{Ln } Y_2$ | 0,831* | -31,752* | 0,031* | 1,329* | 97,45 | 0,139 | <0,0001 | -1,73 |
| | $\text{Ln } G_2$ | $\frac{\alpha_0}{5,712^*}$ | $\frac{\alpha_1}{-0,091^*}$ | | | 96,20 | 0,973 | <0,0001 | -0,65 |
| B.M.S. et al. (2006) | $\text{Ln } Y_2$ | β_0 | β_1 | β_2 | β_3 | R ² (%) | RMSE (%) | Sig. F | Bias |
| | $\text{Ln } dG_2$ | β_4 | β_5 | β_6 | β_7 | | | | |
| SILVA e BAILEY (1986) | V_2 | 1,181* | -27,352* | 0,004* | 1,291* | 98,97 | 0,085 | <0,0001 | -1,84 |
| CLUTTER e JONES (1980) | V_2 | -1,496* | 0,061* | -3,859* | 1,045* | 61,65 | 1,987 | <0,0001 | -0,03 |
| | | β_0 | β_1 | | | R ² (%) | RMSE (%) | Sig. F | Bias |
| | | -8,723* | -0,823* | | | 87,5 | 10,47 | <0,0001 | 3,70 |
| | | β_0 | β_1 | β_2 | | R ² (%) | RMSE (%) | Sig. F | Bias |
| | | 0,233* | 1,701* | 0,340* | | 98,2 | 10,01 | <0,0001 | 0,697 |

*Estimativa do parâmetro significativa a 99% de confiança pelo Teste *t*; VP: Variáveis Projetadas.

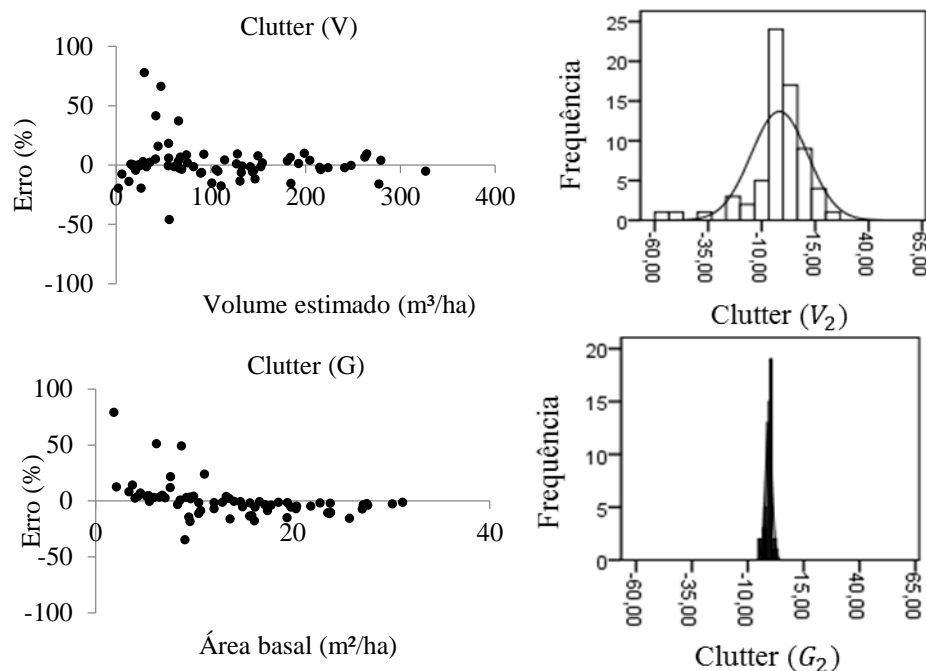
Nas equações de Clutter, o sinal negativo da estimativa do parâmetro β_1 indica a consistência das estimativas de volume. Por outro lado, o mesmo sinal negativo na estimativa do parâmetro α_1 ($\alpha_1 = -0,091$), na equação de projeção da área basal, indica que o efeito da capacidade produtiva (*S*) sobre a área basal foi inconsistente (Tabela 8) como encontrados por Azevedo et al. (2016). Neste caso, Campos e Leite (2017) recomendam que o *S* no termo $(1 - I_1/I_2)S$ seja substituído por $\text{Ln } G_1$, $(\text{Ln } G_1)^2$ ou Hd_1 . No presente estudo, a referida substituição não gerou nenhuma contribuição estatística pelo que se optou por eliminar este termo como recomendado pelos autores acima citados e adotado por Dias et al. (2005). A equação de prognose de área basal ficou então reduzida na seguinte forma:

$$\text{Ln } G_2 = \text{Ln } G_1 \left(\frac{I_1}{I_2} \right) + 3,923 \left(1 - \frac{I_1}{I_2} \right); R^2 = 95,55\%; RMSE = 1,057\%.$$

As mudanças mínimas entre os valores de R^2 (de 96,20% a 95,55%) e $RMSE$ (de 0,973% a 1,057%) de ambas as formas do modelo indicaram que a exclusão do termo não trouxe perda estatística significativa a equação inicial. Assim confirma também a distribuição de resíduos desta equação reduzida (Figura 7) que apresenta os mesmos problemas da equação inicial: uma superestimativa das áreas basais menores e uma subestimativa das maiores, coincidindo assim com as tendências observadas por Demolinari (2006) e Castro et al. (2013a).

Em relação as equações de B.M.S. et al. (2006), as estimativas dos parâmetros relacionados as variáveis índice de sítio (S_1) e área basal (G_1) foram positivas e as relacionadas ao inverso da idade (I_2^{-1}), negativas. Isto indica a consistência biológica das estimativas já que os sinais desses coeficientes garantem que tanto a área basal como o volume aumentem quando haja melhora na capacidade produtiva ou/e incremento na idade (Figura 8).

Nas comparações, as equações de B.M.S. et al. (2006) foram superiores as de Clutter (1963). A referida superioridade é evidente nas equações de projeção do volume pelos valores dos critérios tais como o R^2 (98,97% para a equação de B.M.S. et al. (2006) contra 97,45% para a de Clutter), o RMSE (0,085% contra 0,139%) e uma distribuição dos resíduos não tendenciosa (Figura 5) para o modelo de B.M.S. et al. (2006). Em relação a da projeção da área basal, embora o modelo de Clutter (1963) tenha apresentado indicadores estatísticos superiores (Tabela 8), a tendência de superestimar as menores áreas basais e de subestimar as maiores é evidente como apontado anteriormente. Essa tendência nas estimativas da área basal teve uma marcada influência na prognose do volume cuja precisão foi menor neste modelo como analisado acima. Conforme observado na prognose do volume, as prognoses dos incrementos em áreas basais com a equação de B.M.S. et al. (2006) não foram tendenciosas (Figura 7).



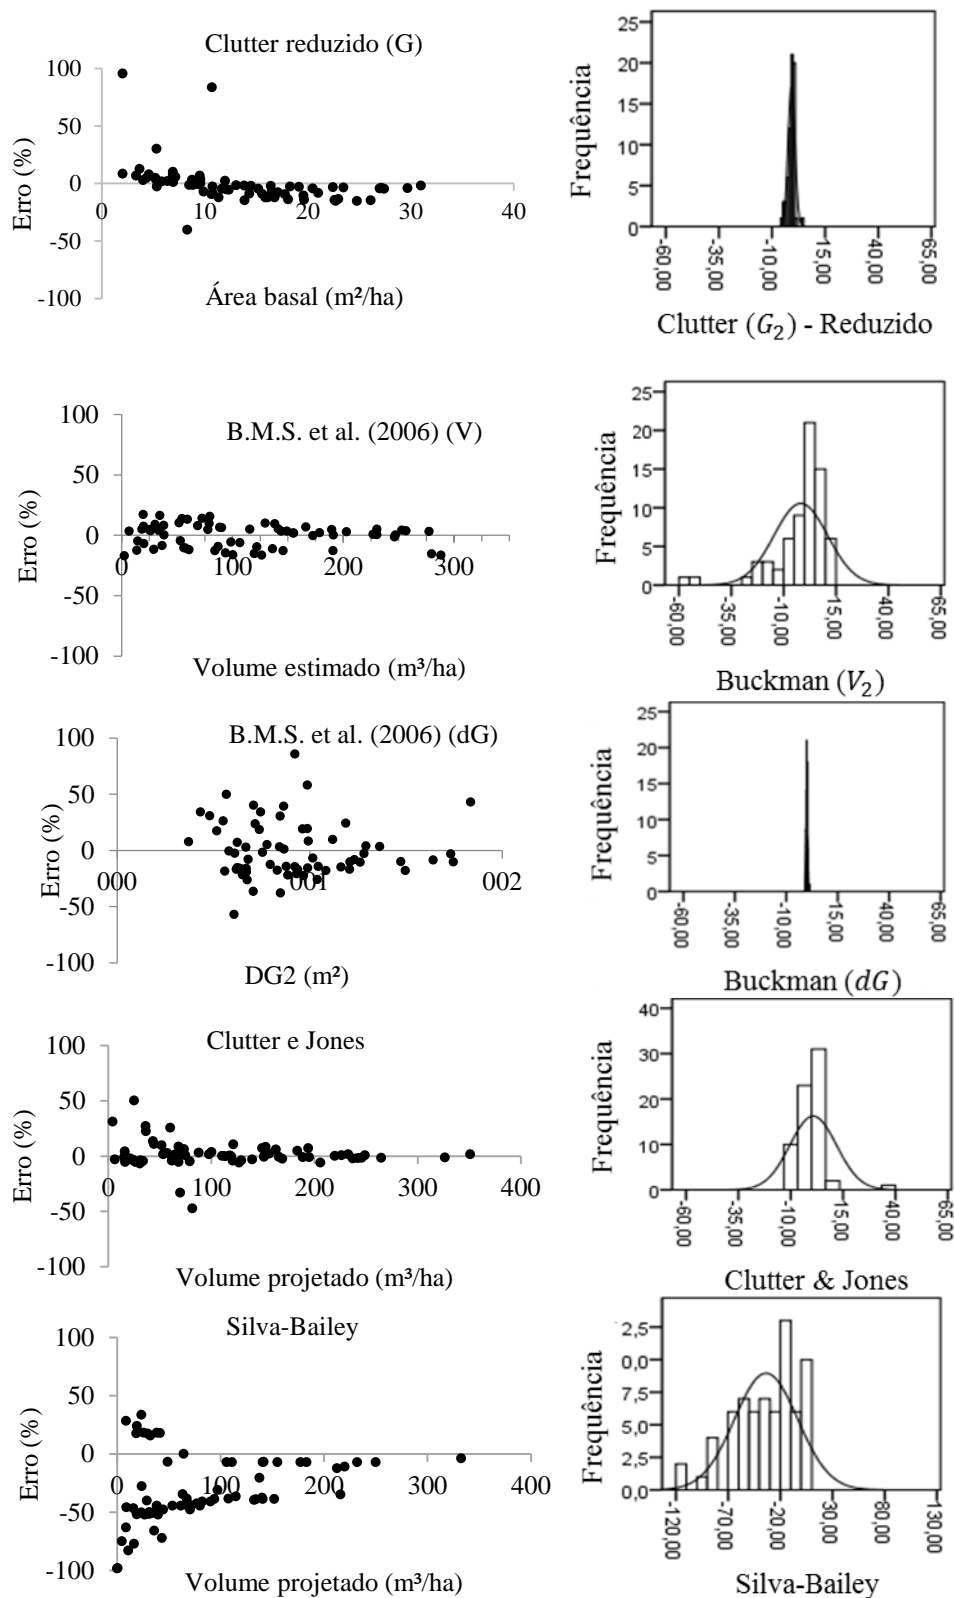


Figura 7 – Distribuição dos resíduos dos modelos de prognose para *P. caribaea* var. *caribaea*

Simulações de prognoses com as equações de B.M.S. et al. (2006) permitiram conferir a consistência biológica das mesmas, observando nas idades de rotação que variam entre 30 e 35 anos, produções variando entre $V_2 = 160,439 \text{ m}^3/\text{ha}$ ($G_2 = 22,46 \text{ m}^2/\text{ha}$) para o sítio SV e $V_2 =$

356,280 m³/ha (G₂=42,81 m²/ha) para o sítio SI (Figura 8), indicando assim proporcionalidade entre a produção, o índice de sítio e a idade. Estes resultados correspondem com Francis (1992) que apontou que a espécie costuma apresentar áreas basais entre 20 e 60 m²/ha.




Figura 8 – Projeção da produção de *P. caribaea* var. *caribaea* por capacidade produtiva na Empresa Florestal Integral Macurije, Pinar del Río, Cuba.

3.4. Modelos de prognose de sobrevivência futura em plantios de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

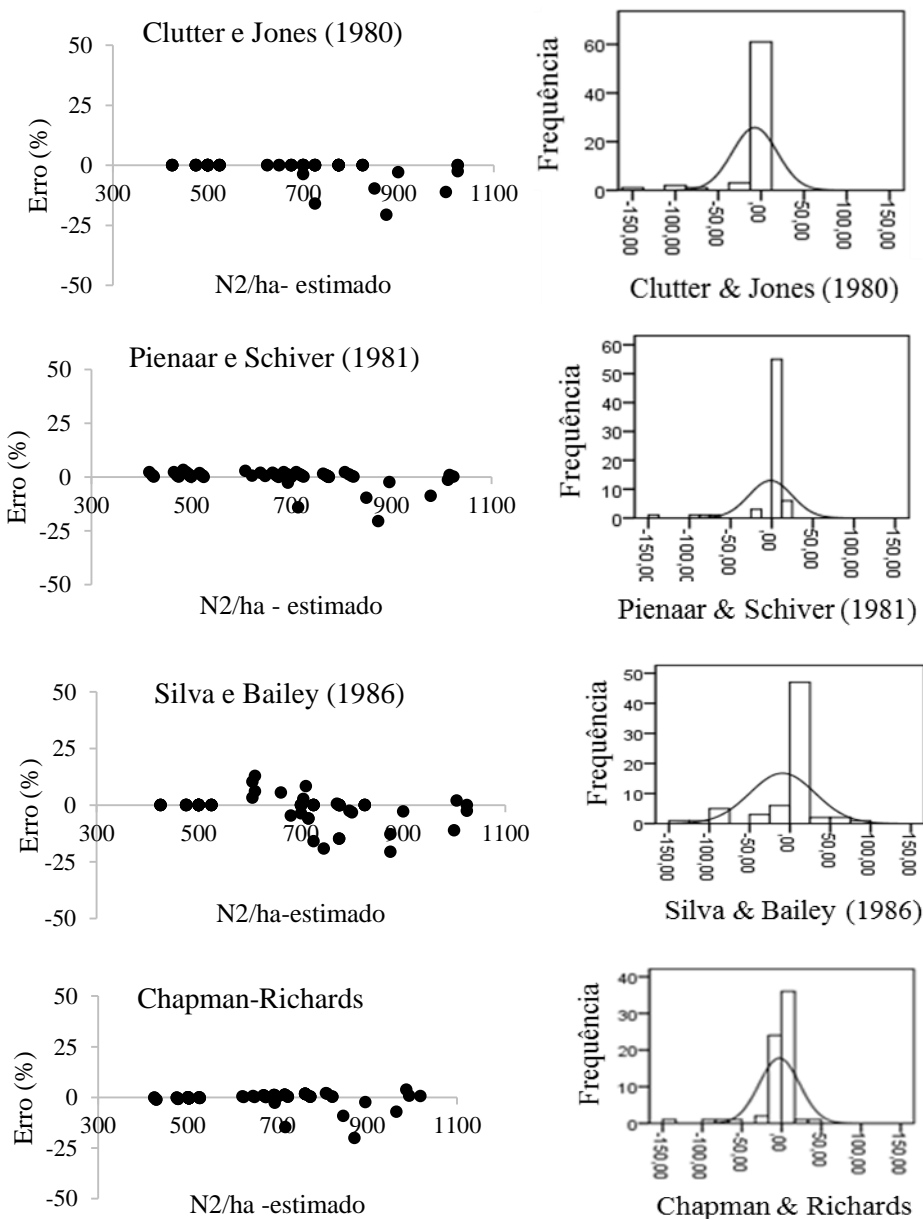
Os resultados dos ajustes dos modelos de sobrevivência (Tabela 9) indicam bons ajustes com R² maiores que 97% e RMSE menores que 5%. Porém, os valores dos Bias e a Figura 9 indicam que as projeções menos tendenciosas foram obtidas com a equação obtida do modelo de Pienaar e Shiver (1981). Conforme apontado por Silva (2015), os modelos de Silva e Bailey (1986) e Chapman-Richards (1959) apresentaram desempenhos semelhantes na prognose da mortalidade.

Tabela 9 – Estimativas dos parâmetros dos modelos de prognose da sobrevivência em plantios de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

| N ^o | MODELOS | Estimativas dos parâmetros | | | R ² (%) | RMSE (%) | Sig. F | Bias (%) |
|----------------|-------------------------|----------------------------|-----------|-----------|--------------------|----------|---------|----------|
| | | β_0 | β_1 | β_2 | | | | |
| 1 | Clutter e Jones (1980) | 9,491* | 8,762* | 7,144* | 97,33 | 4,212 | <0,0001 | -7,353 |
| 2 | Silva e Bailey (1986) | 0,063* | 394,290* | - | 97,55 | 3,939 | <0,0001 | -6,199 |
| 3 | Pienaar e Shiver (1981) | 1,27E-06* | 3,034* | - | 97,52 | 3,003 | <0,0001 | -1,500 |
| 4 | Chapman-Richards (1959) | -2,877* | -540,844* | - | 97,54 | 3,938 | <0,0001 | -6,201 |
| 5 | Weibull | -245939,49* | -35,366* | -10,578* | 97,54 | 3,968 | <0,0001 | -6,205 |

*Estimativa do parâmetro significativa a 99% de confiança pelo Teste t.

Os resultados dos testes de Kolmogorov-Smirnov indicaram que apenas os resíduos dos modelos de Silva e Bailey (1986) e Pienaar e Shiver (1981) se distribuíram normalmente (Apêndice 1.9). Em relação ao Teste de Durbin-Watson, os modelos que apresentaram resíduos livres de autocorrelação serial foram os de Clutter e Jones (1980), Silva e Bailey (1986) e Pienaar e Shiver (1981) (Apêndice 1.10). Os modelos de Chapman-Richards (1959) e de Weibull foram os únicos que violaram o pressuposto de homocedasticidade (Apêndice 1.11). O atendimento de todos os pressupostos no modelo pré-selecionado (Pienaar e Shiver) é indicativo da sua adequabilidade para a projeção da sobrevivência.






Figura 9 – Distribuição dos resíduos dos modelos de predição de sobrevivência do *Pinus caribaea* var. *caribaea* na empresa Macurije.

As prognoses de sobrevivência/mortalidade nos plantios de *Pinus caribaea* var. *caribaea* por meio da equação obtida do ajuste do modelo de Pienaar e Schiver são evidências da consistência e realismo biológico da equação obtida (Figura 10a).




Figura 10 – Prognose de sobrevivências (a) e taxas de mortalidade (b) para diferentes densidades iniciais em plantios de *Pinus caribaea* Morelet var. *caribaea*

É perceptível na Figura 10b, conforme esperado, o aumento da taxa de mortalidade regular com o aumento da idade dos povoamentos. As taxas de mortalidade variaram entre 0,12% aos 10 anos a 8,78% aos 40 anos, seguindo uma forma J (ou U), característica do fenômeno estudado (LORIMER; DAHIR; NORDHEIM, 2001; MALEKI; KIVISTE, 2016).

3.5. Redes Neurais Artificiais para prognose de produção e sobrevivência do *Pinus caribaea* var. *caribaea* Barr. & Golf.

No presente estudo, os resultados indicaram que as redes neurais do tipo Multilayer Perceptron (MLP), com a quantidade de neurônios na camada oculta variando entre 5 e 12, foram as mais eficientes tanto na predição como na prognose de produção e sobrevivência do *Pinus caribaea* var. *caribaea* na EFI Macurije, coincidindo com Lima et al. (2017) que obtiveram os mesmos resultados na prognose da produção em plantios de Eucaliptus. A

inclusão da variável dummy “UBPF” relacionada a localização das áreas, melhorou a capacidade preditiva das RNAs (Tabela 10).

3.5.1. Predição e prognose do crescimento e produção do *Pinus caribaea* var. *caribaea*

Na predição do volume, a inclusão das variáveis categóricas (classes de sítios e UBPFs) permitiram obter uma única arquitetura (RNA_P1) para a estimativa precisa do volume por sítio (Tabela 10 e Figura 11). O gráfico do Apêndice 1.15 indica o realismo biológico dessas estimativas caracterizadas por produtividades proporcionais ao sítio.

Tabela 10 – Resultados dos treinamentos das RNAs para predição e prognose de crescimento e produção em plantios de *Pinus caribaea* var. *caribaea*, Pinar Del Rio, Cuba

| Finalidade | V.I. | V. P. | RNAs | Arquitetura | Funções de ativação | | RMSE (%) | R ² (%) |
|------------------------------------|------------------------------|----------------|------------|-------------|---------------------|-------------|----------|--------------------|
| | | | | | Hidden | Output | | |
| Predição de volume | $I, S, UBPF$ | V | RNA_P1 | MLP 11-8-1 | Tanh | Logistic | 0,0460 | 97,96 |
| | | | RNA_P2 | MLP 11-7-1 | Tanh | Tanh | 0,0537 | 98,96 |
| Prognose de produção | I_1, I_2, S, G_1 | G ₂ | RNA_1 | MLP 8-9-1 | Tanh | Exponential | 0,566 | 99,21 |
| | | | RNA_2 | MLP 8-9-1 | Identity | Logistic | 0,990 | 99,14 |
| | $I_1, I_2, S, G_1, G_2, V_1$ | V ₂ | RNA_3 | MLP 10-8-1 | Tanh | Tanh | 1,599 | 98,10 |
| | | | RNA_4 | MLP 10-11-1 | Identity | Tanh | 1,656 | 98,66 |
| | $I_1, I_2, S, G_1, UBPF$ | G ₂ | RNA_5 | MLP 13-6-1 | Exponential | Logistic | 0,558 | 99,28 |
| | | | RNA_6 | MLP 13-8-1 | Exponential | Logistic | 0,604 | 99,16 |
| $I_1, I_2, S, G_1, G_2, V_1, UBPF$ | V ₂ | RNA_7 | MLP 15-9-1 | Exponential | Tanh | 0,422 | 98,78 | |
| | | RNA_8 | MLP 15-5-1 | Logistic | Exponential | 1,104 | 99,68 | |

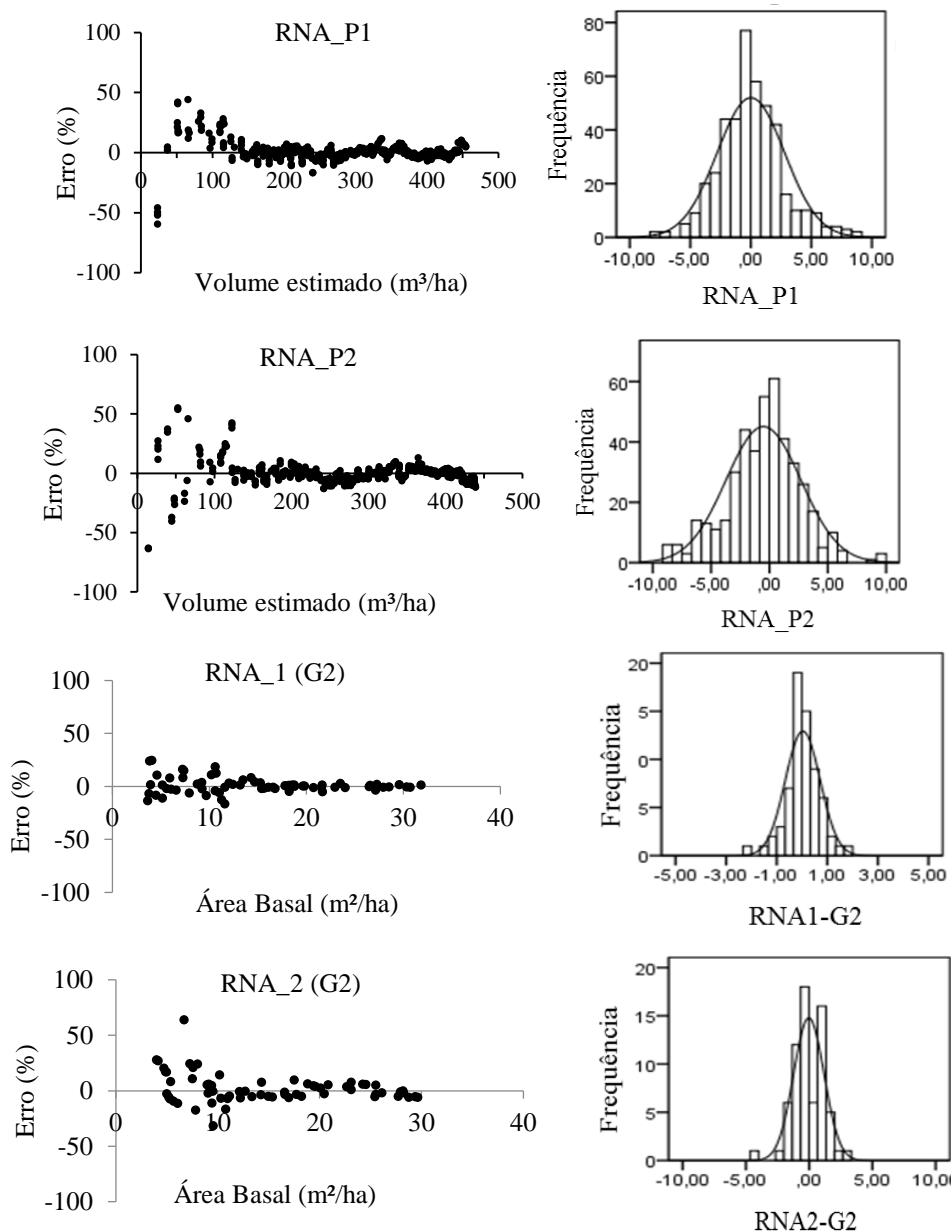
V.P.= variável estimada ou projetada; V= Volume estimada (m³/ha); G₂= Área Basal projetada (m²/ha); V₂= Volume projetado (m³/ha).

Na prognose do volume, os resultados do Teste *t-pareado* indicam que não existe diferença significativa nem entre os volumes estimados pelas duas abordagens (RNAs e regressão), nem entre essas estimativas e os volumes observados (Tabela 11). Este resultado evidenciado pelos valores dos critérios de avaliação das RNAs (Tabela 10) e os dos modelos de regressão (Tabela 9), juntamente com os gráficos de distribuição de resíduos individuais (Figuras 7 e 11) e comparativos (Figura 12), permitem concluir um comportamento similar entre ambas as abordagens na projeção do volume.

Em relação à prognose da área basal, o Teste *t-pareado* indica que não existe diferença significativa ($p = 0,738 > 0,05$) entre as estimativas das RNAs e os valores observados, mais sim entre as estimativas do modelo B.M.S. et al. (2006) e os valores observados (p -valor $< 0,05$); e entre as estimativas das RNAs e as do modelo de B.M.S. et al. (2006). Conclui-se então

uma superioridade das RNAs na prognose de Área Basal, confirmada pelo gráfico comparativo de distribuição de resíduos da Figura 12.

Os resultados anteriores indicam que a aqueabilidade ou não de uma abordagem ou técnica depende do estudo e da variável dependente a ser projetada. Então, não é prudente assumir a superioridade definitiva das RNAs na modelagem de determinado sistema. O desempenho de cada abordagem depende de inúmeros fatores e segundo Desmet (1996), se deve optar pela complementariedade dessas abordagens em vez do uso exclusivo das RNAs como a maioria das pesquisas comparativas tendem a sugerir.



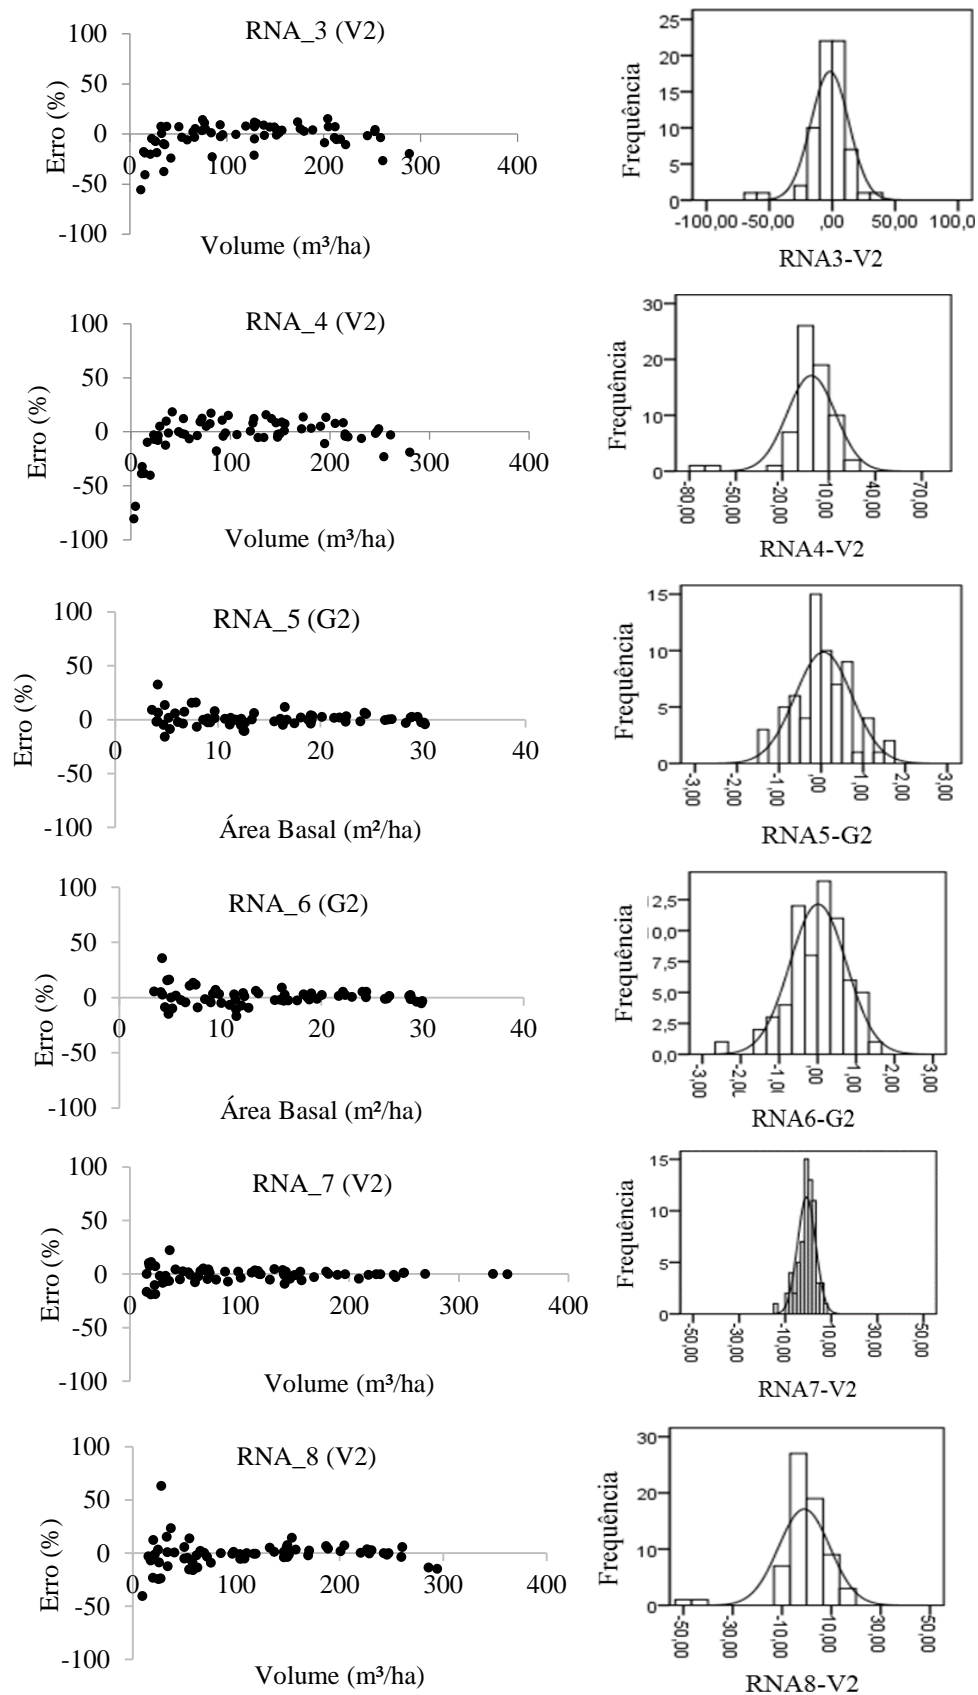


Figura 11– Distribuição dos resíduos das RNAs treinadas para predição e prognose da produção em povoamentos de *Pinus caribaea* var. *caribaea*

Em uma comparação multivariada (bivariada), a não significância do Teste T^2 de Hotteling entre as estimativas das RNAs e os valores observados e a existência de diferença significativa entre esses valores observados e os de B.M.S. et al. (2006) (Tabela 11) indica a superioridade das redes com respeito ao modelo B.M.S. et al. (2006). Os resultados indicam então estimativas mais precisas com as RNAs (Tabela 11 e Figura 12). Estes resultados satisfatórios proporcionados com as RNAs coincidem com os encontrados por Jensen, Qiu e Ji (1999), Porras (2007), Binoti et al. (2015) e Ashraf et al. (2013). Na maioria dos estudos realizados por esses autores, as RNAs apresentaram um desempenho similar ou superior ao das equações e sistemas de equações obtidas com a abordagem tradicional de regressão. Entre outras, essa superioridade pode ser atribuída à capacidade das RNAs de capturar relações não lineares existentes entre as variáveis que constituem a base de dados e a não exigência da normalidade como pressuposto para a significância dos resultados obtidos. Verificou-se então a asseveração de Dreyfus et al. (2004) segundo a qual as RNAs são capazes de proporcionar modelos mais precisos que os obtidos com outros métodos estatísticos com o mesmo tamanho amostral.

Tabela 11 – Testes *t-pareado* e T^2 de Hotteling entre os valores observados e estimados pelo modelo de B.M.S. et al. (2006) e as RNAs

| PARES | VOLUME | | ÁREA BASAL | | T^2 de Hotteling |
|-----------------------------|--------|---------------------|------------|---------------------|--|
| | t | Sig. | t | Sig. | |
| OBS vs RNA | 0,702 | 0,485 ^{ns} | -0,336 | 0,738 ^{ns} | $T^2 = 0,523482$; $F = 0,25976^{ns}$ |
| OBS vs B.M.S. et al. (2006) | 1,674 | 0,099 ^{ns} | -5,400 | 0,000* | $T^2 = 32,5870$; $F = 16,170^*$ |
| RNA vs B.M.S. et al. (2006) | 0,988 | 0,327 ^{ns} | -5,398 | 0,000* | $T^2 = 31,7410$; $F = 15,750^*$ |

*Diferença significativa a 99% de confiança; ns = Diferença não significativa a 99% de confiança; OBS = Valores observados.

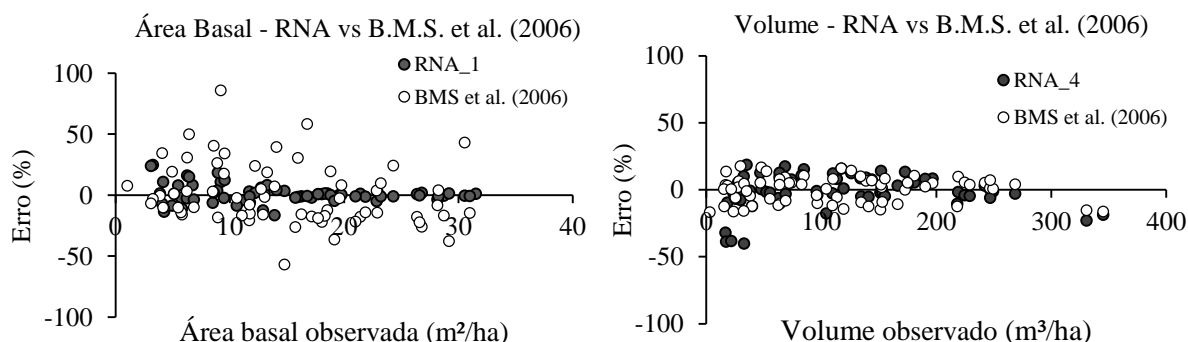


Figura 12 – Distribuição dos resíduos das RNAs e do sistema de equações de B.M.S. et al. (2006) na prognose do volume e da Área Basal em povoamentos de *P. caribaea* var. *caribaea*

3.5.2. Prognose de sobrevivência do *Pinus caribaea* var. *caribaea*

A utilização das RNAs para projeção da sobrevivência nos plantios de *P. caribaea* var. *caribaea* proporcionou resultados satisfatórios (Tabela 12). A RNA1, de arquitetura MLP 13-10-1, apresentou o melhor desempenho com projeções precisas e não tendenciosas (Figura 13).

Tabela 12 – Resultados dos treinamentos das RNAs para a projeção da sobrevivência em plantios de *P. caribaea* var. *caribaea*, Pinar Del Rio, Cuba

| RNAs | Arquitetura RNA | Funções de ativação | | AT | RMSE (%) | R ² (%) | Bias |
|-------|-----------------|---------------------|-------------|---------|----------|--------------------|--------|
| | | Hidden | Output | | | | |
| RNA_1 | MLP 13-10-1 | Tanh | Identity | BFGS 21 | 0,424 | 98,87 | 0,959 |
| RNA_2 | MLP 13-5-1 | Logistic | Exponential | BFGS 9 | 0,889 | 88,93 | 9,831 |
| RNA_3 | MLP 13-12-1 | Logistic | Tanh | BFGS 25 | 0,478 | 98,73 | 2,434 |
| RNA_4 | MLP 13-8-1 | Tanh | Logistic | BFGS 6 | 0,885 | 89,48 | 10,686 |

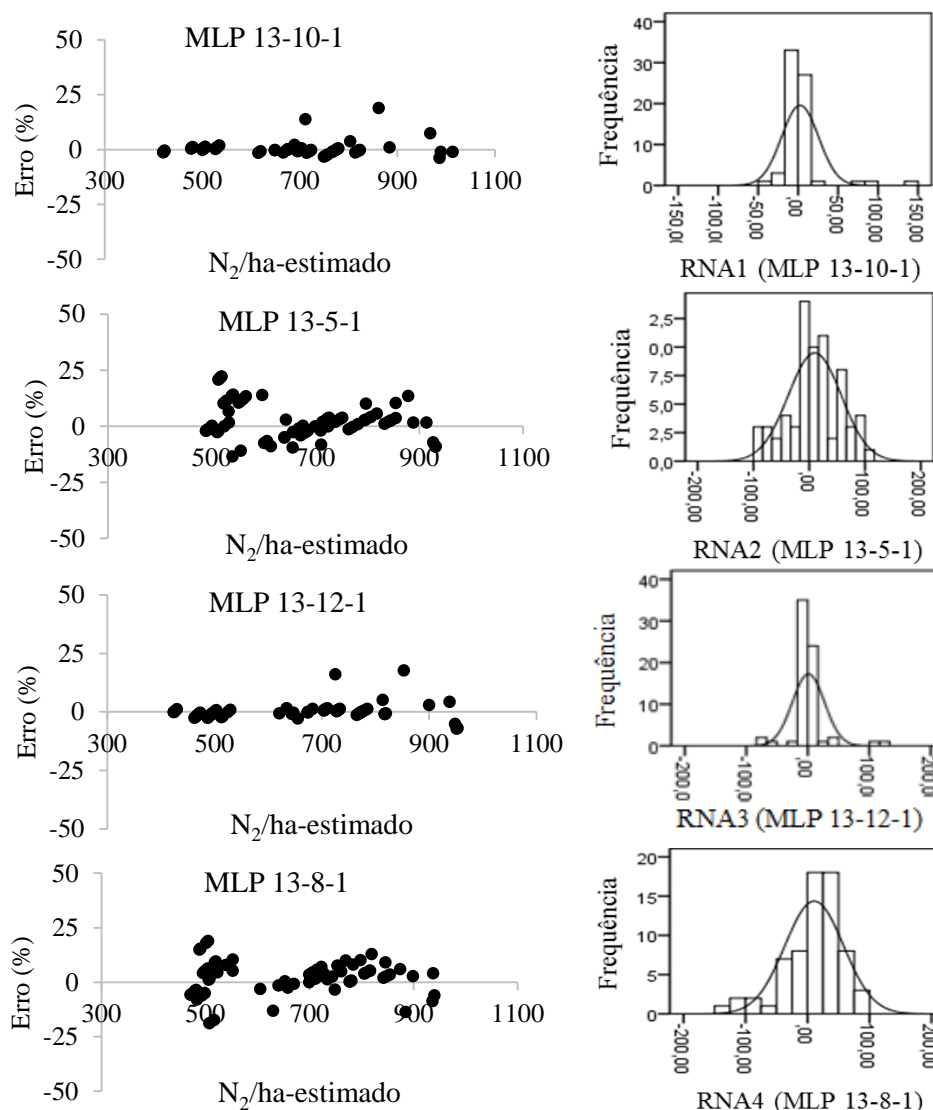


Figura 13– Distribuição dos resíduos das RNAs treinadas para prognose de sobrevivência em povoamentos de *Pinus caribaea* var. *caribaea*

O Teste *t-pareado* não foi significativo em nenhuma das comparações (Tabela 13 e Figura 14). Isso é indicativo de que tanto o modelo de Pienaar e Schiver como a RNA MLP 13-10-1 foram eficientes na projeção da sobrevivência. Porém, os valores dos critérios de avaliação de ambos os modelos, principalmente os do RMSE (Tabelas 9 e 12) indicaram uma maior precisão das RNAs.

Tabela 13 – Teste *t-pareado* entre as sobrevivências observadas e as estimadas pelo modelo de Pienaar e Schiver (1981) e a RNA MLP 13-10-1

| PARES | t | Sig. |
|----------------------------------|--------|---------------------|
| OBS vs MLP 13-10-1 | -0,870 | 0,388 ^{ns} |
| OBS vs Pienaar e Schiver | -0,474 | 0,637 ^{ns} |
| Pienaar e Schiver vs MLP 13-10-1 | -0,679 | 0,500 ^{ns} |

*Diferença significativa a 99% de confiança pelo Teste *t-pareado*; ns = Diferença não significativa a 99% de confiança pelo Teste *t-pareado*; OBS = Valores observados.




Figura 14 – Distribuição dos resíduos das RNAs e do modelo de Pienaar e Shiver (1981) na prognose da sobrevivência em povoamentos de *Pinus caribaea* var. *caribaea*

4. CONCLUSÕES

- A classificação da capacidade produtiva por meio de curvas de índice de sitio indentificou cinco classes de sitio com diferentes tendências de crescimento (Polimorfismo).
- Na predição de crescimento de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na Empresa Florestal Integral Macurije, os modelos de Schumacher (1939) e de Korf (1939) apresentaram as melhores aderências aos dados.
- As equações obtidas dos ajustes do modelo de Buckman modificado por Silva et al. (2006) foram as mais adequadas para a prognose da produção em plantações de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na Empresa Florestal Integral Macurije.
- Na prognose do volume, as RNAs e o modelo B.M.S. et al. (2006) tiveram um desempenho similar. Tal não foi o caso na prognose da área basal na qual as RNAs geraram estimativas mais precisas que as das equações do sistema de Buckman modificado por Silva et al. (2006).
- Na prognose da sobrevivência, a equação resultante do ajuste do modelo de Pienaar e Shiver (1981) foi a mais eficiente e apresentou um desempenho semelhante ao da RNA selecionada.
- A inclusão da variável *dummy* UBPF, relacionado a localização geográfica dos plantios, melhorou significativamente os desempenhos das RNAs tanto na predição de crescimento como na prognose de produção e sobrevivência.

5. REFERÊNCIAS

ALDANA, E.P.; PADILLA, T.G.; RODRÍGUEZ, P. J. Turno de corta eficiente para la obtención de mayores productos maderables en plantaciones de *Pinus caribaea* de la Empresa Forestal Integral Viñales. **Revista Forestal Baracoa**, v. 30, n. 1, p. 29-35, 2011.

ALDANA, E.; PUENTES, M.; ROMERO, J.L. **Proyecto de Ordenación EFI Macurije**. La Habana: Ministerio de la Agricultura; 2006. 101 p.

ALDER, D.; DRICHI, P.; ELUNGAT, D. **Yields of Eucalyptus and Caribbean Pine in Uganda**. Consultancy report, Uganda Forest Resources Management and Conservation Programme. Kampala, Uganda.2003.52p.

ASHRAF, M.I. et al. Integrating biophysical controls in forest growth and yield predictions with artificial intelligence technology. **Canadian Journal of Forest Research**, v. 43, n. 12, p. 1162–1171, 2013.

AZEVEDO, G.B. et al. Modelagem da produção em nível de povoamento e por distribuição diamétrica em plantios de eucalipto. **Sci. For.**, Piracicaba, v. 44, n. 110, p. 383-392, 2016.

BARRERO, M. H. et al. Determinación del Turno de Corta para *Pinus caribaea* var. *caribaea* en la Empresa Forestal Integral “Macurije”. **Floresta e Ambiente**, v. 18, n. 1, p. 109-116, 2011.

BAUM, E.B.; HAUSSLER, D. What net size gives valid generalization? **Neural Computation**, n.1, p. 151-160, 1989.

BIGLER, C.; BUGMANN, H. Growth-dependent tree mortality models based on tree rings. **Canadian Journal of Forest Research**, v. 33, n. 2, p. 210-221, 2003.

BINOTI, M.L.M.S. et al. Prognose em nível de povoamento de clones de eucalipto empregando Redes Neurais Artificiais. **Cerne**, v. 21, n. 1, p. 97-105, 2015.

BINOTI, M.L.M.S. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. 2012. 130 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa.

BISHOP, C. **Neural Networks for Pattern Recognition**. Oxford: University Press, 1995. 482p.

BOTKIN, D.B. **Forest Dynamics: An Ecological Model**. 1^{ra}ed. Oxford: University Press; 1993.

BUCKMAN, R. E. **Growth and yield of red pine in Minnesota.** Tech. Bull. 1272. Washington, DC: U.S. Department of Agriculture, 1962. 50 p.

BUONGIORNO, J.; GILLES, J. K. **Decision methods for forest resource management.** 1^{ra}ed. San Diego: Academic, 2003. 439p.

BURKHART, H.E.; TOMÉ, M. **Modeling forest trees and stands.** Springer, Dordrecht; The Netherlands, 2012. 132p.

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

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas.** 5^a ed. Editora UFV, Viçosa: UFV, 2017. 636 p.

CASTRO, R.V.O. et al. Crescimento e produção de plantios comerciais de eucalipto estimados por duas categorias de modelos. **Pesq. agropec. bras.** Brasília, v. 48, n. 3, p.287-295, 2013a.

CASTRO, R.V.O. et al. Individual Growth Model for *Eucalyptus* Stands in Brazil Using Artificial Neural Network. **Forestry**, v. 2013, p. 1-12, 2013b.

CLUTTER, J.L. Compatible growth and yield models for loblolly pine. **Forest Science**, v.9, n.3, p.354-371, 1963.

CLUTTER, J.L. et al. **Timber management: a quantitative approach.** 1sted. New York: John Wiley & Sons, 1983. 333p.

CLUTTER, J.L.; JONES, E.P. **Prediction of growth after thinning in old-field slash pine plantation.** Res. Pap. SE-217. Asheville, NC: U.S. Dept. of Agriculture, Forest Service, Southeastern Forest Experiment Station, 1980, 14 p.

DEMOLINARI, R. A. **Crescimento de povoamentos de eucalipto não desbastados.** 2006. 72f. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa.

DESMET, P. Comparaison de la prédictivité d'un réseau de neurones à rétropropagation avec celles des méthodes de régression linéaire, logistique et AID pour le calcul des scores en marketing. **Recherche et Applications en Marketing**, v.11, n.2, p. 17-27, 1996.

DIAS, A.N. et al. Emprego de um modelo de crescimento e produção em povoamentos desbastados de eucalipto. **Revista Árvore**, v. 29, n. 5, p. 731-739, 2005.

DRAPER, N.R.; SMITH, H. **Applied regression analysis**. 3rded. New York: New York Wiley; 1998. 736p.

DREYFUS, G. et al. **Réseaux de neurones, Méthodologie et applications**. 2nd ed. France: Collection Algorithmes. Eyrolles; 2004. 436p.

DURBIN, J.; WATSON, G. S. Testing for Serial Correlation in Least Squares Regression, II, **Biometrika**, v. 38, n.1-2, p. 159–179, 1951.

FRANCIS, J. K. **Pinus caribaea Morelet. Caribbean pine**. Ed. SO-ITF-SM-53. New Orleans, LA: U.S. Department of Agriculture, FS, Southern Forest Experiment Station; 1992. 10p.

GLOVER, G.R.; HOLL, J.N. A basal area ratio predictor of loblolly pine plantation mortality. **Forest Science**, v. 25, n. 2, p. 275-282, 1979.

GOLDSCHMIDT, R.; PASSOS, E. Data mining: um guia prático. Conceitos, técnicas, ferramentas, orientações e aplicações. Rio de Janeiro: Elsevier, 2005. 256 p.

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

GUAN, B. T.; GERTNER, G. Z. Modeling red pine tree survival with an artificial neural network. **Forest Science**, v. 37, n. 5, p. 1429–1440, 1991b.

GUAN, B. T.; GERTNER, G. Z. Using a parallel distributed processing system to model individual tree mortality. **Forest Science**, v. 37, n. 3, p. 871–885, 1991a.

HAMILTON, Jr., D. A. A logistic model of mortality in thinned and unthinned mixed conifer stands of Northern Idaho. **Forest Science**, v. 32, n. 4, p. 989–1000, 1986.

HERRERO, J. **Manejo del Pinus caribaea var caribaea en las zonas de Alturas de Pizarra, provincia de Pinar del Río**. La Habana: Ministerio de la Agricultura (Boletín de Reseñas, Grupo de publicaciones CIDA, n. 3.; Centro de Investigaciones Forestales), 1985. 60p.

HIGGINS, J. A. **Neural network growth and yield model for Nova Scotia forests**. 2011. 108f. Dissertação (Mestrado) – University of Dalhousie, Halifax, Nova Scotia.

HOTELLING, H. The Generalization of Student's Ratio. **The Annals of Mathematical Statistics**, v.2, n.3, p. 360–378, 1931.

JENSEN, J.R.; QIU, F.; JI, M. Predictive modelling of coniferous forest age using statistical and artificial neural network approaches applied to remote sensor data. **Int. j. remote sensing**, v.20, n.14, p.2805 – 2822, 1999.

KANGAS, A. On the prediction bias and variance in long-term growth projections. **Forest Ecology and Management**, v. 96, p. 207-216, 1997.

KING, S.L.; BENNETT, K.P.; LIST, S. Modelling non-catastrophic individual tree mortality using logistic regression, neural networks, and support vector methods. **Computers and Electronics in Agriculture**, n. 27, p. 401-406, 2000.

KOLMOGOROV, A.N. Sulla Determinazione Empirica Di Una Legge Di Distribuzione. **Giornale dell'Istituto Italiano Degli Attuari**, v. 4, p. 83–91, 1933.

KORF, V. A mathematical definition of stand volume growth law. **Lesnicka Prace**, v.18, p. 337-379, 1939.

LIMA, M.B.O. et al. Artificial neural networks in whole-stand level modeling of Eucalyptus plants. **African Journal of Agricultural Research**, v.12, n.7, pp.524-534, 2017.

LORIMER, C.G., DAHIR, S.E.; NORDHEIM, E.V. Tree mortality and longevity in mature and old-growth hemlockhardwood forests. **Journal of Ecology**, v. 89, pp.960-971, 2001.

MALEKI, K.; KIVISTE, A. Individual tree mortality of silver birch (*Betula pendula* Roth) in Estonia. **iForest**, v. 9, p. 643-651, 2016.

MARTINS, E.R. et al. Configuração de redes neurais artificiais para estimação do afilamento do fuste de árvores de eucalipto. **Revista Brasileira de Ciências Agrárias**, v.11, n.1, p.33-38, 2016.

ÖZÇELİK, R.; DIAMANTOPOULOU, M.J.; EKER, M.; GURLEVIK, N. Artificial Neural Network Models: An Alternative Approach for Reliable Aboveground Pine Tree Biomass Prediction. **Forest Science**, v. 63, n. 1, p. 1 – 12, 2017.

ÖZÇELİK, R.; DIAMANTOPOULOU, M.J.; BROOKS, J.R. 2014. The use of tree crown variables in over-bark diameter and volume prediction models. **iForest**, v. 7, n. 3, p. 132-139, 2014.

PARDOE, I. **Applied regression modeling**. 2nded. New Jersey: John Wiley & Sons; 2012. 346p.

PERAZA, E.O. **Turno financiero y técnicos forestales para *Pinus caribaea* Morelet var. *caribaea* Barrett & Golfari en sitios de la provincia de Pinar Del Río.** 2011. 54f. Tesis (Maestría en Ciencias Forestales) - Universidad de Pinar del Río “Hermanos Saiz Montes de Oca”, Pinar Del Rio, Cuba.

PIENAAR, L. V.; SHIVER, B. D. Survival functions for site prepared slash pine plantations in the flat woods of Georgia Northern Florida. **Southern Journal Forestry**, v.5, n.2, p.59-62, 1981.

PORRAS, J. C. Growth Evaluation of a Conifer Forest (*Pinus Cooperi* Blanco) using a Neural Net Backpropagation Trained with Distance Independent Competition Measures. **Computación y Sistemas**, v. 10, n. 4, p. 415-427, 2007.

PRODAN, M. et al. **Mensura Forestal.** 1st ed. San José, C.R: Instituto Internacional de Cooperación para la Agricultura (IICA), 1997.586p.

RAWLINGS, J.O.; PANTULA, S.G.; DICKEY, D.A. Applied Regression Analysis: A Research Tool. 2nd ed. New York: Springer; 1998.671p.

REZENDE, A.V. et al. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado sensu stricto em Brasília, DF. **Scientia Forestalis**, n. 71, p. 65-76, 2006.

ROCHA, M.B. et al. Volumetria de Genipa americana em plantio homogêneo no Sudoeste da Bahia. **Pesq. flor. bras.**, Colombo, v. 35, n. 84, p. 419-425, 2015.

RODRÍGUEZ, M.P.R. **Desempeño de los índices de Nesterov, Fórmula de Monte Alegre y Fórmula de Monte Alegre alterada en la Empresa Forestal Macurije, Pinar del Río, Cuba.** 2012. 90f. Tese (Pós-doutorado em Engenharia Florestal) – Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba.

SANQUETTA, C.R. **Predição da sobrevivência em reflorestamentos de *Pinus elliottii* Engelm.** 1990. 97f. Dissertação (Mestrado em Engenharia Florestal) – Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba.

SCHUMACHER, F.X. A new growth curve and its applications to timber-yield studies. **Journal Forestry**, v. 37, p. 819-820, 1939.

SILVA, A.L.; CAMPOS, J.C.C.; LEITE, H.G.; SOUZA, A.L.; LOPES, P.F. Growth and yield prediction using the modified Buckman model. **R. Árvore**, Viçosa-MG, v.30, n.5, p.787-793, 2006.

SILVA, J.A.A. da. Conceitos e princípios básicos de modelagem matemática em ciências florestais. **Anais da Academia Pernambucana de Ciência Agrônômica**, Recife, v. 11/12, p.195-215, 2015.

SILVA, J.A.A. da. **Dynamics of stand structure in fertilized slash pine plantations**. 1986. 136f. Dissertation (Doctor of Philosophy) - University of Georgia, Athens.

SMIRNOV, N. Table for Estimating the Goodness of Fit of Empirical Distributions. **The Annals of Mathematical Statistics**, v.19, n.2, p. 279–81, 1948.

SPATHELF, P.; NUTTO, L. **Modelagem aplicada ao crescimento florestal**. Santa Maria: UFSM; 2000. 70p.

VALENÇA, M. **Fundamentos das redes neurais: Exemplos em Java**. 2ª. Edição, Revisado e ampliado. Olinda-PE: Livro Rápido, 2010. 386p.

VANCLAY, J. K. Mortality functions for north Queensland rain forests. **Journal of Tropical Forest Science**, Kuala, v. 4, n. 1, p. 15-36, 1991.

VANCLAY, J.K.; SKOVSGAARD, J.P.; HANSEN, C.P. Assessing the quality of permanent sample plot databases for growth modelling in forest plantations. **Forest Ecology and Management**, v. 71, n. 3, pp. 177-186, 1995.

VARONA J.C.: **Fomento de plantaciones de pino**. Editorial Pueblo y Educación. Ciudad de La Habana. 1982.101p.

WHITE, H.A. Heterocedasticity-Consistent Covariance Matrix Estimator and a Direct Test for Heterocedasticity. **Econometrica**, v. 48, n. 4, p. 817-838, 1980.

CAPÍTULO II

ABORDAGEM MULTIVARIADA EM EXPERIMENTO DE COLHEITA DA
MADEIRA EM PLANTIOS DE *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, julho 2017. **Abordagem multivariada em experimento de colheita da madeira em plantios de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.** Orientador: Prof. Dr. José Antônio Aleixo da Silva. Co-orientadores: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira e Prof. Dr. Daniel Alberto Álvarez Lazo.

RESUMO

O presente trabalho foi realizado com o objetivo de avaliar, técnica e economicamente, a extração e transporte da madeira em florestas plantadas de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. da Empresa Florestal Integral Macurije – Cuba. As avaliações foram realizadas por meio de estudos de tempos e movimentos tendo como critérios a “produtividade” e o “custo” da execução das diferentes operações. Esses critérios foram utilizados para avaliar os desempenhos dos caminhões KAMAZ-4310, URAL-4320 e KRAZ-257 durante o transporte da madeira e do carregador frontal VOLVO BM L90B durante o carregamento e descarregamento dos caminhões. Em relação a avaliação dos desempenhos dos skidders (John Deere 548E e J-80A) e da junta de bois durante a extração de madeira realizada em dois sistemas de colheita (*tora curta* e *tora longa*), foram realizados experimentos fatoriais (3x3x2) univariados e multivariados (variáveis: custo e/ou produtividade) seguindo um delineamento casualizado em blocos (DCB), sendo os fatores: “*maquinaria*” e “*declividade*” com três níveis e “*sistema de colheita*” com dois níveis. Foram obtidos os custos e as produtividades atualizadas para as respectivas maquinarias avaliadas. Foram evidenciadas no trabalho, a viabilidade e utilidade da abordagem multivariada na avaliação da colheita florestal. Os resultados indicaram que é mais viável a extração de madeira com o sistema de *tora longa* e preferencialmente em povoamentos de 32 anos. A interação dos fatores *maquinaria* e *declividade* influenciou significativamente a variação do conjunto *custo-produtividade*. O skidder John Deere 548E por ser mais econômico e mais produtivo que o skidder J-80A, foi considerado o mais viável para a empresa florestal Macurije. O carregador frontal VOLVO BM L90B apresentou desempenhos satisfatórios no carregamento e descarregamento de caminhões não autocarregáveis. Em relação ao transporte, o caminhão KAMAZ-4310 resultou ser a opção mais viável.

Palavras-chave: Colheita florestal, custo, produtividade, experimento fatorial multivariado.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, July 2017.

Multivariate approach in wood harvesting experiment in plantations of *Pinus caribaea*

Morelet var. *caribaea* Barr. & Golf. Adviser: Prof. PhD. José Antônio Aleixo da Silva. Co-

advisers: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira and Prof. Dr. Daniel Alberto Álvarez Lazo.

ABSTRACT

The present work was carried out with the objective of evaluating, technically and economically, wood extraction and transport in forest plantations of *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. of Macurije Integral Forest Company - Cuba. The evaluations were made through studies of times and movements having as evaluation criteria "productivity" and "cost" of the execution of different operations. These criteria were used to evaluate the performances of the trucks KAMAZ-4310, URAL-4320 and KRAZ-257 during wood transport and the front loader VOLVO BM L90B during loading and unloading of the trucks. In order to evaluate the performance of the skidders (John Deere 548th and J-80A) and the oxen during wood extraction carried out on two harvest systems (cut to length and tree length), it performed a univariate and multivariate factorial experiment (3x3x2) (variables: cost and/or productivity) following a design randomized in blocks (DCB), with the following factors: "machinery" and "declivity" with three levels and "harvesting system" with two levels. Updated costs and productivities were obtained for the respective machineries evaluated. The feasibility and usefulness of the multivariate approach in the evaluation of forest harvesting was evidenced. The results indicated that timber extraction is more viable with the *tree length* harvest systems and preferably in stands of 32 years. The interaction of machinery and declivity factors significantly influenced the change of the whole cost-productivity. The skidder John Deere 548E, being more economical and more productive than the skidder J-80A, was considered the most viable for the Macurije forest company. The front loader VOLVO BM L90B presented satisfactory performances in the loading and unloading of non-loadable trucks. In relation to transport, KAMAZ-4310 truck proved to be the most viable option.

Keywords: Forest harvesting, cost, productivity, multivariate factorial experiment.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, juillet 2017. **Approche multivariée dans une expérience de récolte du bois dans les plantations de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.** Directeur de Thèse: Prof. Dr. José Antônio Aleixo da Silva. Co-directeurs de Thèse: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira et Prof. Dr. Daniel Alberto Álvarez Lazo.

RÉSUMÉ

La présente étude a été réalisée pour évaluer techniquement et économiquement, l'extraction et le transport du bois dans les plantations de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. de l'entreprise forestière Macurije – Cuba. Les évaluations ont été effectuées par des études de temps et mouvements ayant comme critères « productivité » et « coût » de l'exécution des différentes opérations. Ces critères ont été utilisés pour évaluer les performances des camions KAMAZ-4310, URAL-4320 et KRAZ-257 pendant le transport du bois et le chargeur frontal VOLVO BM L90B pendant le chargement et le déchargement des camions. En ce qui concerne l'évaluation de la performance des débusqueuses (John Deere 548E et J-80A) et des bœufs durant l'extraction du bois menée sur deux systèmes d'exploitation (bois tronçonnés et troncs entiers), des expériences factorielles (3x3x2) univariées et multivariées (variables: coûts et de productivités) suivant un dispositif expérimental en blocs complets randomisés (DBCR) ont été exécutées. Les facteurs sont: « machines » et « déclivité » avec trois niveaux et « système de récolte » avec deux niveaux. Les coûts et productivités actualisés des différentes machines évaluées ont été obtenus. Il a été mis en évidence dans la recherche, la faisabilité et l'utilité de l'approche multivariée dans l'évaluation de l'exploitation forestière. Les résultats indiquent que l'extraction du bois avec le système de récolte « troncs entiers » et de préférence dans les peuplements âgés de 32 ans est plus viable. L'interaction des facteurs « machinerie » et « déclivité » a considérablement influencée la variation de l'ensemble productivités-coûts. La débusqueuse John Deere 548E, étant plus économique et plus productive que la débusqueuse J-80A, a été considérée comme l'option la plus viable pour l'entreprise forestière Macurije. Le chargeur frontal VOLVO BM L90B a montré des performances satisfaisantes dans le chargement et déchargement des camions non autochargeables. En ce qui concerne le transport du bois, le camion KAMAZ-4310 s'est avéré être l'option la plus viable.

Mots-clés: Exploitation forestière, coût, productivité, expérience factorielle multivariée.

1. INTRODUÇÃO

A colheita florestal, apesar de ser uma das últimas atividades do processo de produção florestal, é a atividade mais custosa da madeira posta na fábrica (SANTOS et al., 2016). Esta atividade, juntamente com a de transporte, representa mais de 50% do custo da madeira posta na indústria (CÁNDANO, 2003; MACHADO, 2014). A elevação destes custos frente a desafios trazidos pelas pressões de redução de custos de produção e melhoria da produtividade e qualidade, segundo Alencar (2012), levam as empresas a buscarem, continuamente, alternativas de otimização dos seus processos produtivos.

A realização dos últimos estudos sobre a extração e transporte de madeira na empresa Macurije, objeto do presente estudo, remontam aos realizados por Cándano (1998). Em quase 20 anos, muitas mudanças foram registradas nos cenários produtivos preexistentes na empresa, principalmente na maquinaria de colheita e na experiência laboral dos operadores.

Assim, para se obter maior rentabilidade no processo produtivo da empresa, mais especificamente nas atividades de colheita florestal, estudos recentes para um melhor controle e busca de alternativas de minimização dos custos são necessários. Estudos das capacidades e características técnicas e econômicas das máquinas de extração de madeira tem que ser realizados para as condições específicas nas quais serão utilizadas (PEREIRA et al., 2015), já que numerosos são os fatores que influem nas produtividades e custos operacionais de colheita florestal. Dentre desses fatores pode-se citar: fatores florestais principalmente representados pelas dimensões das toras (MACHADO; LOPES, 2000), fatores relacionados a área como a declividade e fatores mecânicos definidos pelo tipo de maquinaria (SANT'ANNA, 1992).

Os skidders, uma das principais classes de maquinaria utilizada na extração da madeira, são definidos por Lopes et al. (2007) como tratores florestais articulados que realizam o arraste das árvores da área de corte até o pátio intermediário e cujo material rodante pode ser de pneus, semi-esteiras ou esteiras. A mobilidade, aspecto que define a produtividade e custo dos skidders, depende da sua performance na tração da madeira que é influenciado por sua vez pelas condições do terreno, principalmente, pela declividade (DUKA, et al., 2016). A forte relação existente entre esses fatores e sua significativa influência no desempenho das máquinas tem levado ao uso de arranjos fatoriais nos experimentos de colheita florestal para estudar as possíveis interações existentes entre os mesmos, porém, as abordagens têm sido maiormente univariadas considerando como critérios o custo ou a produtividade de forma isolada.

A colheita florestal conta hoje com equipamentos altamente produtivos e multifuncionais, porém cada vez mais pesados (SZYMCZAK, 2014). O intenso tráfego desses

equipamentos dentro dos povoamentos florestais vem causando problemas ambientais, entre eles a compactação do solo (SAMPIETRO; LOPES, 2011). A recorrência desses problemas ambientais causou a reintrodução da tração animal nas atividades de colheita florestal de países altamente industrializados, principalmente, na exploração de florestas nativas para atenuar danos que podem comprometer o desenvolvimento futuro da floresta.

Além de razões ambientais, a tração animal é também utilizada em países menos industrializados por outras razões como a da falta de rede rodoviária florestal, falta de equipamentos mecanizados, terreno muito inclinado, pequenas áreas de colheita e baixo volume de colheita (EZZATI; NAJAFI; DURSTON, 2011). Os principais animais utilizados são: bois, burros, mulas, cavalos, elefantes, lamas e iaques (DYKSTRA; HEINRICH, 1996).

Em Cuba, como na empresa florestal integral Macurije, os animais utilizados são os bois. Os principais motivos da utilização das juntas de bois são os baixos custos de exploração e a significativa melhora que sua combinação com skidders proporciona a produtividade de extração de madeira (CÁNDANO, 1998).

Dessa forma, o problema de pesquisa abordado no presente estudo está relacionado com a necessidade de realização de estudos específicos do desempenho das máquinas, bem como a divergência e/ou ambiguidade dos resultados desses estudos atribuída ao uso isolado dos critérios de avaliação. Supondo-se que uma avaliação do desempenho dos meios de colheita florestal baseada simultaneamente no custo e na produtividade proporcionaria resultados mais acurados que auxiliem nas tomadas de decisões sem fazer apelo a muita subjetividade, o objetivo geral desta pesquisa foi avaliar tecnicamente e economicamente, por meio de experimentos fatoriais univariados e multivariados, os desempenhos das máquinas de extração e transporte de madeira em diferentes cenários identificados nas florestas plantadas de *Pinus caribaea* var. *caribaea* da empresa florestal integral Macurije, Pinar del Río, Cuba.

Os objetivos específicos para alcançar o objetivo geral supracitado foram:

- Estimar os custos e as produtividades de todas as máquinas envolvidas nas operações de extração e transporte de madeira na EFI Macurije;
- Avaliar a influência dos fatores “maquinaria”, “declividade” e “sistema de colheita” e suas interações na produtividade e no custo de extração de madeira de forma isolada;
- Avaliar em diferentes idades de corte, a influência dos fatores “maquinaria”, “declividade” e “sistema de colheita” e suas interações no conjunto produtividade-custo de extração de madeira.

2. MATERIAIS E MÉTODOS

2.1. Caracterização da área de estudo

A presente pesquisa foi realizada em áreas montanhosas de plantações de *P. caribaea* var. *caribaea* da unidade básica de produção florestal (UBPF) “Las Cañas” pertencente a unidade silvícola Mantuada Empresa Florestal Macurije, localizada aproximadamente entre as coordenadas geográficas 22° 06’ a 22° 42’ latitude Norte e 83° 48’ a 84° 23’ longitude oeste na região mais ocidental da província de Pinar del Rio, Cuba (Figura 1). A UBPF tem uma superfície de 9871,0 ha distribuída em 34 lotes e 722 talhões. Os talhões envolvidos na pesquisa estão descritos na Tabela 1.




Figura 1 – Localização da unidade de produção florestal “Las Cañas” da EFI Macurije

Algumas características dos povoamentos nos quais foram realizados os experimentos são resumidas na Tabela 1.

Tabela 1 – Características dos plantios de *P. caribaea* na empresa Macurije, Cuba

| Número do lote | 80 | | 81 | 88 | | |
|------------------------|--------|--------|--------|--------|--------|--------|
| Número do talhão | 18 | 20 | 06 | 09 | 12 | 18 |
| Áreas (ha) | 7,67 | 6,00 | 28,7 | 27,2 | 19,8 | 16,4 |
| Declividade (%) | 05 | 04 | 17 | 12 | 11 | 24 |
| Idade (anos) | 21,00 | 32,00 | 32,00 | 21,00 | 32,00 | 21,00 |
| DAP _m (cm) | 20,83 | 21,80 | 22,10 | 20,10 | 22,40 | 20,95 |
| H _m (m) | 15,5 | 16,00 | 17,21 | 15,70 | 16,00 | 17,00 |
| Densidade (N/ha) | 959 | 1002 | 999 | 989 | 1099 | 993 |
| G (m ² /ha) | 32,66 | 37,38 | 38,32 | 31,36 | 43,28 | 34,21 |
| V (m ³ /ha) | 237,95 | 281,10 | 309,97 | 231,45 | 325,52 | 273,36 |

H_m = Altura média, DAP_m = média dos diâmetros a 1.30, G = Área Basal do talhão.

O clima, segundo a classificação de Köppen é Aw e a precipitação média anual é de 1484,53 mm, com temperatura média anual de 24,5 °C e umidade relativa média anual de 81% (ALDANA; PUENTES; ROMERO, 2006).

O climograma de Walter- Lieth e o diagrama de balanço hídrico (para uma capacidade de campo de 100 mm/m) foram elaborados por meio do software PROCLI versão 2.0 (LAGO, 2013) com dados de precipitação e temperatura dos últimos dez anos (2002-2012) fornecidos pela estação meteorológica de Isabel Rubio (Pinar del Río). O climograma indica uma precipitação média anual de 1520,1 mm, uma temperatura média de 26,6°C e três temporadas: uma chuvosa marcada pelos meses de fevereiro, março, início de maio e início de novembro; uma de abundante chuva que começa do final do mês de maio até o mês de outubro e uma temporada seca representada pelos meses de dezembro, janeiro, março e abril (Figura 2a).

O diagrama de balanço hídrico (Figura 2b) indica duas temporadas: uma temporada de déficit de água que vai de janeiro ao início do mês de agosto e do final de novembro a dezembro. Essa temporada pode ser considerada favorável para intensas atividades de colheita florestal já que a alta umidade, que é um dos principais fatores que reduzem a produtividade das máquinas e aumenta a compactação do solo (DA SILVA LOPES et al. 2011; SZYMCZAK et al. 2014), é minimizada nesse período. A segunda temporada correspondente a de abundante chuva delimitada no climograma (Figura 2a) e caracterizada por um excesso de umidade, vai do final do mês de agosto ao início do mês de novembro.

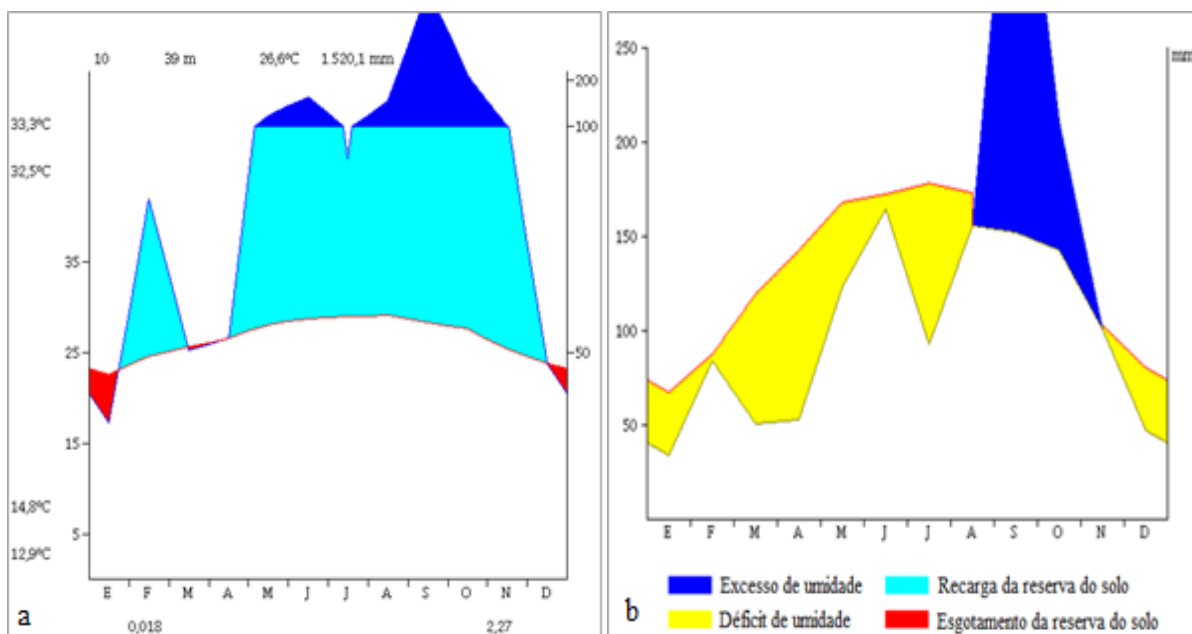


Figura 2 – Climograma de Walter-Lieth para o período 2002-2012 (a) e diagrama de balanço hídrico para uma capacidade de campo de 100 mm/m (b).

2.2. Características das máquinas de extração e transporte de madeira avaliadas

As características dos meios utilizados nas diferentes fases da colheita são:

SKIDDER JOHN DEERE 548E: De origem americana, possui peso de 10,34 ton., motor de potência 121HP, velocidade permitida entre 2,4 a 26,7 km/h e rodados de pneumáticos (Figura 3a).

SKIDDER HARBIN SONGJIANG J-80A: De origem chinesa, possui peso de 8,25 ton., velocidades permissíveis entre 2,22 e 32,60 km/h, força de tração máxima de 61,5 KN, motor de potência 73.5KW (110HP) e rodados de pneumáticos (Figura 3b).

JUNTA DE BOIS: Com um jugo para seu controle e cabos para amarre da madeira como aditamentos, tem uma idade média de 7 anos, um peso médio de 538 kg e uma experiência de trabalho na colheita florestal de 2 anos (Figura 3c).

CAMINHÃO AUTOCARREGÁVEL KRAZ- 257: De origem ucraniana, possui peso de 11,160 ton., potência de 240 Hp, capacidade de carga de 12 ton. e uma velocidade máxima de 60 km/h (Figura 3d).

CAMINHÃO URAL- 4320: De origem russa, possui peso de 15,3 ton., potência de 177 KW, capacidade de carga de 6 ton. e uma velocidade máxima de 75 km/h (Figura 3e).

CAMINHÃO KAMAZ-4310: De origem russa, possui peso de 7 ton., potência de 210 Hp, capacidade de carga de 6 ton. e uma velocidade máxima de 85 km/h (Figura 3f).

CARREGADOR FRONTAL VOLVO BML90B: De origem sueca, possui peso de 12,6 ton., potência de 115 KW, capacidade de carga de 10 ton. e velocidade máxima de 45 km/h (Figuras 3g e 3h)





Figura 3 – Maquinaria de colheita e transporte florestal na EFI Macurije: A) Extração da madeira com o Skidder americano "John Deere 548E"; B) Skidder Chinês "J-80A". C) Junta de bois; D) Caminhão autocarregável KRAZ- 257; E) Caminhão URAL- 4320; F) Caminhão KAMAZ-4310; G) Carregador frontal "VOLVO BM L90B"; H) O carregador frontal "VOLVO BM L90B" carregando um caminhão URAL- 4320.

2.3. Coleta de dados experimentais e cálculo de custos e produtividades

O experimento cobriu o período de colheita florestal da empresa, nos meses de janeiro a maio de 2015. As medições foram realizadas nas condições reais de trabalho dos operadores para que os resultados fossem os mais reais possíveis.

Os dados foram obtidos por meio de estudos de tempo e movimento, sendo o método de tempo individual o utilizado para a medida dos seguintes tempos:

Skidders e Juntas de bois: Tempo de deslocamento sem carga (T_{dsc}), Tempo de deslocamento com carga (T_{dcc}), Tempo de amarre (T_a), Tempo de desamarre (T_d) e Tempo de Interrupções (T_i).

Carregador Frontal: Tempo de deslocamento sem carga (T_{dsc}); Tempo de deslocamento com carga (T_{dcc}); Tempo de movimentação do braço vazio (T_{mbv}); Tempo de agarre das toras (T_{at}); Tempo de depósito e ajuste das toras (T_{dat}); Tempo de manobras (T_m) e Tempo de interrupções (T_i).

Caminhões: Tempo de carregamento (T_c), Tempo de descarregamento (T_{dc}), Tempo de viagem sem carga (T_{vsc}), Tempo de viagem com carga (T_{vcc}), Tempo de Interrupções (T_i).

Também foram medidos simultaneamente as distâncias de extração e de transporte correspondentes a cada um dos tempos para a determinação das velocidades médias de deslocamento e o volume de madeira extraída por ciclo de extração e de transporte.

Os dados acima coletados somados aos requeridos nas fórmulas dos anexos 2.1 e 2.2 permitiram a estimativa dos custos e produtividades por meio das fórmulas do anexo 2.2.

2.4. Análise de suficiência amostral

As quantidades mínimas de ciclos operacionais necessários por máquina de extração (m_1 , m_2 e m_3), carregamento/descarregamento (m_4) e transporte (m_5 , m_6 e m_7) de madeira para obter uma precisão fixada por um erro de amostragem máximo permissível de 10%, foi determinado com a fórmula de Barnes (1977) adaptada para todas as máquinas (Expressão 1). Os respectivos erros de amostragem foram determinados por meio da expressão 2.

$$n_m \geq \frac{t_m^2 * CV_m^2}{E^2} \quad (1) \qquad E_m(\%) \leq \left(\frac{S_y^m * t_m}{\bar{Y}_m} \right) * 100 \quad (2)$$

Em que: n_m = número mínimo de ciclos operacionais necessários para a máquina m (m_1 = skidder chinês J-80A; m_2 = skidder John Deere 548E; m_3 = junta de bois; m_4 = carregador frontal VOLVO BM L90B; m_5 = Kamaz-4310; m_6 = Kraz- 257 e ; m_7 = Ural- 4320); t_m = valor de t para a máquina m , determinado, para o nível de confiança de 95% e para $(n - 1)$ graus de liberdade; CV_m = coeficiente de variação para m (%); e E = erro admissível (10 %); $E_m(\%)$ = erro de amostragem da máquina m ; S_y^m = desvio padrão da média da máquina m ; \bar{Y}_m = média aritmética da máquina m .

2.5. Sistemas de colheita avaliados e indicadores de desempenho

Foram avaliados os sistemas de toras curtas (*Cut to length*) de 3 e 4 m de comprimento e o de toras longas (*tree length*) de 12 m de comprimento. Os indicadores de desempenho ou critérios de avaliação utilizados foram os custos unitários (US\$/m³) e a produtividade (m³/hora). Os custos exploração das máquinas (US\$/hora), necessários para a estimativa dos custos unitários, foram determinados pelas fórmulas apresentados nos anexos 2.1 e 2.2 (CÁNDANO, 1998; MACHADO, 2014).

2.6. Análise estatística

Previamente à realização das análises paramétricas de variância (ANOVA e MANOVA), os pressupostos de normalidade e homocedasticidade foram testados. A normalidade univariada foi avaliada para cada uma das variáveis com o Teste de Shapiro-Wilk no programa SPSS versão 20 e a normalidade multivariada com os Testes de assimetria e

curtoses por meio do pacote estatístico LISREL 9.2. Em relação à homocedasticidade, a univariada foi avaliada com o Teste de Levene e a multivariada com o Teste M de Box.

2.6.1. Experimento fatorial univariado

Um arranjo fatorial foi realizado para um delineamento casualizado em blocos (DCB) com três fatores no esquema fatorial 3x3x2: maquinaria de colheita ($m=3$), declividade ($d=3$) e sistema de colheita ($s=2$). Com a finalidade de atender o controle de possíveis fontes de variação relativas à idade de rotação (muito variável na empresa), foi realizado o controle local pela blocagem de talhões de 21 anos (bloco I) e 32 anos (bloco II) de idade em diferentes declividades (Tabela 1). Os níveis dos três fatores supracitados foram:

- Fator M (maquinaria de colheita) com três níveis:

- 1) skidder chinês J-80A;
- 2) skidder americano John Deere 548E;
- 3) junta de bois.

- Fator D (Declividade) com três níveis:

- 1) $D < 8\%$;
- 2) $8\% \leq D \leq 16\%$;
- 3) $16\% \leq D < 25\%$.

- Fator S (sistema de colheita) com dois níveis:

- 1) toras longas de 12 m;
- 2) toras curtas de 3 ou 4 m.

As hipóteses nulas testadas nos arranjos fatoriais (univariado e multivariado) foram as seguintes:

H_{01} : Não existe diferença significativa entre a utilização das diferentes máquinas na extração da madeira;

H_{02} : Não existe diferença significativa entre a extração da madeira nas diferentes declividades;

H_{03} : Não existe diferença significativa entre os diferentes sistemas de colheita;

H_{04} : Não são significativas, as interações MxD; MxS; DxS e MxDxS.

O modelo matemático (Expressão 3) para o arranjo fatorial univariado 3x3x2 do delineamento casualizado em blocos (DCB) foi:

$$Y_{ijkl} = \mu + \alpha_i + \beta_j + \gamma_k + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + \delta_{ijk} + b_{lk} + e_{ijkl} \quad (3)$$

Em que: Y_{ijkl} = valores observados das variáveis respostas (produtividade ou custo) no i -ésimo nível do fator M, j -ésimo nível do fator D, k -ésimo nível do fator S do l -ésimo bloco; μ : uma

constante (média geral); α_i : efeito do i -ésimo nível do fator M; β_j : efeito do j -ésimo nível do fator D; γ_k : efeito do k -ésimo nível do fator S; $(\alpha\beta)_{ij}$: efeito da interação entre M e D; $(\alpha\gamma)_{ik}$: efeito da interação entre M e S; $(\beta\gamma)_{jk}$: efeito da interação entre D e S; δ_{ijk} : efeito da interação entre M, D e S; b_{lk} : efeito do bloco l; e_{ijkl} : erro experimental.

Em casos de existência de diferença significativa, a comparação de médias foi realizada por meio do Teste de Tukey ao nível de 5% de significância.

O experimento seguiu um delineamento casualizado em blocos porque se considerou a existência de diferença significativa entre os custos ou produtividades de extração de toras provenientes de povoamentos de 21 anos e os de toras provenientes de povoamentos de 32 anos. A verificação dessa diferença foi realizada por meio do cálculo da Eficiência de Blocos (EB), para cada uma das variáveis custo unitário e produtividade, pela fórmula da Expressão 4.

$$EB = \frac{(J - 1)QMB + J(I - 1)QMR}{(IJ - 1)QMR} \quad (4)$$

Em que: EB= Eficiência dos blocos; QMB=Quadrado Médio dos Blocos; QMR=Quadrado Médio do Resíduo; I= Número de tratamentos; J= Número de blocos.

Valores de EB iguais a 1,0 indicam que tanto o delineamento inteiramente casualizado (DIC) como o delineamento casualizado em blocos (DCB) são eficientes, podendo usar qualquer um dos dois. Valores de EB inferiores a 1,0 indicam a não efetividade do uso de blocos, recomendando o uso do DIC e valores de EB superiores a 1,0 indicam a eficiência dos blocos, recomendando o uso do DCB.

2.6.2. Experimento fatorial multivariado

Para o estudo comparativo dos diferentes meios de extração nos diferentes cenários, baseando-se simultaneamente nas produtividades e nos custos, foi realizado um experimento fatorial multivariado adotando a mesma estrutura (blocos, fatores e seus respectivos níveis) que no experimento univariado anteriormente descrito.

O modelo matemático (Expressão 5) para o arranjo fatorial multivariado 3x3x2 foi:

$$Y_{ijklr} = \mu_r + \alpha_{ir} + \beta_{jr} + \gamma_{kr} + (\alpha\beta)_{ijr} + (\alpha\gamma)_{ikr} + (\beta\gamma)_{jkr} + \delta_{ijk} + b_{lkr} + e_{ijklr} \quad (5)$$

Em que: Y_{ijklr} : valor observado da r -ésima variável resposta no i -ésimo nível do fator M, j -ésimo nível do fator D, k -ésimo nível do fator S, no l -ésimo bloco; μ_r : uma constante (média geral) da r -ésima variável; α_{ir} : efeito do i -ésimo nível do fator M na r -ésima variável; β_{jr} :

efeito do j -ésimo nível do fator D na r -ésima variável; γ_{kr} : efeito do k -ésimo nível do fator S na r -ésima variável; $(\alpha\beta)_{ijr}$: efeito da interação entre M e D na r -ésima variável; $(\alpha\gamma)_{ikr}$: efeito da interação entre M e S na r -ésima variável; $(\beta\gamma)_{jkr}$: efeito da interação entre D e S na r -ésima variável; δ_{ijk} : efeito da interação entre M, D e S na r -ésima variável; b_{lkr} : efeito do bloco l na r -ésima variável; e_{ijklr} : erro aleatório associado à observação Y_{ijklr} .

A significância das hipóteses foi testada pelos Testes de lambda de Wilks, traço de Pillai, traço de Lawley-Hotelling e a Maior Raiz de Roy. A rejeição da hipótese nula a um nível de significância $\alpha = 0,05$, foi sujeita à condição $F_{\text{calculado}} > F_{\text{crítico}}$ (tabelado) ou $p < 0,05$. As análises foram realizadas com os softwares estatísticos SAS (SAS, 1999) e SPSS v. 20.

Em casos de rejeição da hipótese nula, as comparações múltiplas entre vetores de médias foram realizadas com o Teste T^2 de Hotelling (HOTELLING, 1931), análogo multivariado do Teste *t de Student*, por meio do pacote STATISTICA 8.0. Testando a hipótese nula, $H_0: \mu_1 = \mu_2$, sendo μ_1 e μ_2 os vetores de médias, as seguintes expressões foram utilizadas para o cálculo do estatístico T^2 (Expressões 6 e 7).

$$T^2 = (\bar{X} - \bar{Y})^T \left[S \left(\frac{1}{n_x} + \frac{1}{n_y} \right) \right]^{-1} (\bar{X} - \bar{Y}) \quad (6)$$

$$S = \frac{(n_x - 1)S_X + (n_y - 1)S_Y}{(n_x - 1) + (n_y - 1)} \quad (7)$$

Em que: S_X e S_Y são as matrizes de covariância de X e Y respectivamente; e \bar{X} e \bar{Y} as médias de X e Y respectivamente; n_x e n_y são os tamanhos das variáveis X e Y, respectivamente.

As significâncias foram determinadas fazendo uma aproximação do Teste F ao Teste T^2 de Hotelling conforme a seguinte relação (Expressão 8):

$$F = \frac{n - k}{k(n - 1)} T^2 \sim F(k, n - k) \quad (8)$$

Em que: $n = n_x + n_y - 1 =$ grau de liberdade e $k =$ número de variáveis

3. RESULTADOS E DISCUSSÃO

3.1. Suficiência amostral e resultados de estudos de tempos e movimentos na extração e transporte de madeira.

As amostragens iniciais (pilotos), de 45 ciclos operacionais para cada uma das máquinas de extração, 25 ciclos para as máquinas de transporte e 30 ciclos para o carregador frontal, foram consideradas definitivas já que apresentaram erros de amostragem inferiores ao permissível de 10% (Tabela 2).

Tabela 2 – Tamanhos mínimos de amostragem e erros de amostragem correspondentes

| Atividades | Máquinas | Tamanho de amostra mínima (n_m) | E_A (%) |
|----------------------------------|---------------------------------------|-------------------------------------|-----------|
| Extração | Skidder J-80A | 29 | 3,01 |
| | Skidder John Deere | 17 | 3,97 |
| | Junta de Bois | 23 | 3,54 |
| Carregamento/ Descarregamento | Carregador frontal “VOLVO BM L90B” | 19 | 6,42 |
| Transporte | Kamaz-4310 | 20 | 8,99 |
| | Kraz- 257 | 22 | 9,19 |
| | Ural- 4320 | 20 | 8,91 |

O estudo de tempo realizado nos ciclos operacionais indicou porcentagens similares nos skidders avaliados (Figura 4 e Apêndice 2.5). Porém, é perceptível que os ciclos operacionais do skidder J-80A consomem ligeiramente mais tempos do que os do skidder John Deere. Percebeu-se que as interrupções levaram a maior porcentagem de tempo nos três meios de extração de madeira. Nas juntas de bois, os tempos de interrupções foram os maiores, seguidos dos tempos de viagens, sendo isto característico da extração animal. As maiores causas das interrupções em todos os meios de extração foram: reposição de peças desgastadas, ruptura de cabo de tração e aguardo de derrubada de árvores para iniciar a extração.

Em relação aos skidders, os tempos de amarre e desamarre foram superiores aos tempos das viagens. Isto é devido a dificuldade que encontram os operadores nessas operações manuais de amarre e desamarre da madeira com os cabos antes do seu guinchamento para iniciar a viagem carregada. Foi observado que, nas áreas de colheita, limpezas pré-colheita que objetivam tirar galhos secos e cortar cipós para liberar as áreas não foram realizadas. Pular essa fase pode aumentar significativamente os tempos terminais (amarre e desamarre) de extração de madeira como foi observado nos resultados e colocar a vida dos trabalhadores em perigo, principalmente na fase de corte semimecamizado das árvores com motosserra. Estes resultados

correspondem aos encontrados por Lopes e Diniz (2015), sendo este comportamento típico de skidders de cabo como os avaliados no presente estudo.

Futuras ações para a melhora da produtividade das máquinas tem que ser orientadas a minimização das interrupções e dos tempos de amarre e desamarre das toras. Uma ação básica mas efetiva é a realização das limpezas pré-colheita abordadas anteriormente.




Figura 4 – Percentagens de tempos dos componentes dos ciclos operacionais de extração de madeira de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

Em relação ao transporte da madeira, percebe-se que devido à distância, os tempos de transporte são amplamente superiores e, como era de esperar, os tempos de carregamentos foram maiores que os descarregamentos e os de viagens vazias menores que os de viagens carregadas (Figura 5). Percebe-se também que o caminhão KRAZ-257, apesar de apresentar os maiores tempos de viagens, realizou os ciclos em menores tempos, sendo um tempo de 164,2 min. contra 222,45 min. para o caminhão URAL-4320 e 202,73 min. para o caminhão KAMAZ-4310 (Apêndice 2.7). Esse resultado atribui-se ao fato que esse caminhão é autocarregável, sendo mais eficiente nas fases de carregamento e descarregamento. Os outros dois caminhões foram carregados por um carregador frontal “VOLVO BM L90B” que pode perder mais tempos nas manobras e interrupções.




Figura 5 – Percentagens de tempos dos componentes dos ciclos operacionais de transporte de madeira de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

O carregador frontal VOLVO BM L90B, no carregamento/descarregamento dos caminhões não autocarregáveis, apresentou um tempo médio do ciclo operacional de 06 min. 15 seg. e uma capacidade média de 6 toras longas de 12m por ciclo. A capacidade de cada caminhão em quantidade de toras depende do volume médio de cada tora. A quantidade de toras transportadas por cada um dos caminhões variou entre 24 e 27, necessitando entre 4 e 5 ciclos operacionais do cargador frontal para carregar cada caminhão.

A Figura 6 e o Apêndice 2.6 indicam que os maiores tempos foram consumidos pelas operações de depósito e ajuste de toras (24,96%) e as interrupções (44,48%). A maior parte dessas interrupções é atribuída ao tempo parado. O pouco espaço existente no pátio de armazenamento causou muitas interrupções já que as manobras do carregador frontal e o agarre das toras são sempre seguidos de uma fase de espera para que o caminhão se coloque em uma posição na qual a madeira pode ser depositada adequadamente. Se considera que com um maior espaço no pátio de armazenamento, os caminhões estariam estáticos durante todo o processo de carregamento, o que eliminaria os tempos de espera e por consequência melhora a produtividade de carregamento. Essa melhoria na produtividade de carregamento terá também uma influência positiva na produtividade dos caminhões.




Figura 6 – Porcentagens de tempos dos componentes dos ciclos operacionais do Volvo BM L90B no carregamento e descarregamento dos caminhões na EFI Macurije.

3.2. Produtividades e custos de extração e transporte de madeira em florestas plantadas de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na EFI Macurije

Os custos de exploração dos meios de extração (Tabela 3 e Figura 7) indicam, como era de se esperar, que a menos onerosa foi a *junta de bois* com apenas 1,34 \$/h, mas também foi a que apresentou a menor produtividade (3,95 m³/h). O trator chinês foi o mais oneroso com um custo de exploração de 29,55 \$/h e uma produtividade intermediária de 15,98m³/h. A diferença da junta de bois na qual o principal componente dos custos de exploração foi o custo de mão

de obra, em ambos os skidders, o principal componente desses custos foram os custos operacionais.

Estes resultados acima encontrados indicam que o skidder John Deere é a melhor alternativa por apresentar a maior produtividade (17,20 m³/h) e o menor custo unitário entre os dois skidders.




Figura 7 – Componentes dos custos (fixos-Cf, variáveis- Cv, mão de obra-Cmo; Cem = Cf + Cv + Cmo) de extração de madeira de *P. caribaea* var. *caribaea*, Pinar Del Rio, Cuba

A junta de bois pode ser uma alternativa viável em um regime de produção desacelerado (quando o tempo não é um recurso limitante na satisfação dos planos de produção) devido a sua baixa produtividade e baixo custo operacional. Uma alternativa factível de uso pode ser associando-a a outros meios de extração mecanizada para um aumento da produtividade sem significativo aumento de custo operacional. Isto é evidenciado pelos resultados de Cándano (1998) que, ao combinar com os tratores e as juntas de bois, utilizando-as para a formação de pilhas de madeira antes da sua extração, registrou uma redução média de 10,88 minutos no tempo total do ciclo dos tratores.

Em relação ao transporte, os custos operacionais ou variáveis são os que mais contribuem aos custos de exploração das maquinarias. Dos três caminhões avaliados, o modelo KRAZ-257, o único de plataforma que transporta as toras curtas, apresentou o maior custo de exploração (Figura 8) e a menor produtividade (Tabela 3) o que faz que resulte o mais oneroso.




Figura 8 – Componentes dos custos (propriedade-Cp, operacionais- Cop, mão de obra-Cmo; Cem = Cp + Cop + Cmo) de transporte da madeira em plantações de *P. caribaea* var. *caribaea*, EFI Macurije, Pinar Del Rio, Cuba.

Dos dois caminhões semirreboque, o mais econômico foi o modelo KAMAZ-4310 que apesar de apresentar um custo de exploração menor que o do modelo URAL- 4320, apresentou uma produtividade alta que reduziu significativamente o seu custo unitário (Tabela 3). Este resultado está em consonância com os de Cándano (1998) que encontrou, nos seus estudos ao nível da província de Pinar del Río, incluindo a EFI Macurije, maiores custos no transporte de toras curtas como no presente trabalho.

Os indicadores técnicos e econômicos do carregador frontal Volvo BM L90B indicam que o carregamento e descarregamento de madeira é realizado a uma produtividade bem maior que os extração e transporte de madeira. Isso é muito importante para evitar possíveis acumulações de madeira nos pátios de armazenamento ou possíveis filas de caminhões aguardando serem carregados. Baseado nos resultados de produtividades da Tabela 3, o carregador frontal avaliado pode funcionar sem provocar momentos de estrangulamento em pontos de extração e transporte de madeira constituídos por 2 skidders, uma junta de bois e 5 caminhões.

Tabela 3 - Produtividades e custos da extração e transporte da madeira em florestas plantadas de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf., Pinar del Rio, Cuba

| Atividade avaliada | Maquinaria | GERAL | | | Por sistema de colheita | | | |
|--------------------------------|-----------------|---------------------------|--------------|----------------------------|---------------------------|-------|----------------------------|------|
| | | PROD. (m ³ /h) | CEM (US\$/h) | CU. (US\$/m ³) | PROD. (m ³ /h) | | CU. (US\$/m ³) | |
| | | | | | STL | STC | STL | STC |
| *Extração | John Deere 548E | 17,20 | 17,48 | 1,02 | 17,97 | 16,65 | 1,01 | 1,17 |
| | J-80A | 15,98 | 29,55 | 1,85 | 16,06 | 14,91 | 1,67 | 1,91 |
| | Junta de bois | 3,95 | 1,343 | 0,34 | 3,98 | 3,41 | 0,32 | 0,59 |
| **Carregamento/Descarregamento | Volvo BM L90B | 34,5 | 30,26 | 0,88 | 34,5 | - | 0,88 | - |
| ***Transporte | KAMAZ-4310 | 6,52 | 15,89 | 2,44 | 6,52 | - | 2,44 | - |
| | KRAZ- 257 | 5,34 | 16,79 | 3,15 | - | 5,34 | - | 3,15 |
| | URAL- 4320 | 5,85 | 15,43 | 2,64 | 5,85 | - | 2,64 | - |

*Distância média de extração de 150m;**Carregamento apenas de caminhões de tora longa;

***Distância média de transporte de 35km; PROD.=Produtividade; CEM=Custo de Exploração da Máquina; CU.=Custo Unitário; STL=Sistema de Tora Longa; STC=Sistema de Tora Curta.

Os resultados da Tabela 3 também indicam que, na extração de madeira, os sistemas de toras longas são mais viáveis por proporcionarem maiores produtividades e menores custos de produção. Porém, esta conclusão é parcial porque é necessário analisar a interação do sistema

de colheita com outros fatores (exemplo: maquinaria e declividade) cuja influência nas produtividades e custos de extração de madeira é conhecida.

3.3. Experimentos fatoriais univariadas e multivariadas

3.3.1. Normalidade e homocedasticidade univariada e multivariada

A não significância do Teste de Shapiro-Wilk indicou a satisfação do pressuposto de normalidade tanto para a variável custo como para a variável produtividade (Apêndice 2.1). A significância do Teste de assimetria e curtose indicou igualmente a satisfação da normalidade multivariada (Apêndice 2.2).

Para a homocedasticidade univariada, a não significância do Teste de Levene em ambas as variáveis indicou homogeneidade de variância nas mesmas (Apêndice 2.3). Por outro lado, a significância do Teste M de Box indicou presença de heterocedasticidade nas matrizes de variância-covariância (Apêndice 2.4). Segundo O'Rourke et al. (2005), esse pressuposto é raramente satisfeito em dados de pesquisas do mundo real. O não atendimento desse pressuposto tem impacto mínimo se os grupos têm aproximadamente o mesmo tamanho (STEVENS, 2002; HAIR Jr et al., 2005; MAROCO, 2007) como é o caso no presente trabalho.

As discussões se basearam apenas nos resultados do traço de Pillai-Bartlett devido a sua maior robustez frente à violação do pressuposto de homocedasticidade quando as amostras são iguais (BRAY; MAXWELL, 1985).

3.3.2. Experimento fatorial univariado para custo e para produtividade

Os resultados da análise prévia da eficiência de blocos ($EB_{Prod} = 13,71$ e $EB_{Custo} = 1,68$) indicam a necessidade de uso dos blocos (bloco I=21 anos; bloco II = 32 anos) tanto para a variável custo como para produtividade. Por isso, foi mantido o delineamento casualizado em blocos inicialmente adotado na pesquisa.

A produtividade da extração da madeira no bloco II correspondente à idade de rotação de 32 anos (média = 9,08 m³/h) é superior a produtividade da extração da madeira do bloco I que representa uma idade de corte de 21 anos (média = 7,49 m³/h). Estes resultados que indicam que é mais viável a colheita de povoamentos de 32 anos que os 21 anos, coincidem com os encontrados por Gingra (1988), Santos e machado (1995), Holtzcher e Lanford (1997) e Eliasson (1999) segundo os quais povoamentos com árvores de pequenos diâmetros médios requerem maior tempo de operação por metro cúbico que povoamentos com maiores diâmetros médios, proporcionando assim menores produtividades. A alta correlação positiva existente

entre a idade e o diâmetro das árvores explica a similaridade da influência de ambas as variáveis sobre a produtividade neste estudo.

O custo da extração de toras provenientes de povoamentos de 32 anos (1,49 US\$/m³) foi inferior ao da extração de toras provenientes de povoamento de 21 anos (1,64 US\$/m³). Este resultado, que confirma a maior viabilidade do bloco II, coincide com os de Santos e Machado (1995) e Holtzcher e Lanford (1997) segundo os quais os custos de produção, incluindo os de extração, são inversamente proporcionais as dimensões das árvores que estão, pela sua vez, altamente correlacionadas com a idade.

Tabela 4 – Análise de variância para o arranjo fatorial univariado 3x3x2

| VD* | PRODUTIVIDADE | | | | CUSTO | | | |
|---------------------|---------------|---------|--------|---------|-------|--------|---------|---------|
| | GL | QM | F | Pr > F | GL | QM | F | Pr > F |
| Bloco | 1 | 22,753 | 27,90 | <0,0001 | 1 | 0,198 | 25,29 | <0,0001 |
| Tratamento | 17 | 24,683 | 30,27 | <0,0001 | 17 | 1,325 | 169,16 | <0,0001 |
| Maquinaria | 2 | 353,475 | 433,49 | <0,0001 | 2 | 11,400 | 1455,79 | <0,0001 |
| Declividade | 2 | 43,781 | 53,69 | <0,0001 | 2 | 1,765 | 225,42 | <0,0001 |
| Sistema de colheita | 1 | 7,765 | 9,52 | 0,0670 | 1 | 0,178 | 22,71 | 0,0002 |
| MxD | 4 | 6,007 | 7,37 | <0,0001 | 4 | 0,162 | 20,66 | <0,0001 |
| MxS | 2 | 0,676 | 0,83 | 0,4533 | 2 | 0,021 | 2,67 | 0,0981 |
| DxS | 2 | 1,614 | 1,98 | 0,1688 | 2 | 0,002 | 0,33 | 0,7262 |
| MxDxS | 4 | 0,051 | 0,06 | 0,9922 | 4 | 0,002 | 0,28 | 0,8850 |
| Erro | 17 | 0,815 | | | 17 | 0,008 | | |
| TOTAL | 35 | | | | 35 | | | |

*Variável Dependente.

Em relação aos fatores, os resultados indicam que, para a variável dependente *custo*, os três fatores *maquinaria*, *declividade*, *sistema de colheita* e a interação *maquinaria*declividade* foram significativos ($p < 0,05$).

Para a variável dependente produtividade, os resultados foram similares, com exceção do fator *sistema de colheita* que não foi significativo. A não significância deste fator, para a variável dependente produtividade, indica que não existe diferença significativa entre as produtividades de extração de toras curtas e as de extração de toras longas. Este resultado pode ser explicado pelas pilhas de madeira realizadas no sistema de tora curta. No sistema de toras longas, os meios de extração levam ao máximo três toras longas por ciclo por questões operacionais e de mobilidade; já no sistema de toras curtas de 3 ou 4 m, são extraídas, por ciclo, até 5 toras e em ocasiões, com terrenos menos declivosos, até 6 toras. Esta prática pode ter

permitido minimizar a influência do comprimento de toras na produtividade e custo da colheita. Já para a variável custo, os resultados indicam que existe diferença significativa entre os custos de extração de toras curtas e os de extração de toras longas. Percebe-se uma divergência entre os resultados deste fator, segundo a variável dependente, o que leva a certa ambiguidade na tomada de decisão. Qual é o critério mais importante para a tomada de decisão? O custo unitário ou a produtividade?

Para a variável dependente produtividade, o Teste de Tukey aplicado a interação MxD, única significativa, permite afirmar que em todas as declividades, existiu diferença significativa entre as produtividades das máquinas avaliadas, sendo a de maior produtividade do John Deere (Tabela 5). Em relação ao desempenho de cada uma das máquinas ao longo das declividades, os skidders tiveram um desempenho diferenciado, apresentando uma produtividade maior na classe de declividade baixa e menor na classe de declividade alta. Estes resultados estão em consonância com Behjou et al. (2008) e Leite et al. (2014), segundo os quais a declividade do terreno é um dos fatores mais influentes na produtividade das máquinas florestais. Igual a presente pesquisa, estes autores encontraram que o aumento da declividade do terreno provoca uma significativa diminuição na produtividade das máquinas. Embora a junta de bois tenha apresentado uma tendência similar, não houve diferença significativa entre seus desempenhos ao longo das três classes de declividades (Tabela 5).

Tabela 5 – Teste de Tukey para a interação MxD para a variável produtividade

| MAQUINARIA | DECLIVIDADE | | |
|------------------|-------------|--------------|---------------|
| | D < 8% | 8% ≤ D ≤ 16% | 16% ≤ D < 25% |
| J-80A | 13,1025 bA | 10,1650 bB | 8,0425 bC |
| John Deere 548 E | 15,0825 aA | 12,1375 aB | 9,7150 aC |
| Junta de bois | 2,7000 cA | 1,9250 cA | 1,7200 cA |

Médias seguidas de mesma letra (minúsculas nas colunas e maiúsculas nas linhas) não diferem entre si para o Teste de Tukey ao nível de 5% de probabilidade de erro.

Em relação a variável custo, o Teste de Tukey aplicado a esta interação (Tabela 6) permite dizer que em todas as classes de declividades existiu diferença significativa entre os custos unitários dos skidders J-80A e John Deere 548E e da junta de bois, sendo esta última, a menos onerosa e a primeira a mais onerosa. Em relação ao comportamento de cada uma das máquinas ao longo das três declividades, percebe-se que as três apresentaram custos unitários estatisticamente diferentes. Apresentou-se uma tendência de aumento dos custos unitários a medida que aumenta a declividade.

Tabela 6 – Teste de Tukey para a interação MxD para a variável custo

| MAQUINARIA | DECLIVIDADE | | |
|-----------------|-------------|--------------|---------------|
| | D < 8% | 8% ≤ D ≤ 16% | 16% ≤ D < 25% |
| J-80A | 2,0075 aC | 2,5575 aB | 3,2025 aA |
| John Deere 548E | 1,1275 bC | 1,3150 bB | 1,7925 bA |
| Junta de bois | 0,4325 cC | 0,6675 cB | 0,8650 cA |

Médias seguidas de mesma letra (minúsculas nas colunas e maiúsculas nas linhas) não diferem entre si para o Teste de Tukey ao nível de 5% de significância.

3.3.3. Experimento fatorial multivariado combinando “produtividade” e “custo”

A significativa correlação (moderada) existente entre as variáveis *custo* e *produtividade* ($r=0,404$; Prob. =0,014) foi um indicativo da viabilidade da MANOVA para as análises de variância no presente estudo.

Utilizando a abordagem multivariada, no intento de resolver a ambiguidade gerada pela divergência entre os resultados encontrados na abordagem univariada para as duas variáveis dependentes, encontrou-se uma significância a 1% de probabilidade (Tabela 7) para todos os fatores. Isso indica que, tanto a maquinaria utilizada na extração da madeira como o comprimento das toras e a declividade em que ela é extraída, influem significativamente no conjunto custo-produtividade.

Tabela 7 - Efeito dos fatores maquinaria, declividade e sistema de colheita sobre o conjunto produtividade-custo na extração da madeira de *P. caribaea* var. *caribaea*

| FAT. | MAQUINARIA | | | DECLIVIDADE | | | SISTEMA DE COLHEITA | | |
|------|------------|---------|---------|-------------|--------|---------|---------------------|-------|--------|
| | EST. | Valor | F | Pr> F | Valor | F | Pr> F | Valor | F |
| LW | 0,0001 | 668,53 | <0,0001 | 0,02 | 40,02 | <0,0001 | 0,42 | 10,83 | 0,0011 |
| TP | 1,9410 | 279,78 | <0,0001 | 1,19 | 12,61 | <0,0001 | 0,57 | 10,83 | 0,0011 |
| THL | 419,72 | 1650,29 | <0,0001 | 27,01 | 106,22 | <0,0001 | 1,35 | 10,83 | 0,0011 |
| MRR | 403,02 | 3425,73 | <0,0001 | 26,71 | 227,08 | <0,0001 | 1,35 | 10,83 | 0,0011 |

FAT. = Fatores; EST. = Estatísticas; LW = Lambda de Wilks; TP = Traço de Pilai; THL=Traço de Hotelling – Lawley;MRR = Maior Raiz de Roy.

A significância do fator *sistema de colheita* indicou que os custos do sistema de toras curtas (com uma média de 1,622 US\$/m³) foram maiores aos do sistema de toras longas (1,482 US\$/m³) e as produtividades menores (7,823 m³/h vs 8,752 m³/h). Estes resultados seguem a mesma tendência que os encontrados por Machado e Lopes (2000) na extração da madeira em

povoamentos de Eucalipto e por Mousavi (2012) em estudos realizados em povoamentos mistos. Coincidindo com o experimento univariado, quase todos os Testes indicam que apenas a interação MxD foi significativa. Notou-se que todas as interações que envolveram o fator *sistema de colheita* não foram significativos (Tabelas 8 e 9).

Tabela 8 - Efeito das interações MxD, MxS e DxS sobre o conjunto produtividade-custo

| INT. | MxD | | | MxS | | | DxS | | |
|------|------|-------|---------|-------|-------|--------|-------|-------|--------|
| | EST. | VALOR | F | Pr> F | VALOR | F | Pr> F | VALOR | F |
| LW | 0,07 | 10,96 | <0,0001 | 0,66 | 1,83 | 0,1472 | 0,65 | 1,92 | 0,1315 |
| TP | 1,40 | 9,95 | <0,0001 | 0,36 | 1,88 | 0,1372 | 0,35 | 1,80 | 0,1516 |
| THL | 6,37 | 12,35 | <0,0001 | 0,47 | 1,86 | 0,1603 | 0,54 | 2,11 | 0,1213 |
| MRR | 5,07 | 21,56 | <0,0001 | 0,38 | 3,22 | 0,0653 | 0,53 | 4,55 | 0,0261 |

INT. = Interações; EST. = Estatísticas; LW = Lambda de Wilks; TP = Traço de Pilai; THL = Traço de Hotelling – Lawley; MRR = Maior Raiz de Roy.

Tabela 9 - Efeito da interação MxDxS sobre o conjunto produtividade – custo

| ESTATÍSTICAS | VALOR | F | Pr> F |
|-----------------------------|---------|------|--------|
| Lambda de Wilks | 0,86351 | 0,30 | 0,9588 |
| Traço de Pilai | 0,13685 | 0,31 | 0,9561 |
| Traço de Hotelling - Lawley | 0,15762 | 0,31 | 0,9554 |
| Maior Raiz de Roy | 0,15483 | 0,66 | 0,6294 |

3.3.3.1. Teste T² de Hotelling para vetores de médias na interação MxD

Os resultados deste teste indicaram uma alta influência da interação MxD no conjunto produtividades-custos. Registrou-se diferença significativa entre os desempenhos do skidder J-80A nas três classes de declividade. O skidder John Deere apresentou desempenhos similares nas duas primeiras classes de declividades (D₁ e D₂), sendo estes dois diferentes e superiores ao seu desempenho na terceira classe (D₃) (Tabela 10). Este resultado se atribuí a queda da produtividade operacional com o aumento da declividade já que a velocidade de deslocamento é menor em áreas declivosas.

Tabela 10 – Teste T^2 de Hotelling entre os pares de vetores de médias de custo e produtividade para a interação MxD

| | M_1D_1 | M_1D_2 | M_1D_3 | M_2D_1 | M_2D_2 | M_2D_3 | M_3D_1 | M_3D_2 | M_3D_3 |
|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| M_1D_1 | -- | * | * | * | # | # | * | # | # |
| M_1D_2 | | -- | * | # | * | # | # | * | # |
| M_1D_3 | | | -- | # | # | * | # | # | * |
| M_2D_1 | | | | -- | NS | * | * | # | # |
| M_2D_2 | | | | | -- | * | # | * | # |
| M_2D_3 | | | | | | -- | # | # | * |
| M_3D_1 | | | | | | | -- | * | * |
| M_3D_2 | | | | | | | | -- | NS |
| M_3D_3 | | | | | | | | | -- |

*Significativo ($p < 0,05$); NS = Não Significativo ($p > 0,05$); # = comparação sem interesse. M_1 , M_2 e M_3 são os meios de extração J-80A, John Deere 548E e Junta de Boi respectivamente. D_1 , D_2 e D_3 são as três declividades $D < 8\%$, $8\% \leq D \leq 16\%$ e $16\% \leq D < 25\%$ respectivamente.

Os custos unitários são afetados de duas formas: uma primeira relacionada ao seu crescimento em função da diminuição da produtividade e uma segunda relacionada ao aumento substancial no consumo de combustível em declividades altas, como resultados do requerimento de maiores potências na realização das operações. A diferença do J-80A no qual foi registrado desempenhos diferentes (decrecentes) ao longo das declividades, percebeu-se que o John Deere manteve um desempenho similar nas duas primeiras classes de declividades antes de apresentar uma queda significativa na terceira classe. Isso indica sua capacidade de manter seu desempenho até uma declividade de 16%.

As múltiplas significâncias encontradas nas comparações realizadas na Tabela 10 indicam um efeito real da interação MxD nas produtividades e nos custos de extração de madeira. Frente a cenários de diferentes classes de declividades e máquinas, combinações ótimas tem que ser realizadas tendo em conta os resultados aqui encontrados já que as mesmas são decisivas para a minimização dos custos globais de extração de madeira na EFI Macurije.

4. CONCLUSÕES

- O experimento fatorial multivariado, combinando as variáveis custo e produtividade, é uma abordagem viável para uma avaliação mais criteriosa do desempenho das máquinas de extração da madeira em diferentes sistemas de colheita e declividades.
- Na empresa Macurije, a extração de toras provenientes de povoamentos de 32 anos é mais viável que a extração das provenientes de povoamentos de 21 anos e em relação ao comprimento das mesmas, é mais econômico adotar o sistema de toras longas.
- A declividade teve uma influência significativa na produtividade e custo de extração da madeira. Seu acréscimo provocou um aumento dos custos de extração e uma diminuição das produtividades.
- Dos skidders avaliados, o skidder John Deere 548E foi o mais econômico e produtivo e por consequência o recomendado para a extração de madeira na empresa Macurije. Em períodos de produção desacelerada, o uso exclusivo da junta de bois em algumas áreas seria uma alternativa viável já que a mesma apresentou custos unitários menores que os dos skidders. Seu uso combinado com o skidder John Deere pode trazer ganhos significativos na produtividade.
- No transporte de madeira, o caminhão KAMAZ-4310, por apresentar o menor custo de produção e a maior produtividade, é a opção mais viável.

5. REFERÊNCIAS

ALDANA, E.; PUENTES, M.; ROMERO, J.L. **Proyecto de Ordenación EFI Macurije**. La Habana: Ministerio de la Agricultura, 2006. 101p.

BARNES, R. M. **Estudos de movimentos e de tempos - projeto e medida do trabalho**. Tradução da 6^{ta}. ed. americana, São Paulo: E. Blucher, 1977. 635p.

BEHJOU, F. K. et al. Time study and skidding capacity of the wheeled skidder Timberjack 450C in Caspian forests. **Journal of Forest Science**, v. 54, p.183–188, 2008.

BRAY, J.H.; MAXWELL, S.E. **Multivariate analysis of variance**. Sage university paper series on quantitative applications in the social sciences, 07-054. Newbury Park, CA: Sage. 1985. 80p.

CÁNDANO, F. **Aprovechamiento Forestal**. Pinar del Rio, Cuba: Editorial Científico Técnica, 2003. 111p.

CÁNDANO, F. **Propuesta para el perfeccionamiento de la tecnología de aprovechamiento de madera en rodales de *Pinus caribaea* en la provincia de Pinar del Río**. 1998. 117 f. Tesis (Doctorado en Ciencias Forestales) – Universidad de Pinar del Rio, Pinar del Rio, Cuba, 1998.

DA SILVA LOPES, E. et al. Avaliação da umidade na compactação do solo submetido ao tráfego de máquinas de colheita florestal. **Revista Árvore**, v. 35, n. 3, p. 659-667, 2011.

ĐUKA, A. et al. Modelling of Downhill Timber Skidding: Bigger Load – Bigger Slope. **Croat. J. For. Eng**, v. 37, n. 1, p. 139–150, 2016.

DYKSTRA, D.P.; HEINRICH, R. **FAO Model code of forest harvesting practice**. FAO Publication, Rome, 1996.

ELLIASSON, L. Simulation of thinning with a single-grip harvester. **Forest Science**, v. 45, n. 1, p. 26-34, fev. 1999.

EZZATI, S.; NAJAFI, A.; DURSTON, T. Impact of animal logging on soil physical properties in mule trail in Hyrcanian forests. **Transportation Research, Part D**, n. 16, p. 316-320, 2011.

GINGRAS, J.F. The effects of site and stand factors on feller-buncher performance. **Feric Technical Report**, n. 84, p.1-18, nov. 1988.

HAIR Jr, J.F.; ANDERSON, R.E.; TATHAM, R.L.; BLACK, W.C. **Análise multivariada de dados**, 5 ed. Porto Alegre: Bookman, 2005. 593p.

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

HOTELLING, H. The Generalization of Student's Ratio. **The Annals of Mathematical Statistics**, v. 2, n. 3, p. 360–378, 1931.

LAGO, M.J. Referência de Procli. 10 p. 2013. Consultado o dia 09/09/2016 e disponível em: <http://www.uhu.es/03009/procli/ref_procli.pdf>

LEITE, E.S. et al. Desempenho do harvester na colheita de eucalipto em diferentes espaçamentos e declividades. **Revista Árvore**, v.38, n.1, p. 95-102, 2014.

LOPES, E.S. DA; DINIZ, C. C. C. Produtividade do trator florestal *chocker skidder* na extração de madeira em terrenos declivosos. **Floresta**, v. 45, n. 3, p. 625 - 634, 2015.

LOPES, S.E. et al. Avaliação técnica do trator florestal arrastador "skidder" com diferentes tipos de rodados na extração de madeira em povoamentos de pinus. **Revista Árvore**, v. 31, n. 6, p. 1053-1061, 2007.

MACHADO, C.C. **Colheita florestal**. Minas Gerais: Editora UFV, 2014. 543 p.

MACHADO, C.C.; LOPES, E.S. Análise da influência do comprimento de toras de eucalipto na produtividade e custo da colheita e transporte florestal. **Cerne**, v. 6, n. 2, p. 124-129, 2000.

MAROCO, J. **Análise Estatística – Com Utilização do SPSS**. 3. ed. Lisboa: Edições Sílabo, 2007. 822p.

MOUSAVI, R. Effect of log length on productivity and cost of Timberjack 450C skidder in the Hyrcanian forest in Iran. **Journal of forest science**, v. 58, n. 11, p. 473–482, 2012.

O'ROURKE, N.; HATCHER, L.; STEPANSKI E.J. **Using SAS for Univariate and Multivariate Statistics**. SAS Institute, Inc; Cary, NC: 2005. 514p.

O'ROURKE, N.; HATCHER, L.; STEPANSKI, E.J. **Using SAS for Univariate and Multivariate Statistics**. SAS Institute, Inc; Cary, NC: 2005. 514p.

PEREIRA, A.L.N.; LOPES, E.S.; DIAS, A.N. Análise técnica e de custo do *feller buncher* e *skidder* na colheita de madeira em diferentes produtividades do povoamento. **Ciência Florestal**, v. 25, n. 4, p. 981-989, 2015.

SAMPIETRO, J.A.; LOPES, E.S. Compactação de um Cambissolo e Neossolo submetidos a diferentes intensidades de tráfego de Feller Buncher e Skidder. **Scientia Forestalis**, v.39, n.90, p.265-272, 2011.

SANT'ANNA, C. M. **Fatores humanos relacionados com a produtividade do operador de motosserra no corte florestal**. 1992. 145 f. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG, 1992.

SANTOS, L.N. et al. Avaliação de custos da operação de extração da madeira com forwarder. **Cerne**, v. 22, n.1, p. 27-34, 2016.

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

SAS 9.2. Language Reference: Dictionary, Fourth Edition. Cary, NC: **SAS Institute Inc**, 1999.

STEVENS, J. **Applied multivariate statistics for the social sciences**. 4th ed. Mahwah, NJ: Erlbaum. 2002. 720p.

SZYMCZAK, D.A. et al. Compactação do solo causada por tratores florestais na colheita de *Pinus taeda* L. na região sudoeste do Paraná. **Revista Árvore**, Viçosa-MG, v.38, n.4, p. 641-648, 2014.

CAPÍTULO III

**MODELO DE PROGRAMAÇÃO POR METAS LEXICOGRÁFICA PARA O
PLANEJAMENTO DA EXTRAÇÃO E TRANSPORTE DE MADEIRA NA EMPRESA
FLORESTAL INTEGRAL MACURIJE**

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, julho 2017. **Modelo de programação por metas lexicográfica para o planejamento da extração e transporte de madeira na Empresa Florestal Integral Macurije.** Orientador: Prof. PhD. José Antônio Aleixo da Silva. Coorientadores: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira e Prof. Dr. Daniel Alberto Álvarez Lazo.

RESUMO

O presente trabalho foi realizado com o objetivo de propor uma ferramenta de apoio a tomada de decisão nas atividades de transbordo (extração e transporte) de madeira nas florestas plantadas de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. da Empresa Florestal Integral Macurije, Província de Pinar Del Río - Cuba. Dada a característica multiobjetivo da política de gestão utilizada no planejamento da colheita florestal na empresa Macurije, justificada pela complexidade dos cenários presentes e o caráter ordinal das metas preestabelecidas, a técnica de modelagem utilizada foi a de Programação por Metas Lexicográfica (PML). Para a integração da colheita e do transporte da madeira no sistema de gestão, a PML foi combinada com o algoritmo de transbordo. A resolução do modelo proposto e especificado para o presente caso de estudo foi realizada com o software Lindo 6.1. Os resultados indicam que os principais problemas que afetam as atividades de extração e transporte de madeira na empresa Macurije foram: os elevados custos de extração e transporte; as baixas produtividades dos equipamentos de extração e transporte que dificultam a satisfação das demandas de madeira no tempo disponível; os frequentes registros de insatisfação das demandas de madeira nas unidades de transformação primária da empresa. O modelo de programação por metas lexicográficas proposto foi eficiente no auxílio do planejamento das atividades de extração e transporte de madeira para o cenário analisado e pode ser implementado a escala empresarial tanto para planejamentos operacionais como táticos da extração e transporte de madeira.

Palavras-chave: Skidders, caminhões, custos, produtividades, tomada de decisão multicritério.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, July 2017. **Lexicographic Goal Programming for wood extraction and transport planning in Macurije Integrate Forest Company.** Adviser: Prof. PhD. José Antônio Aleixo da Silva. Co-advisers: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira and Prof. Dr. Daniel Alberto Álvarez Lazo.

ABSTRACT

The present work was carried out with the objective of proposing a tool to support decision making in wood transshipment activities (extraction and transportation) in the plantations of *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. of Macurije Integrate Forest Company, Province of Pinar Del Río - Cuba. Given the multiobjective characteristic of management policy used in forest harvest planning in Macurije Company, justified by the complexity of the present scenarios, and the ordinal character of the pre-established goals, the modeling technique used was the Lexicographic Goal Programming (LGP). For the integration of wood harvesting and transportation into the management system, the LGP was combined with the transshipment algorithm. The resolution of the proposed model specified for the present case study was performed with the software Lindo 6.1. The results indicate that the main problems affecting wood extraction and transportation activities at Macurije were: high extraction and transportation costs; The low productivity of the extraction and transport equipment that make it difficult to satisfy the demands of wood in the time available; The frequent records of dissatisfaction of the demands of wood in the primary processing units of the company. The proposed Lexicographic Goal Programming model was efficient in assisting the planning of wood extraction and transport activities in the scenario analyzed and can be implemented at enterprise scale for both operational and tactical planning of wood extraction and transportation.

Keywords: Skidders, trucks, costs, productivities, Multicriteria decision making.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, juillet 2017. **Modèle de Goal Programming Lexicographique (GPL) pour la planification de l'extraction et transport du bois dans l'entreprise forestière intégrale Macurije.** Directeur de Thèse: Prof. Dr. José Antônio Aleixo da Silva. Co-directeurs de Thèse: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira et Prof. Dr. Daniel Alberto Álvarez Lazo.

RÉSUMÉ

La présente étude a été réalisée dans le but de proposer un outil de soutien à la prise de décision dans les activités de transbordement (extraction et transport) du bois dans les plantations de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. de l'entreprise forestière intégrale Macurije, province de Pinar Del Río - Cuba. Compte tenu de la caractéristique multiobjective de la politique de gestion utilisée dans la planification de la récolte forestière dans l'entreprise Macurije, justifiée par la complexité des scénarios actuels, et le caractère ordinal des buts préétablis, la technique de modélisation utilisée fut le Goal Programming Lexicographique (GPL). Pour l'intégration de l'extraction et du transport du bois dans le système de gestion, le GPL a été combiné avec l'algorithme de transbordement. La résolution du modèle proposé pour la présente étude de cas a été réalisée avec le logiciel Lindo 6.1. Les résultats indiquent que les principaux problèmes affectant les activités d'extraction et de transport du bois dans l'entreprise Macurije sont: les coûts élevés d'extraction et de transport; la basse productivité des équipements d'extraction et de transport qui difficile la satisfaction des demandes de bois (grumes) dans les unités de transformation primaire de l'entreprise; les enregistrements fréquents d'insatisfaction des demandes de bois dans les unités de première transformation de l'entreprise. Le modèle de Goal Programming Lexicographique proposé a été efficace dans l'aide à la planification des activités d'extraction et de transport du bois dans le scénario analysé et peut être implémenté à l'échelle de l'entreprise pour la planification opérationnelle et tactique de l'extraction et du transport du bois.

Mots clés: Débusqueuses, camions, coûts, productivités, la prise de décision multicritère.

1. INTRODUÇÃO

O ponto básico da tomada de decisão no Processo Produtivo Florestal é encontrar o uso mais eficiente dos recursos produtivos escassos (SOUSA et al., 2012). A colheita e transporte florestal, uma das atividades finais desse processo, constitui uma das etapas determinantes da rentabilidade florestal (ARCE; MACDONAGH; FRIEDL, 2004). A importância dessa atividade inserida no planejamento tático e/ou operacional das empresas florestais, é atribuída a sua alta participação nos custos totais da madeira posta na fábrica; participação que pode chegar até 50% dos custos totais (MALINOVSKI; MALINOVSKI, 1998; CÁNDANO, 2003).

Dada essa grande importância, as operações que integram a atividade de colheita florestal devem ser planejadas no aspecto técnico, econômico, operacional e ambiental (FREITAS; MACHADO; SILVA, 2009), o que geralmente não acontece nas empresas florestais. Por ser a última fase do processo de produção florestal, essa atividade é geralmente postergada deixando lugar à improvisações, mas essas improvisações podem ser evitadas com um planejamento das operações a serem executadas em prol de objetivos predefinidos.

A maior parte dos desafios do planejamento da colheita florestal nas empresas florestais se resume em definir de onde, para onde, quando e quanto de madeira transportar e os meios com os quais essa madeira deve ser transportada para minimizar os custos globais. Embora essas perguntas pareçam simples, as suas respostas são dificultadas pelos inúmeros e complexos cenários existentes nas empresas florestais.

O uso desses modelos matemáticos para auxílio à tomada de decisão na produção madeireira data dos anos 1960 e tem evoluído muito, passando de modelos individuais propostos para cada atividade à modelos integradores de atividades para capturar possíveis sinergias existentes entre as mesmas (BEAUDOIN; LEBEL; FRAYRET, 2005). Em relação as atividades de colheita florestal, poucas pesquisas abordam a sua integração. Entre elas se encontra o trabalho de Burger e Jamnick (1995) que integraram as atividades de colheita, armazenamento e transporte florestal.

Segundo Karsu e Morton (2015), a pesquisa operacional é o método de otimização mais utilizado no planejamento e otimização de operações, incluindo as de colheita e transporte florestal. Nessas atividades, as técnicas utilizadas são: Programação Linear, Programações Inteira e Mista, Programação Dinâmica, utilização de algoritmos e simulações (MALINOVSKI, 2007). Objetivando orientar as indústrias individualmente e facilitar o uso mais eficiente de seus recursos, a programação linear é a mais utilizada das técnicas supracitadas (MALINOVSKI et al., 2006; SOUSA et al., 2012). A literatura florestal conta com inúmeras

pesquisas que abordam esses questionamentos por meio de métodos de planejamento como a programação linear (PL) com resultados satisfatórios. Entre a ampla gama de pesquisas disponíveis na literatura florestal, pode-se citar as de Weintraub e Abramovich (1995), Brack e Marshall (1996), Palander (1997), Carlsson e Arvidsson (1998), Faria (2013), Rudek (2015), Cardoso, Oliveira e Joaquim Jr. (2016). Porém, nas últimas décadas, a comunidade científica percebeu-se dos falhos deste método e entre eles se encontra a consideração de um objetivo único que o torna um método ingênuo (LEUSCHNER, 1990).

Diante disto, as técnicas de análise de decisão multicritério (MCDA) foram se tornando as técnicas alternativas predominantemente utilizadas para auxílio a tomada de decisão em quaisquer atividades do PPF (CHEN; CHANG, 2014; COLAPINTO; JAYARAMAN e MARSIGLIO, 2015). Dessas técnicas multicritérios, as mais utilizadas na gestão florestal são os modelos de programação por metas, sendo, segundo Diaz-balteiro e Romero (2008), a programação por metas lexicográficas uma das suas variantes mais utilizadas.

Outro aspecto importante e comum à maioria dos modelos de otimização de colheita florestal encontrados na literatura, é que essas atividades mesmo sendo integradas na sua execução no campo, são analisadas por esses modelos de forma separada. Essa diferenciação, embora apresentem vantagens na hora de propor soluções técnicas específicas, não favorece uma projeção com uma visão mais integrada para propostas de soluções estratégicas em longo prazo, como permitiria sua integração. Inicialmente, as empresas otimizavam as diferentes partes de seus processos produtivos de forma separada, porém nas últimas décadas, numerosas pesquisas têm demonstrado que a integração ou ligação dessas atividades podem diminuir consideravelmente o custo global, aumentando a produtividade e reduzindo desperdícios ao longo de toda a cadeia de produção (GUNNARSSON, 2007; SINGER; DONOSO, 2007). Nesse sentido, Weintraub (2002) aponta que a integração das atividades de extração e transporte da madeira melhoraria o planejamento e a eficiência da execução das mesmas.

Adicionalmente a esses problemas de ordem técnico e metodológico na elaboração de ferramentas de otimização, a empresa Macurije cuja estrutura foi considerada na presente pesquisa, apresenta inúmeros problemas que encarecem a extração e transporte de madeira e por consequência, seu processo produtivo. Entre esses problemas, pode-se citar:

- ✓ Elevados custos de extração e transporte de madeira reportados por Guera (2013). Esse trabalho indica que os custos de colheita e transporte florestal representaram, no período de avaliação (2010-2011), 77% dos custos totais da madeira posta nos pátios das serrarias e ainda sem atingir o plano de transporte projetado para o referido período;

- ✓ Frequentes interrupções do funcionamento das unidades de transformação primária devido ao esgotamento da madeira nos pátios de armazenamento das serrarias. Tais são os casos das serrarias “Combate de Tenerías” e “Isabel Rubio” que registram numerosas interrupções devido ao atraso de abastecimento de matéria-prima;
- ✓ Frequentes abandonos de árvores derrubadas nas áreas de colheita (DOMÍNGUEZ, 2003) ou a permanência das toras durante longos períodos nos pátios das indústrias (ÁLVAREZ et al., 2010). Essas ocorrências provocam uma redução do valor da madeira no mercado, devido ao surgimento, disseminação e crescimento de fungos que afetam a qualidade da mesma. O crescimento desses fungos é favorecido pelas condições ambientais de países tropicais como Cuba. Estudos realizados por Álvarez et al. (2010) para o *Pinus caribaea* na mesma empresa revelam que as toras, após serem derrubadas, devem sofrer uma secagem ou um processamento (desdobro) em um tempo não superior a 21 dias na estação seca e não mais de 14 dias na estação chuvosa, evitando-se assim perdas na qualidade da madeira pela aparição do azulado da madeira causado pela ação de fungos como o *Aureobasidium pullulans* ou/e o *Sphaeropsis sapinea*. A coloração azul-escura que a madeira adquire depois do ataque desse fungo, apesar de não prejudicar suas propriedades físico-mecânicas, afeta-a esteticamente e a desvaloriza (NUNES, 1990);
- ✓ O baixo Incremento Médio Anual (IMA) de $6,5 \text{ m}^3/\text{ha}/\text{ano}$, nas plantações de *P. caribaea* var. *caribaea* da empresa (ALDANA et al., 2006), impõem o cultivo da espécie sobre áreas extensas para atingir as metas de produção e assegurar a sustentabilidade na mesma. Consequência disso é o aumento exponencial das distâncias de transporte da madeira que afetam significativamente as produtividades e os custos operacionais de transporte.

Baseado no anterior, para a integração das atividades de extração e transporte, se estabelece uma analogia entre o algoritmo de transbordo e a colheita e transporte de madeira. Esta analogia se realiza considerando as atividades de colheita e transporte como um sistema em que o transporte da madeira é identificado como a última atividade da colheita florestal que se define, conforme Machado et al. (2014), como um conjunto de atividades, integradas entre si, que permitem o fluxo constante de madeira, evitando-se os pontos de estrangulamento, levando os equipamentos a sua máxima utilização. Essa definição ressalta a importância da integração das duas partes (colheita e transporte florestal) como um sistema ampliado na hora de propor soluções estratégicas para evitar problemas que podem ser gerados da perda de controle do fluxo da madeira, dentro deles pontos de estrangulamentos aos que faz referência Machado et al. (2014). Esses pontos são frequentemente observados nos pátios intermediários

onde os caminhões se abastecem de madeira ou outros produtos florestais. O sistema ampliado colheita - transporte florestal visto então desde o ângulo da modelagem matemática corresponde ao modelo de transbordo onde as plantações correspondem às origens de transbordo; os pátios intermediários ou temporários situados ao bordo dos povoamentos para armazenamento da madeira após a colheita correspondem aos nós de transbordo e o destino de transbordo, aos destinos finais da madeira que, geralmente, são as indústrias de transformação primária de madeira.

Diante do acima exposto, o problema de pesquisa abordado no presente estudo é: Planejamento deficiente e elevados custos globais de extração e transporte de madeira na empresa florestal integral Macurije.

Com a hipótese de que a abordagem multicritério utilizada em um sistema ampliado que integra ambas as atividades de extração e transporte auxiliaria eficientemente a extração e transporte de madeira, o objetivo geral desta pesquisa foi propor um modelo de programação por metas lexicográfica para auxiliar o planejamento de extração e transporte de madeira em florestas plantadas de *P. caribaea* var. *caribaea* da empresa florestal integral Macurije, Cuba.

Os objetivos específicos para alcançar este objetivo geral foram:

- Determinar os principais problemas que afetam as atividades de extração e transporte de madeira e estabelecer a ordem lexicográfica dos mesmos;
- Elaborar o modelo de planejamento de extração e transporte de madeira utilizando a programação por metas lexicográfica e o algoritmo de transbordo;
- Aplicar e avaliar a eficiência do modelo de programação por metas lexicográfica no planejamento da extração e transporte de madeira em uma área da EFI Macurije.

2. MATERIAIS E MÉTODOS

2.1. Caracterização da área de estudo

A presente pesquisa foi realizada em plantações de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. das unidades silvícolas Guane e Mantua da EFI Macurije, província de Pinar del Rio, Cuba (Figura 1). O clima, segundo a classificação de Köppen (1936), é Aw e a precipitação média anual é de 1484,53 mm, a temperatura média anual de 24,53 °C e umidade relativa média anual de 81% (ALDANA et al., 2006).



Figura 1 - Localização da empresa florestal Macurije, Pinar Del Rio, Cuba

2.2. Caracterização de colheita e transporte de madeira na EFI Macurije

A empresa florestal Macurije conta com um pátio de máquinas de colheita e transporte florestal diversificado, com características técnico-econômicas específicas para o aproveitamento dos multiprodutos florestais disponíveis nas suas plantações. O fluxo tecnológico da madeira através dos processos de colheita e transporte florestal se resume nas seguintes etapas (Figura 2): A fase (1-2) corresponde à extração da madeira. Nesta fase, as plantações de *Pinus caribaea* var. *caribaea* em idade de corte sofrem uma derrubada semi-mecanizada com motosserra e subsequentemente, acontece a movimentação da madeira das áreas de abate das árvores (origens) para os pátios de armazenamento temporário (nós de transbordo) por meio de tratores (skidders) e/ou juntas de bois. As fases seguintes (2-3) e (3-4) correspondem ao transporte da madeira dos pátios de armazenamento (nós de transbordo) para as indústrias de transformação primária da madeira (serrarias, torno) e do torno para a planta de impregnação, respectivamente. Esse transporte é essencialmente rodoviário e realizado por meio de caminhões cujas características variam segundo o comprimento da madeira que é transportada em duas formas: toras curtas de 3 e 4 metros e toras longas de 12 metros. A maquinaria utilizada está composta pelas juntas de bois e os skydders para a extração da

madeira, os semirreboques para o transporte das toras longas e os caminhões articulados (carretas) para o transporte das toras curtas.

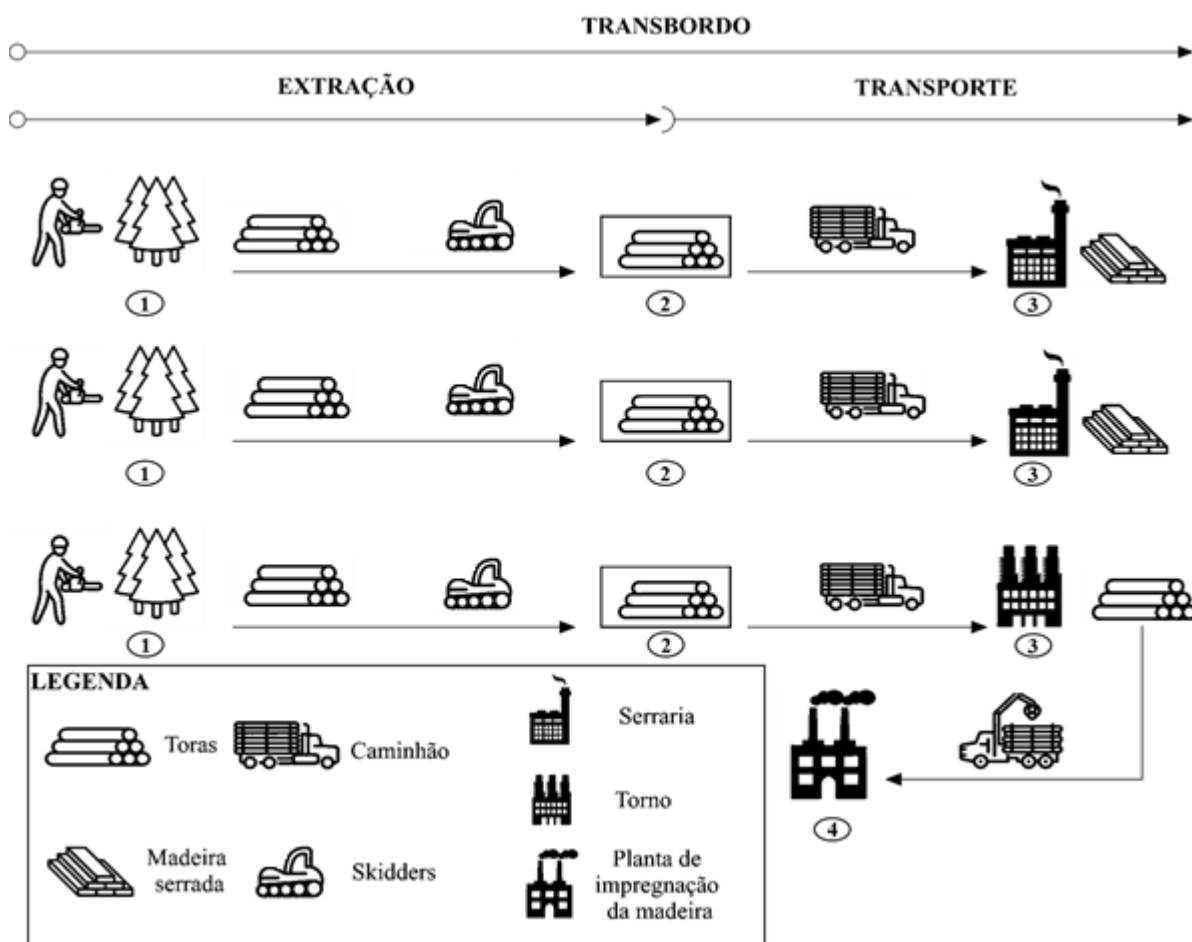


Figura 2 – Fluxo de transbordo de madeira na Empresa Florestal Integral (EFI) Macurije.

2.3. Metodologia

Para abordar a problemática da presente pesquisa, buscou-se combinar as abordagens de transbordo e as de programação por metas lexicográfica para a proposta de uma ferramenta eficiente para o auxílio de tomada de decisões adequadas na extração e transporte da madeira.

Na formulação matemática do modelo proposto, se estabeleceu uma analogia entre o algoritmo de transbordo e a colheita e transporte de madeira. Esta analogia se realizou considerando as atividades de colheita e transporte como um sistema ampliado em que o transporte da madeira é identificado como a última atividade da colheita florestal.

O sistema ampliado colheita - transporte visto então desde o ângulo da modelagem matemática corresponde ao modelo de transbordo onde os talhões correspondem às origens de transbordo, os pátios intermediários ou temporários situados ao bordo dos povoamentos para armazenamento da madeira após a extração correspondem aos nós de transbordo e o destino de

transbordo correspondem aos destinos finais da madeira que são, geralmente, as indústrias instaladas para sua transformação primária (Figura 3).

O algoritmo de transbordo foi utilizado principalmente na etapa de definição das variáveis de decisão e na etapa de formulação de determinadas restrições duras do modelo de programação por metas lexicográficas.

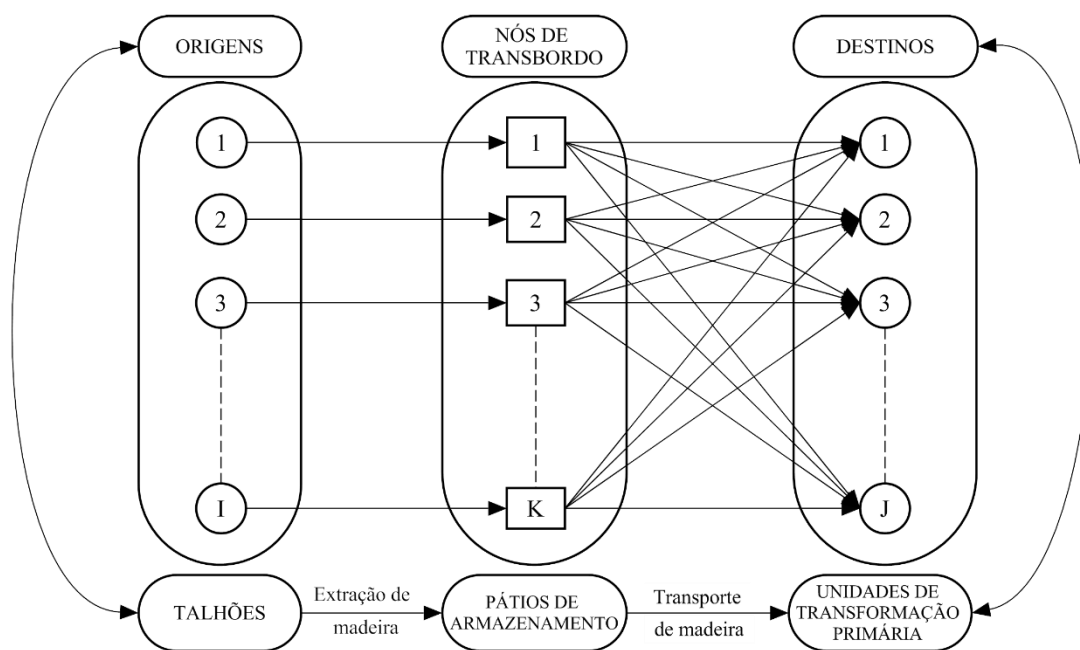


Figura 3 – Analogia entre o algoritmo de transbordo e a extração - transporte de madeira

A abordagem do problema de transbordo descrito foi realizada por um modelo de programação por metas lexicográfica cuja formulação seguiu o fluxograma da Figura 4. Esta pesquisa abrange até a fase de validação, sendo a etapa de implementação, posterior a de validação, responsabilidade da empresa. A ocorrência de mudanças significativas, no ambiente inicial no qual o modelo foi elaborado, pode levar a necessidade de atualizar os coeficientes econômicos e tecnológicos do modelo, podendo ser imperativa em caso de mudança extrema, uma reformulação do modelo, adicionando novas metas e/ou restrições.

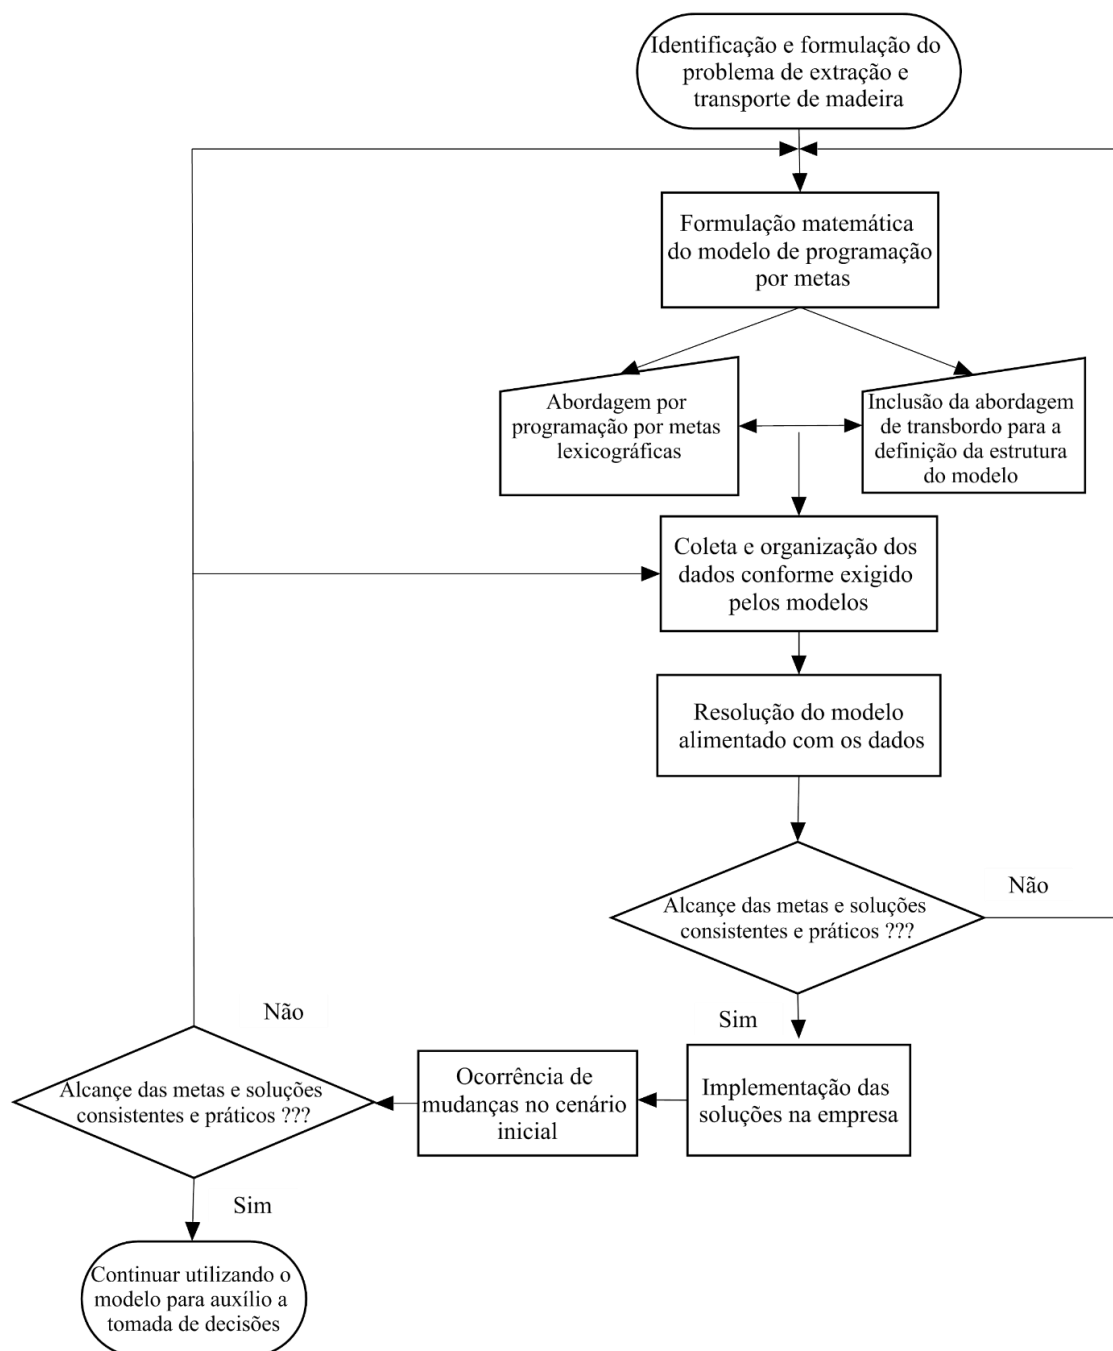


Figura 4 - Fluxograma de abordagem do problema de transbordo de madeira

2.3.1. Modelo de Programação por Metas Lexicográfica de transbordo proposto

2.3.1.1. Definição das metas e ordem lexicográfica

Uma análise previa pelo diagrama de Pareto (Figura 5) realizada em conjunto com os departamentos de economia e de transporte da empresa, permitiu identificar cinco categorias principais (20%) responsáveis pela maior parte dos problemas registrados (80%) na empresa. Convertendo essas principais categorias nas metas a serem abordadas no modelo de transbordo, tem-se por ordem de importância:

META 1: Manter, satisfazendo os planos de transporte projetados, os custos globais inferiores ao orçamento previsto para o período considerado;

META 2: Manter a produtividade de cada meio de extração e transporte para atender o suprimento da madeira as unidades de transformação primária dentro dos limites da disponibilidade tempo. Por estarem inter-relacionadas, as categorias de produtividade e tempo foram aboradas por esta meta;

META 3: Satisfazer as demandas de madeira de todas as unidades de transformação primária de madeira;

META 4: Satisfazer a demanda de madeira da planta de impregnação para postes.




Figura 5 – Diagrama de Pareto (80/20) para as atividades de colheita florestal na EFI Macurije.

2.3.1.2. Proposta de um modelo de programação por metas lexicográfica para transbordo (extração e transporte) de madeira.

2.3.1.2.1. Especificação dos conjuntos, parâmetros e variáveis de decisão.

- **Conjuntos**

I: Total das origens de transbordo (talhões);

J: Total dos destinos de transbordo (unidades de transformação primária);

K: Total de pátios de armazenamento, sendo a quantidade de pátios proporcional à área do talhão;

L: Sistema de colheita ou formas (comprimentos) em que a madeira é extraída e transportada;

$l = 1 \Rightarrow tora curta$

$l = 2 \Rightarrow tora longa$

M: Total de tipos de maquinaria de extração e transporte de madeira utilizada;

Extração de madeira

$m = 1 \Rightarrow J - 80A$

$m = 2 \Rightarrow John\ Deere$

$m = 3 \Rightarrow Boi$

$m = 4 \Rightarrow J - 80A + Boi$

$m = 5 \Rightarrow John\ Deere + Boi$

Transporte de madeira

$m = 6 = KRAZ - 257$ (madeira curta)

$m = 7 = KAMAZ - 4310$ (madeira comprida)

$m = 8 = URAL - 4320$ (madeira comprida)

- **Parâmetros**

DM_j : Demanda de madeira no destino j ($j \in J$);

$DMUTP$: Demanda de Madeira nas Unidades de Transformação Primária;

α : Máxima redução tolerável para a variação da demanda de madeira nas unidades de transformação primária;

β : Máximo aumento tolerável para a variação da demanda de madeira nas unidades de transformação primária;

τ_{ik}^{lm} : Tempo de extração da madeira de tipo l ($l \in L$) do talhão i ($i \in I$) ao pátio de armazenamento k ($k \in K$) com a maquinaria m ($m \in M$);

τ_{ik} : Disponibilidade de tempo para a extração da madeira da origem i ($i \in I$) ao pátio de armazenamento k ($k \in K$);

τ_{kj}^{lm} : Tempo de transporte da madeira de tipo l ($l \in L$) do pátio de armazenamento k ($k \in K$) ao destino j ($j \in J$) com a maquinaria m ($m \in M$);

τ_{kj} : Disponibilidade de tempo para o transporte do pátio de armazenamento k ($k \in K$) ao destino j ($j \in J$);

R_{ik}^{lm} : Produtividade de extração (m^3/h) da madeira de tipo l ($l \in L$) do talhão i ($i \in I$) ao pátio de armazenamento k ($k \in K$) com a maquinaria m ($m \in M$);

R_{kj}^{lm} : Produtividade de transporte (m^3/h) da madeira de tipo l ($l \in L$) do pátio de armazenamento k ($k \in K$) ao destino j ($j \in J$) com a maquinaria m ($m \in M$);

C_{ik}^{lm} : Custo unitário de extração da madeira de tipo l ($l \in L$) do talhão i ($i \in I$) ao pátio de armazenamento k ($k \in K$) com a maquinaria m ($m \in M$). Nestes custos de extração, estão incluídos os custos fixos de ativação dos pátios intermediários de armazenamento de madeira;

T_{kj}^{lm} : Custo unitário de transporte da madeira de tipo l ($l \in L$) do pátio de armazenamento k ($k \in K$) ao destino j ($j \in J$) com a maquinaria m ($m \in M$);

A_i : Área (em hectares) da origem i associada ao conjunto de pátios de armazenamento k .

$OR\mathcal{C}_e$: Orçamento destinado para as atividades de extração de madeira para um período determinado

$OR\mathcal{C}_t$: Orçamento destinado para as atividades de transporte de madeira para um período determinado

O_{ORIG} : Oferta de madeira em todas origens de transbordo

O_i : Oferta de madeira em cada origem i

- **Variáveis de decisão e variáveis de desvios**

X_{ik}^{lm} : Volume (m^3) de madeira l ($l \in L$) a ser extraída do talhão i ($i \in I$) ao pátio de armazenamento k ($k \in K$) com a maquinaria m ($m \in M$);

Y_{kj}^{lm} : Volume (m^3) de madeira l ($l \in L$) a serem transportados do pátio de armazenamento k ($k \in K$) ao destino j ($j \in J$) com a maquinaria m ($m \in M$);

n_i & p_i : São os desvios negativos e positivos da prioridade p com respeito ao seu nível de aspiração.

2.3.1.2.2. Formulação matemática do modelo genérico

$$LexMin [(p_1); (p_2 + p_3 + p_4 + p_5 + p_6 + p_7 + p_8 + p_9); (n_{10} + n_{11} + n_{12}); (n_{13})] \quad (01)$$

Sujeito a:

RESTRICÇÕES FRACAS (METAS)

$$\sum_{i=1}^I \sum_{k=1}^K \sum_{l=1}^L \sum_{m=1}^M C_{ik}^{lm} X_{ik}^{lm} + \sum_{j=1}^J \sum_{k=1}^K \sum_{l=1}^L \sum_{m=1}^M T_{kj}^{lm} Y_{kj}^{lm} + n_1 - p_1 = OR\mathcal{C}_e + OR\mathcal{C}_t \quad (02)$$

$$\sum_{i=1}^I \sum_{k=1}^K \sum_{l=1}^L X_{ik}^{l1} + n_2 - p_2 = \tau_{ik}^1 \cdot R^1 \quad (03)$$

$$\sum_{i=1}^I \sum_{k=1}^K \sum_{l=1}^L X_{ik}^{l2} + n_3 - p_3 = \tau_{ik}^2 \cdot R^2 \quad (04)$$

$$\sum_{i=1}^I \sum_{k=1}^K \sum_{l=1}^L X_{ik}^{l3} + n_4 - p_4 = \tau_{ik}^3 \cdot R^3 \quad (05)$$

$$\sum_{i=1}^I \sum_{k=1}^K \sum_{l=1}^L X_{ik}^{l4} + n_5 - p_5 = \tau_{ik}^4 \cdot R^4 \quad (06)$$

$$\sum_{i=1}^I \sum_{k=1}^K \sum_{l=1}^L X_{ik}^{l5} + n_6 - p_6 = \tau_{ik}^5 \cdot R^5 \quad (07)$$

$$\sum_{i=1}^I \sum_{k=1}^K \sum_{l=1}^L Y_{kj}^{l6} + n_7 - p_7 = \tau_{kj}^6 \cdot R^6 \quad (08)$$

$$\sum_{i=1}^I \sum_{k=1}^K \sum_{l=1}^L Y_{kj}^{l7} + n_8 - p_8 = \tau_{kj}^7 \cdot R^7 \quad (09)$$

$$\sum_{i=1}^I \sum_{k=1}^K \sum_{l=1}^L Y_{kj}^{l8} + n_9 - p_9 = \tau_{kj}^8 \cdot R^8 \quad (10)$$

$$\sum_{k=1}^K \sum_{l=1}^L \sum_{m=1}^M Y_{k1}^{lm} + n_{10} - p_{10} = DM_1 \quad (11)$$

$$\sum_{k=1}^K \sum_{l=1}^L \sum_{m=1}^M Y_{k2}^{lm} + n_{11} - p_{11} = DM_2 \quad (12)$$

$$\sum_{k=1}^K \sum_{l=1}^L \sum_{m=1}^M Y_{k3}^{lm} + n_{12} - p_{12} = DM_3 \quad (13)$$

$$\sum_{k=11}^L \sum_{l=2}^L \sum_{m=7}^8 Y_{k4}^{2m} + n_{13} - p_{13} = D_{IMP} \quad ; (l = 2 \text{ e } m = 7 \text{ e } 8) \quad (14)$$

RESTRICÇÕES DURAS

$$\sum_{i=1}^I \sum_{k=1}^K \sum_{l=1}^L \sum_{m=1}^M X_{ik}^{lm} - \sum_{j=1}^J \sum_{k=1}^K \sum_{l=1}^L \sum_{m=1}^M Y_{kj}^{lm} = 0 \quad (15)$$

$$\sum_{i=1}^I \sum_{k=1}^K \sum_{l=1}^L \sum_{m=1}^M X_{ik}^{lm} \geq D_{MIN} \quad (16)$$

$$\sum_{j=1}^J \sum_{k=1}^K \sum_{l=1}^L \sum_{m=1}^M Y_{kj}^{lm} \leq D_{MAX} \quad (17)$$

Sendo:

$$D_{MIN} = (1 - \alpha) \cdot DMUTP \quad (18)$$

$$D_{MAX} = (1 + \beta) \cdot DMUTP \quad (19)$$

$$\sum_{i=1}^I \sum_{k=1}^K \sum_{l=1}^L \sum_{m=1}^M X_{ik}^{lm} \leq O_{ORIG} \quad (20)$$

$$\sum_{k=1}^K \sum_{l=1}^L \sum_{m=1}^M X_{ik}^{lm} \leq O_i \tag{21}$$

$$\sum_{m=1}^M X_{ik}^{lm} - \sum_{m=1}^M Y_{kj}^{lm} \leq 0; \text{ para } l = 1 \text{ \& } \forall X, i = k \tag{22}$$

$$\sum_{m=1}^M X_{ik}^{lm} - \sum_{m=1}^M Y_{kj}^{lm} \geq 0; \text{ para } l = 2 \text{ \& } \forall X, i = k \tag{23}$$

No modelo de programação por metas lexicográficas acima proposto, a expressão 01 que representa a função objetivo, indica a minimização das variáveis de desvio não desejadas, $(p_1); (p_2 + p_3 + p_4 + p_5 + p_6 + p_7 + p_8 + p_9); (n_{10} + n_{11} + n_{12}); (n_{13})$, correspondentes as metas 1, 2, 3, e 4, respectivamente. As expressões 02 a 14 representam as metas ou conjunto de restrições fracas e as restrições de 15 a 22 representam o conjunto de restrições duras.

A expressão 02 corresponde a meta 1 que permite garantir que os custos globais de transbordo serão menores ou iguais ao orçamento previsto para o período considerado. As expressões de 03 a 10 representam a meta 2 que consiste em manter a produtividade de cada meio de extração e transporte para atender as demandas de madeira nas unidades de transformação primária dentro dos limites da disponibilidade tempo. Em relação as expressões 11, 12, e 13, as mesmas representam a meta 3 que corresponde a satisfação das demandas de madeira em cada unidade e todas as unidades de transformação primária de madeira.

A planta de impregnação de madeira para produção de postes é uma das unidades mais lucrativas da empresa. A satisfação da demanda de madeira nessa unidade, que é única ao nível do país, foi representada no modelo pela expressão 14. A restrição da expressão 15 permite se assegurar que o volume de madeira extraído é igual ao volume de madeira transporte. A mesma restrição tem que ser aplicada em cada um dos pátios de armazenamento para garantir que todo o volume de madeira extraído é igual ao transportado. As restrições nas expressões 16, 17, 18 e 19 indicam que as demandas de madeira nas unidades de transformação primária podem variar 10% a mais ou a menos. A restrição da expressão 20 permite garantir que o somatório de toda a madeira a ser extraída e transportada para atender as demandas é menor ou igual ao volume disponível e habilitado para corte nas origens. A restrição da expressão 21 garante o mesmo em cada uma das origens.

As restrições das expressões 22 e 23 permitem assegurar a compatibilidade entre os sistemas de colheita utilizados em ambas as fases de transbordo de madeira. A expressão 22 indica que a quantidade de toras curtas extraídas até determinado pátio de armazenamento tem

que ser menor ou igual a quantidade de toras curtas a ser transportado desde esse ponto. Os volumes de toras longas extraídas e transportadas são controladas pela restrição da expressão 23. A mesma estabelece que o volume de madeira extraída em toras longas tem que ser maior o igual ao transportado. As toras longas excedentes podem ser cortadas nos pátios de armazenamento para a obtenção de toras curtas, mais o inverso é impossível já que essas toras, uma vez obtidas antes da extração, não podem aumentar suas dimensões nos pátios para ser transportadas em forma de toras longas.

Na EFI Macurije, os pátios intermediários de armazenamento de madeira são construídos pelos próprios skidders antes da inicialização da extração de madeira, pelo que os custos fixos de ativação desses pátios são incluídos nos custos de extração de madeira.

2.3.2. Implementação do modelo de programação por metas lexicográfica proposto

Para validar o modelo genérico proposto através da verificação da sua funcionalidade e consistência dos resultados gerados, o mesmo foi utilizado para a resolução de um problema de planejamento de transbordo de madeira na EFI Macurije para um período de um mês.

O presente problema consiste em determinar de onde, para onde, quando e quanto de madeira transportar e os meios a serem utilizados para atender as metas definidas no modelo genérico.

Apesar da abundância de informações nas empresas florestais, as mesmas não se encontram nas formas exigidas pelos modelos e organiza-las é um trabalho difícil e desgastante (FELIPE *et al.*, 2001). Os dados necessários para a resolução do presente problema foram obtidos seguindo a sequência de trabalho utilizado por Guera (2013):

- Definição das origens de transbordo suas respectivas ofertas de madeira para determinado período (Tabela 1);
- Definição dos nós de transbordo (pátios intermediários de armazenamento) construídos a uma distância ótima de extração de madeira (Apêndice 3.2);
- Definição dos destinos de transbordo (pátio de armazenamento das serrarias) e suas respectivas demandas para determinado período (Tabelas 1);
- Determinação das distâncias de extração e transporte da madeira. As de transporte foram obtidas com a base cartográfica (1:25:000) do grupo empresarial GEOCUBA, com erro máxima de 10 m (Tabela 1);
- Determinação dos coeficientes econômicos, tecnológicos dos médios de extração e transporte de madeira (resultados do capítulo II).

Tabela 1 – Distâncias entre origens e destinos e ofertas e demandas de madeira

| | | ORIGENS ^a | | | DESTINOS ^b (km) | | |
|--------|----------------------------|----------------------|--------|--------------------------|----------------------------|------|----------------------|
| US | UBPF | LOTE | TALHÃO | OFERTA (m ³) | SCT | SIR | PIM |
| MANTÚA | GUASIMAS | 39 | 13 | 462,4 | 30,5 | 46,5 | 38,4 |
| | CAÑAS | 88 | 17 | 218,6 | 26 | 42 | 92 |
| | MACURIJE | 17 | 27 | 251,6 | 70 | 86 | 77,95 |
| | RÍO MANTÚA | 125 | 12 | 639 | 26 | 42 | 21,03 |
| | | 125 | 20 | 491,4 | | | |
| GUANE | SÁBALO | 96 | 1 | 636,5 | 31 | 16,4 | 22,76 |
| | 20 DE MAYO | 36 | 13 | 158,2 | 7 | 12,7 | 19,8 |
| | LOS OCUJES | 49 | 34 | 159 | 28 | 44 | 35,9 |
| | LA MINADORA | 46 | 11 | 466,1 | 28 | 44 | 35,9 |
| | | 11 | 17 | 255 | 39,5 | 42,5 | 34,4 |
| | O TORNO | | | | | | 9 |
| | DEMANDAS (m ³) | | | | 2300 | 500 | 875 (2500 postes) |

^a Parte das áreas em idades de rotação no ano 2015; ^b Principais destinos da madeira na EFI Macurije.

O problema de programação por metas de extração e transporte de madeira acima descrito foi resolvido com o software LINDO versão 6.1.

3. RESULTADOS E DISCUSSÃO

3.1. Solução do problema de transbordo de madeira por meio do modelo de programação por metas lexicográficas proposto

O problema de extração e transporte de madeira abordado com o modelo de programação por metas lexicográfica proposto gerou um modelo específico constituído por 208 variáveis, das quais 182 são variáveis de decisão e 26 variáveis de desvio; 4 metas subdivididas em 13 prioridades; e 45 restrições (Apêndice 3.1). Os resultados da resolução desse problema estão resumidos na Tabela 2.

Tabela 2 - Resultados da resolução do problema de transbordo planteado

| Origem | EXTRAÇÃO | | | TRANSPORTE | | | Destino |
|---------------|-----------------|---------|-------------------------------------|----------------|---------|----------------------------------|----------------|
| | Var. | V (m³) | Observação | Var. | V (m³) | Observação | |
| 1 | X_{11}^{12} | 134,027 | SC: Tora curta ME: John Deere | Y_{12}^{16} | 134,027 | SC: Tora curta MT: Kraz- 257 | Serraria CT |
| | X_{11}^{22} | 328,373 | SC: Tora longa ME: John Deere | Y_{13}^{27} | 328,373 | SC: Tora longa MT: Kamaz-4310 | O torno |
| 2 | X_{22}^{23} | 218,600 | SC: Tora longa ME: Junta de bois | Y_{22}^{27} | 218,600 | SC: Tora longa MT: Kamaz-4310 | Serraria CT |
| 3 | X_{33}^{23} | 192,673 | SC: Tora longa ME: Junta de bois | Y_{32}^{27} | 192,673 | SC: Tora longa MT: Kamaz-4310 | Serraria CT |
| 4 | X_{44}^{12} | 639,000 | SC: Tora curta ME: John Deere | Y_{42}^{16} | 639,000 | SC: Tora curta MT: Kraz- 257 | Serraria CT |
| 5 | X_{55}^{12} | 491,399 | SC: Tora curta ME: John Deere | Y_{52}^{16} | 491,399 | SC: Tora curta MT: Kraz- 257 | Serraria CT |
| 6 | X_{66}^{22} | 636,500 | SC: Tora longa ME: John Deere | Y_{61}^{27} | 500,000 | SC: Tora longa MT: Kamaz-4310 | Serraria IR |
| | | | | Y_{63}^{27} | 136,500 | SC: Tora longa MT: Kamaz-4310 | O torno |
| 7 | X_{77}^{12} | 158,199 | SC: Tora curta ME: John Deere | Y_{72}^{16} | 158,199 | SC: Tora curta MT: Kraz- 257 | Serraria CT |
| 8 | X_{88}^{22} | 159,000 | SC: Tora longa ME: John Deere | Y_{83}^{27} | 159,000 | SC: Tora longa MT: Kamaz-4310 | O torno |
| 9 | X_{99}^{22} | 118,973 | SC: Tora longa ME: John Deere | Y_{92}^{27} | 466,100 | SC: Tora longa | Serraria CT |
| | X_{99}^{23} | 347,127 | SC: Tora longa ME: Junta de bois | | | MT: Kamaz-4310 | |
| 10 | X_{1010}^{22} | 255,000 | SC: Tora longa ME: John Deere | Y_{103}^{27} | 255,000 | SC: Tora longa MT: Kamaz-4310 | O torno |
| 11 (Torno) | | | | Y_{114}^{27} | 878,873 | SC: Tora longa MT: Kamaz-4310 | PIM |

SC: Sistema de Colheita; ME: Meio de extração; MT: Meio de transporte; CT: Combate de Tenerías; IR: Isabel Rubio; PIM: Planta de Impregnação da Madeira.

Em todos os níveis, as variáveis de desvio não desejadas foram iguais a zero (Tabela 3). Isso indica que todas as metas e submetas foram alcançadas para os valores das variáveis de decisão resumidos na Tabela 2.

Tabela 3 - Valores das variáveis de desvio nos diferentes níveis

| Níveis | Variáveis de desvio | Valores | Níveis | Variáveis de desvio | Valores |
|-----------|---------------------|----------|-----------|---------------------|----------|
| 01 | N1 | 0,000 | 08 | N8 | 618,481 |
| | P1* | 0,000 | | P8* | 0,000 |
| 02 | N2 | 3068,159 | 09 | N9 | 3367,679 |
| | P2* | 0,000 | | P9* | 0,000 |
| 03 | N3 | 381,927 | 10 | N10* | 0,000 |
| | P3* | 0,000 | | P10 | 0,000 |
| 04 | N4 | 0,000 | 11 | N11* | 0,000 |
| | P4* | 0,000 | | P11 | 0,000 |
| 05 | N5 | 3826,560 | 12 | N12* | 0,000 |
| | P5* | 0,000 | | P12 | 3,873 |
| 06 | N6 | 4060,800 | 13 | N13* | 0,000 |
| | P6* | 0,000 | | P13 | 3,873 |
| 07 | N7 | 1653,213 | | | |
| | P7* | 0,000 | | | |

*Variáveis de desvio não desejadas.

Na fase da extração de madeira, a solução do modelo indicou uma maior utilização do sistema de colheita “tora longa” (61,33%) e do skidder John Deere (79,38%) para atingir as metas estabelecidas (Tabela 4).

Em relação ao transporte, o sistema de colheita “tora longa” foi também o mais indicado, com sua utilização no transporte de 61,33% da madeira transportada (Tabela 4). O caminhão Kamaz-4310 foi mais indicada, sendo o mesmo utilizado para o transporte de 61,33% da madeira. A solução do modelo indicou que não é viável utilizar o skidder J-80A e o caminhão URAL-4320 se aspirar-se alcançar as metas preestabelecidas.

Tabela 4 – Distribuição da madeira por maquinaria e sistema de colheita no transbordo de madeira

| S.C. | Extração | | | | Transporte | | | |
|--------------|-------------------|----------------------|------------------|----------------------|----------------------|----------------------|------------------|----------------------|
| | Junta de bois | John Deere | J-80A | Total | Kraz-257 | Kamaz-4310 | URAL-4320 | Total |
| T.C. | - | 1422,625 | 0,000 | 1422,625 (38,67%) | 1422,625 | - | - | 1422,625 (38,67%) |
| T.L. | 758,4 | 1497,846 | - | 2256,246 (61,33%) | - | 2256,246 | 0,000 | 2256,246 (61,33%) |
| Total | 758,4 (20,62%) | 2920,471 (79,38%) | 0,000 (0,00%) | 3678,871 | 1422,625 (38,67%) | 2256,246 (61,33%) | 0,000 (0,00%) | 3678,871 |

S.C.: Sistema de colheita; TC: Tora curta; T.L.: Tora longa

3.2. Análise da sensibilidade do modelo a variação dos recursos

A possibilidade de variação dos coeficientes econômicos e tecnológicos utilizados, para alimentar os modelos determinísticos como o proposto, impõe a necessidade de realizar uma

análise de sensibilidade. Analisou-se o comportamento do modelo a mudanças no orçamento previsto para extração e transporte de madeira, nas disponibilidades de madeira nas origens e nas demandas de madeira nos destinos.

A Tabela 5 indica, para cada recurso, os acréscimos e decréscimos permissíveis sem que se modifique o conjunto de variáveis básicas que constituem a solução ótima para alcançar as metas desejadas pela empresa. Mudanças nos valores atuais dos recursos, que levarem a valores que se encontrarem fora dos intervalos, inviabilizariam a solução encontrada para o problema de planejamento de transbordo de madeira. Essas mudanças gerariam um novo cenário para o qual uma nova solução ótima deveria ser determinada rodando o modelo.

A comparação dos volumes de madeira disponíveis nas origens com os volumes extraídos indicou a existência de um excedente de 58,927 m³ no talhão 27 do lote 17 da UBPF “Macurije” (Figura 6). Esse excedente será incluído nos planejamentos subsequentes.




Figura 6- Volumes de madeira disponíveis e extraídos

Todas as demandas de madeira foram atendidas em todos os destinos. Nas serrarias “Combate de Tenerías” e “Isabel Rubio” os volumes de madeira recebidas foram exatamente iguais as demandas, porem no torno e na planta de impregnação, registrou-se um excedente de apenas 3,873 m³ (Figura 7 e Tabela 5). Esse excedente observado para um período de um mês é considerado negligenciável e manejável por essas unidades sem gerar maiores problemas de planejamento.




Figura 7 – Relação entre as demandas e os volumes de madeira recebida nos destinos

Tabela 5 – Resultados da análise da sensibilidade do modelo a variação dos recursos

| RECURSOS | | Recurso Atual | Excesso ou Deficiência | AP | DP |
|-------------------------------|---------------------------|---------------|------------------------|----------|----------|
| DISPONIBILIDADE DE MADEIRA | Orçamento para transbordo | 14000 | 0,00 | 453,620 | 29,814 |
| | Guasimas (L39-T13) | 462,4 | 0,00 | 148,290 | 9,746 |
| | Cañas (L88-T17) | 218,6 | 0,00 | 126,780 | 8,333 |
| | Macurije (L17-T27) | 251,6 | 58,927 | INFINITO | 58,927 |
| | Río Mantúa (L125-T12) | 639 | 0,00 | 130,953 | 8,607 |
| | Río Mantúa (L125-T20) | 491,4 | 0,00 | 130,953 | 8,607 |
| | Sábalo (L96-T1) | 636,5 | 0,00 | 150,305 | 9,879 |
| | 20 de Mayo (L36-T13) | 158,2 | 0,00 | 87,673 | 5,762 |
| | Los Ocujes (L49-T34) | 159 | 0,00 | 139,062 | 9,139 |
| | Los Ocujes (L46-T11) | 466,1 | 0,00 | 132,793 | 8,727 |
| | La Minadora (L11-T17) | 255 | 0,00 | 170,518 | 12,812 |
| | TOTAL | 3737,800 | 58,927 | INFINITO | 58,927 |
| PRODUTIVIDADES DE MAQUINARIAS | J-80A | 15,98 | 15,98 | INFINITO | 15,98 |
| | John Deere | 17,2 | 1,989 | INFINITO | 1,989 |
| | Junta de bois | 3,95 | 0,00 | 0,689 | 0,200 |
| | J-80A + Boi | 19,93 | 19,93 | INFINITO | 19,93 |
| | John Deere + Boi | 21,15 | 21,15 | INFINITO | 21,15 |
| | Kraz- 257 | 16,02 | 8,610 | INFINITO | 8,610 |
| | Kamaz-4310 | 19,55 | 3,221 | INFINITO | 3,221 |
| | Ural-4320 | 17,54 | 17,54 | INFINITO | 17,54 |
| DEMANDAS DE MADEIRA | Isabel Rubio | 500 | 0,00 | 5,123 | 487,415 |
| | Combate de Tenerías | 2300 | 0,00 | 4,164 | 144,098 |
| | Torno | 875 | 3,873 | 3,873 | INFINITO |
| | Planta de impregnação | 875 | 3,873 | 3,873 | INFINITO |

AP = Acréscimo Permissível; DP= Decréscimo Permissível

Em relação as produtividades das maquinas, os resultados indicam todas as disponibilidades das produtividades das maquinas não foram explotadas. A solução indica como excedentes as produtividades de todas as máquinas que não foram indicadas na solução. Na extração de madeira, o skidder John Deere operou 1,989 m³/h por debaixo da sua capacidade máxima e a junta de bois na sua capacidade máxima. Em relação ao transporte, os caminhões Kraz- 257 e Kamaz-4310 operaram 8,61 m³/h e 3,22 m³/h, respectivamente abaixo das suas capacidades máximas.

Os resultados obtidos indicam que o modelo proposto é capaz de auxiliar, eficientemente, o planejamento da extração e transporte de madeira na empresa Macurije. As combinações propostas pelo modelo permitem atender as demandas nas principais unidades de transformação primária com as máquinas disponíveis, no tempo disponível.

4. CONCLUSÕES

- Os principais problemas que afetam as atividades de extração e transporte de madeira na EFI Macurije foram principalmente: elevados custos de extração e transporte; baixas produtividades dos equipamentos de extração e transporte que dificultam a satisfação das demandas de madeira no tempo disponível; insatisfação das demandas de madeiras nas unidades de transformação primária da empresa;
- O modelo de programação por metas lexicográfica foi eficiente no auxílio do planejamento das atividades de extração e transporte de madeira para o cenário analisado;
- O modelo pode ser utilizado a escala empresarial tanto para os planejamentos operacionais como táticos da extração e transporte de madeira.

5. REFERÊNCIAS

ALDANA, E.; PUENTES, M.; ROMERO, J.L. **Proyecto de Ordenación EFI Macurije**. La Habana: Ministerio de la Agricultura; 2006. 101 p.

ÁLVAREZ, L.D. et al. **Aprovechamiento forestal en el occidente de cuba y su impacto sobre el medio ambiente**. Pinar del Rio: UPR, 2010. 48 p. Acesso em: 15/07/2016 e disponível em: <<http://www.monografias.com/trabajos-pdf/aprovechamiento-forestal/aprovechamiento-forestal.shtml>>

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.207-217, 2004.

BEAUDOIN, D.; LEBEL, L.; FRAYRET, J. **Tactical supply chain planning in the forest products industry**. Working Paper DT-2005-JMF-6. Université Laval, Québec, Canada, 2005. 42p.

BRACK, C.L.; MARSHALL, P.L. A test of knowledge-based forest operations scheduling procedures. **Canadian Journal of Forest Research**, v. 26, n. 7, p. 1193-1202, 1996.

BURGER, D.H.; JAMNICK, M.S. Using linear programming to make wood procurement and distribution decisions. **The Forestry Chronicle**, v. 71, n. 1, p. 89-96, 1995.

CÁNDANO, F. **Propuesta para el perfeccionamiento de la tecnología de aprovechamiento de madera en rodales de *Pinus caribaea* en la provincia de Pinar del Río**. 1998. 117 f. Tesis (Doctorado en Ciencias Forestales) - Universidad de Pinar del Rio, Cuba.

CÁNDANO, F. **Aprovechamiento Forestal**. Pinar del Rio, Cuba: Editorial Científico Técnica, 2003. 111 p.

CARDOSO, L.E.Z.; OLIVEIRA, P.P.; JOAQUIM JUNIOR, C.F. Redução de custos no transporte de madeira por meio de roteirização otimizada: um estudo de caso. Botucatu, SP, **Tekhne e Logos**, v.7, n.1, p. 31-46, 2016.

CARLSSON, D.; ARVIDSSON, P. A. Optimized route planning – good for both: profits and the environment. **Resultat-SkogForsk**, n. 23, p. 4, 1998.

CHEN, Y.T.; CHANG, C.T. Multi-coefficient goal programming in thinning schedules to increase carbon sequestration and improve forest structure. **Annals of Forest Science, Springer Verlag/EDP Sciences**, v. 71, n. 8, p. 907-915, 2014.

COLAPINTO, C.; JAYARAMAN, R.; MARSIGLIO, S. **Multi-criteria decision analysis with goal programming in engineering, management and social sciences: a state-of-the art review**, *Annals of Operations Research*, 2015, 1–34.

DIAZ-BALTEIRO, L.; ROMERO, C. Making forestry decisions with multiple criteria: A review and an assessment. **Forest Ecology and Management**, v. 255, n.8, p. 3222-3241, 2008.

DOMÍNGUEZ, F. **Selección de tecnologías de Aprovechamiento de la Madera con Impacto Reducido, mediante técnicas de decisión multicriterio**. 2003. 141f. Tesis (Doctorado en Ciencias Forestales) - Universidad de Alicante (España) – Universidad de Pinar del Río, Cuba.

FARIA, A.L.R. Programação aplicada ao microplanejamento da colheita florestal em plantios de *Eucalyptus* sp. 2013. 108f. Dissertação (Mestrado em Engenharia Florestal) - Universidade de Lavras, Minas Gerais.

FELIPE, P. et al. **Programación matemática I**. Habana, Cuba: Editorial Félix Varela, 2001.351p.

FREITAS, L.C.; MACHADO, C.C.; SILVA, G.C. Colheita Florestal. **Revista da madeira** - edição n°121. 2009. Acesso em: 31/08/2016 e disponível em: http://www.remade.com.br/br/revistadamadeira_materia.php?num=1422&subject=Colheita%20Florestal&title=A%20mecaniza%20E3o%20da%20colheita%20florestal%20no%20Brasil

GUERA, O.G.M. **Modelo matemático de extracción-transporte de madera y control de calidad de madera aserrada para *Pinus caribaea* Morelet var. *caribaea* Barret y Golfari**. ESTUDIO DE CASO EFI MACURIJE. 2013. 137f. Tesis (Maestría en Ciencias Forestales) – Universidad de Pinar del Río, Pinar del Río, Cuba.

GUNNARSSON, H. **Supply chain optimization in the forest industry**. 2007. 40 f. Dissertation (PhD) - Linkoping University (Institute of Technology), Sweden.

KARSU, Ö.; MORTON, A. Inequity averse optimization in operational research. **European Journal of Operational Research**, v. 245, p. 343–359, 2015.

LEUSCHNER, W. A. **Forest regulation, harvest scheduling, and planning techniques**. New York: John Wiley & Sons, 1990. 281 p.

MACHADO, C.C. et al. O setor Florestal Brasileiro e a colheita florestal. In: MACHADO, C.C. **Colheita florestal**. 2. Ed. Minas Gerais: Editora UFV, 2014. Cap. I, p. 15-45.

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

MALINOVSKI, R. A. et al. 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**, Curitiba, v. 36, n. 2, p. 169-182, 2006.

MALINOVSKI, R. A. **Otimização da distância de extração de madeira com forwarder**. 2007. 94 f. Tese (Doutorado em Agronomia/Energia na Agricultura) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2007.

NUNES, L. Tratamento do azulado de madeira verde: problemas e perspectivas futuras. In: CONGRESSO FLORESTAL NACIONAL, 2. 1990, Porto.

PALANDER, T. A local DLP-GIS-LP system for geographically decentralized wood procurement planning and decision making. **Silva Fennica**, v. 31, n. 2, p. 179-192, 1997.

RUDEK, A. **Planejamento da colheita de madeira em região montanhosa com uso de modelagem espacial e programação linear inteira**. 2015. 91f. Dissertação (Mestrado em Ciências Florestais) – Universidade estadual do centro-oeste (UNICENTRO), Paraná, Brasil.

SINGER, M.; DONOSO, P. Internal supply chain management in the chilean sawmill industry. **International Journal of Operations and Production Management**, v. 27, n. 5, p. 524-542, 2007.

SOUSA, R.A.T.M. et al. Utilização de programação linear na análise do transporte principal de madeira. Campo Grande, MS, **Multitemas**, n. 41, p. 73-88, 2012.

SOUZA, A.P. et al. Influence of distance travelled for three types of logging trucks on the percentage distribution of time elements in the forest transportation cycle. **Revista Arvore**, v.19, n.4, 1996, p. 525-539.

WEINTRAUB, A. The supply chain in the forest industry: models and linkages, In: GEUNES, J. et al. **Supply Chain Management: Models, Applications, and Research Directions**. Netherlands: Kluwer Academic Publishers, 2002. Cap. 13, p. 343-362.

WEINTRAUB, A.; ABRAMOVICH, A. Analysis of uncertainty of future timber yields in forest management. **Forest Science**, v. 41, n. 2, p. 217-234, 1995.

CAPÍTULO IV

MODELOS DE REGRESSÃO E REDES NEURAS ARTIFICIAIS PARA PREDIÇÃO DO RENDIMENTO EM MADEIRA SERRADA DE *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, julho 2017. **Modelos de regressão e redes neurais artificiais para predição do rendimento em madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.** Orientador: Prof. Dr. José Antônio Aleixo da Silva. Co-orientadores: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira e Prof. Dr. Daniel Alberto Álvarez Lazo.

RESUMO

O presente trabalho foi desenvolvido na serraria *Combate de Tenerías*, pertencente à Empresa Florestal Integral Macurije, localizada em Pinar Del Río-Cuba, com o objetivo de obter modelos de regressão e Redes Neurais Artificiais (RNAs) para predição precisa do rendimento em madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. a partir do conhecimento de características das toras. As características utilizadas como entradas dos modelos foram: o diâmetro menor da tora (D), o diâmetro a altura do peito (DAP) e a conicidade da tora. Os modelos de predição do rendimento foram obtidos treinando RNAs e ajustando modelos de regressão linear e não lineares tradicionais, modelos desenvolvidos por meio de Equações Diferenciais Ordinárias (EDOs) e modelos construídos por regressão stepwise. Resultados de uma análise de variância prévia indicaram que o rendimento em madeira serrada é proporcional as classes de DAP e D e inversamente proporcional as classes de conicidade. O modelo de regressão de melhor ajuste foi o modelo V dos baseados nas EDOs, porém seu desempenho foi inferior ao das RNAs III (MLP 3-3-1) e V (MLP 12-8-1). De forma geral, as RNAs demonstraram ser técnicas viáveis e capazes de proporcionar precisões iguais ou maiores que as obtidas com os modelos de regressão na predição do rendimento em madeira serrada. A variável de maior importância na predição do rendimento em madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na serraria *Combate de Tenerías* foi a conicidade.

Palavras-chave: Transformação primária da madeira, rendimento em madeira serrada, Equações Diferenciais ordinárias (EDO), regressão stepwise, inteligência artificial.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, July 2017. **Regression models and artificial neural networks for lumber recovery factor prediction for *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.** Adviser: Prof. PhD. José Antônio Aleixo da Silva. Co-advisers: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira and Prof. Dr. Daniel Alberto Álvarez Lazo.

ABSTRACT

This study was conducted at the sawmill *Combate de Tenerías*, owned by Macurije forest company, located in Pinar del Río, Cuba, in order to obtain regression models and Artificial Neural Networks (ANNs) for accurate prediction of *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. lumber recovery factor from the knowledge of logs characteristics. The characteristics used as the models inputs were: the small diameter (D), the diameter to breast height (DBH) and logs conicity. Lumber recovery factor prediction models were obtained by training ANNs and adjusting classic linear and nonlinear regression models, models developed using Ordinary Differential Equations (ODEs) and models constructed by stepwise regression. Results of a previous analysis of variance indicated that lumber recovery factor is proportional to DAP and D classes and inversely proportional to conicity classes. The best fit regression model was the model V of those based on ODEs, but its performance was lower than that of ANN III (MLP 3-3-1) and V (MLP 12-8-1). In general, ANNs have been shown to be viable techniques capable of providing equal or greater precision than those obtained with the regression models in predicting *Pinus caribaea* var. *caribaea* lumber recovery factor. The most important variable in *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. lumber recovery factor prediction at the sawmill Combate de Tenerías was logs conicity.

Keywords: Wood primary transformation, Lumber Recovery Factor, Ordinary Differential Equations (ODEs), stepwise regression, artificial intelligence.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, juillet 2017. **Modèles de régression et réseaux de neurones artificiels pour la prédiction du rendement en bois d'oeuvre du *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.** Directeur de Thèse: Prof. Dr. José Antônio Aleixo da Silva. Co-directeurs de Thèse: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira et Prof. Dr. Daniel Alberto Álvarez Lazo.

RÉSUMÉ

La présente étude a été réalisée à la scierie « Combate de Tenerías », appartenant à l'entreprise forestière intégrale Macurije, située à Pinar del Río, Cuba, afin d'obtenir des modèles de régression et de réseaux de neurones artificiels (RNAs) pour la prédiction précise du rendement en bois d'oeuvre du *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. à partir de la connaissance des caractéristiques des grumes. Les caractéristiques des grumes utilisées comme variables d'entrée des modèles furent: le diamètre inférieur de la grume (D), le diamètre à hauteur de poitrine (DHP) et la conicité de la grume (Con.). Les modèles de prédiction du rendement en bois d'oeuvre ont été obtenus en entraînant des RNAs et en ajustant des modèles de régression linéaire et non-linéaire classiques, des modèles développés en utilisant des équations différentielles ordinaires (EDOs) et des modèles construits par la régression pas à pas (stepwise). Les résultats d'une analyse de variance préliminaire indiquent que le rendement en bois d'oeuvre est proportionnelle aux classes de DHP et D et inversement proportionnelle aux classes de conicité. Le meilleur modèle de régression a été le modèle V de ceux basés sur les EDOs, mais sa performance a été inférieure à celle des RNAs III (MLP 3-3-1) et V (MLP 12-8-1). De façon générale, les RNAs ont démontrés être des techniques viables et capables de fournir des précisions égales ou supérieures à celles obtenues avec des modèles de régression classiques dans la prédiction du rendement en bois d'oeuvre. La variable la plus importante dans la prédiction du rendement en bois d'oeuvre du *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. dans la scierie « Combate de Tenerías » fut la conicité de la grume.

Mots-clés: Transformation primaire du bois, rendement en bois d'oeuvre, équations différentielles ordinaires (EDOs), régression pas à pas (stepwise), intelligence artificielle.

1. INTRODUÇÃO

O crescimento da população mundial provocou uma crescente demanda de madeira serrada, o que exerce pressão sobre as florestas tropicais nativas do mundo (MARTINS et al., 2002). Esse desafio somado ao da limitação de exploração dessas florestas nativas tem sido geralmente enfrentado por mudanças drásticas no perfil de consumo de madeira oriunda de florestas plantadas (MURARA JUNIOR; ROCHA; TRUGILHO, 2013).

A indústria madeireira nem sempre foi capaz de enfrentar a crescente demanda. Semelhantemente aos produtos comercializados nas últimas décadas, os produtos florestais (toras, madeira serrada, painéis de madeira, celulose e papel) têm conhecido várias crises e a maior das mais recentes aconteceu nos anos 2008 e 2009 (FAO, 2010). A crise na comercialização da madeira serrada, principal produto afetado no setor florestal, teve uma recuperação notável, porém os níveis de produção ainda estão abaixo dos de 2007. As melhores recuperações foram registradas na Ásia, no Pacífico, na América Latina e o Caribe e na América do Norte. A China, com o aumento da sua produção em 18%, atingindo assim níveis históricos em 2013, aparece como líder no consumo (superando EUA) e na produção (superando Canadá) (FAOSTAT, 2014). Entre as estratégias utilizadas pela China encontra-se o aperfeiçoamento dos processos de produção que tem como principais pilares: o aumento do rendimento de produção e a exigência da qualidade dos produtos para satisfazer as demandas tanto em quantidade como em qualidade. Segundo Manhiça (2010), o controle desse rendimento é o ponto de partida do processo de melhoria do desempenho das serrarias, principais unidades de transformação primária da madeira.

Com aproximadamente 30% do seu território coberto de florestas e uma política de reflorestação sustentável, Cuba ainda não satisfaz suas necessidades de madeira (DOMÍNGUEZ, 2016). É esperado nesta ilha em contínuo crescimento demográfico, um incremento de consumo de madeira serrada (EGAS; ÁLVAREZ; ESTEVEZ, 2001), principal produto florestal da ilha (LECKOUNDZOU, 2011). Apesar da introdução de serrarias modernas com altas capacidades produtivas para reforçar a força produtiva preexistente (HERRERO, 2004), essa demanda continua sendo superior à oferta e Cuba continua com registros de altas e onerosas importações de madeira serrada.

A maximização do rendimento é uma das formas mais comuns de melhorar a eficiência de conversão e aumentar a competitividade na produção de madeira serrada (RAPPOLD et al., 2007). A importância de conhecimento do desempenho das serrarias cubanas radica na sua

utilidade na planificação e controle do processo de desdobro (GARCÍA, 2006). Numerosos fatores afetam o rendimento e qualidade de desdobro da madeira e entre eles pode-se citar: as características externas das toras (conicidade, curvatura e achatamento) e as características internas (tensões de crescimento, excentricidade da medula e largura da rachadura) (FERREIRA et al., 2004).

Importantes pesquisas são referências dos estudos de rendimento em madeira serrada nas serrarias cubanas. Dentre esses destacam-se os trabalhos de Fosado (1999), Egas et al. (2001), Velázquez et al. (2006) e Cabrera e Días (2015), todos voltados ao estudo de rendimento de madeira serrada; e os de Egas (1998) e Leckoundzou (2011) voltados especificamente à modelagem do rendimento em madeira serrada em função de variáveis dendrométricas como altura total (Ht), altura comercial (Hc), diâmetro a altura do peito (DAP) e conicidade. Os modelos de regressão ajustados por Plank (1985), Willits e Fahey (1991) e Parry et al. (1996) são referências clássicas da literatura específica que aborda o tema.

Um problema geralmente identificado nos modelos utilizados nos estudos supracitados é o de multicolinearidade. Este problema é recorrente em modelos polinomiais ou modelos com variáveis combinadas que são caracterizados por bons ajustes, mas com baixas capacidades preditivas. Nesta situação, o coeficiente de determinação é inflado devido à alta correlação existente entre as variáveis preditivas, o que não permite saber a verdadeira aderência do modelo ajustado à base de dados. As equações, ao apresentarem este problema, não cumprem de forma eficiente seu papel que é o de auxiliar o planejamento de desdobro de madeira, realizando estimativas precisas dos rendimentos em madeira serrada. Diante dessas limitações, as relações funcionais entre o rendimento volumétrico em madeira serrada e as variáveis dendrométricas, ainda se consideram exploráveis e o uso de técnicas como as Equações Diferenciais Ordinárias (EDOs), a regressão stepwise ou as Redes Neurais Artificiais podem facilitar o entendimento dessas relações e proporcionar maior qualidade e precisão nas predições realizadas.

As RNAs são modelos matemáticos que tem como metáfora, o funcionamento do cérebro humano com suas redes neurais biológicas (VALENÇA, 2010). Segundo Leite et al. (2016), as mesmas se destacam entre as ferramentas computacionais que tem sido utilizada com êxito no setor florestal. Uma das suas principais vantagens que motivaram a sua utilização na presente pesquisa é a sua capacidade de ajustar dados com relações não lineares sem especificar previamente um modelo, diferindo da abordagem por regressão (MARTINS et al. 2016).

Diante do exposto, o presente trabalho foi realizado com o objetivo de obter sistemas de predição de rendimento em madeira serrada de *Pinus caribaea* var. *caribaea* na serraria Combate de Tenerías, por meio de ajustes de modelos de regressão e treinamentos de Redes Neurais Artificiais.

Como objetivos específicos para atingir este objetivo geral, o trabalho se propõe:

- Ajustar modelos tradicionais de regressão para a predição do rendimento em madeira serrada de *Pinus caribaea* var. *caribaea* na serraria Combate de Tenerías;
- Propor e ajustar modelos de predição de rendimento em madeira serrada baseados em equações diferenciais ordinárias (EDOs) para a predição do rendimento em madeira serrada de *Pinus caribaea* var. *caribaea* na serraria Combate de Tenerías;
- Treinar Redes Neurais Artificiais para a predição do rendimento em madeira serrada de *Pinus caribaea* var. *caribaea* na serraria Combate de Tenerías;
- Determinar as variáveis que mais contribuem na predição do rendimento em madeira serrada de *Pinus caribaea* var. *caribaea* na serraria Combate de Tenerías.

2. MATERIAL E MÉTODOS

2.1. Características do local de estudo

O presente estudo foi realizado na serraria *Combate de Tenerías*, pertencente à Empresa Florestal Integral (EFI) Macurije, localizada na parte ocidental do município de Guane, Pinar del Río-Cuba (Figura 1), a qual, segundo González (2015), é responsável pela produção de aproximadamente 22% da madeira serrada consumida em Cuba (GONZÁLEZ, 2015) e conta com uma capacidade de produção de 36000 m³ de madeira serrada por ano. A alta representatividade do *P. caribaea* var. *caribaea* na madeira processada nessa serraria (aproximadamente 90% segundo GODOY, 1999) e sua importância nos sistemas produtivos cubanos, justificaram a sua escolha para a realização do presente trabalho.

A tecnologia instalada na serraria está constituída por um Layout (Anexo 4.1) que conta com uma ampla gama de serras de fita de diferentes calibres e larguras, permitindo assim obter todos os esquemas possíveis de desdobro. As serras operantes são serras verticais, duplas e madeira móvel, as quais trabalham em jornadas de 8 horas diárias. Existem duas linhas de produção para a produção uma grande variedade de produtos (Anexo 4.3) na serraria: uma linha de grandes dimensões para o processamento de toras de 4 m e uma de pequenas dimensões para as toras de 3 m (Anexo 4.2).



Figura 1 – Localização geográfica da serraria *Combate de Tenerías* da EFI Macurije.

2.2. Coleta de dados e suficiência amostral

Os dados foram coletados durante o desdobro de toras de *Pinus caribaea* var. *caribaea* na serraria “Combate de Tenerías” da EFI Macurije. Para obter os dados, diferentes medidas

foram tomadas para identificar cada uma das toras tanto na sua entrada no processo de transformação como na sua saída já em forma de madeira serrada. Foi selecionada uma amostra piloto de 104 toras de 12m. Cada uma das árvores da amostra foi marcada com uma tinta amarela nas extremidades, submetida ao processo de desdobro, além de medidos os diâmetros nas pontas fina e grossa da tora para a determinação da conicidade, e o diâmetro a uma distância de 1,30 m da ponta grossa da tora (DAP). Cada uma delas foi acompanhada durante todo o processo tecnológico e as tabuas originadas delas receberam as mesmas marcas para possibilitar a quantificação do volume de madeira serrada obtida de cada tora e assim calcular o rendimento de desdobro por tora.

A suficiência amostral foi analisada por meio do erro de amostragem (E_A) e tamanho mínimo de amostra calculados por meio das expressões 1 e 2 (MEUNIER; SILVA; FERREIRA, 2001) ao nível de probabilidade de 95% e um erro permissível de 5%.

$$E_A(\%) = \frac{t_\alpha \cdot S_{\bar{R}}}{\bar{R}} * 100 \quad (1) \qquad n = \frac{t_\alpha^2 \cdot S^2}{E^2} \quad (2)$$

Em que: E_A = Estimativa do erro de amostragem cometido (%); \bar{R} = Rendimento médio (%) estimada na amostra de tamanho n ; S^2 = Estimativa da variância de R ; E = Erro admissível, na unidade da média; $E = (LE \cdot R) / 100$; t_α = valor de t tabelar com $(n-1)$ graus de liberdade e nível de significância α .

2.3. Variáveis envolvidas no estudo de rendimento em madeira serrada

A principal e mais popular medida de desempenho das serrarias é o rendimento - R (%) - também conhecido como Porcentagem de Recuperação de madeira serrada - PR (%). O mesmo representa a variável dependente dos modelos testados e é calculada para cada árvore com as expressões 3, 4, 5 e 6:

$$PR(\%) = \frac{VMS}{VT} * 100 \quad (3)$$

$$VMS = \sum_{i=1}^n V_i \quad (4)$$

$$V_i = e * l * c \quad (5)$$

$$VT = \frac{g_m + g_M}{2} \cdot l \quad (6)$$

Em que: PR : Rendimento ou Porcentagem de Recuperação de madeira serrada (%); VMS : Volume de madeira serrada (m^3); VT : Volume total da tora (m^3); g_M = área transversal na base da tora (m^2); g_m = área transversal no topo da tora (m^2); l = comprimento da tora (m); V_i , e , l , c e n são respectivamente o volume (m^3), a espessura (m), a largura (m), o comprimento (m) e o número total de uma tábua.

Diversas são as variáveis dendrométricas e suas derivadas que influenciam o rendimento de desdobra de madeira. O menor diâmetro da tora (D); o diâmetro a altura do peito (DAP), a altura (Ht) e a conicidade (Con.) são os mais importantes e geralmente mais utilizados na modelagem do rendimento (STEELE, 1984; PLANK, 1985; WILLITS E FAHEY, 1991; PARRY, 1996; LUNA et al. 2012). Em numerosas pesquisas, a variável altura (Ht) é excluída pela sua alta correlação com outras variáveis independentes e suas baixas correlações com a variável dependente (rendimento). Dessa forma, as variáveis independentes selecionadas na presente pesquisa foram: o diâmetro a altura do peito (DAP), o menor diâmetro da tora (D) e a conicidade (Con.), cujas distribuições por classe se encontram nas Tabelas 1, 2 e 3, respectivamente. Essa última variável foi calculada por meio da expressão 7.

$$Conic. (cm/m) = \frac{D_M - D_m}{C} \tag{7}$$

Em que: *Conic. (cm/m)*= Conicidade da tora; *D_M*= Diâmetro maior (cm); *D_m*= Diâmetro menor (cm); *C* = Comprimento da tora (m).

Tabela 1- Distribuição da amostra de *Pinus caribaea* por classes de DAP e REND.

| DAP (cm) | REND (%) | | | | | | | Total geral |
|-------------|----------|-------|-------|-------|-------|-------|-----|-------------|
| | 30-35 | 40-45 | 45-50 | 50-55 | 55-60 | 60-65 | >65 | |
| 18-22 | | 10 | 5 | 4 | 1 | 1 | | 21 |
| 22-26 | 2 | 3 | 4 | 3 | 3 | 1 | 1 | 17 |
| 26-30 | | | | 9 | 6 | 13 | 3 | 31 |
| 30-34 | | | 4 | 5 | 4 | 13 | 9 | 35 |
| Total geral | 2 | 13 | 13 | 21 | 14 | 28 | 13 | 104 |

Tabela 2- Distribuição da amostra de *Pinus caribaea* por classes de D e REND.

| D (cm) | REND (%) | | | | | | | Total Geral |
|-------------|----------|-------|-------|-------|-------|-------|-----|-------------|
| | 30-35 | 40-45 | 45-50 | 50-55 | 55-60 | 60-65 | >65 | |
| 13-17 | | 10 | 6 | 4 | 1 | 1 | | 22 |
| 17-21 | 2 | 3 | 3 | 3 | 3 | 1 | 1 | 16 |
| 21-25 | | | | 9 | 7 | 13 | 4 | 33 |
| 25-29 | | | 4 | 5 | 3 | 13 | 8 | 33 |
| Total Geral | 2 | 13 | 13 | 21 | 14 | 28 | 13 | 104 |

Tabela 3- Distribuição da amostra de *Pinus caribaea* por as classes de Con. e REND.

| Conic. (cm/m) | REND (%) | | | | | | | Total Geral |
|---------------|----------|-------|-------|-------|-------|-------|-----|-------------|
| | 30-35 | 40-45 | 45-50 | 50-55 | 55-60 | 60-65 | >65 | |
| 0,2-0,4 | | | 4 | 9 | 9 | 19 | 11 | 52 |
| 0,4-0,6 | 2 | 3 | 7 | 8 | 4 | 9 | 2 | 35 |
| 0,6-0,8 | | 10 | 1 | 4 | 1 | | | 16 |
| 0,8-1 | | | 1 | | | | | 1 |
| Total Geral | 2 | 13 | 13 | 21 | 14 | 28 | 13 | 104 |

2.4. Análise estatística

Foi analisada a influência das classes diamétricas e de conicidades no rendimento em madeira serrada. As análises seguiram um delineamento experimental inteiramente casualizado e os fatores de base das análises de variância independentes foram: as classes de DAP, as classes de diâmetros menores das toras (D) e as classes de conicidade (Con.) com quatro categorias (classes) cada um. As comparações múltiplas foram realizadas com o Teste de Tukey ao nível de 5% de significância.

2.5. Modelos clássicos de predição do rendimento em madeira serrada

Os modelos testados para a determinação da melhor equação de predição do rendimento de madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. se encontram na Tabela 4.

Tabela 4 – Modelos testados para a determinação da melhor equação de predição de rendimento de madeira serrada de *Pinus caribaea* var. *caribaea* na EFI Macurije, Cuba

| MODELOS | Nº | EXPRESSÕES MATEMÁTICAS |
|------------------|----|---|
| $f(D)$ | 01 | $\beta_0 + \beta_1 * D$ |
| | 02 | $\beta_0 + \beta_1 * \frac{1}{D}$ |
| | 03 | $\beta_0 + \beta_1 * D + \beta_2 * \frac{1}{D}$ |
| $f(D; DAP; Con)$ | 04 | $\beta_0 + \beta_1 * D + \beta_2 * DAP + \beta_3 * Con$ |
| | 05 | $b_0 + \beta_1 * \frac{1}{D} + \beta_2 * \frac{1}{DAP} + \beta_3 * \frac{1}{Con}$ |
| | 06 | $\beta_0 + \beta_1 * D + \beta_2 * \frac{1}{D} + \beta_3 * DAP + \beta_4 * \frac{1}{DAP} + \beta_5 * con + \beta_6 * \frac{1}{con}$ |

Fonte: Adaptado de Plank (1985), Willits e Fahey (1991) e Parry (1996). *Rend* = Rendimento de madeira serrada. *D* = menor diâmetro da tora; *DAP*= Diâmetro a Altura do Peito; *Con.* = Conicidade.

2.6. Modelo de regressão stepwise para a predição do rendimento em madeira serrada

Os problemas de multicolinearidade frequentemente encontrados nos modelos com variáveis combinadas (Tabela 4) ou polinomiais e a complexa relação entre as variáveis predictoras do rendimento de madeira serrada, motivou a escolha da técnica de regressão stepwise como possível alternativa de modelagem. A mesma permitiu a construção do modelo utilizando o seguinte modelo máximo de regressão:

$$REND = f(D, DAP, Con., 1/D, 1/DAP, 1/Con., D^2, DAP^2, Con^2, D^2Con., DAP^2Con., Con^2D, Con^2DAP, DAP^2Con^2, D^2Con^2, DAP * D, DAP^2D^2, D^3, DAP^3, Con^3)$$

2.7. Modelos de regressão baseados em Equações Diferenciais Ordinárias (EDOs)

A técnica de modelagem utilizada foi a das equações diferenciais ordinárias (EDOs). As taxas de variação das variáveis foram matematicamente representadas por derivadas e o modelo em si por uma equação diferencial ordinal na sua forma diferencial. A construção dos modelos matemáticos $REND = f(D, DAP, Con.)$ foi realizada em cinco etapas, conforme descrito por Dobson (2003):

- 1) Identificação das variáveis mais correlacionadas com o rendimento em madeira serrada;
- 2) Elaboração de hipóteses ou pressuposições sobre a variação do rendimento de madeira serrada em função do diâmetro menor da tora (D), do diâmetro a altura do peito (DAP) e da Conicidade (Con.);
- 3) Transformação dos modelos: transformação das hipóteses de uma forma diferencial a uma forma integrada ajustável;
- 4) Estimativa dos parâmetros dos modelos com base de dados disponível (ajuste);
- 5) Validação do modelo: avaliação da estabilidade dos parâmetros do modelo assim como a precisão, a flexibilidade e os custos do mesmo.

As hipóteses do ponto dois são hipóteses simplificadoras elaboradas em base a teorias existentes sobre as relações entre o rendimento e as variáveis independentes envolvidas. Os modelos propostos (Apêndice 4.1) se basearam nas seguintes hipóteses:

H₀₁: A conicidade da tora tende a ser inversamente proporcional ao rendimento em madeira serrada (STEELE, 1984; TSOUMIS, 1991; VITAL, 2008).

H₀₂: Os diâmetros tendem a ser diretamente proporcionais aos rendimentos em madeira serrada (TSOUMIS, 1991).

Os modelos múltiplos foram obtidos combinando os modelos simples por meio da metodologia das diferenças de equações proposta por Clutter e Jones (1980) e implementado por Brito (2005).

2.8. Treinamentos de RNAs para a predição do rendimento em madeira serrada

Na modelagem das RNAs, a base de dados foi dividida em três conjuntos segundo as seguintes as proporções: 50% para o treinamento, 25% para a avaliação do desempenho da rede e 25% para a validação cruzada.

Para aumentar a eficiência do algoritmo de treinamento (convergência estável dos pesos e desvios) que pode ser afetada pela variação das escalas das variáveis, os dados foram normalizados no intervalo [0,1] ou [-1,1], em dependência da função de ativação utilizada. As funções de ativação testadas para os neurônios ocultos e de saída foram: Seno, Identidade, Logística, Exponencial e Tangente hiperbólica. A normalização foi realizada pela transformação linear (Expressão 8).

$$y = \frac{(b - a)(x_i - x_{min})}{(x_{max} - x_{min})} + a \tag{8}$$

Em que: y é o valor normalizado; x_i é o valor original; x_{min} é o valor mínimo da variável; x_{max} é o valor máximo da variável; b e a são os limites superiores e inferiores da normalização.

Foram treinados dois tipos de RNAs: as redes Multi-Layer Perceptron (MLP) e as redes Radial Basis Function (RBF). As funções de ativações testadas nas camadas intermediárias e de saída foram as funções Seno, Identidade, Logística, Exponencial e Tangente hiperbólica e o algoritmo utilizado nos treinamentos foi o Broyden-Fletcher-Goldfarb-Shanno (BFGS). Segundo Bishop (1995), o algoritmo BFGS, juntamente com o Método do Gradiente Conjugado Escalonado (SCG) é o mais recomendado para o treinamento supervisionado das RNAs. Segundo esse autor, estas técnicas exibem geralmente um menor número de iterações devido a sua melhor taxa de convergência e uma capacidade de pesquisa mais inteligente.

A análise da importância de cada uma das variáveis independentes, também conhecida como análise de sensibilidade, foi realizada para determinar a contribuição de cada uma delas na predição do rendimento de madeira serrada. A referida importância, definida pela contribuição percentual de cada variável independente (j) com relação a variável dependente ($Rend$), foi calculada com as expressões 9 e 10 (VALENÇA, 2010):

$$Cont_j(\%) = \frac{\sum_{n=1}^N Sen_{jn}^2}{\sum_{j=1}^{N_{inp}} \sum_{n=1}^N Sen_{jn}^2} \tag{9}$$

Sendo:

$$Sen_{jn} = \sum_{k=1}^{N_{hid}} W_{kj} \cdot f'(net_k) \cdot \sum_{i=1}^{N_{out}} W_{ik} \cdot f'(net_i) \cdot e_i(n) \tag{10}$$

Em que: $Cont_j(\%)$ = Contribuição percentual de cada variável; Sen_{jn} é a sensibilidade para cada variável j ($j = 1, \dots, N_{inp}$) de entrada com relação a saída para um dado exemplo

$n (1, \dots, N)$; N_{inp} que representa o número total de neurônios ou variáveis na camada de entrada é igual a 3 (D_{pr}, DAP, Con) no presente trabalho; N_{out} que representa o número de neurônios na camada de saída é igual a 1 ($Rend$). W_{kj} são os pesos sinápticos que conectam a camada escondida a camada de entrada e W_{ik} são os que conectam a camada de saída a camada escondida. $f'(net_i)$ e $f'(net_k)$ são as derivadas das funções de ativação dos neurônios das camadas de saída e escondida respectivamente; $e_i(n)$ é o erro na camada de saída.

Os ajustes dos modelos de regressão e os treinamentos das RNAs foram realizados nos softwares STATISTICA 8.0. (STATSOFT, 2012) e SPSS versão 20. Os pesos iniciais foram determinados seguindo os métodos aleatórios de inicialização dos pesos.

2.9. Critérios de avaliação dos modelos de regressão e das RNAs

A avaliação e seleção dos modelos de regressão e RNAs mais adequados foram baseadas nos seus desempenhos tanto no ajuste como na validação (com 10% dos dados). As avaliações se basearam nas seguintes estatísticas: maior coeficiente de determinação ajustado - R_{aj}^2 (Expressão 11), menor Raiz quadrada do erro médio percentual - $RMSE$ (Expressão 12) e a distribuição de resíduos (Expressão 13). Na seleção dos modelos, também foram considerados os pressupostos de normalidade e homocedasticidade verificados pelos Testes de Shapiro-Wilk e White, respectivamente, e a autocorrelação serial analisada pelo Teste de Durbin-Watson.

$$R_{aj}^2 = R^2 - \left[\frac{N - 1}{N - K} \right] * (1 - R^2) \tag{11}$$

Em que: R^2 =Coeficiente de determinação; K = número de parâmetros do modelo; N = número de observações.

$$RMSE(\%) = 100 \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} / \bar{Y} \tag{12}$$

Em que: Y : Rendimento de desdobro observado; \hat{Y} : Rendimento de desdobro estimado; \bar{Y} : média dos rendimentos de desdobro observados e; n : número de observação.

$$E_i = \frac{(Y_i - \hat{Y}_i)}{Y_i} * 100 \tag{13}$$

Em que: E_i = Resíduo da i -ésima observação; Y_i = Variável dependente observada; \hat{Y}_i = Variável dependente estimada pela equação.

Os melhores modelos foram os que apresentaram um maior coeficiente de determinação ajustado (R_{aj}^2), uma menor raiz quadrada do erro médio percentual - $RMSE$ (%) e uma dispersão dos resíduos sem tendenciosidade e entorno a zero.

3. RESULTADOS E DISCUSSÃO

3.1. Rendimento em madeira serrada de *Pinus caribaea* na serraria Combate de Tenerías

O tamanho mínimo de amostra necessário para atender o erro permissível de 5% foi de 46 toras, indicando que a amostra piloto de 104 toras, com um erro de amostragem de 3,32%, é definitiva para a realização do estudo. O rendimento em madeira serrada variou entre 35,95 e 67,63% com uma média de 57,25%. A maioria dos rendimentos em madeira serrada registrados se encontrou no intervalo de 32,60-61,7% encontrado por Cardoso Jr. (2008) para espécies de *Pinus* spp. O rendimento médio de 57,25% encontrado no presente trabalho é similar ao encontrado por Pinto et al. (2006) para *Pinus pinaster* (57%) e superior aos encontrados por Manhiça, Rocha e Júnior (2012) para *Pinus* sp. (49,01%), Murara Jr. (2005) para *Pinus taeda* (53,60%).

Com relação a relação existente entre o rendimento de madeira serrada e suas variáveis predictoras, foi observada uma forte relação negativa entre o rendimento e a conicidade ($r=-0,819$) cujo valor médio foi 0,48 cm/m.. Este resultado está em correspondência com Egas et al. (2001) e Vital (2008) segundo os quais o rendimento em madeira serrada é inversamente proporcional a conicidade. Os diâmetros (DAP e D) também apresentaram uma relação forte, porém positiva, com o rendimento de madeira serrada ($r=0,734$ e $0,749$). Esta relação, de acordo com Tsoumis (1991), se traduz pelo incremento do rendimento com o acréscimo nos diâmetros.

3.2. Influência das classes de diâmetros e conicidade no rendimento em madeira serrada

Os resultados das análises de variância (p -valor $<0,05$) indicaram que tanto as classes de DAP, de diâmetro menor das toras (D) como de conicidade (Con.) influíram significativamente na variação do rendimento em madeira serrada. As comparações múltiplas, pelo Teste de Tukey, permitiram identificar as classes com rendimentos semelhantes (Tabela 5).

Observa-se na Tabela 5, o incremento do rendimento em madeira serrada com o crescimento das classes diamétricas. Estes resultados estão em correspondência com os de Juizo et al. (2015) que também observaram uma proporcionalidade direta entre as classes diamétricas e o rendimento de madeira serrada no desdobro de toras de *Combretum imberbe* e *Pterocarpus angolensis*. Nas classes de DAP, os resultados indicaram que não existe diferença significativa entre os rendimentos em madeira serrada das classes 26-30 cm e 30-34cm. Porém, ambas as classes tiveram rendimentos superiores aos registrados nas classes 18-22 e 22-26cm. A mesma tendência foi observada nas classes dos diâmetros menores das toras (D). As duas maiores

classes diamétricas geraram rendimentos em madeira serrada semelhantes. Porém, os rendimentos destas classes foram superiores aos obtidos nas classes duas primeiras classes.

Os resultados supracitados estão em correspondência com Fahey e Sachet (1993) que apontam que o acréscimo nos diâmetros das toras proporciona o incremento dos rendimentos em madeira serrada. Em relação a conicidade, um decréscimo do rendimento em madeira serrada foi observado com seu acréscimo. A exceção das classes II e III que apresentaram rendimento similares, todas as demais classes de conicidade proporcionaram rendimento em madeira serrada diferentes.

Tabela 5 – Comparações múltiplas nas classes de DAP, D e Con. pelo Teste de Tukey

| Classes de DAP | REND | Classes de D | REND | Classes de Con. | REND |
|----------------|----------|--------------|----------|-----------------|----------|
| 18-22 | 47,7774c | 13-17 | 47,3075c | 0,2-0,4 | 63,7407a |
| 22-26 | 53,0677b | 17-21 | 53,3782b | 0,4-0,6 | 52,3974b |
| 26-30 | 63,2334a | 21-25 | 62,2575a | 0,6-0,8 | 45,1969b |
| 30-34 | 63,7079a | 25-29 | 64,2584a | 0,8-1,0 | 35,9250c |

Médias com letras diferentes diferem pelo Teste de Tukey ao nível de 5% de significância.

3.3. Modelos de regressão tradicionais para a predição do rendimento em madeira serrada

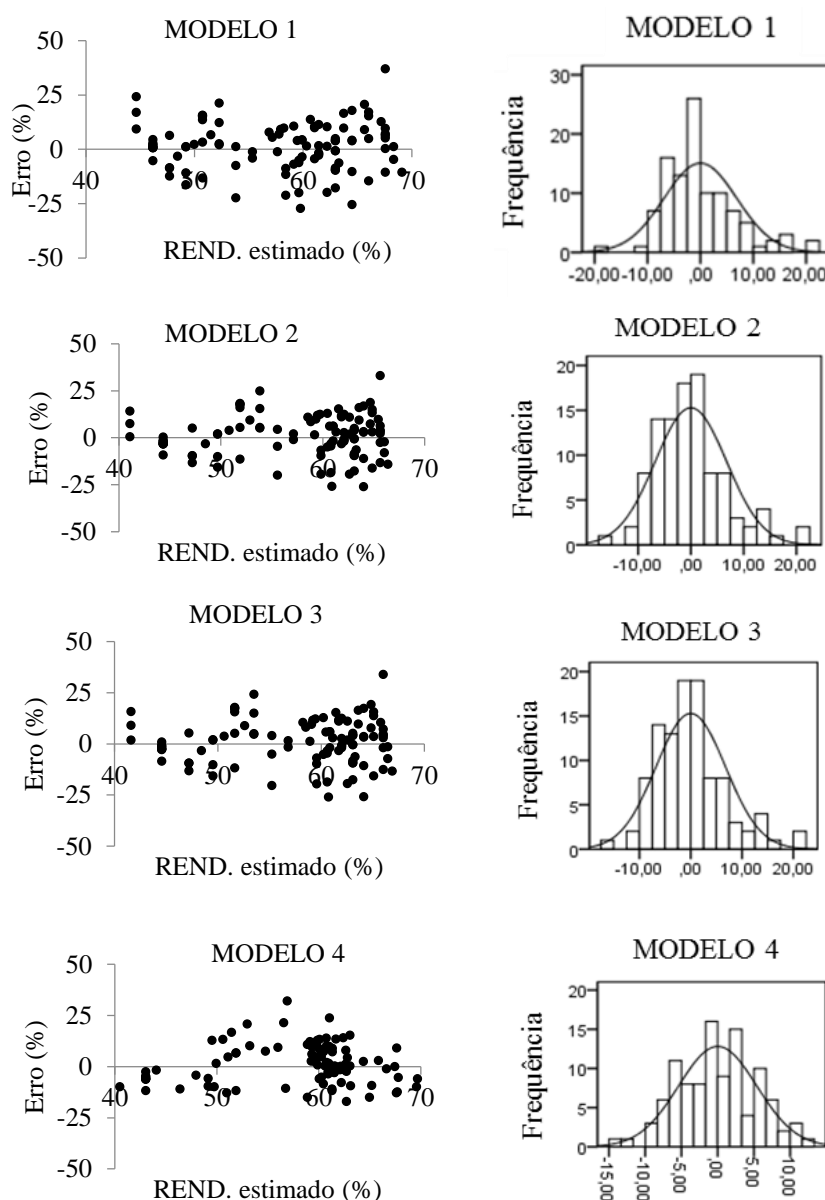
Os resultados dos ajustes dos modelos encontram-se na Tabela 6. As melhores equações são as obtidas dos modelos 05 e 06 que apresentaram um coeficiente de determinação ajustado (R^2_{aj}) de 76,0 e 78,1 e uma RMSE de 4,96 e 4,81 respectivamente.

Tabela 6– Resultados dos ajustes dos modelos tradicionais de predição do rendimento em madeira serrada de *Pinus caribaea* var. *caribaea* na serraria *Combate de Tenerías*.

| Nº | R^2_{aj} (%) | RMSE (%) | Estimativas dos parâmetros dos modelos | | | | | | Sig. F | |
|----|-------------------|-------------|--|-----------------|-----------------|-----------------|-----------------|-----------------|--------|-----------------|
| | | | $\hat{\beta}_0$ | $\hat{\beta}_1$ | $\hat{\beta}_2$ | $\hat{\beta}_3$ | $\hat{\beta}_4$ | $\hat{\beta}_5$ | | $\hat{\beta}_6$ |
| 01 | 52,4 | 6,91 | 24,76* | 1,53* | | | | | | <0,0001 |
| 02 | 53,7 | 6,82 | 86,94* | -596,28* | | | | | | <0,0001 |
| 03 | 53,8 | 6,85 | 76,23* | 0,27* | -495,31* | | | | | <0,0001 |
| 04 | 70,7 | 5,48 | 113,66* | 1,04* | -1,71* | -76,42* | | | | <0,0001 |
| 05 | 76,0 | 4,96 | 22,07* | -650,88* | 1082,28* | 9,84* | | | | <0,0001 |
| 06 | 78,1 | 4,81 | 102,83* | 1,64* | 65,45* | -2,90* | -704,25* | -10,69* | 9,81* | <0,0001 |

*Estimativa do parâmetro significativa a 95% de probabilidade pelo Teste t.

A distribuição não tendenciosa dos resíduos (Figura 2) e os resultados do Teste de White (Apêndice 4.3) indicaram que as seis equações satisfazem o pressuposto de homocedacidade. Em relação a normalidade, os histogramas da Figura 2, assim como os Testes de Shapiro-Wilk (Apêndice 4.2), indicam que apenas os resíduos dos modelos 04, 05 e 06 seguem uma distribuição normal. Em relação a autocorrelação serial dos resíduos, os resultados do Teste de Durbin-Watson (Apêndice 4.4) indicaram que os modelos 4, 5 e 6 não apresentaram o problema.



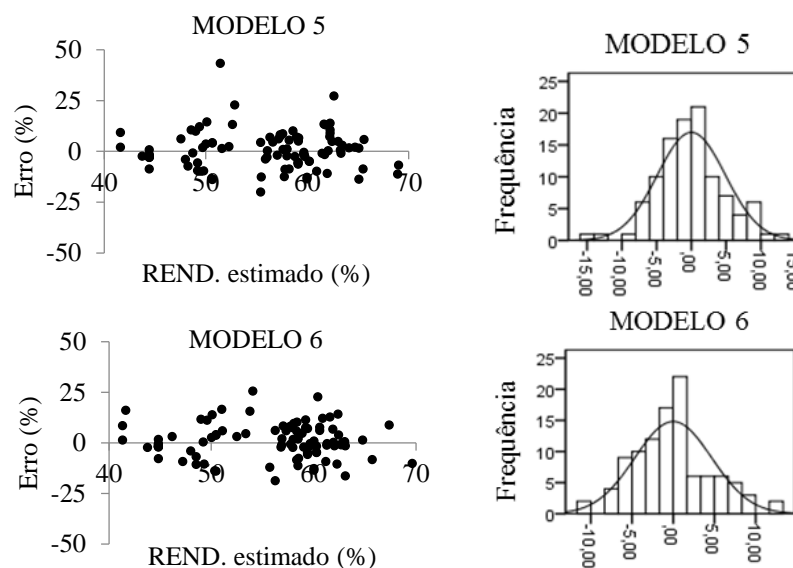


Figura 2- Distribuição dos resíduos das equações tradicionais de estimativa do rendimento em madeira serrada do *P. caribaea* Morelet var. *caribaea* Barr. & Golf. na EFI Macurije, Cuba.

Os resultados da tolerância, definida como a parte da capacidade preditiva de uma variável independente não prevista pelas demais variáveis independentes na equação (HAIR et al. 2006), apontam para as variáveis *Con* e $1/Con$ como as que têm as maiores variâncias remanescentes nos modelos. Foram também as únicas variáveis que apresentaram $VIF < 10$ nos modelos 04 e 05 (Tabela 7). Porém, todos os modelos de regressão múltiplos apresentaram variáveis independentes com valores de inflação de variância maiores que dez ($VIF > 10$), sendo este um indicativo da existência do problema de multicolinearidade. Esse problema era de esperar-se devido a que muitas das variáveis independentes utilizadas nesses modelos clássicos são obtidas de transformações e/ou combinações das variáveis independentes mensuradas.

Tabela 7 – Valor de Inflação da Variância (VIF) e Tolerância das variáveis independentes de cada um dos modelos tradicionais

| MOD. | VALOR DE INFLAÇÃO DA VARIÂNCIA - VIF | | | | | |
|------|--------------------------------------|---------------------|---------------------|---------------------|---------------------|--------------------|
| | <i>D</i> | $1/D$ | <i>DAP</i> | $1/DAP$ | <i>Con</i> | $1/Con$ |
| 01 | - | | | | | |
| 02 | | - | | | | |
| 03 | 27,421 (0,036) | 27,421 (0,036) | | | | |
| 04 | 43,648 (0,0229) | - | 33,577 (0,0298) | - | 7,971 (0,1254) | - |
| 05 | | 28,039 (0,0356) | | 27,095 (0,0369) | | 3,378 (0,2960) |
| 06 | 263,456 (0,0038) | 287,408 (0,0035) | 180,030 (0,0055) | 172,026 (0,0058) | 134,066 (0,0075) | 38,096 (0,0262) |

() Tolerância

A análise exploratória da relação entre as variáveis indicou que as mesmas estão altamente correlacionadas (Tabela 8). Isso justifica a existência do problema de multicolinearidade acima detectado. O referido problema aumenta as variâncias dos coeficientes dos modelos, o que os torna instáveis. Essa instabilidade, embora não afete o ajuste dos modelos, assim como sua capacidade preditiva, faz que as interpretações dos coeficientes sejam pouco confiáveis.

Tabela 8 – Correlação de Pearson entre as variáveis dos modelos

| | <i>REND</i> | <i>D</i> | <i>DAP</i> | <i>Con.</i> | <i>1/D</i> | <i>1/DAP</i> | <i>1/Con</i> |
|--------------|-------------|--------------|--------------|--------------|------------|--------------|--------------|
| <i>REND</i> | 1,00 | | | | | | |
| <i>D</i> | 0,74 | 1,00 | | | | | |
| <i>DAP</i> | 0,70 | 0,89 | 1,00 | | | | |
| <i>Con.</i> | -0,80 | -0,84 | -0,83 | 1,00 | | | |
| <i>1/D</i> | -0,76 | -0,94 | -0,82 | 0,85 | 1,00 | | |
| <i>1/DAP</i> | -0,65 | -0,82 | -0,94 | 0,78 | 0,79 | 1,00 | |
| <i>1/Con</i> | 0,80 | 0,82 | 0,82 | -0,95 | -0,76 | -0,73 | 1,00 |

3.4. Modelo de regressão stepwise para a predição do rendimento em madeira serrada

O modelo definido (Expressão 14) foi obtido em dois passos: um primeiro passo correspondente a seleção da variável *1/Con* e um segundo correspondente a seleção da variável combinada $DAP^2 Con^2$.

$$\widehat{REND} = 56,194 + 5,527 * \frac{1}{Con} - 0,109 * DAP^2 Con^2 \quad (R_{aj}^2 = 75,4\%; RMSE = 1,83\%) \quad (14)$$

A equação obtida é mais precisa (menor RMSE) e mais parcimoniosa que os anteriormente obtidos na Tabela 6, já que explica bem a variação do rendimento e envolve menos parâmetros que os modelos anteriores baseados nas estruturas dos modelos de Plank (1985), Willits e Fahey (1991) e Parry (1996). Os resultados dos Testes de Shapiro-Wilk (Apêndice 4.5) e de White (Apêndice 4.6) e a Figura 3 indicaram que a equação construída satisfaz os pressupostos de normalidade e de homocedasticidade, respectivamente.




Figura 3- Distribuição dos resíduos da equação de regressão stepwise para estimativa do rendimento de madeira serrada do *P. caribaea* Morelet var. *caribaea* na EFI Macurije, Cuba.

Em relação a autocorrelação serial dos resíduos, o resultado do Teste de Durbin-Watson (Apêndice 4.7) indicou que o modelo construído está livre do problema.

3.5. Modelos baseados em Equações Diferenciais Ordinárias e seus ajustes

Os ajustes dos modelos baseados nas equações diferenciais ordinárias (EDOs) propostos (Apêndice 4.1) se encontram resumidas na Tabela 9. O modelo que melhor se ajustou aos dados foi o modelo V com um coeficiente de determinação de 77,5 % e um RMSE de 4,37%.


Tabela 9 – Resultados dos ajustes dos modelos (EDOs) de predição do rendimento em madeira serrada de *Pinus caribaea* var. *caribaea* na serraria *Combate de Tenerías*.

| Mod. | R ² _{aj} | RMSE (%) | $\hat{\kappa}$ | $\hat{\beta}$ | $\hat{\delta}_1$ | $\hat{\delta}_2$ | $\hat{\delta}_3$ | $\hat{\beta}_2$ | $\hat{\beta}_3$ | Sig. F |
|------|------------------------------|----------|----------------|---------------|------------------|------------------|------------------|-----------------|-----------------|---------|
| I | 73,6 | 5,18 | 4597,527* | -4,822* | 0,104* | | | | | <0,0001 |
| II | 52,9 | 6,92 | 0,953* | 2,713* | 0,135* | | | | | <0,0001 |
| III | 46,6 | 7,36 | 6,622* | 0,797* | 0,304* | | | | | <0,0001 |
| IV | 53,0 | 6,98 | 0,155* | 4,447* | 0,093* | 45,20* | 86,15* | | | <0,0001 |
| V | 77,5 | 4,37 | 3,683 E-017* | 0,048* | 0,780* | -0,01* | 0,82* | 41,76* | -0,06* | <0,0001 |

*Estimativa do parâmetro significativa a 95% de probabilidade pelo Teste t.

O resultado do Teste de Shapiro-Wilk indica a satisfação do pressuposto de normalidade em todos os modelos (Apêndice 4.8) e o mesmo foi confirmado com os histogramas da Figura 4. Em relação ao pressuposto de homocedasticidade, os resultados do Teste de White (Apêndice 4.9) indicam sua violação apenas nos modelos II e IV. Todos os modelos, exceto os modelos I e V, apresetaram autocorrelação serial positiva (Apêndice 4.10).

O modelo V pré-selecionado atendeu a todos os pressupostos e foi considerado adequado para a predição do rendimento em madeira serrada na serraria *Combate de Tenerías*. A Figura 4 indica que todos os modelos proporcionaram estimativas aleatórias e não tendenciosas.



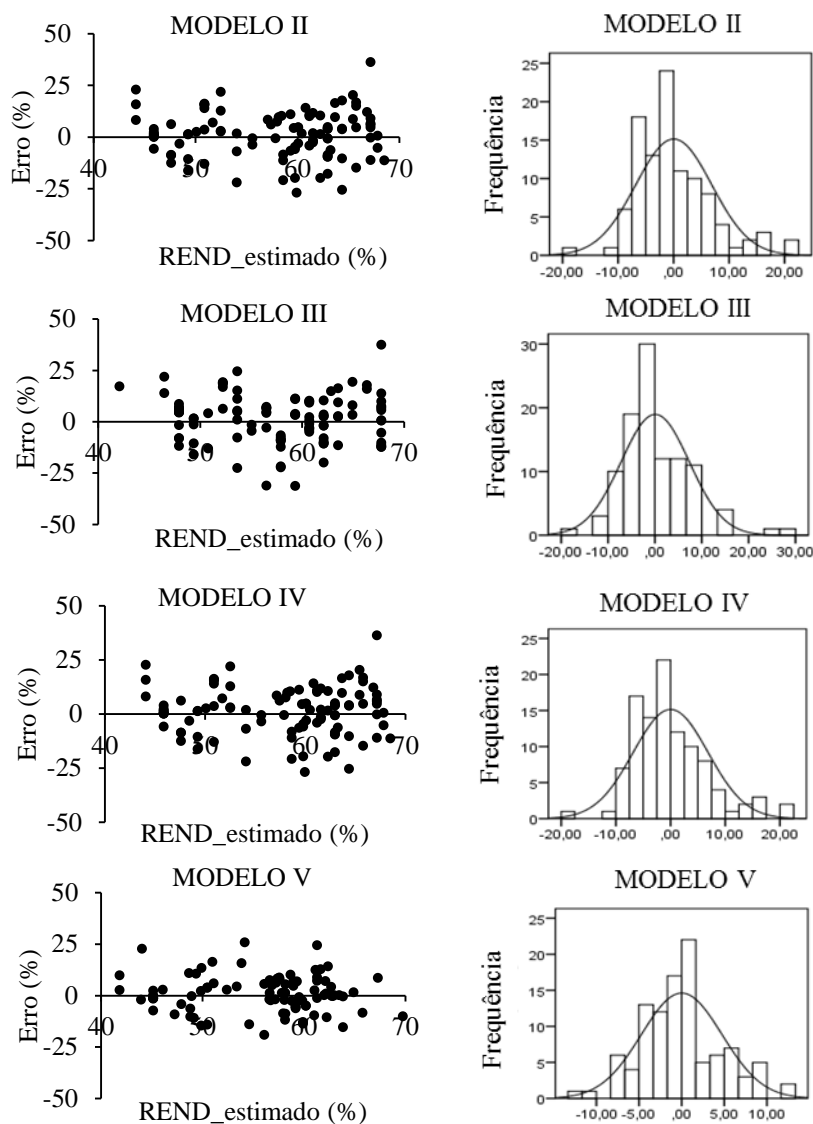


Figura 4 - Distribuição dos resíduos das equações baseadas nas EDOs para a estimativa do rendimento em madeira serrada do *Pinus caribaea* var. *caribaea* na EFI Macurije, Cuba.

3.6. Redes Neurais Artificiais para predição do rendimento em madeira serrada

Com base nos valores dos critérios de avaliação dos resultados de treinamento das RNAs, conclui-se que a RNA III (MLP 3-3-1), com um $R^2 = 82,37\%$ e um $RMSE = 1,279\%$ (Tabela 10), foi a melhor das RNAs que foram treinadas sem inclusão de variáveis categóricas.

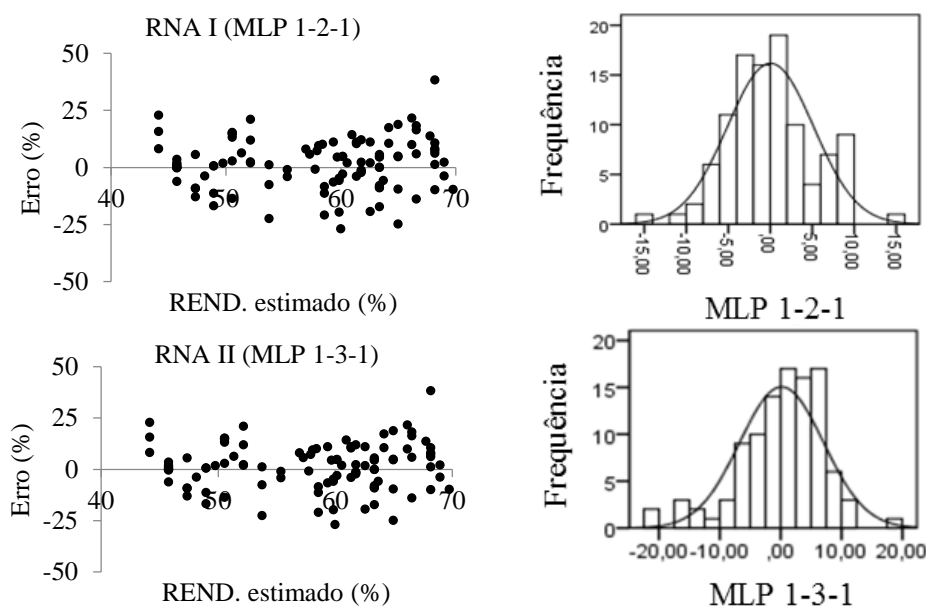
Embora a normalidade não seja exigida nas RNAs, os resultados do Teste de Shapiro-Wilk (Apêndice 4.11) e os histogramas (Figura 5) indicam a satisfação desse pressuposto nas RNAs III e IV e sua violação nas RNAs I e II. Em relação à homocedasticidade, os gráficos de distribuição dos resíduos (Figura 5) indicam sua observação em todos os modelos.

Tabela 10 – Resultados dos treinamentos das Redes Neurais Artificiais (RNAs) para a predição do rendimento em madeira serrada de *Pinus caribaea* var. *caribaea*.

| RNAs | V. I. | Arquitetura RNA | Funções de ativação | | AT | R ² (%) | RMSE (%) |
|--------|---------------------------|-----------------|---------------------|------------|---------|--------------------|----------|
| | | | Hidden | Output | | | |
| RNAI | D | MLP 1-2-1 | Tanh | Identity | BFGS 12 | 73,31 | 1,267 |
| RNAII | | MLP 1-3-1 | Identity | Identity | BFGS 3 | 63,86 | 1,319 |
| RNAIII | D, DAP, | MLP 3-3-1 | Tanh | Identity | BFGS 72 | 82,37 | 1,279 |
| RNAIV | Con | MLP 3-9-1 | Logistic | Identity | BFGS 25 | 69,24 | 1,308 |
| RNAV | D, DAP, Con, CD, CDAP, CC | MLP 12-8-1 | Tanh | Identidade | BFGS 20 | 91,17 | 1,113 |
| RNAVI | | MLP 12-11-1 | Identidade | Identidade | BFGS 17 | 87,33 | 1,201 |

Arquitetura RNA = número de neurônios em cada camada; AT= Algoritmo de Treinamento; RMSE = Raiz Quadrada do Erro Médio Percentual; V.I. = Variável Independente.

As classes de diâmetros (CDAP, CD) e de conicidades (CC) foram reagrupadas, com base nos resultados da Tabela 5, unificando as classes que apresentaram rendimento em madeira serrada semelhantes. A inclusão dessas classes no conjunto de entrada, possibilitada pela flexibilidade da técnica de RNAs, melhorou significativamente a capacidade de generalização dos modelos de RNAs construídos, necessitando apenas uma camada oculta com 8 neurônios.



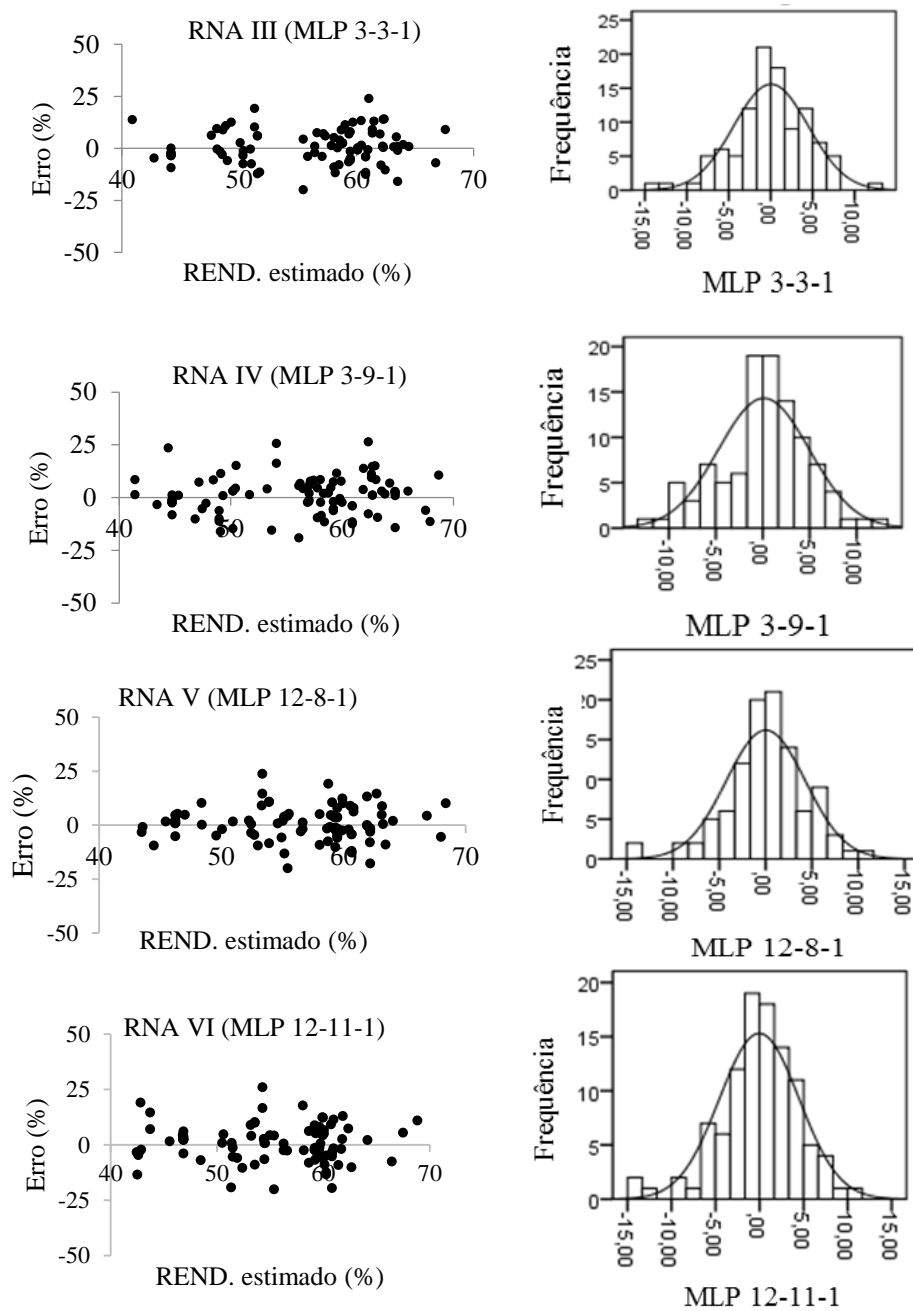


Figura 5 - Distribuição dos resíduos das RNAs na predição do rendimento em madeira serrada do *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na EFI Macurije, Cuba.

A RNA V por ser ligeiramente mais precisa e principalmente mais parcimoniosa (MLP 12-8-1), foi retida como a mais adequada para a predição do rendimento em madeira serrada na serraria Combate de Tenerías. Esta RNAV além de aprender adequadamente e gerar estimativas precisas, conseguiu captar a lógica e realismo da variação dos rendimentos em função dos diâmetros e conicidades observados nos resultados da Tabela 5 (Figura 6).




Figura 6 – Variação do rendimento observado e estimado pela RNA MLP 12-8-1.

A análise de sensibilidade indicou que a variável de maior importância na predição do rendimento em madeira serrada foi a concicidade, com uma contribuição de 0,512 (Figura 7) apesar dos baixos valores registrados. Segundo Grosser (1980), isto acontece quando o desdobro de madeira é realizado para a obtenção de produtos diferenciados como é o caso da serraria “Combate de Tenerías” (Anexo 4.3). Em todos os modelos de regressão ajustados assim como Redes Neurais Artificiais treinadas, observou-se uma forte correlação negativa entre o rendimento em madeira serrada e a concicidade, indicando que o aumento da concicidade influenciou significativamente na diminuição do rendimento em madeira serrada. Este resultado está em correspondência com os encontrados por Willits e Fahey (1991) para *Pinus lambertiana*, Missanjo e Magodi (2015) para *Pinus Kesiya* e *Pinus Patula* e difere dos resultados de Egas et al. (2001) e Leckoundzou (2011) para *Pinus caribaea* var. *caribaea*. Nos resultados desses autores, os diâmetros foram as variáveis que mais influíram no rendimento em madeira serrada.

O diâmetro menor das toras (D) e o diametro a altura do Peito (DAP) apresentaram contribuições de 0,318 e 0,170, respectivamente.




Figura 7 – Importância das variáveis independentes nas RNAs treinadas para a predição do rendimento em madeira serrada do *P. caribaea* var. *caribaea* na EFI Macurije, Cuba.

As equações obtidas no presente estudo e as RNAs III e V apresentaram maiores precisões que as obtidas por Leckoundzou et al. (2012) para a espécie, na mesma empresa Macurije ($R^2 = 64,60\%$ e $RMSE = 4,11\%$).

3.7. Comparação e validação dos modelos de regressão e das RNAs

A validação dos modelos, com 10% do conjunto de dados, comparando suas estimativas com os valores reais de rendimento, indicou que todos os modelos são adequados para a estimativa do rendimento de madeira serrada de *Pinus caribaea* var. *caribaea* na serraria Combate de Tenerías (Figura 8).




Figura 8 - Desempenhos das RNAs e dos modelos de regressão no processo de validação.

Esta conclusão é resultante da análise dos resultados do Teste de χ^2 (Tabela 11) cuja não significância ($\chi^2_{cal} < \chi^2_{Tab}$) para nenhuma das abordagens indica que não existe diferença significativa entre os modelos ao nível de 5% de significância e que todos os modelos (regressão e RNA) podem ser utilizados para estimativa do rendimento em madeira serrada. Porém, a análise dos valores das outras estatísticas (RMSE e Bias) indica uma ligeira superioridade de ambas as RNAs treinadas (Tabela 11).

Tabela 11 – Estatísticas das diferentes abordagens na validação

| MODELOS | RMSE (%) | Bias | χ^2_{cal} | $\chi^2_{Tab}(95\%)$ |
|---------------------|----------|-------|----------------|----------------------|
| MODELO EDOV | 1,0167 | -0,86 | 0,401 | |
| MODELO – MOD-6 | 1,1098 | 0,616 | 0,418 | |
| STEPWISE | 1,5133 | -1,07 | 0,497 | 22,362 |
| RNA III (MLP 3-3-1) | 0,9333 | -0,34 | 0,397 | |
| RNA V (MLP 12-8-1) | 0,3761 | -0,31 | 0,333 | |

Essas RNAs resultantes dos treinamentos das redes do tipo MLP (Tabela 11) apresentaram arquiteturas flexíveis e mais parcimoniosas com boas capacidades de generalização. As variáveis categóricas representadas pelas classes de diâmetros ou conicidades proporcionaram um grau de flexibilidade adicional as estruturas das RNAs e com isso uma melhor exploração da relação não-linear entre o conjunto de variáveis preditivas e o rendimento em madeira serrada.

4. CONCLUSÕES

- Os modelos tradicionais, apesar de apresentarem boa capacidade preditiva, não são recomendáveis pois geralmente apresentam problemas de multicolinearidade que amiúde comprometem a aplicabilidade das equações obtidas;
- A modelagem por equações diferenciais permitiu uma melhor exploração da relação existente entre as variáveis independentes e a dependente para uma melhor descrição do fenômeno estudado;
- As Redes Neurais Artificiais constituíram uma opção viável e até superior aos modelos tradicionais de regressão na predição do rendimento de madeira serrada a partir do conhecimento de variáveis dendrométricas obtidas das toras;
- A variável de maior importância na predição do rendimento de madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. foi a conicidade.

5. REFERÊNCIAS

BISHOP, C. **Neural Networks for Pattern Recognition**. Oxford: University Press. 1995. 482p.

BRITO, C.C.R. **Novos modelos de crescimento resultantes da combinação e das variações dos modelos de Chapman-Richards e Silva-Bailey aplicados em Leucena [*Leucaena leucocephala* (Lam) de Wit] e tubarão-Junteiro (*Carcharhinus porosus*)**. 2005. 141f. Dissertação (Mestrado em Biometria) – Universidade Federal Rural de Pernambuco, Recife.

CABRERA, F.E.G.; DÍAS, P.A.L. Eficiencia de la sierra principal en el proceso de aserrado. **Quebracho**, v.23, n. (1,2), p.15-26. 2015.

DOBSON, D.C. **Mathematical Modeling. Lecture Notes**. 2003. 6p.

DOMÍNGUEZ, G. A. Sector forestal cubano se inclina a la energía renovable (Opiniones recogidas por IPS-Cuba). 2016. Acesso em: 19/02/2017 e disponível em: <<http://www.ipscuba.net/economia/sector-forestal-cubano-se-inclina-a-la-energia-renovable/>>

EGAS, A.F. **Consideraciones para el incremento de la eficiencia de conversión de madera en rollo de *Pinus caribaea* Morelet var. *caribaea* en sierras de bandas**. 1998. 116f. Tesis (Doctorado en Ciencias Forestales) - Universidad de Pinar Del Río, Pinar del Río, Cuba.

EGAS, A.F.; ÁLVAREZ, L.D.; ESTEVEZ, I. Factores fundamentales para aumentar el rendimiento volumétrico en los aserraderos de Cuba. **Revista Chapingo Serie Ciencias Forestales y del Ambiente**, v.7, n.2, p. 163-168, 2001.

FAHEY, T.D.; SACHET, J.K. **Lumber recovery of ponderosa pine in Arizona and New Mexico**. Pacific Northwest Research Station. Portland, Oregon, 1993.

FAOSTAT - **Food and agriculture organization corporate statistical database**. 2014. Disponível em: <[http:// faostat.fao.org />](http://faostat.fao.org/). Acesso em: 08/05/2015.

FERREIRA, S. et al. Influência de métodos de desdobro tangenciais no rendimento e na qualidade da madeira de clones de *Eucalyptus* spp. **Cerne**, Lavras, v.10, n.1, p.10-21, 2004.

FERREIRA, S. **Produção e qualidade da madeira serrada de clones de híbridos de *Eucalyptus* spp**. 2003. 71f. Dissertação (Mestrado em Ciência e Tecnologia da Madeira). Universidade Federal de Lavras, Lavras. MG.

FOSADO, O. **Tratamiento económico matemático de la planificación operativa del proceso de aserrado de la madera.** 1999. 100f. Tesis (Doctorado en Ciencias Forestales) - Universidad de Pinar Del Río, Pinar del Río, Cuba.

GARCÍA, D.J.M. **Clasificador de madera aserrada. Especies de coníferas. Especificaciones.** 1ra ed. NORMA RAMAL NRAG. Instituto de Investigaciones Forestales, Ciudad de Habana. 2006.13p.

GARCÍA, D.J.M. **Diagnostico de la industria forestal en Cuba y Estudio de Caso del complejo "Combate de las Tenerías"** In: 5to CONGRESO FORESTAL DE CUBA, 2011, Cuba. Memorias del congreso, 28p.

GODOY, E.A. Aprovechamiento del aserrín mediante su transformación hidrolítica y como fuente de biomasa Cuba. **Revista forestal centroamericana (CATIE)**, n. 39-40, p. 67-69. 1999.

GONZÁLEZ, M.E. Sobre innovadores en tierra de reyes de la madera. Trabajadores (Órgano de la central de trabajadores de Cuba). Acceso em: 17/09/2016 e disponível em: <http://www.trabajadores.cu/20151007/sobre-innovadores-en-tierra-de-reyes-de-la-madera/>.

GROSSER, D. **Defeitos da madeira.** Série Técnica n. 2. Curitiba: FUPEF; 1980. 62 p.

HAIR, J.F. et al. **Multivariate Data Analysis.** 6ª edição. Upper Saddle River, NJ: Pearson Prentice Hall, 2006. 899p.

HERRERO, E.J.A. **Estudio de tendencias y perspectivas del sector forestal en América Latina.** Documento de trabajo, 2004. 59p.

JUIZO, C.G.F. et al. Influência da classe diamétrica no rendimento em madeira serrada de duas espécies nativas de Moçambique. **Pesq. flor. bras.**, v.35, n. 83, p. 293-298, 2015

LECKOUNDZOU, A. et al. Modelación de los rendimientos de madera aserrada en relación con determinadas características del árbol. **Revista Forestal Baracoa**, v.31, n.2, p. 73-81, 2012.

LECKOUNDZOU, A. **Influencia de diferentes variables dendrométricas y calidad de árboles en pie sobre los rendimientos de madera aserrada de *Pinus caribaea* morelet var. *caribaea* Barret y Golfari.** 2011. 156f. Tesis (Doctorado en Ciencias Forestales). Universidad de Pinar Del Río, Pinar del Río, Cuba.

LEITE, H.G. et al. Redes Neurais Artificiais para a estimação da densidade básica da madeira. **Sci. For.** Piracicaba, v. 44, n. 109, p. 149-154, 2016.

LUNA, J.A.N. et al. Rendimiento de la madera aserrada en dos aserraderos privados de El Salto, Durango, México. **Investigación y Ciencia de la Universidad Autónoma de Aguascalientes**, n. 55, p. 11-23, 2012.

MANHIÇA, A. A. **Rendimento e eficiência no desdobro de Pinus sp. utilizando modelos de corte numa serraria de pequeno porte.** 2010, 85 f. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal do Paraná, Curitiba, 2010.

MANHIÇA, A.A.; ROCHA, M.P.; JÚNIOR, R.T. Rendimiento no desdobro de *Pinus* sp. utilizando modelos de corte numa serraria de pequeno porte. **Floresta**, v. 42, n. 2, p. 409-420, 2012.

MARTINS, E.P. et al. **Rendimento de Desdobro de Toras nas Serrarias e Laminadoras do Município de Jarú, Estado de Rondônia.** Boletim de pesquisa e desenvolvimento / Embrapa CPAF-Rondônia. Porto Velho: Embrapa CPAF-Rondônia, 2002.14 p.

MARTINS, E.R. et al. Configuração de redes neurais artificiais para estimação do afilamento do fuste de árvores de eucalipto. **Revista Brasileira de Ciências Agrárias**, v.11, n.1, p.33-38, 2016.

MEUNIER, I.M.J.; SILVA, J.A.A.; FERREIRA, R.L.C. **Inventário florestal: programas de estudo.** 1.ed. Recife: Imprensa Universitária da UFRPE, 2001. 189p.

MISSANJO, E.; MAGODI, F. Impact of Taper and Sawing Methods on Lumber Volume Recovery for *Pinus Kesiya* and *Pinus Patula* Logs in Circular Sawmills. **Journal of forest products & industries**, v.4, n.1, p. 12-16, 2015.

MURARA JUNIOR, M.I.; ROCHA, M.P.; TRUGILHO, P.F. Estimativa do Rendimento em Madeira Serrada de Pinus para Duas Metodologias de Desdobro. **Floresta e Ambiente**, v.20, n.4, p. 556-563, 2013.

PARRY, D.L. et al. **Lumber recovery and deterioration of beetle-killed Douglas-fir and grand fir in the Blue Mountains of eastern Oregon.** Gen. Tech. Rep. PNW-GTR-376. Portland, OR: U. S. Department of Agriculture, Forest Service, Pacific Northwest Research Station. 1996. 24 p.

PINTO, I.; KNAPIC, S.; PEREIRA H.; USENIUS A. Simulated and realised industrial yields in sawing of maritime pine (*Pinus pinaster* Ait). **Holz als Roh- und Werkstoff**, Berlin, v. 64, n. 1, p. 30-36, 2006.

PLANK, M.E. 1985: **Lumber recovery from ponderosa pine in the Black Hills, South Dakota**. Res. Pap. PNW-328. Portland, OR: U.S. Department of Agriculture, Forest Service, Pacific Northwest Forest and Range Experiment Station.14 p.

RAPPOLD, P.M. et al. Impact of elliptical shaped red oak logs on lumber grade and volume recovery. **For. Prod. Journ.** v. 59. p. 29 – 34. 2007.

STEELE, P.H. **Factors determining lumber recovery in sawmilling**. Gen. Tech. Rep. FPL-39. Madison, WI: U.S. Department of Agriculture, Forest Service, Forest Products Laboratory, 1984. 8 p.

TSOUMIS, G. **Science and technology of Wood: structure, properties, utilization**. New York: Chapman and Hall, 1991. 494 p.

VELÁZQUEZ, V.D. et al. Rendimiento de materia prima en un aserradero de la Provincia de Pinar del Río, Cuba. **Revista Forestal Baracoa**. v.25, n.1, p. 97–104, 2006.

VITAL, B.R. Planejamento e operação de serrarias. Minas Gerais: Editora UFV, 2008. 211p.

WILLITS, S.; FAHEY, T.D. **Sugar pine utilization: a 30-year transition**. Res. Pap. PNW-RP-438. Portland, OR: U.S. Department of Agriculture, Forest Service, Pacific Northwest Research Station, 1991.21 p.

CAPÍTULO V

REGRESSÃO LOGÍSTICA ORDINAL E REDES NEURAS ARTIFICIAIS PARA A
CLASSIFICAÇÃO DE MADEIRA SERRADA DE *Pinus caribaea* Morelet var. *caribaea*
Barr. & Golf.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, julho 2017. **Regressão Logística Ordinal e Redes Neurais Artificiais para a classificação de madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.** Orientador: Prof. Dr. José Antônio Aleixo da Silva. Co-orientadores: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira e Prof. Dr. Daniel Alberto Álvarez Lazo.

RESUMO

A classificação da madeira serrada é uma das atividades mais subjetivas da fase final do processo de transformação mecânica das toras. Objetivou-se com a presente pesquisa propor ferramentas que auxiliem na classificação de madeira serrada de coníferas (*Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.). A pesquisa foi realizada na serraria *Combate de Tenerías* pertencente a Empresa Florestal Macurije localizada em Pinar Del Río-Cuba. Para atingir o objetivo, procedeu-se ao ajuste de um modelo de regressão logit-ordinal e ao treinamento de Redes Neurais Artificiais (RNAs). Os parâmetros do modelo *logit-ordinal* foram estimados usando o método de máxima verossimilhança otimizada com o algoritmo de Newton-Raphson. Para o treinamento das RNAs, o algoritmo Broyden-Fletcher-Goldfarb-Shanno (BFGS) foi utilizado. As variáveis envolvidas na classificação da madeira serrada por classe de qualidade (quatro categorias), foram em total 24, todas obtidas do classificador de madeira serrada de coníferas utilizado em Cuba. A alternativa utilizada para solucionar o problema de multicolinearidade, quase sempre presente em modelagens com numerosas variáveis preditivas, foi a análise fatorial cujos fatores retidos foram utilizados como entradas dos modelos. Baseando-se na porcentagem de acertos na classificação, a RNA de arquitetura RBF 24-8-4 foi superior aos modelos de regressão logística politômica ordinal. Esta superioridade é atribuída, principalmente, a capacidade das RNAs de separar os efeitos combinados (multicolinearidade) entre as variáveis de entrada, a sua tolerância a falhas devido ao paralelismo da sua estrutura e a sua maior parcimônia.

Palavras-chave: Serraria, desdobro da madeira, qualidade, defeitos da madeira serrada, análise fatorial.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, July 2017. **Ordinal Logistic Regression and Artificial Neural Networks for *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. lumber grading.** Adviser: Prof. PhD. José Antônio Aleixo da Silva. Co-advisers: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira and Prof. Dr. Daniel Alberto Álvarez Lazo.

ABSTRACT

The lumber classification is one of the most subjective activities of the final phase of logs primary processing process. The objective of this research was to get tools that assist in conifers lumber grading (*Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.). The research was carried out at the sawmill *Combate de Tenerías*, owned by Macurije forest company located in Pinar del Río – Cuba. To achieve the objective, it was proceeded to adjustment of logit-ordinal regression model and Artificial Neural Networks (ANNs) training. The parameters of Logit-Ordinal model were estimated using the maximum likelihood method optimized with the Newton-Raphson algorithm. For the ANNs training, the Broyden-Fletcher-Goldfarb-Shanno (BFGS) algorithm was used. The variables involved in the lumber grading (four categories), were in total 24, all obtained from the lumber grader of conifers used in Cuba. The alternative used to solve the multicollinearity problem, usually present in modeling with numerous predictive variables, was a factorial analysis. The retained factors were used as inputs in the modelling. Based on the percentage of correct classification, the ANN RBF 24-8-4 was higher than the Ordinal Logistic Regression model. This superiority is mainly attributed to the ability of ANNs to separate the combined effects (multicollinearity) between the input variables, their tolerance to failures due to the parallelism of their structure and their greater parsimony.

Keywords: Sawmill, sawing wood, quality, lumber defects, factorial analysis.

GUERA, Ouorou Ganni Mariel, Msc. Universidade Federal Rural de Pernambuco, juillet 2017.
Régression logistique ordinaire et réseaux de neurones artificiels pour la classification du bois débité du *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. Directeur de Thèse: Prof. Dr. José Antônio Aleixo da Silva. Co-directeurs de Thèse: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira et Prof. Dr. Daniel Alberto Álvarez Lazo.

RÉSUMÉ

La classification du bois d'œuvre est l'une des activités les plus subjectives de la phase finale du processus de transformation mécanique des grumes. L'objectif de la présente étude était de proposer des outils d'aide à la classification du bois débité des conifères (*Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.). L'étude a été menée dans la scierie « Combate de Tenerías » appartenant à l'entreprise Forestière Macurije située à Pinar del Río, Cuba. Pour atteindre l'objectif décrit ci-dessus, il a été procédé à l'ajustement d'un modèle de régression logit-ordinal et à l'entraînement des Réseaux de Neurones Artificiels (RNAs). Les paramètres du modèle logit-ordinal ont été estimés en utilisant la méthode du maximum de vraisemblance optimisé avec l'algorithme de Newton-Raphson. Pour l'entraînement des RNAs, l'algorithme Broyden-Fletcher-Goldfarb-Shanno (BFGS) a été utilisé. Les variables impliquées dans la classification du bois par classe de qualité (quatre catégories), sont au nombre de 24, toutes obtenues du classeur de bois débités de conifères utilisé à Cuba. L'alternative utilisée pour résoudre le problème de multicollinéarité, presque toujours présent dans la modélisation avec de nombreuses variables prédictives, fut l'analyse factorielle dont les facteurs retenus ont été utilisés comme variables d'entrée des modèles. D'après les pourcentages de classification correcte, le réseau de neurones artificiels dont l'architecture est RBF 24-8-4 a présentée une performance supérieure à celle du modèle de régression logistique ordinaire. Cette supériorité est attribuée, principalement, à la capacité des RNAs de séparer les effets combinés (multicollinéarité) entre les variables d'entrée (prédictives), leur tolérance aux failles due au parallélisme de leur structure et leur meilleure parcimonie.

Mots clés: Scierie, sciage de bois, qualité, défauts du bois d'œuvre, analyse factorielle.

1. INTRODUÇÃO

A madeira, um dos poucos recursos naturais renováveis, é predominante em nossa vida cotidiana bem como nos processos econômicos (DURBAK, et al., 2000). Uma transformação mecânica primária que este recurso comumente sofre para adquirir maior utilidade e maior valor agregado é o processo de desdobro ou serragem que ocorre geralmente em serrarias.

As propriedades físicas e mecânicas da madeira podem variar de forma inter e intraespecífica e em função da sua posição na mesma árvore. Essas propriedades intrínsecas, somadas a fatores ambientais e variações oriundas de desdobro e secagem proporcionam madeira serrada de diversas qualidades, gerando a necessidade da sua classificação por classe de qualidade para um uso mais adequado. Porém, irregularidades, padrões não repetidos e defeitos dificultam essa classificação (LOUBAN, 2009).

A classificação da madeira serrada é geralmente realizada por regras ou normas padronizadas e mais ou menos uniforme em todo o território nacional de um país (KRETSCHMANN, 2010). Existem dois tipos de classificação: a visual e a mecânica (GAVA, 2005). A qualificação visual ocorre quase sempre na serraria (KRETSCHMANN, 2010) e é realizada de acordo com determinada norma de classificação geralmente baseada no número, tamanho e localização dos defeitos presentes nas peças (ARRIAGA, et al., 2007). Segundo Carreira e Dias (2005), essa classificação é baseada na premissa de que os defeitos podem ser observados e avaliados pelo olho humano. A classificação mecânica é realizada com testes não destrutivos acompanhados de uma análise visual. Embora este último tipo de classificação seja mais eficiente conforme reporta a literatura, segundo Carreira (2003), ele é custoso e demorado, razão pela qual a classificação visual é amplamente mais usada. Sendo assim, o aperfeiçoamento da classificação visual é uma tendência de resolução da alta subjetividade envolvida no processo de classificação da madeira.

Numerosas normas de classificação de madeira serrada foram propostas e implementadas por países, por grupo de espécies (coníferas e folhosas) e até mesmo por espécie. Uma das mais conhecidas é a norma americana ASTM D245 (*Standard Practice for Establishing Structural Grades and Related Allowable Properties for Visually Graded Lumber*), proposta especificamente para uma classificação visual (CARREIRA; DÍAS, 2006). Em Cuba, uma das normas utilizadas para a classificação de madeira serrada de coníferas é o classificador proposto por García (2006), o qual baseia-se em 24 variáveis para a classificação visual.

A avaliação visual das exigências técnicas contempladas nas normas e a decisão da inclusão ou não de uma peça em uma determinada classe de qualidade pode ser subjetiva, principalmente para peças com características que a posicionam no limite entre duas classes.

A alta velocidade (até 5ms^{-1}) a qual as toras são geralmente processadas nas serrarias, exige uma classificação rápida e eficaz da madeira serrada, que não é possível sem automação de processos (LOUBAN, 2009). As serrarias cubanas, incluindo a serraria Combate de Tenería objeto do presente estudo, são semi-automatizadas com entrada de madeira automática e uma saída manual finalizada com a classificação manual da madeira serrada. A lentidão dessa classificação manual confrontada a esta velocidade de desdobro obriga os classificadores em trabalhar sob pressão, o que aumenta a probabilidade de erro na classificação.

A classificação da madeira serrada pode ser automatizada através da utilização de um meio computadorizado rápido e preciso de classificação da madeira serrada (THOMAS, 2017). Estes sistemas automáticos anunciados por Kline; Araman e Surak (2001) já são funcionais em numerosas serrarias. Os mesmos incluem mecanismos complexos compostos por câmeras, luzes, lasers, raios-x, computadores e outros dispositivos necessários para identificar defeitos de madeira serrada.

Para a automação da classificação da madeira serrada nas serrarias Combate de Tenerías, um sistema similar ao desenvolvido e treinado por Xiao (2001) pode ser montado e treinado para o reconhecimento dos defeitos em madeira serrada. O conjunto de saída deste sistema alimentará as Redes Neurais Artificiais (RNAs) treinadas para a classificação de madeira serrada e cujas entradas são exatamente os defeitos identificados pelo sistema de varredura laser. Segundo Klinkhachorn, Moody e Araman (1995), essa automatização é imprescindível para agilizar o processo e reduzir a taxa de reclassificação da madeira que surge de divergências recorrentes entre vendedores (as serrarias) e compradores que procuram verificar sua madeira comprada.

Dentre das técnicas utilizadas para auxiliar o processo de classificação, se destacam: a análise de regressão logística ordinal, cuja utilização tem crescido nos últimos anos na análise de dados e cuja resposta é apresentada de forma categórica e ordenada (ABREU; SIQUEIRA; CAIAFFA, 2009), e as Redes Neurais Artificiais (RNAs), cuja estrutura permite a classificação de dados em categorias ou classes (LUGER, 2008; HANRAHAN, 2011; CARTWRIGHT, 2015), considerada como um caso particular de problemas de aproximação de função (BISHOP, 1995).

Diante do problema de alta subjetividade na classificação de madeira serrada acima exposto e partindo da hipótese segundo a qual o estudo e seleção das variáveis consideradas na Norma Cubana de Classificação de Espécies de Coníferas (NCCEC) e sua utilização como variáveis de entrada em modelos de classificação permitiriam obter ferramentas que auxiliem a classificação de madeira serrada, o presente trabalho teve como objetivo geral, obter sistemas de auxílio a classificação de madeira serrada de *Pinus caribaea* var. *caribaea* na serraria Combate de Tenerías da Empresa Florestal Integral (EFI) Macurije, por meio de ajustes de modelos de Regressão Logística Ordinal e treinamentos de Redes Neurais Artificiais.

Os objetivos específicos para atingir esse objetivo foram:

- Ajustar um modelo de regressão logit-ordinal para a classificação de madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. com base nas 24 variáveis do classificador de García (2006).
- Determinar, com o mínimo de perda de informação, possíveis fatores determinantes da qualidade de madeira serrada.
- Ajustar um modelo de regressão logit-ordinal para a classificação da madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. com base nos fatores extraídos.
- Treinar as Redes Neurais Artificiais (RNAs) para a classificação da madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.
- Determinar as variáveis mais determinantes ou contribuintes na classificação de madeira serrada do *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

2. MATERIAL E MÉTODOS

2.1. Localização e características do local de estudo

Esta pesquisa foi realizada na serraria *Combate de Tenerías* pertencente a Empresa Florestal Integral Macurije localizada em Pinar del Río, Cuba (Figura 1). A espécie objeto de estudo foi o *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. que representa aproximadamente 90% da madeira processada nessa serraria (GODOY,1999). A predominância da espécie no sistema de produção da empresa está em consonância com as estatísticas nacionais segundo as quais a espécie ocupa o primeiro lugar nos planos de reflorestamento e nos sistemas de produção na ilha (ONEI, 2014).

A tecnologia instalada na serraria, com serras de diferentes calibres e largas, permite utilizar muitos esquemas de desdobro. Em duas linhas de produção, uma de grandes dimensões (toras de 4 m) e outra de pequenas dimensões (toras de 3 m), operam serras de fitas verticais, duplas e de madeira móvel, os quais trabalham em uma jornada de 8 horas diárias.

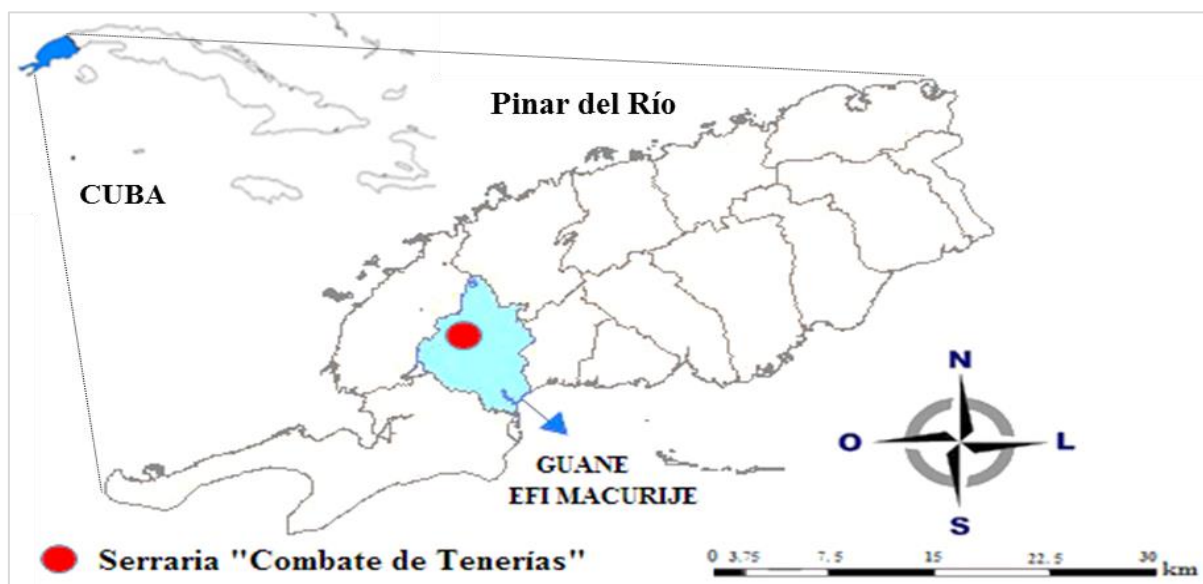


Figura 1 –Localização geográfica da serraria “Combate de Tenerías” na EFI Macurije.

2.2. Coleta de dados

Os dados utilizados no trabalho foram obtidos no acompanhamento do desdobro de toras na serraria *Combate de Tenerías* no mês de março 2015. Esses dados são oriundos da classificação visual e minuciosa de 259 tábuas seguindo as exigências e classes estabelecidas no classificador (norma) de madeira serrada de coníferas de Cuba elaborado por García (2006). As variáveis independentes ou preditivas consideradas na elaboração dos modelos de predição da qualidade da madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf., sejam

os de regressão como os de RNAs, são as “exigências técnicas” do classificador de García (2006) (Tabela 1). A variável dependente da modelagem foi a qualidade, uma variável categórica que conta com quatro categorias ou classes. Ordenando-as de melhor a pior, tem-se as classes: seleta, Classe I, Classe II e Classe III. A classificação de uma tábua em determinada classe de qualidade depende da quantidade de defeitos registrados na mesma. A probabilidade de uma tábua ser classificada na classe SELETA diminui com o aumento do número e quantidade de defeitos na mesma. Os limites de inclusão das tábuas em cada classe de qualidade se encontram no classificador de García (2006).

Tabela 1 – Variáveis preditoras das classes de qualidade de madeira serrada de coníferas

| Nº | Variáveis | Símbolos |
|----|--|----------|
| 1 | Diâmetros de nós sãs e aderidos (cm) | DNSA |
| 2 | Nós aderidos parcialmente e não aderidos (quantidade) | NSPAnA |
| 3 | Nós soltos, parcialmente podres e podres (quantidade) | NSPPeP |
| 4 | Diâmetro das Rachaduras (cm) | DRch |
| 5 | Largura das rachaduras (cm) | LRch |
| 6 | Deflexão das fibras (%) | DFibr |
| 7 | Medula simples e dupla (quantidade) | MSeD |
| 8 | Bolsas de resina (quantidade/metro linear) | BR |
| 9 | Largura dos Bolsos de casca (cm) | LBC |
| 10 | Comprimento dos bolsos de casca (cm) | CBC |
| 11 | Podridão externa reduzida à poeira (quantidade) | PERP |
| 12 | Manchas de fungos no Cerne (%) | MFC |
| 13 | Orifícios causados por insetos (quantidade/metro linear) | OCI |
| 14 | Danos mecânicos (quantidade) | DM |
| 15 | Gema (%) | G |
| 16 | Curvatura canto (%) | CC |
| 17 | Curvatura largura (%) | CL |
| 18 | Curvatura no comprimento (%) | Ccomp |
| 19 | Desvios permissíveis de serragem da madeira (DPSM) – Comprimento+ (cm) | DPSM_C+ |
| 20 | Desvios permissíveis de serragem da madeira (DPSM)-Comprimento- (cm) | DPSM_C- |
| 21 | Desvios permissíveis de serragem da madeira (DPSM)-Largo+ (cm) | DPSM_L+ |
| 22 | Desvios permissíveis de serragem da madeira (DPSM)-Largos- (cm) | DPSM_L- |
| 23 | Desvios permissíveis de serragem da madeira (DPSM)-Grosor+ (cm) | DPSM_G+ |
| 24 | Desvios permissíveis de serragem da madeira (DPSM)-Grosor- (cm) | DPSM_G- |

Fonte: Baseada no classificador de madeira serrada de coníferas de García (2006)

2.3. Modelo de regressão logística politômica ordinal (RLPO)

Dado que a variável resposta (Qualidade) da classificação da madeira serrada é discreta, com mais de duas categorias ordenadas de melhor a pior (Seleta, Classe I, Classe II, Classe III), o modelo de regressão mais adequado para a classificação é o *modelo de regressão logística politômica ordinal* também conhecido como modelo de regressão *logit-ordinal*. Este modelo

tem uma parametrização diferente do modelo logístico ordinário, seja binário ou multinomial. A modelagem centra na probabilidade de escolher uma das J categorias sabendo algumas variáveis explicativas e se baseia nas probabilidades cumulativas.

No modelo de RLPO, a probabilidade de que uma tábua de madeira serrada pertença a uma categoria j ou a uma categoria inferior, já que a mesma é cumulativa, foi determinada por meio das expressões 1 e 2.

$$\text{Log} \left[\frac{p(y \leq j|x_i)}{p(y > j|x_i)} \right] = \alpha_j + \beta X_i + \varepsilon_i \tag{1}$$

$$p(y \leq j|x_i) = \frac{\text{Exp}(\alpha_j + \beta X_i)}{1 + \text{Exp}(\alpha_j + \beta X_i)} + \varepsilon_i \tag{2}$$

Em que: y é a variável dependente com j categorias ; X_i é a i -ésima variável preditora; α_j é o parâmetro da j -ésima categoria a ser estimado e β o parâmetro comum a todas as categorias.

A equação de RLPO foi estimada usando o método de máxima verossimilhança (Expressão 3) otimizado no programa XLSTAT version 2016 com o algoritmo de Newton-Raphson.

$$l(\alpha, \beta) = \sum_{i=1}^n \sum_{j=1}^J y_{ij} \text{Log}[p(y \leq j|x_i) - p(y \leq j - 1|x_i)] \tag{3}$$

Em que: y é a variável dependente com j categorias ; x_i é a i -ésima variável preditora; α_j é o parâmetro da j -ésima categoria a ser estimado e β o parâmetro comum a todas as categorias.

2.3.1. Teste da significância do modelo de regressão logístico ordinal

A significância do modelo independente (só o intercepto) foi testada pelo Teste da Razão de Verossimilhanças (TRV) (Expressões 4 e 5). No mesmo, testou-se também se todos os coeficientes de regressão são todos nulos com exceção da intercepção (b_0).

$$D = -2 \text{Ln} \left[\frac{FMVMC}{FMVMS} \right] \tag{4}$$

$$D = -2 \sum_{i=1}^n \left[y_i \text{Ln} \left(\frac{\pi_i}{y_i} \right) + (1 - y_i) \text{Ln} \left(\frac{1 - \pi_i}{1 - y_i} \right) \right] \tag{5}$$

Em que: *FMVMC*: Função de Máxima Verossimilhança do Modelo Corrente (só variáveis desejadas no estudo); *FMVMS*: Função de Máxima Verossimilhança do Modelo Saturado (inclui todas as variáveis).

As hipóteses testadas foram as seguintes:

$$H_0: b_0 = \dots = b_p = 0$$

$$H_1: \exists j = 1, \dots, p: b_j \neq 0$$

No caso de rejeitar a hipótese nula (segundo a qual todos os coeficientes do modelo são nulos com exceção do intercepto), conclui-se que pelo menos um dos coeficientes é estatisticamente diferente de zero. A significância deste teste conduz a realização do Teste de Wald para cada coeficiente.

2.3.2. Teste de Wald para cada coeficiente

Testou-se se cada coeficiente é significativamente diferente de zero, verificando assim se a variável independente associada ao coeficiente testado apresenta uma relação estatisticamente significativa com a variável dependente (Expressão 6).

$$W_j = \frac{b_j}{Var(b_j)} \quad (6)$$

Em que: b_j é a estimativa do parâmetro associado a categoria j ; $Var(b_j)$ é a variância da estimativa do parâmetro associado a categoria j .

Sendo as hipóteses testadas:

$$H_0: b_0 = \dots = b_p = 0$$

$$H_1: \exists j = 1, \dots, p: b_j \neq 0$$

2.4. Análise fatorial com as variáveis preditoras da qualidade de madeira serrada do classificador de madeira serrada proposto por García (2006)

Dada a grande quantidade de variáveis que envolve a classificação de madeira serrada, a probabilidade de existência de multicolinearidade é alta. Esse fenômeno, embora melhore os ajustes dos modelos, afeta significativamente a capacidade preditiva dos modelos elaborados. Para contorná-lo, uma análise fatorial foi realizada para reduzir a dimensão do conjunto de dados sem significativa perda de informação. Os fatores obtidos foram utilizados como inputs dos modelos logit-ordinal.

A aplicação da análise fatorial seguiu os seguintes passos: (1) Suficiência amostral determinada pela regra de Hair et al. (2006), segundo a qual, a razão entre o número de observações e a quantidade de variáveis deve exceder cinco para um ou mais; (2) Verificação da adequabilidade da aplicação da técnica pelo Teste do KMO, cuja interpretação foi feita com base em Friel (2009). Segundo este autor, um KMO entre 0,90 e 1 é considerado excelente;

entre 0,80 e 0,89 é bom; entre 0,70 e 0,79 é mediano; entre 0,60 e 0,69 é medíocre; entre 0,50 e 0,59 é ruim e entre 0 e 0,49 é totalmente inadequado.

A técnica de extração de fatores utilizada foi a de componentes principais. Procurando-se um maior grau de parcimônia (inversamente proporcional ao número de fatores), uma maior variância explicada (diretamente proporcional ao número de fatores) e cumprindo com a exigência de Tabachnick e Fidell (2007) de ter entre 20 e 50 variáveis, o número ótimo de fatores foi determinado pelo critério de Kaiser, o qual estabelece que todos os fatores extraídos têm que apresentar um autovalor acima de 1 (um).

Para uma melhor interpretação dos fatores, foi realizada uma rotação ortogonal varimax, método proposto por Kaiser (1958) (COOLEY e LOHNES, 1971). A análise fatorial foi realizada no software SAS (SAS, 1999).

2.5. Redes Neurais Artificiais para a classificação de madeira serrada

2.5.1. Características do treinamento das Redes Neurais Artificiais

Os treinamentos das RNAs foram realizados com o algoritmo Broyden-Fletcher-Goldfarb-Shanno (BFGS) conhecido pela sua melhor taxa de convergência e sua capacidade de pesquisa mais inteligente (BISHOP, 1995). As RNAs treinadas foram do tipo Radial Basis Function (RBF) e Multi-Layer Perceptron (MLP). As funções de ativação para os neurônios ocultos e de saída foram as funções seno, exponencial, identidade, logística e tangente hiperbólica. Conforme recomendado por Valença (2010), a base de dados foi dividida em três subconjuntos independentes com as seguintes proporções: 50% da base de dados para o ajuste dos pesos sinápticos durante o treinamento; 25% para a validação cruzada e 25% para a verificação. Para facilitar a convergência das RNAs, as variáveis foram normalizadas para o intervalo [0,1] por meio da transformação linear. Os treinamentos foram realizados com os softwares Statística v. 8. (STATSOFT, 2012) e SPSS v. 20.0.

2.5.2. Análise de sensibilidade

A análise da importância de cada uma das variáveis de entrada foi realizada para determinar a contribuição de cada uma delas na classificação da madeira serrada. A contribuição percentual de cada variável j foi calculada com as expressões 7 e 8 (VALENÇA, 2010):

$$Cont_j(\%) = \frac{\sum_{n=1}^N Sen_{jn}^2}{\sum_{j=1}^{N_{inp}} \sum_{n=1}^N Sen_{jn}^2} \quad (7)$$

Sendo:

$$Sen_{jn} = \sum_{k=1}^{N_{hid}} W_{kj} \cdot f'(net_k) \cdot \sum_{i=1}^{N_{out}} W_{ik} \cdot f'(net_i) \cdot e_i(n) \quad (8)$$

Em que: $Cont_j(\%)$ = Contribuição percentual de cada variável; Sen_{jn} = sensibilidade para cada variável j ($j = 1, \dots, N_{inp}$) de entrada com relação a saída para um dado exemplo n ($1, \dots, N$); N_{inp} que representa o número total de neurônios ou variáveis na camada de entrada; N_{out} que representa o número de neurônios na camada de saída. W_{kj} são os pesos sinápticos que conectam a camada escondida a camada de entrada e W_{ik} são os que conectam a camada de saída a camada escondida. $f'(net_i)$ e $f'(net_k)$ são as derivadas das funções de ativação dos neurônios das camadas de saída e escondida respectivamente; $e_i(n)$ é o erro na camada de saída.

2.6. Critérios de avaliação e seleção dos modelos de regressão e das RNAs

As melhores RNAs foram as que apresentaram uma maior porcentagem de acerto nos treinamentos e testes. Os modelos de regressão logística politômica ordinal sendo baseados em estimativas da máxima verossimilhança, os critérios utilizados para sua avaliação foram os pseudo- R^2 : R^2 -McFadden (MCFADDEN, 1973) (Expressão 9); R^2 - Cox e Snell (COX; SNELL, 1968) (Expressão 10) e R^2 - Nagelkerke (NAGELKERKE, 1991) (Expressão 11). Estes pseudo- R^2 são interpretados como o R^2 em uma análise de regressão ordinária. Sendo assim, analogamente ao R^2 , quando maiores forem seus valores, melhor é o ajuste. Outro critério utilizado foi o critério de informação bayesiano – BIC ou SBC (SCHWARZ, 1978) (Expressão 12).

$$R_{MF}^2 = 1 - \frac{L_f}{L_0} \quad (9)$$

$$R_{CS}^2 = 1 - \exp\left[-\frac{2}{n}(L_f - L_0)\right] \quad (10)$$

$$R_N^2 = \frac{R_{CS}^2}{R_{MAX}^2} \quad (11)$$

Sendo: $R_{MAX}^2 = 1 - \exp\left[\frac{2}{n}(L_0)\right]$

Em que: L_0 = Log-verossimilhança do modelo nulo; L_f = Log-verossimilhança do modelo final.

$$BIC = -2 \log f(X_n \parallel \theta) + p \log n \quad (12)$$

Em que: $f(X_n \parallel \theta)$ é o modelo escolhido, p é o número de parâmetros a serem estimados e n é o número de observações da amostra.

3. RESULTADOS E DISCUSSÃO

3.1. Modelo de regressão logística ordinal para a classificação da madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

Uma análise previa da multicolinearidade indicou a necessidade de exclusão de duas variáveis da base de dados: desvios positivos permissíveis de serragem da madeira na largura (DPSM_L+) e desvios positivos permissíveis de serragem da madeira no grossor (DPSM_G+).

A significância do Teste da razão de verossimilhanças (Tabela 3) é um indicativo de que pelo menos um coeficiente, diferente do intercepto, é não nulo. Esta significância conduz a realização do Teste de Wald, o qual foi significativo apenas para a variável DPSM_C+ (desvios positivos permissíveis de serragem no comprimento da madeira) (Apêndice 5.1). Isso indica que na equação logit-ordinal obtida, apenas essa variável tem uma relação estatisticamente significativa com a qualidade da madeira serrada. Pode-se concluir então uma falta de consistência das estimativas dos parâmetros.

Em relação aos pseudo-R² (Tabela 2), seus valores indicam que uma boa porcentagem de variância da qualidade da madeira serrada é explicada pelas equações de regressão logística ordinal obtidas. O modelo completo (intercepto + variáveis independentes) apresentou um valor de BIC menor que o do modelo independente que só considera o intercepto (Tabela 2), indicando assim a superioridade do modelo completo.

Tabela 2 - Estatísticas do ajuste do modelo de regressão logística politômica ordinal

| Estatística | Independente | Completo |
|------------------------------|--------------|----------|
| -2 Log (Verossimilhança) | 648,955 | 100,025 |
| R ² (McFadden) | 0,000 | 0,322 |
| R ² (Cox e Snell) | 0,000 | 0,311 |
| R ² (Nagelkerke) | 0,000 | 0,323 |
| BIC | 665,626 | 383,446 |

Tabela 3 - Teste da significância dos parâmetros do modelo Logit ordinal

| Estatística | Qui-quadrado | Pr > Qui ² |
|------------------------|--------------|-----------------------|
| -2Log(Verossimilhança) | 648,930 | < 0,0001 |
| Score | 692,166 | < 0,0001 |
| Wald | 0,952 | 1,000 |

A validação da equação de regressão logística ordinal obtida indicou uma porcentagem de classificação correta de 54,44% (Tabela 4). Supõe-se que essa porcentagem de acerto

relativamente baixa é causada pela não significância da participação da maioria das variáveis no modelo.

Tabela 4 – Validação do modelo de regressão logística ordinal usando as 22 variáveis

| De \ a | CLASSE I | CLASSE II | CLASSE III | SELECTA | Total | % correto |
|------------|----------|-----------|------------|---------|-------|-----------|
| CLASSE I | 64 | 27 | 0 | 25 | 116 | 55,17 |
| CLASSE II | 9 | 23 | 17 | 0 | 49 | 46,94 |
| CLASSE III | 0 | 20 | 43 | 6 | 69 | 62,32 |
| SELECTA | 6 | 0 | 8 | 11 | 25 | 44,00 |
| Total | 79 | 70 | 68 | 42 | 259 | 54,44 |

Para abordar o problema de não significância de quase a totalidade dos parâmetros do modelo, a introdução dos dados de uma forma mais reduzida foi considerada uma alternativa viável. Para o mesmo, foi realizada uma análise fatorial descrita na seção subsequente para a obtenção de fatores cujos escores seriam os novos inputs do modelo.

3.2. Análise fatorial para a redução da dimensionalidade das variáveis preditivas da qualidade da madeira serrada

O valor do KMO da amostra foi de 0,962, sendo considerado excelente segundo a classificação de Friel (2009). Conclui-se assim que os dados são adequados para a aplicação da análise fatorial. Para o número de fatores a serem extraídos, o critério de Kaiser sugeriu a extração de três fatores. Esses três fatores explicam 77,93% da variância total das variáveis. A aplicação do método de rotação VARIMAX (Figura 2 e Tabela 5) permitiu a inclusão de outros dois fatores que proporcionaram o aumento da variância total explicada de 77,93% para 85,3%.

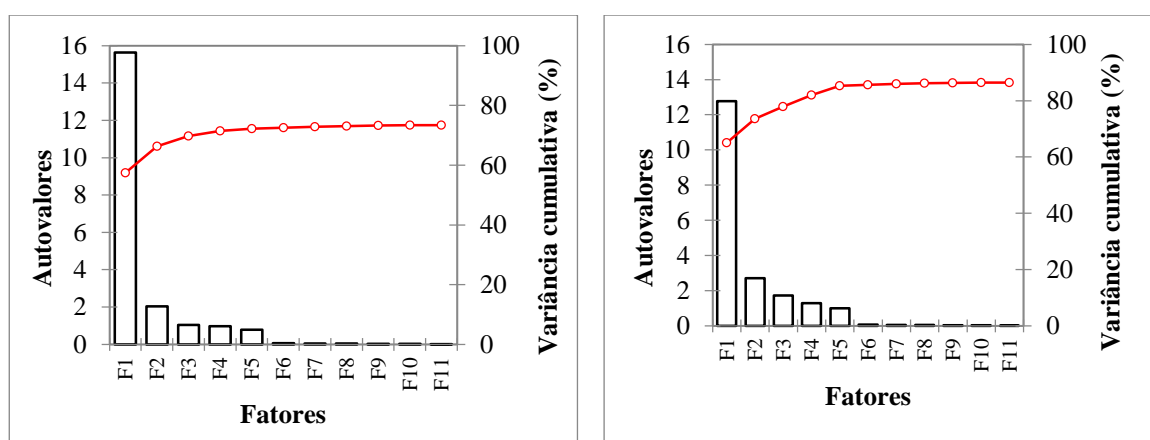


Figura 2 – Scree plot dos autovalores antes (a) e depois (b) da rotação varimax

O primeiro fator apresentou um autovalor de 12,766, responsável por 65,13% da variância total; o segundo fator apresentou um autovalor de 2,700 e explica cerca de 8,47% da variância; o terceiro, com um autovalor de 1,731, é responsável por 4,32% da variância; o quarto com um autovalor de 1,281 é responsável por 4,10% da variância e o quinto e último, com um autovalor de 1,005, é responsável por 3,30% da variância.

Na Figura 2 e na Tabela 5, pode-se observar que após a rotação varimax, a maior mudança ocorre ao em torno dos cinco primeiros fatores. A rotação permitiu uma redistribuição da variância entre fatores obtendo assim cinco fatores com os autovalores acima de um. Concluimos então, seguindo o critério de Kaiser, que esses fatores são suficientes para descrever as relações de covariância entre as variáveis avaliadas.

Tabela 5 – Matriz de cargas fatoriais rotacionadas para as 24 variáveis predictoras da qualidade da madeira serrada de *Pinus caribaea* var. *caribaea*.

| VARIÁVEIS | FATORES ROTACIONADOS - MÉTODO VARIMAX | | | | | C |
|----------------------------|---------------------------------------|--------|--------|--------|--------|-------|
| | F1 | F2 | F3 | F4 | F5 | |
| DNSA | 0,826 | 0,498 | 0,021 | 0,025 | -0,013 | 0,932 |
| NSPAnA | 0,321 | 0,605 | 0,234 | 0,125 | -0,004 | 0,540 |
| NSPPeP | 0,755 | 0,568 | -0,049 | -0,067 | -0,002 | 0,899 |
| DRch | -0,251 | 0,157 | 0,569 | 0,552 | 0,024 | 0,717 |
| LRch | 0,834 | 0,327 | 0,083 | 0,073 | -0,035 | 0,816 |
| DFibr | 0,804 | 0,391 | -0,018 | -0,041 | 0,004 | 0,802 |
| MSeD | 0,623 | 0,407 | 0,278 | 0,285 | 0,021 | 0,713 |
| BR | 0,701 | 0,554 | 0,139 | 0,100 | -0,038 | 0,829 |
| LBC | 0,157 | 0,093 | 0,754 | 0,019 | -0,052 | 0,604 |
| CBC | 0,156 | -0,058 | 0,732 | 0,082 | 0,136 | 0,588 |
| PERP | 0,561 | 0,740 | -0,025 | -0,012 | -0,003 | 0,863 |
| MFC | 0,809 | 0,502 | -0,066 | -0,064 | -0,009 | 0,916 |
| OCI | 0,828 | 0,503 | 0,054 | 0,015 | -0,010 | 0,942 |
| DM | 0,552 | 0,748 | -0,052 | 0,037 | -0,003 | 0,868 |
| G | 0,833 | 0,321 | 0,088 | 0,032 | -0,043 | 0,808 |
| CC | 0,226 | 0,011 | 0,090 | 0,895 | 0,027 | 0,861 |
| CL | -0,036 | -0,006 | 0,084 | 0,033 | 0,989 | 0,987 |
| Ccomp | 0,807 | 0,536 | 0,033 | 0,021 | -0,002 | 0,940 |
| DPSM_C+ | 0,951 | 0,221 | 0,133 | 0,085 | -0,003 | 0,978 |
| DPSM_C- | 0,944 | 0,240 | 0,133 | 0,091 | -0,004 | 0,975 |
| DPSM_L+ | 0,949 | 0,212 | 0,139 | 0,087 | -0,005 | 0,972 |
| DPSM_L- | 0,950 | 0,200 | 0,127 | 0,072 | -0,006 | 0,965 |
| DPSM_G+ | 0,950 | 0,215 | 0,121 | 0,071 | -0,009 | 0,969 |
| DPSM_G- | 0,950 | 0,202 | 0,149 | 0,091 | -0,005 | 0,974 |
| Autovalores | 15,633 | 2,033 | 1,037 | 0,974 | 0,783 | - |
| Autovalores (Rotacionados) | 12,766 | 2,700 | 1,731 | 1,281 | 1,005 | - |
| Variância (%) | 65,1 | 8,5 | 4,3 | 4,1 | 3,3 | - |
| Variância cumulativa (%) | 65,1 | 73,6 | 77,9 | 82,0 | 85,3 | - |

F1, F2, F3, F4 e F5 são os fatores extraídos e C é a comunalidade.

Os resultados das Tabelas 5 e 6 indicam que o primeiro fator (F_1) correlacionou-se mais fortemente e positivamente com as variáveis DPSM_C+, DPSM_C-, DPSM_L+, DPSM_L-, DPSM_G+ e DPSM_G-. A natureza dessas variáveis permite afirmar que o Fator 1 reflete os defeitos de serragem da madeira serrada. As variáveis NSPAnA, BR, PERP e DM se correlacionaram fortemente com F_2 identificado como Fator associado aos defeitos de consistência da madeira serrada (Tabelas 5 e 6). O fator F_3 se correlacionou fortemente com as variáveis LBC e CBC e pela natureza dessas variáveis, foi associado aos defeitos relacionados à estética da madeira serrada (Tabelas 6 e 7). As variáveis DRch e CC estão fortemente correlacionadas com o fator F_4 e a variável CL com o fato F_5 , etiquetando esses dois fatores como descritores de defeitos relacionados à secagem da madeira serrada (Tabelas 5 e 6).

Tabela 6 – Nomenclatura dos fatores e variáveis explicativas associadas.

| Fatores | Variáveis associadas | Nomenclatura |
|---------|--|--------------------------------------|
| 01 | DPSM_C+ ; DPSM_C-; DPSM_L+ ; DPSM_L-DPSM_G+ ; DPSM_G- | Defeitos de serragem |
| 02 | NSPAnA; NSPPeP; BR; PERP; DM | Defeitos relacionados à consistência |
| 03 | LBC; CBC | Defeitos relacionados à estética |
| 04 | DRch; CC; L | Defeitos relacionados à secagem |
| 05 | | |

3.3. Modelo de regressão logística ordinal baseado nos fatores

Os ajustes obtidos com os fatores foram relativamente semelhantes aos anteriores, com uma diferença no BIC, o qual foi melhor com a introdução desses fatores (Tabelas 7 e 8).

Tabela 7 - Estatísticas da qualidade de ajuste da regressão logit-ordinal baseada nos fatores.

| Estatística | Independente | Completo |
|------------------------------|--------------|----------|
| -2 Log(Verossimilhança) | 648,955 | 100,117 |
| R ² (McFadden) | 0,000 | 0,688 |
| R ² (Cox e Snell) | 0,000 | 0,602 |
| R ² (Nagelkerke) | 0,000 | 0,689 |
| BIC | 665,626 | 100,140 |

Tabela 8 - Teste da hipótese nula no modelo de regressão logística ordinal baseada nos fatores

| Estatística | GL | Qui-quadrado | Pr > Qui ² |
|-------------------------|----|--------------|-----------------------|
| -2 Log(Verossimilhança) | 15 | 648,838 | < 0,0001 |
| Score | 15 | 591,048 | < 0,0001 |
| Wald | 15 | 2,627 | 1,000 |

Em relação a significância das variáveis predictoras, percebe-se que o problema foi solucionado devido a significância dos fatores retidos pelo critério de Kaiser (Tabela 9).

Tabela 9 – Significância dos fatores (análise do tipo II)

| Fonte | GL | Qui-quadrado (Wald) | Pr > Wald | Qui-quadrado (LR) | Pr > LR |
|-------|----|---------------------|-----------|-------------------|----------|
| F1 | 3 | 1,152 | 0,764 | 129,633 | < 0,0001 |
| F2 | 3 | 0,264 | 0,967 | 144,071 | < 0,0001 |
| F3 | 3 | 0,159 | 0,984 | 10,087 | < 0,0001 |
| F4 | 3 | 0,190 | 0,979 | 5,113 | < 0,0001 |
| F5 | 3 | 0,033 | 0,998 | 4,117 | < 0,0001 |

A contribuição de cada um dos fatores sendo significativa (Tabela 9), as estimativas dos parâmetros associados (Tabela 10) podem ser consideradas e sua interpretação realizada. Na classe II, para o fator F₁ relacionado aos defeitos de serragem, diríamos que para um aumento de uma unidade se espera um aumento de 14,806 nas chances (odds) de estar em um nível mais elevado (classe III) quando todos os outros fatores no modelo são mantidos constantes. Essa interpretação pode ser realizada em todas as classes para analisar a influência dos fatores na inclusão ou não das peças de madeira serrada em determinada classe.

Tabela 10 - Estimativas de parâmetros do modelo de regressão logit-ordinal baseado nos fatores

| Categoria | Fonte | Valor | Erro padrão | Qui-quadrado de Wald | Pr > Qui ² | Razão de Odds |
|-------------------|------------|--------|-------------|----------------------|-----------------------|-------------------------|
| CLASSE II | Intercepto | -2,200 | 24,485 | 0,008 | 0,928 | |
| | F1 | 14,806 | 16,742 | 0,782 | 0,377 | 269,168.10 ⁴ |
| | F2 | 0,133 | 33,892 | 0,000 | 0,997 | 1,142 |
| | F3 | -5,453 | 20,941 | 0,068 | 0,795 | 0,004 |
| | F4 | -3,952 | 16,409 | 0,058 | 0,810 | 0,019 |
| | F5 | -2,763 | 32,898 | 0,007 | 0,933 | 0,063 |
| CLASSE III | Intercepto | -8,207 | 33,492 | 0,060 | 0,806 | |
| | F1 | 24,854 | 23,857 | 1,085 | 0,298 | 622,158.10 ⁸ |
| | F2 | 10,486 | 39,142 | 0,072 | 0,789 | 35825,115 |
| | F3 | -3,253 | 29,683 | 0,012 | 0,913 | 0,039 |
| | F4 | -1,593 | 22,408 | 0,005 | 0,943 | 0,203 |
| | F5 | 1,221 | 9,531 | 0,016 | 0,898 | 3,389 |
| SELECTA | Intercepto | -6,602 | 28,066 | 0,055 | 0,814 | |
| | F1 | 6,323 | 49,219 | 0,017 | 0,898 | 557,475 |
| | F2 | 1,703 | 55,595 | 0,001 | 0,976 | 5,490 |
| | F3 | -8,500 | 27,694 | 0,094 | 0,759 | 0,000 |
| | F4 | -6,144 | 16,185 | 0,144 | 0,704 | 0,002 |
| | F5 | 0,665 | 11,858 | 0,003 | 0,955 | 1,944 |

A consistência dos resultados obtidos usando os fatores como inputs foi verificado por meio da porcentagem de acerto de 84,55% obtida na validação do modelo (Tabela 11).

Tabela 11 - Validação do modelo de regressão logística ordinal usando como inputs os fatores

| De \ a | CLASSE I | CLASSE II | CLASSE III | SELECTA | Total | % correto |
|------------|----------|-----------|------------|---------|-------|-----------|
| CLASSE I | 105 | 11 | 0 | 0 | 116 | 90,52% |
| CLASSE II | 6 | 38 | 5 | 0 | 49 | 77,55% |
| CLASSE III | 2 | 10 | 57 | 0 | 69 | 82,61% |
| SELECTA | 6 | 0 | 0 | 19 | 25 | 76,00% |
| Total | 119 | 59 | 62 | 19 | 259 | 84,55% |

3.4. Redes Neurais Artificiais para a classificação da madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

A RNA 4 de arquitetura RBF 24-8-4 cujas características de aprendizagem encontram-se na Tabela 12, foi a de melhor capacidade de generalização. Essa capacidade foi comprovada no teste e validação da mesma (Tabela 13 e Figura 3). A superioridade das redes do tipo RBF coincide com Valença (2010) que alega que este tipo de RNA são superiores às do tipo MLP na atividade de classificação. Esta superioridade das redes RBF é atribuída a sua própria estrutura que exige um treinamento não supervisionado para determinar as estimativas dos parâmetros das funções de base radial da camada escondida e um treinamento supervisionado para ajustar os pesos que ligam a camada escondida a de saída. No treinamento não supervisionado, o algoritmo de clusterização utilizado (k-médias) permitiu a identificação de grupos potencializada com a capacidade de identificação de relações não lineares.

Tabela 12 – Estatísticas dos ajustes e características das Redes Neurais Artificiais (RNAs) para a classificação da madeira serrada de *Pinus caribaea* var. *caribaea* considerando como input as 24 variáveis determinantes da qualidade da madeira serrada.

| RNAs | Arquitetura | Funções de ativação | | | R (%) | |
|------|-------------|---------------------|----------|--------|--------|--------|
| | | Hidden | Output | Train. | Teste | Valid. |
| RNA1 | RBF 24-28-4 | Gaussian | Softmax | 81,420 | 84,210 | 68,421 |
| RNA2 | RBF 24-32-4 | Gaussian | Softmax | 76,503 | 78,947 | 65,789 |
| RNA3 | RBF 24-28-4 | Gaussian | Identity | 90,710 | 84,210 | 84,210 |
| RNA4 | RBF 24-8-4 | Softmax | Identity | 99,453 | 97,368 | 98,661 |
| RNA5 | RBF 24-29-4 | Gaussian | Softmax | 53,552 | 63,158 | 50,000 |

Arquitetura RNA = número de neurônios em cada camada; Train.= Treinamento; Valid. = Validação.

A segunda fase de treinamento, a qual Valença (2010) compara a uma rede ADALINE, seguiu o treinamento supervisionado padrão. Isto se resumiu na abordagem realizada na seção anterior fazendo uma análise fatorial e usando depois os fatores na regressão logística com a grande diferença que a rede consegue captar as complexas relações não lineares multivariadas existentes entre as variáveis (VIRIYAMETANONT, 2008). A superioridade da rede atribui-se também a sua maior parcimônia e, principalmente, sua capacidade de separar os efeitos combinados (multicolinearidade) entre as variáveis de entrada devido ao paralelismo da sua estrutura (VIRIYAMETANONT, 2008), evitando assim os problemas de multicolinearidade e não significância de variáveis enfrentados na modelagem por regressão logística.

Tabela 13 – Resultados de treinamento, teste e validação da RNA RBF 24-8-4 na classificação da madeira serrada de *Pinus caribaea* var. *caribaea*.

| AMOSTRA | OBSERVADO | ESTIMADO | | | | PC (%) |
|---------|------------|----------|----------|-----------|------------|--------|
| | | SELETA | CLASSE I | CLASSE II | CLASSE III | |
| TREIN. | SELETA | 8 | 2 | 0 | 0 | 80,00 |
| | CLASSE I | 4 | 49 | 2 | 0 | 89,09 |
| | CLASSE II | 0 | 0 | 26 | 3 | 89,65 |
| | CLASSE III | 0 | 0 | 3 | 33 | 91,67 |
| | PT (%) | 9,23 | 39,23 | 23,85 | 27,69 | 89,23 |
| TESTE | SELETA | 10 | 1 | 0 | 0 | 90,91 |
| | CLASSE I | 2 | 20 | 1 | 0 | 86,96 |
| | CLASSE II | 0 | 0 | 12 | 2 | 85,71 |
| | CLASSE III | 0 | 0 | 1 | 13 | 92,86 |
| | PT (%) | 19,35 | 33,87 | 22,58 | 24,19 | 88,71 |
| VALID. | SELETA | 4 | 0 | 0 | 0 | 100,00 |
| | CLASSE I | 0 | 33 | 5 | 0 | 86,84 |
| | CLASSE II | 0 | 1 | 5 | 0 | 83,33 |
| | CLASSE III | 0 | 0 | 1 | 18 | 94,74 |
| | PT (%) | 5,97 | 50,75 | 16,42 | 26,87 | 89,55 |

TREIN. = Treinamento; VALID. = Validação; PT= Porcentagem Total; PC= Porcentagem correta.

Os resultados da Figura 3 confirmam a significativa melhoria que a análise fatorial trouxe ao desempenho do modelo de RLPO proposto e a superioridade do desempenho das RNAs. As porcentagens gerais de acertos foram de 54,44%, 84,55% e 89,55% para os modelos RLPO, RLPO (com fatorial) e RBF 24-8-4 respectivamente (Tabelas 4, 11 e 13).




Figura 3 – Desempenhos dos diferentes modelos na classificação de madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na serraria Combate de Tenerías.

A análise da importância ou contribuição das variáveis (Apêndice 5.2) indicou que as mais importantes foram: CL (Curvatura largura), DRch (Diâmetro das Rachaduras) e LRch (Largura das rachaduras) relacionados aos defeitos de secagem da madeira serrada; PERP (Podridão externa reduzida à poeira), G (Gema) e DM (Danos mecânicos) e DFibr (Deflexão das fibras) relacionados a consistência da madeira serrada e MFC (Manchas de fungos no Cerne) relacionada à estética.

Este resultado indica que medidas têm que ser tomadas para controlar, principalmente, os defeitos de secagem, consistência e estética já que são os mais influentes na classificação da madeira serrada. A maioria das variáveis pertencentes a estes fatores caracteriza defeitos que aparecem com o tempo quando determinados cuidados não são observados no armazenamento da madeira serrada. Este resultado pode auxiliar na tomada de decisões a serem tomadas para minimizar os defeitos que mais influem na qualidade da madeira serrada.

4. CONCLUSÕES

- A regressão logística ordinal precedida de uma análise fatorial é uma alternativa viável de modelagem da classificação da madeira serrada.
- A equação de regressão logística politômica ordinal obtida (com os fatores) auxiliou eficientemente a classificação da madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na serraria Combate de Tenerías da Empresa Florestal Integral Macurije
- As redes neurais artificiais do tipo RBF, com apenas 8 neurônios na camada oculta, foram superiores ao modelo de regressão logística politômica ordinal na classificação da madeira serrada.
- As variáveis de maior contribuição na classificação da madeira serrada foram: a curvatura na largura (CL), o diâmetro das rachaduras (DRch), podridão externa reduzida à poeira (PERP), a gema (G) e os danos mecânicos (DM).

5. REFERÊNCIAS

ABREU, M.N.S.; SIQUEIRA, A.L.; CAIAFFA, W.T. Regressão logística ordinal em estudos epidemiológicos. **Rev Saúde Pública**, v.43, n.1, 11p, 2009.

ARRIAGA, M.F. et al. Madera aserrada de gran escuadría para uso estructural y sus particularidades. **Informes de la Construcción**, v. 59, n. 506, p. 29-41, 2007.

BISHOP, C. **Neural Networks for Pattern Recognition**. 1st ed. Oxford: University Press.1995. 482p.

CARREIRA, M.R. **Critérios para classificação de peças estruturais de Pinus sp**. 2003. 182f. Dissertação (Mestrado em Engenharia) - Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, SP.

CARREIRA, M.R.; DIAS, A.A. Classificação visual de coníferas: análise da aplicação do método norte-americano às espécies de Pinus sp plantadas no Brasil. **Scientia Forestalis**, n. 67, p.78-87, 2005.

CARREIRA, M.R.; DIAS, A.A. Critérios para classificação visual de peças estruturais de pinus sp. **Cadernos de Engenharia de Estruturas**, São Carlos, v. 8, n. 34, p. 17-43, 2006.

CARTWRIGHT, H.M. **Artificial Neural Networks**, 2nd ed. Vol 1260 in the Methods in Molecular Biology series. Springer, New York, 2015. 340p.

COOLEY, W.W.; LOHNES, P.R. **Multivariate data analysis**. New York, John Wiley & Sons, Inc. 1971. 364 p.

COX, D.R.; SNELL, E.J. A general definition of residuals (with discussion). **J R Stat Soc.**, v.3, p. 248-275, 1968.

DURBAK, I. et al. **Wood**. Fourth ed., Vol. 25. John Wiley and Sons, Inc., p. 627–664. 1998.

FRIEL, C. M. **Notes on Factor Analysis**. Criminal Justice Centre, Sam Houston State University. 2009. 45p.

GARCÍA, D.J.M. **Clasificador de madera aserrada. Especies de coníferas. Especificaciones**. Primera edición. NORMA RAMAL NRAG. Instituto de Investigaciones Forestales, Ciudad de Habana, 2006.13p.

GAVA, M. **Viabilidade técnica e econômica da produção de componentes para habitação social utilizando madeira serrada de pinus de terceira classe de qualidade.** 2005. 232f. Dissertação (Mestrado em Arquitetura e Urbanismo) - Escola de Engenharia de São Carlos, Universidade de São Carlos, São Carlos.

GODOY, E.A. Aprovechamiento del aserrín mediante su transformación hidrolítica y como fuente de biomasa Cuba. **Revista forestal centroamericana (CATIE)**, n. 39-40, p. 67-69. 1999.

HAIR, J.F. et al. **Multivariate Data Analysis.** 6ª edição. Upper Saddle River, NJ: Pearson Prentice Hall, 2006. 899p.

HANRAHAN, G. **Artificial neural networks in biological and environmental analysis.** CRC Press, 2011.182p.

LOUBAN, R. **Image Processing of Edge and Surface Defects: Theoretical Basis of Adaptive Algorithms with Numerous Practical Applications,** Springer Series in Materials Science, 2009. 173p.

LUGER, G.F. **Artificial Intelligence: Structures and Strategies for Complex Problem Solving.** Sixth ed. Boston: Addison-Wesley, 2008. 754p.

KLINE, D.E.; ARAMAN, P.A.; SURAK, C. Evaluation of an Automated Hardwood Lumber Grading System. Proceedings of ScanTech 2001. **The ninth international conference on scanning technology and process optimization for the wood industry,** Seattle, Washington, U.S.A. p.141-151, 2001.

KLINKHACHORN, P.; MOODY, J.; ARAMAN, P. Automated lumber processing system: grading the hardwood lumber? **Hardwood Symposium Proceedings,** May 17-20, p. 77-83, 1995.

KRETSCHMANN, D.E. Commercial Lumber, Round Timbers, and Ties. In: FOREST PRODUCTS LABORATORY. **Wood handbook—Wood as an engineering material.** General Technical Report FPL-GTR-190. Madison, WI: U.S. Department of Agriculture, Forest Service, Forest Products Laboratory. 508 p. 2010. Chapter 6, p.146-170.

MCFADDEN, D. Conditional logit analysis of qualitative choice behavior. In: ZAREMBKA, P. (ed.), **Frontiers in Econometrics,** Academic Press, New York, USA, 1973. Chapter 4, p. 105-142.

NAGELKERKE, N.J.D. A note on a general definition of the coefficient of determination. **Biometrika**, v.78, n.3, p. 691-692, 1991.

ONEI (Oficina Nacional de Estadística e Información). **Anuario estadístico de cuba 2014**. Medio ambiente, Edición 2014. República de cuba. 53p.

SCHWARZ, G. Estimating the dimensional of a model. **Annals of Statistics, Hayward**, v.6, n.2, p.461-464, 1978.

STATSOFT - **STATISTICA (Data Analysis Software System)**, version 8. StatSoft, Inc., 2012.

TABACHNICK, B.; FIDELL, L. **Using multivariate analysis**.5th. Ed. Needham Heights: Allyn & Bacon, 2007. 980p.

THOMAS, E. An artificial neural network for real-time hardwood lumber grading. **Computers and Electronics in Agriculture**, v. 132, pp. 71–75, 2017.

VALENÇA, M. **Fundamentos das redes neurais: Exemplos em Java**. 2ª. Edição, Revisado e ampliado. Olinda-PE: Livro Rápido, 2010. 386p.

VIRIYAMETANONT, K. **Reconnaissance physique et géométrique d'éléments en béton armé par radar et réseaux de neurones artificiels**. 2008. 248 f. Thèse (Doctorat en Génie Civil) - Institut National des Sciences Appliquées de Toulouse (INSA de Toulouse) de l'Université de Toulouse. France.

CONSIDERAÇÕES FINAIS

O presente trabalho propôs desenvolver ferramentas de auxílio a tomadas de decisões em determinadas etapas do Processo Produtivo Florestal (PPF) da Empresa Florestal Integral (EFI) Macurije por meio da aplicação de técnicas multivariadas, multicritérios e Redes Neurais Artificiais. Para atingir esse objetivo, três etapas do processo produtivo florestal foram envolvidas na pesquisa (Apêndice 6.1):

- Na etapa de crescimento e produção florestal, os modelos de regressão e de Redes Neurais Artificiais elaborados para a predição e prognose mais precisa da produção sobrevivência do *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na EFI Macurije (Capítulo I) permitirão obter uma maior eficiência no planejamento da produção florestal.
- Na segunda etapa composta pelas atividades de colheita e transporte florestal, avaliaram-se os desempenhos das máquinas de extração de madeira em diferentes cenários por meio de técnicas de análise multivariada (bivariada) que possibilitaram comparações mais criteriosas para tomadas de decisões mais objetivas (Capítulo II). Essa abordagem multicritério pode favorecer a escolha da combinação ótima de maquinaria e sistema de colheita em diferentes declividades para a minimização global dos custos de extração de madeira. Nesta mesma fase do PPF, elaborou-se um modelo de programação por metas lexicográfica para auxílio a tomada de decisão no transbordo (extração e transporte) da madeira (Capítulo III). A praticidade das soluções propostas nesta etapa é diretamente influenciada pelas anteriores. Os modelos de predição e prognose de produção e sobrevivência da primeira etapa auxiliariam na estimativa precisa do volume de madeira disponível e por consequência as ofertas de madeira nas diferentes origens de transbordo. A correta determinação das idades de rotação (capítulo I) influencia a extração da madeira já que os resultados do capítulo II indicaram a existência de diferença significativa entre a extração de toras de 21 anos (IRT adotada na empresa Macurije) e a de 32 anos que está próxima das IRTs encontradas na presente pesquisa. A extração de toras provenientes de árvores de maiores idades apresenta maiores produtividades e menores custos unitários.
- Na terceira etapa correspondente a de transformação primária da madeira (desdobro), duas classes de ferramentas foram propostas: uma primeira constituída de modelos de

regressão e de RNAs para a predição do rendimento em madeira serrada (Capítulo IV); e uma segunda classe constituída por modelos de regressão logística ordinal e RNAs para a classificação de madeira serrada (Capítulo V). Esse rendimento de madeira serrada é influenciado pela correta determinação da idade de rotação (capítulo I) já que os resultados indicaram que as toras de maiores dimensões, que são geralmente obtidas em maiores rotações, apresentam maiores rendimentos em madeira serrada. Por outro lado, o modelo de extração e transporte de madeira proposto no capítulo III auxiliaria o planejamento da extração e transporte de madeira para assegurar o abastecimento contínuo de madeira nos pátios das unidades de transformação primária da empresa (serrarias e planta de impregnação de madeira para produção de postes elétricos).

Evidenciou-se na presente pesquisa, a sinergia existente entre as diferentes etapas do Processo de Produção Florestal. As soluções, mesmo propostas de forma individual e específica, têm influencia sobre as etapas subsequentes. É recomendada, de ser possível, a integração de determinadas atividades na elaboração de ferramentas de auxílio à tomada de decisão para a tomada de decisões mais certas com uma visão integrada.

Essa integração permitiu um melhor entendimento da ligação entre as ações que perpassam todas as etapas do processo produtivo florestal. A falta dessa visão integrada no planejamento da produção pode levar numerosas empresas florestais a soluções específicas desconectadas e, dessa maneira, uma incapacidade em se atingir o real objetivo da empresa.

CONCLUSÕES GERAIS

- As Redes Neurais Artificiais foram eficientes nas predições e prognoses do crescimento, produção e sobrevivência em florestas plantadas de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf. na empresa florestal Macurije.
- O sistema de avaliação baseado em técnicas de análise multivariada (experimento fatorial multivariado) auxiliou em uma avaliação mais criteriosa e menos subjetiva dos desempenhos das máquinas de colheita florestal.
- O modelo de Programação por Metas Lexicográfica de transbordo de madeira proposto, integrando as operações de extração e transporte de madeira, auxiliou no planejamento e minimização dos custos globais e pode ser implementado a escala empresarial.
- Os modelos desenvolvidos baseados em Equações Diferencias Ordinárias e em Redes Neurais Artificiais apresentaram desempenhos satisfatórios na predição precisa do rendimento em serrada.
- Os modelos de regressão logística ordinal e de Redes Neurais Artificiais desenvolvidos demonstraram alta precisão na classificação da madeira serrada.
- As soluções específicas propostas para as etapas iniciais do processo produtivo florestal têm efeitos indiretos positivos sobre as etapas subsequentes.
- A integração das etapas do processo produtivo florestal permitiu a proposta de soluções técnicas e práticas com uma visão integrada, assim como a identificação de sinergias existentes entre essas etapas para um melhor planejamento procurando minimizar custos e melhorar produtividade.

ANEXOS
&
APÊNDICES

Anexo 1.0 - Principais modelos de crescimento biológicos/sigmoidais (teóricos) utilizados na modelagem do crescimento florestal

| Modelo | Expressão matemática | | | Propriedades | | |
|--------------------|--|---|------------------------------|---|--|---|
| | Forma Diferencial | Forma integrada | Restrições dos parâmetros | Valor inicial $\lim_{t \rightarrow 0} Y$ | Ponto de Inflexão $\frac{d^2Y}{dt^2} = 0$ | Assíntota $\lim_{t \rightarrow +\infty} Y$ |
| Chapman-Richards | $\frac{dY}{dt} = \alpha Y^m - \gamma Y$ | $Y = A(1 - \gamma e^{-\alpha t})^{\frac{1}{1-m}} + \varepsilon$ | $\gamma > 0$ $\alpha > 0$ | $Y = A(1 - \gamma)^{\frac{1}{1-m}}$ | $t = \frac{\log(\frac{\gamma}{1-m})}{\alpha}$; $Y = Am(\frac{1}{1-m})$ | $Y \rightarrow A$ |
| Von Bertalanffy | $\frac{dY}{dt} = \alpha(A - Y)$ | $Y = A(1 - \gamma e^{-\alpha t})^3 + \varepsilon$ | $\alpha > 0$ | $Y = A(1 - \gamma)^3$ | $t = \frac{1}{\alpha} \log 3\gamma$; $Y = \frac{8}{27} A$ | $Y \rightarrow A$ |
| Gompertz | $\frac{dY}{dt} = \alpha Y \ln \frac{A}{Y}$ | $Y = Ae^{-\gamma \text{Exp}(-\alpha t)} + \varepsilon$ | $\alpha > 0$ | $Y = Ae^{-\gamma}$ | $t = \frac{\log \gamma}{\alpha}$; $Y = \frac{A}{e}$ | $Y \rightarrow A$ |
| Logística | $\frac{dY}{dt} = \frac{\alpha}{A}(AY - Y^2)$ | $Y = A/(1 + \gamma e^{-\alpha t}) + \varepsilon$ | $\alpha > 0$ | $Y = \frac{A}{1 + \gamma}$ | $t = \frac{1}{\alpha} \log \gamma$; $Y = \frac{A}{2}$ | $Y \rightarrow A$ |
| *Monomolecular | $\frac{dY}{dt} = \alpha(A - Y)$ | $Y = A(1 - \gamma e^{-\alpha t}) + \varepsilon$ | $\alpha > 0$ | $Y = A(1 - \gamma)$ | Nenhum | $Y \rightarrow A$ |
| Schumacher | $\frac{dY}{dt} = Y \frac{\alpha}{t^2}$ | $Y = Ae^{-\frac{\alpha}{t}} + \varepsilon$ | $\alpha > 0$ | $Y = 0$ | $t = \frac{\alpha}{2}$; $Y = \frac{A}{e^2}$ | $Y \rightarrow A$ |
| Lundqvist-Korf | $\frac{dY}{dt} = mY \frac{\alpha}{t^{m+1}}$ | $Y = Ae^{-\frac{\alpha}{t^m}} + \varepsilon$ | $\alpha > 0$ | $Y = 0$ | $t = \left(\frac{mk}{m+1}\right)^{\frac{1}{m}}$; $Y = Ae^{-\frac{m+1}{m}}$ | $Y \rightarrow A$ |
| Silva-Bailey | $\frac{dY}{dt} = \gamma Y \alpha^t$ | $Y = Ae^{k\alpha^t} + \varepsilon$ | $\alpha > 0$ | $Y = Ae^k$ | $t = \frac{\ln(-1/k)}{\ln(\alpha)}$; $Y = Ae^{k\alpha^{\frac{\ln(-1/k)}{\ln(\alpha)}}$ | $Y \rightarrow A$ |
| Johnson-Schumacher | $\frac{dY}{dt} = Y \frac{\alpha}{(t+k)^2}$ | $Y = Ae^{-\frac{\alpha}{t+k}} + \varepsilon$ | $\alpha > 0$ | $Y = Ae^{\frac{\alpha}{k}}$ | $t = \frac{\alpha}{2} - k$; $Y = \frac{A}{e^2}$ | $Y \rightarrow A$ |

Fonte: Burkhart e Tomé (2012) modificada e ampliada; *também conhecido como modelo de Mitscherlich ou de Brody, é o único modelo não sigmoidal da lista, por não apresentar um ponto de inflexão.

Anexo 2.0 - Parâmetros sugeridos por Schnute (1981) e os tipos de modelo correspondentes

| Valores de α e β | Tipo de modelo |
|-------------------------------|---|
| $\alpha < 0, \beta = 1$ | Exponencial |
| $\alpha > 0, \beta = -1$ | Logístico |
| $\alpha > 0, \beta = 0$ | Gompertz |
| $\alpha > 0, \beta < 0$ | Richards |
| $\alpha > 0, \beta = 1$ | Von Bertalanfy generalizado: Putter No. 1 |
| $\alpha > 0, \beta = 1/3$ | Von Bertalanfy generalizado: Putter No. 2 |
| $\alpha > 0, \beta > 0$ | Von Bertalanfy generalizado |
| $\alpha = 0, \beta = 1$ | Linear |
| $\alpha = 0, \beta = 1/2$ | Quadrático |
| $\alpha = 0, \beta = 0$ | n-ésima potência |

Fonte: Bentil et al. (2007)

APÊNDICES DO CAPÍTULO I

Apêndice 1.1 – Testes de Normalidade dos resíduos dos modelos de predição de crescimento ajustados

| Modelos | Kolmogorov-Smirnov ^a | | | Normalidade |
|------------------|---------------------------------|-----|------|-------------|
| | Estatístico | GL | Sig. | |
| Schumacher | ,042 | 550 | ,059 | Sim |
| Korf | ,051* | 550 | ,003 | Não |
| Chapman_Richards | ,060* | 550 | ,000 | Não |
| Logístico | ,035 | 550 | ,186 | Sim |
| Silva_Bailey | ,037 | 550 | ,092 | Sim |

*Teste significativo em um nível de significância de 5%; a. Correção de significância de Lilliefors

Apêndice 1.2 – Teste de Durbin-Watson para autocorrelação serial dos resíduos

| Modelos | d _L | d _U | 4 - d _U | 4 - d _L | DW | AS* |
|------------------|----------------|----------------|--------------------|--------------------|------|---------|
| Schumacher | 1,856 | 1,863 | 2,137 | 2,144 | 2,04 | Não |
| Korf | 1,852 | 1,867 | 2,133 | 2,148 | 0,49 | Sim (+) |
| Chapman-Richards | 1,852 | 1,867 | 2,133 | 2,148 | 2,61 | Sim (-) |
| Logístico | 1,852 | 1,867 | 2,133 | 2,148 | 2,24 | Sim (-) |
| Silva e Bailey | 1,852 | 1,867 | 2,133 | 2,148 | 3,22 | Sim (-) |

* Autocorrelação serial

Apêndice 1.3 – Teste de homogeneidade de variância de White

| Modelos | LM | p-valor | Homocedasticidade |
|------------------|---------|-----------|-------------------|
| Schumacher | 2,241 | 0,134 | Sim |
| Korf | 2,212 | 0,137 | Sim |
| Chapman-Richards | 0,367 | 0,832 | Sim |
| Logístico | 261,366 | 0,000 | Não |
| Silva e Bailey | 22,489 | 1,307E-05 | Não |

Apêndice 1.4 - Limites de altura dominante (Hd) por idade e Índice de Sitio com definição de cinco classes de capacidade produtiva, considerando uma idade índice de 30 anos.

| Idade | Índice de sitio | | | | |
|-------|-----------------|---------------|---------------|---------------|---------------|
| | V | IV | III | II | I |
| 06 | 0,83 - 1,05 | 1,05 - 1,43 | 1,43 - 2,13 | 2,13 - 3,48 | 3,48 - 6,27 |
| 08 | 1,83 - 2,30 | 2,30 - 3,05 | 3,05 - 4,29 | 4,29 - 6,46 | 6,46 - 10,42 |
| 10 | 2,94 - 3,68 | 3,68 - 4,80 | 4,80 - 6,54 | 6,54 - 9,37 | 9,37 - 14,13 |
| 12 | 4,02 - 5,04 | 5,04 - 6,50 | 6,50 - 8,66 | 8,66 - 12,00 | 12,00 - 17,32 |
| 14 | 5,04 - 6,31 | 6,31 - 8,07 | 8,07 - 10,59 | 10,59 - 14,32 | 14,32 - 20,02 |
| 16 | 5,96 - 7,47 | 7,47 - 9,49 | 9,49 - 12,30 | 12,30 - 16,34 | 16,34 - 22,32 |
| 18 | 6,80 - 8,52 | 8,52 - 10,77 | 10,77 - 13,83 | 13,83 - 18,12 | 18,12 - 24,29 |
| 20 | 7,55 - 9,46 | 9,46 - 11,91 | 11,91 - 15,19 | 15,19 - 19,68 | 19,68 - 26,00 |
| 22 | 8,23 - 10,31 | 10,31 - 12,94 | 12,94 - 16,39 | 16,39 - 21,05 | 21,05 - 27,48 |
| 24 | 8,84 - 11,07 | 11,07 - 13,86 | 13,86 - 17,47 | 17,47 - 22,27 | 22,27 - 28,78 |
| 26 | 9,39 - 11,76 | 11,76 - 14,70 | 14,70 - 18,44 | 18,44 - 23,35 | 23,35 - 29,92 |
| 28 | 9,90 - 12,39 | 12,39 - 15,45 | 15,45 - 19,32 | 19,32 - 24,33 | 24,33 - 30,94 |
| 30 | 10,35 - 12,96 | 12,96 - 16,13 | 16,13 - 20,11 | 20,11 - 25,20 | 25,20 - 31,85 |
| 32 | 10,77 - 13,48 | 13,48 - 16,76 | 16,76 - 20,83 | 20,83 - 25,99 | 25,99 - 32,67 |
| 34 | 11,15 - 13,95 | 13,95 - 17,32 | 17,32 - 21,48 | 21,48 - 26,71 | 26,71 - 33,41 |
| 36 | 11,50 - 14,39 | 14,39 - 17,85 | 17,85 - 22,08 | 22,08 - 27,37 | 27,37 - 34,08 |
| 38 | 11,82 - 14,79 | 14,79 - 18,33 | 18,33 - 22,63 | 22,63 - 27,97 | 27,97 - 34,70 |
| 40 | 12,12 - 15,16 | 15,16 - 18,77 | 18,77 - 23,14 | 23,14 - 28,52 | 28,52 - 35,26 |

Apêndice 1.5 - Análise de covariância da altura dominante (Hdom) do índice de sitio

| FV | GL | SQ | QM | F | Sig. |
|------------------|-----|------------|----------|----------|----------|
| Modelo corrigido | 41 | 10519, 780 | 256,580 | 119,653 | <0, 0001 |
| Intercepto | 1 | 242, 464 | 242,464 | 113,071 | <0, 0001 |
| Idade | 20 | 23, 016 | 1,151 | 0,537 | 0, 942 |
| Sítio | 1 | 3754, 094 | 3754,094 | 1750,684 | <0, 0001 |
| IdadexSítio | 20 | 682, 701 | 34,135 | 15,919 | <0, 0001 |
| Erro | 84 | 180, 126 | 2,144 | | |
| Total | 126 | 34373, 005 | - | - | - |

Apêndice 1.6 – Testes de Normalidade dos resíduos dos modelos de prognose de produção

| Modelos | Kolmogorov-Smirnov ^a | | Normalidade |
|---------------------------------------|---------------------------------|-------|-------------|
| | Estatístico | Sig. | |
| dG ₂ _B.M.S. et al. (2006) | ,114 | ,056 | Sim |
| V ₂ _ B.M.S. et al. (2006) | ,197 | ,071 | Sim |
| G_Clutter | ,143* | ,003 | Não |
| V_Clutter | ,181* | ,000 | Não |
| Silva e Bailey (1986) | 0,107 | 0,050 | Sim |
| Clutter e Jones (1980) | 0,280 | 0,000 | Não |

*Teste significativo em um nível de significância de 5%; a. Correção de significância de Lilliefors.

Apêndice 1.7 – Teste de Durbin-Watson para autocorrelação serial dos resíduos dos modelos de prognose de produção

| Modelos | d _L | d _U | 4 - d _U | 4-d _L | DW | AS* |
|--|----------------|----------------|--------------------|------------------|-------|---------|
| dG ₂ _ B.M.S. et al. (2006) | 1,516 | 1,700 | 2,300 | 2,484 | 1,707 | Não |
| V ₂ _ B.M.S. et al. (2006) | 1,516 | 1,700 | 2,300 | 2,484 | 1,888 | Não |
| G_Clutter | 1,577 | 1,637 | 2,363 | 2,423 | 1,020 | Sim (+) |
| V_Clutter | 1,516 | 1,700 | 2,300 | 2,484 | 1,173 | Sim (+) |
| Silva e Bailey (1986) | 1,580 | 1,639 | 2,361 | 2,420 | 1,537 | Sim (+) |
| Clutter e Jones (1980) | 1,551 | 1,669 | 2,331 | 2,449 | 1,94 | Não |

* Autocorrelação serial

Apêndice 1.8 – Teste de homogeneidade de variância de White para os modelos de prognose de produção

| Modelos | LM | p-valor | Hom. |
|--|--------|---------|------|
| dG ₂ _ B.M.S. et al. (2006) | 5,372 | 0,1465 | Sim |
| V ₂ _ B.M.S. et al. (2006) | 7,6636 | 0,0535 | Sim |
| G_Clutter | 2,725 | 0,2559 | Sim |
| V_Clutter | 11,074 | 0,0113 | Não |
| Silva e Bailey (1986) | 2,887 | 0,409 | Sim |
| Clutter e Jones (1980) | 2,1415 | 0,5435 | Sim |

Apêndice 1.9 – Testes de Normalidade dos resíduos dos modelos de prognose de sobrevivência

| Modelos | Kolmogorov-Smirnov ^a | | Normalidade |
|-------------------------|---------------------------------|------|-------------|
| | Estatístico | Sig. | |
| Clutter e Jones (1980) | ,507 | ,000 | Não |
| Silva e Bailey (1986) | ,261 | ,053 | Sim |
| Pienaar e Shiver (1981) | ,124 | ,068 | Sim |
| Chapman-Richards (1959) | ,496 | ,000 | Não |
| Weibull | ,500 | ,000 | Não |

*Teste significativo em um nível de significância de 5%; a. Correção de significância de Lilliefors.

Apêndice 1.10 – Teste de Durbin-Watson para autocorrelação serial dos resíduos dos modelos de prognose de sobrevivência

| Modelos | d _L | d _U | 4 - d _U | 4-d _L | DW | AS* |
|-------------------------|----------------|----------------|--------------------|------------------|-------|---------|
| Clutter e Jones (1980) | 1,551 | 1,669 | 2,331 | 2,449 | 1,700 | Não |
| Silva e Bailey (1986) | 1,580 | 1,639 | 2,361 | 2,420 | 1,762 | Não |
| Pienaar e Shiver (1981) | 1,580 | 1,639 | 2,361 | 2,420 | 1,718 | Não |
| Chapman-Richards (1959) | 1,580 | 1,639 | 2,361 | 2,420 | 1,215 | Sim (+) |
| Weibull | 1,551 | 1,669 | 2,331 | 2,449 | 1,150 | Sim (+) |

* Autocorrelação serial.

Apêndice 1.11 – Teste de homogeneidade de variância de White para os modelos de prognose de sobrevivência

| Modelos | LM | p-valor | Hom. |
|-------------------------|-------|---------|------|
| Clutter e Jones (1980) | 4,962 | 0,174 | Sim |
| Silva e Bailey (1986) | 2,985 | 0,225 | Sim |
| Pienaar e Shiver (1981) | 3,629 | 0,163 | Sim |
| Chapman-Richards (1959) | 9,578 | 0,008 | Não |
| Weibull | 9,561 | 0,023 | Não |

Apêndice 1.12 – Demonstração matemática da expressão de determinação da Idade Técnica de Rotação (ITR) com o modelo de Silva e Bailey (1986)

Seja o modelo de Silva e Bailey (1986) definido pela seguinte expressão (01) na qual Y é a produção (m³/ha) e I é a idade (anos).

$$Y = \beta_0 e^{\beta_1 \beta_2^I} \tag{01}$$

A ITR é a idade na qual o povoamento atinge a sua máxima produtividade, geralmente definida pela relação (2) que indica que a ITR corresponde também a idade em que o Incremento Médio Anual (IMA) e Incremento Corrente Anual (ICA) do povoamento se igualam:

$$ICA = IMA \tag{02}$$

- Determinando a expressão do Incremento Corrente Anual (ICA)

A expressão de determinação do ICA sendo definida pela primeira derivada da função de produção (01), estabelecemos então:

$$\begin{aligned} ICA = \frac{dY}{dI} &= \left[\beta_0 e^{\beta_1 \beta_2^I} \right]' = \beta_0 \left[(\beta_1 \beta_2^I)' \cdot (e^{\beta_1 \beta_2^I}) \right] \\ &= \beta_0 \beta_1 \left[(\ln \beta_2 \cdot \beta_2^I) \cdot (e^{\beta_1 \beta_2^I}) \right] \\ ICA &= \beta_0 \beta_1 \beta_2^I \cdot \ln \beta_2 \cdot e^{\beta_1 \beta_2^I} \end{aligned} \tag{03}$$

- Determinando a expressão do Incremento Médio Anual (IMA)

A expressão matemática do IMA (04) foi determinada dividindo a produção (01) pela idade:

$$IMA = \frac{\beta_0 e^{\beta_1 \beta_2^I}}{I} \tag{04}$$

- Igualando as relações (03) e (04) como indicado na equação (02) tem-se:

$$\begin{aligned} \beta_0 \beta_1 \beta_2^I \cdot \ln \beta_2 \cdot e^{\beta_1 \beta_2^I} &= \frac{\beta_0 e^{\beta_1 \beta_2^I}}{I} \longrightarrow \beta_0 \beta_1 \beta_2^I \cdot \ln \beta_2 \cdot e^{\beta_1 \beta_2^I} = \frac{\beta_0 e^{\beta_1 \beta_2^I}}{I} \\ \longrightarrow \beta_1 \beta_2^I \cdot \ln \beta_2 &= \frac{1}{I} \end{aligned} \tag{05}$$

A equação (5) não tendo solução na matemática convencional, recorreu-se às propriedades da função de Lambert segundo a qual $x = W_n(a)$ é a solução da equação $xe^x = a$, sendo W_n a função de Lambert. Para o mesmo procedeu-se a transformação da equação (05) para obter a identidade da função de Lambert:

$$\begin{aligned} \text{Seja } f(I) &= \beta_2^I \\ \text{Ln}[f(I)] &= \text{Ln}(\beta_2^I) \longrightarrow \text{Ln}[f(I)] = I \cdot \text{Ln}(\beta_2) \\ e^{\text{Ln}[f(I)]} &= e^{I \cdot \text{Ln}\beta_2} \longrightarrow f(I) = e^{I \cdot \text{Ln}\beta_2} \\ \beta_2^I &= e^{I \cdot \text{Ln}\beta_2} \end{aligned} \tag{06}$$

Substituindo (06) em (05) tem-se:

$$\begin{aligned} \beta_1 \cdot e^{I \cdot \text{Ln}\beta_2} \cdot \text{Ln}\beta_2 &= \frac{1}{I} \longrightarrow I \cdot \text{Ln}\beta_2 \cdot e^{I \cdot \text{Ln}\beta_2} = \frac{1}{\beta_1} \\ \text{Considerando } x &= I \cdot \text{Ln}\beta_2, \text{ tem-se: } xe^x = \frac{1}{\beta_1} \end{aligned} \tag{07}$$

Identificando e aplicando a função de Lambert para a resolução da equação (07) tem-se:

$$x = W_n\left(\frac{1}{\beta_1}\right)$$

Substituindo x pelo seu valor, tem-se: $I \cdot \text{Ln}\beta_2 = W_n\left(\frac{1}{\beta_1}\right)$

A expressão de determinação da ITR com o modelo de Silva e Bailey (1986) é então:

$$ITR = \frac{W_n(1/b_1)}{\text{Ln } b_2} ; \text{ com } b_1, b_2 \text{ e } \text{Ln}(b_2) \neq 0; n \in \mathbb{Z}.$$

Em que: b_1 e b_2 são as estimativas respectivas dos parâmetros β_1 e β_2 do modelo obtidas após ajuste do mesmo e W_n é a função de Lambert.

Apêndice 1.13 – Demonstração matemática da expressão de determinação da Idade Técnica de Rotação (ITR) com o modelo de Korf (1939)

Seja o modelo de Korf (1939) definido pela seguinte expressão (01) na qual $Y(\text{m}^3/\text{ha})$ é a produção e I (anos) a idade.

$$Y = \beta_0 e^{-\beta_1 I^{-\beta_2}} \tag{01}$$

A ITR é a idade na qual o povoamento atinge a sua máxima produtividade, geralmente definida pela relação (02) que indica que a ITR corresponde também a idade em que o Incremento Médio Anual (IMA) e Incremento Corrente Anual (ICA) do povoamento se igualam:

$$ICA = IMA \tag{02}$$

- Determinando a expressão do Incremento Corrente Anual (ICA)

A expressão de determinação do ICA sendo definida pela primeira derivada da função de produção (01), estabelecemos então:

$$\begin{aligned}
 ICA &= \frac{dY}{dI} = \left[\beta_0 e^{-\beta_1 I^{-\beta_2}} \right]' = \beta_0 \left[\frac{d(e^{-\beta_1 I^{-\beta_2}})}{dI} \right] \\
 &= \beta_0 \left[-\beta_1 I^{-\beta_2} \right]' e^{-\beta_1 I^{-\beta_2}} \\
 &= \beta_0 (-\beta_1) \left[(-\beta_2) I^{(-\beta_2-1)} \right] e^{-\beta_1 I^{-\beta_2}} \\
 ICA &= \beta_0 \beta_1 \beta_2 I^{(-\beta_2-1)} e^{-\beta_1 I^{-\beta_2}} \tag{03}
 \end{aligned}$$

- Determinando a expressão do Incremento Médio Anual (IMA)

A expressão matemática do IMA (04) foi determinada dividindo a produção (01) pela idade:

$$IMA = \frac{\beta_0 e^{-\beta_1 I^{-\beta_2}}}{I} \tag{04}$$

- Igualando as relações (03) e (04) como indicado na equação (02) tem-se:

$$\begin{aligned}
 \beta_0 \beta_1 \beta_2 I^{(-\beta_2-1)} e^{-\beta_1 I^{-\beta_2}} &= \frac{\beta_0 e^{-\beta_1 I^{-\beta_2}}}{I} \\
 \beta_0 \beta_1 \beta_2 I^{(-\beta_2-1)} e^{-\beta_1 I^{-\beta_2}} &= \frac{\beta_0 e^{-\beta_1 I^{-\beta_2}}}{I} \longrightarrow \beta_1 \beta_2 I^{(-\beta_2-1)} = \frac{1}{I} \\
 I * I^{(-\beta_2-1)} &= \frac{1}{\beta_1 \beta_2} \longrightarrow I^{(-\beta_2)} = \frac{1}{\beta_1 \beta_2} \longrightarrow I = \left(\frac{1}{\beta_1 \beta_2} \right)^{\left(\frac{1}{-\beta_2} \right)}
 \end{aligned}$$

A expressão de determinação da ITR com o modelo de Korf (1939) é então:

$$ITR = \left(\frac{1}{b_1 b_2} \right)^{\left(\frac{1}{-b_2} \right)} ; \text{ com } b_1, b_2 \neq 0$$

Em que: b_1 e b_2 são as estimativas respectivas dos parâmetros β_1 e β_2 do modelo de Korf obtidas após ajuste do mesmo.

Apêndice 1.14 – Demonstração matemática da expressão de determinação da Idade Técnica de Rotação (ITR) com o modelo de Chapman-Richards (1959)

Seja o modelo de Chapman-Richards (1959) definido pela seguinte expressão (01) na qual $Y(m^3/ha)$ é a produção e $I(\text{anos})$ a idade.

$$Y = \beta_0 (1 - e^{-\beta_1 I})^{\beta_2} \tag{01}$$

A ITR é a idade na qual o povoamento atinge a sua máxima produtividade, geralmente definida pela relação (02) que indica que a ITR corresponde também a idade em que o Incremento Médio Anual (IMA) e Incremento Corrente Anual (ICA) do povoamento se igualam:

$$ICA = IMA \tag{02}$$

- Determinando a expressão do Incremento Corrente Anual (ICA)

A expressão de determinação do ICA sendo definida pela primeira derivada da função de produção (01), estabelecemos então:

$$\begin{aligned}
 ICA &= \frac{dY}{dI} = [\beta_0(1 - e^{-\beta_1 I})^{\beta_2}]' = \beta_0 \left[\frac{d((1 - e^{-\beta_1 I})^{\beta_2})}{dI} \right] \\
 &= \beta_0 [\beta_2(1 - e^{-\beta_1 I})' * (1 - e^{-\beta_1 I})^{\beta_2 - 1}] \\
 &= \beta_0 \beta_2 [-(-\beta_1)e^{-\beta_1 I}] * (1 - e^{-\beta_1 I})^{\beta_2 - 1} \\
 ICA &= \beta_1 \beta_0 \beta_2 e^{-\beta_1 I} * (1 - e^{-\beta_1 I})^{\beta_2 - 1} \tag{03}
 \end{aligned}$$

- Determinando a expressão do Incremento Médio Anual (IMA)

A expressão matemática do IMA (04) foi determinada dividindo a produção (01) pela idade:

$$IMA = \frac{\beta_0(1 - e^{-\beta_1 I})^{\beta_2}}{I} \tag{04}$$

- Igualando as relações (03) e (04) como indicado na equação (02) tem-se:

$$\begin{aligned}
 \beta_1 \beta_0 \beta_2 e^{-\beta_1 I} * (1 - e^{-\beta_1 I})^{\beta_2 - 1} &= \frac{\beta_0(1 - e^{-\beta_1 I})^{\beta_2}}{I} \\
 \beta_1 \beta_0 \beta_2 e^{-\beta_1 I} * \frac{(1 - e^{-\beta_1 I})^{\beta_2}}{(1 - e^{-\beta_1 I})} &= \frac{\beta_0(1 - e^{-\beta_1 I})^{\beta_2}}{I} \\
 \frac{\beta_1 \beta_2 e^{-\beta_1 I}}{(1 - e^{-\beta_1 I})} &= \frac{1}{I} \implies I \beta_1 \beta_2 e^{-\beta_1 I} = 1 - e^{-\beta_1 I} \implies I \beta_1 \beta_2 e^{-\beta_1 I} + e^{-\beta_1 I} = 1 \\
 e^{-\beta_1 I} * (I \beta_1 \beta_2 + 1) &= 1 \implies I \beta_1 \beta_2 + 1 = e^{\beta_1 I} \\
 \frac{I \beta_1 \beta_2 + 1}{e^{\beta_1 I}} &= 1 \implies (I \beta_1 \beta_2 + 1) e^{-\beta_1 I} = 1 \tag{05}
 \end{aligned}$$

$$(05) \div -\beta_2 \implies (-\beta_1 * I - \frac{1}{\beta_2}) e^{-\beta_1 I} = -\frac{1}{\beta_2} \tag{06}$$

$$\begin{aligned}
 (06) * e^{-\frac{1}{\beta_2}} &\implies e^{-\frac{1}{\beta_2}} * (-\beta_1 * I - \frac{1}{\beta_2}) e^{-\beta_1 I} = (-\frac{1}{\beta_2}) * e^{-\frac{1}{\beta_2}} \\
 \implies (-\beta_1 * I - \frac{1}{\beta_2}) * e^{(-\beta_1 I - \frac{1}{\beta_2})} &= -\frac{e^{-\frac{1}{\beta_2}}}{\beta_2} \tag{07}
 \end{aligned}$$

Aplicando a função de Lambert à equação (07) tem-se:


$$\begin{aligned}
 -\beta_1 * I - \frac{1}{\beta_2} &= W_n \left(-\frac{e^{-\frac{1}{\beta_2}}}{\beta_2} \right) \implies -\beta_1 * I = W_n \left(-\frac{e^{-\frac{1}{\beta_2}}}{\beta_2} \right) + \frac{1}{\beta_2} \\
 I &= \frac{W_n \left(-\frac{e^{-\frac{1}{\beta_2}}}{\beta_2} \right) + \frac{1}{\beta_2}}{-\beta_1} \implies I = \frac{\beta_2 * W_n \left(-\frac{e^{-\frac{1}{\beta_2}}}{\beta_2} \right) + 1}{-\beta_1 * \beta_2} \implies I = \frac{-\beta_2 * W_n \left(-\frac{e^{-\frac{1}{\beta_2}}}{\beta_2} \right) - 1}{\beta_1 * \beta_2}
 \end{aligned}$$

A expressão de determinação da ITR com o modelo de Chapman-Richards (1959) é então:

$$ITR = \frac{-b_2 * W_n \left(-\frac{1}{b_2} \right) - 1}{b_1 * b_2} ; \text{com } b_1, b_2 \neq 0$$

Em que: b_1 e b_2 são as estimativas respectivas dos parâmetros β_1 e β_2 do modelo de Chapman-Richards (1959) obtidas após ajuste do mesmo.

Apêndice 1.15 – ICAs e IMAs e idades técnicas de rotação por sítio geradas pela RNA_P1



ANEXOS E APÊNDICES DO CAPÍTULO II

ANEXOS

Anexo 2.1 – Custos fixos, variáveis e de mão de obra das maquinas

| Custos fixos ou de propriedade $C_f = C_d + C_j + C_s + C_{ip}$ | Custos variáveis ou operacionais $C_v = C_c + C_l + C_{rm} + C_{om}$ | Custo de mão de obra $C_{lb} = C_{dl} + C_s$ |
|--|---|--|
| Custo de depreciação (Método de Matheson) $V_n = V_a(1 - T)^n$ | Custos do combustível $C_{mc} = (K * GHP * L_f) / KPL$ $C_{cc} = C_{mc} * P_c$ | Custo direto do trabalho $C_{dl} = S_b * \left[1 + \left(\frac{B}{100}\right)\right] * (T_{nw} + T_w) / T_w$ |
| Custo de juros $C_j = \frac{T_j * IHM}{100}$ $IMA = \left[(V_a - V_r) * \frac{N + 1}{2N} \right] + V_r$ $IHM = IMA / n$ | Custo de lubrificante $C_l = C_{ml} * P_l$ $C_{ml} = C_{mc} * \%C_{ml} / 100$ | Custo de supervisão $C_s = C_{dl} + (S / 100)$ |
| Custo dos seguros $C_s = T_s * IMH / 100$ | Custos da reparação e manutenção $C_{rm} = C_d * \%C_{rm} / 100$ | |
| Custo de impostos das máquinas $C_{ip} = T_{ip} * IMH / 100$ | Custo de outros materiais $C_{om} = P_m / V_u$ | Custo de taxas administrativas $T = \frac{Va * FA}{He}$ |

Fonte: Cándano (1998) e Machado (2014).

Em que:

C_f = Custos fixos
 C_d = Custo de depreciação.
 C_j =Custo de juros
 C_s =Custo de seguros
 C_{ip} = Custo do imposto
 C_{lb} = Custo de mão da obra (\$/h).
 C_{dl} = Custo direto do trabalho, (\$/ h).
 C_s = Custo de supervisão, (\$/h).
 C_{mc} = Consumo de combustível (l/ h).
 K = Kg de combustíveis utilizados pela HP ou KW por hora.
 GHP = Motor em CV ou KW no trabalho velocidade nominal (rpm).
 L_f = Fator de carga do motor (%)
 KPL = Peso do combustível (kg/l).
 C_{cc} = Custo do combustível (\$/h).
 P_c = Preço do Combustível (\$/l).
 IMA = Investimento médio anual (\$ / ano).
 IMH =Investimento médio horário (\$ / h).
 C_j = Custo dos juros da máquina (\$/ h)
 T_j =Taxa de juros (por cento).
 n =Tempo de trabalho da máquina (h / ano).

C_c = Custos do combustível
 C_l = Custo de lubrificante
 C_{rm} = Custos da reparação e manutenção
 C_{om} = Custo de outros materiais
 V_n = Valor do ativo no período n
 V_a = Valor de aquisição
 $T = \sqrt[n]{V_n/V_o}$ = Taxa de depreciação.
 S_b = Salário básico do operador e dos assistentes, (\$/ h).
 B = Benefícios recebidos pelos trabalhadores (%).
 T_{nw} = Tempo não trabalhado pela máquina no dia, (h).
 T_w = Tempo de trabalho da máquina no dia, (h).
 C_l = Custo de lubrificante (\$ / h).
 C_{ml} = Consumo de lubrificante (l/ h).
 P_l = Preço de lubrificante (\$/ l).
 $\%C_{ml}$ = Percentagem utilizada para calcular o lubrificante a partir do consumo de combustível.

- C_{dl} = Custo direto do trabalho, (\$/ h).
- S = Percentagem dos custos de trabalho de supervisão, (%).
- C_s = Custo do seguro da máquina (\$ / h).
- T_s = Taxa de seguros (%)
- C_{ip} =Custo de imposto (\$/h)
- T_{ip} = Taxa de impostos (%)
- C_{om} = Preço do material (\$)
- V_u = Vida útil (h)
- C_{rm} = Custo de reparação e manutenção(\$/h).
- C_d = Custo de depreciação (\$/h). = Porcentagem baseada na depreciação para calcular o custo de reparação e manutenção.
- V_a = Valor de aquisição da máquina
- FA = Fator de ajuste (varia de 1 a 5%)

Anexo 2.2 – Custos unitários e produtividades por atividade avaliada

| Custo unitário de extração (\$/m ³) | Produtividade da máquina (m ³ /h) |
|---|--|
| $C_{ua} = \frac{C_f + C_v + C_{lb}}{Prod.}$ | $Prod. = \frac{V * [60 - T_i]}{\frac{d_a}{V_{pv}} + T_a + \frac{d_a}{V_{pc}} + T_d}$ |
| Custo unitário de transporte | Produtividade dos caminhões |
| $C_{ut} = \frac{C_f + C_v + C_{lb}}{Prod.}$ | $Prod. = \frac{V_c * [60 - T_i]}{\frac{D_t}{V_{pv}} + T_c + \frac{D_t}{V_{pc}} + T_d}$ |

Fonte: Elaborada com base a Cándano (1998) e Machado (2014).

Em que:

- C_f = Custos fixos
- $C_v = C_c + C_l + C_{rm} + C_{om}$ Custos variáveis
- C_{lb} = Custo de mão da obra (\$/h).
- V_c = Volume médio de carga por ciclo, (m³).
- T_i = Tempo de interrupção do caminhão em uma hora de trabalho, (min./h).
- D_t =Distância média de transporte (km).
- T_c = Tempo médio de carregamento da madeira (h).
- T_d = Tempo médio de descarregamento da madeira (h).
- V_{pv} =Velocidade de percurso vazia,(km/ h).
- T_a = Tempo dedesamarreda madeira(min.).
- V_{pc} =Velocidade de percurso com carga(km/ h).
- C_{ua} = Custo unitário de arastre
- Prod. =Produtividade da máquina (m³/h)
- V = Volume médio de carga da máquina por ciclo,(m³).
- T_i =Tempo de interrupção do trabalho da máquina, (min/ h)
- d_a =Distância média de arastre (m).
- V_{pv} =Velocidade de percurso vazia,(m/ min.).
- T_a = Tempode amarre da madeira(min.).
- V_{pc} =Velocidade de percursocom carga(m/ min.).

APÊNDICES

Apêndice 2.1 - Teste do suposto de Normalidade univariada para as variáveis Custo e Produtividade

| Variáveis | Shapiro-Wilk | | |
|-----------|--------------|----|-------|
| | Estatística | GL | Sig. |
| Prod. | 0,900 | 36 | 0,053 |
| Custo | 0,936 | 36 | 0,089 |

Apêndice 2.2 – Normalidade Univariada e Multivariada para as variáveis Custo e Produtividade no programa LISREL 9.2.

Test of Univariate Normality for Continuous Variables

| Variable | Skewness | | Kurtosis | | Skewness and Kurtosis | |
|----------|----------|---------|----------|---------|-----------------------|---------|
| | Z-Score | P-Value | Z-Score | P-Value | Chi-Square | P-Value |
| PROD | 0.000 | 1.000 | 0.137 | 0.891 | 0.019 | 0.991 |
| CUSTO | 0.000 | 1.000 | 0.138 | 0.890 | 0.019 | 0.991 |

Relative Multivariate Kurtosis = 0.861

Test of Multivariate Normality for Continuous Variables

| Value | Skewness | | Kurtosis | | | Skewness and Kurtosis | |
|-------|----------|---------|----------|---------|---------|-----------------------|---------|
| | Z-Score | P-Value | Value | Z-Score | P-Value | Chi-Square | P-Value |
| 0.627 | 0.150 | 0.880 | 6.887 | -0.406 | 0.684 | 0.188 | 0.910 |

Covariance Matrix

| | PROD | CUSTO |
|-------|--------|-------|
| PROD | 24.792 | |
| CUSTO | 1.300 | 0.787 |

Total Variance = 25.578 Generalized Variance = 17.819

Largest Eigenvalue = 24.862 Smallest Eigenvalue = 0.717

Condition Number = 5.890

Apêndice 2.3 - Teste do suposto de Homogeneidade de variância univariada para as variáveis Custo e Produtividade

| Variáveis | Base do teste | Estatística de Levene | GL1 | GL2 | Sig. |
|-----------|---------------|-----------------------|-----|-----|------|
| Prod. | Média | 6,702 | 2 | 33 | ,061 |
| Custo | Média | 6,667 | 2 | 33 | ,081 |

Apêndice 2.4 – Teste M de Box para Homogeneidade das matrizes de variância-covariância

| | |
|----------------------|-----------|
| Estatística M de Box | 33,533 |
| F | 5,098 |
| GL1 | 6 |
| GL2 | 27141,231 |
| Sig. | 0,000 |

Apêndice 2.5 - Distribuição de tempos médios de extração de madeira na Empresa Florestal Integral Macurije para uma distância de 150 m.

| Componentes | Tempos médios (min.) | | |
|---------------------------------|-------------------------|---------------|---------------|
| | Skidder John Deere 548E | Skidder J-80A | Junta de Bois |
| Tempo de deslocamento sem carga | 1,56 | 1,84 | 5,56 |
| Tempo de deslocamento com carga | 1,76 | 2,32 | 7,00 |
| Tempo de amarre das toras | 3,50 | 4,44 | 2,26 |
| Tempos de desamarre das toras | 2,62 | 2,48 | 1,22 |
| Tempo de interrupções | 3,82 | 4,58 | 8,54 |
| Tempo acumulado | 13,26 | 15,66 | 24,58 |

Apêndice 2.6 - Distribuição de tempos médios do carregador frontal VOLVO BM L90B no carregamento e descarregamento de madeira na Empresa Florestal Integral Macurije

| Componentes | Tempos médios (min.) | Porcentagens (%) |
|--------------------------------------|----------------------|------------------|
| Tempo de deslocamento sem carga | 0,22 | 3,52 |
| Tempo de deslocamento com carga | 0,13 | 2,08 |
| Tempo de movimentação do braço vazio | 0,36 | 5,76 |
| Tempo de agarre das toras | 0,51 | 8,16 |
| Tempo de depósito e ajuste das toras | 1,56 | 24,96 |
| Tempo de manobras | 0,69 | 11,04 |
| Tempo de interrupções | 2,78 | 44,48 |
| Tempo acumulado | 6,25 | 100,00 |

Apêndice 2.7 - Distribuição de tempos médios de transporte de madeira na Empresa Florestal Integral Macurije para uma distância de 35 km.

| Componentes | Tempos médios (min.) | | |
|---------------------------|----------------------|---------------|---------------|
| | KRAZ-257 | URAL-4320 | KAMAZ-4310 |
| Tempo de carregamento | 16,42 | 24,47 | 22,30 |
| Tempo de descarregamento | 6,57 | 13,35 | 12,16 |
| Tempo de viagem sem carga | 52,55 | 64,51 | 60,82 |
| Tempo de viagem com carga | 68,96 | 84,53 | 79,06 |
| Tempo de interrupções | 19,70 | 35,59 | 28,38 |
| Tempo acumulado | 164,2 | 222,45 | 202,73 |

APÊNDICES DO CAPÍTULO III

Apêndice 3.1 – Último nível do modelo de programação por metas lexicográfica de transbordo de madeira

Min n13

Subject to

! META1: GARANTIR QUE OS CUSTOS GLOBAIS DE EXTRAÇÃO E TRANSPORTE SEJAN MENORES OU IGUAIS QUE O ORÇAMENTO PREVISTO PARA SUA EXECUÇÃO

2.472X1111+1.356X1112+0.617X1113+3.088X1114+1.973X1115+2.707X1121+1.467X112+
 0.69X1123+3.4X1124+2.16X1125+2.472X2211+1.356X2212+0.617X2213+3.088X2214+
 1.973X225+2.707X2221+1.467X2222+0.693X2223+3.4X2224+2.16X2225+2.472X3311+
 1.356X332+0.617X3313+3.088X3314+1.973X3315+2.707X3321+1.467X3322+0.693X3323+
 3.4X324+2.16X3325+2.472X4411+1.356X4412+0.617X4413+3.088X4414+1.973X4415+
 2.707X4421+1.467X4422+0.693X4423+3.4X4424+2.16X4425+2.472X5511+1.356X5512+
 0.617X5513+3.088X5514+1.973X5515+2.707X5521+1.467X5522+0.693X5523+3.4X5524+
 2.16X5525+2.472X6611+1.356X6612+0.617X6613+3.088X6614+1.973X6615+2.707X6621+
 1.467X6622+0.693X6623+3.4X6624+2.16X6625+2.472X7711+1.356X7712+0.617X7713+
 3.088X7714+1.973X7715+2.707X7721+1.467X7722+ 0.693X7723+3.4X7724+2.16X7725+
 2.472X8811+1.356X8812+0.617X8813+3.088X8814+1.973X8815+2.707X8821+1.467X882+
 0.693X8823+3.4X8824+2.16X8825+2.472X9911+1.356X9912+0.617X9913+3.088X9914+
 1.973X9915+2.707X9921+1.467X9922+0.693X9923+3.4X9924+2.16X9925+2.472X101011+
 1.356X101012+0.617X101013+3.088X101014+1.973X101015+2.707X101021+1.467X1010+
 0.693X101023+3.4X101024+2.16X101025+4.185Y1116+3.782Y1127+4.154Y1128+2.745Y216+2.481Y122
 7+2.725Y1228+2.44Y1327+2.68Y1328+3.78Y2116+3.416Y2127+3.752Y2128+2.34Y2216+2.115Y2227+2.
 323Y2228+2.074Y2327+2.278Y2328+7.74Y3116+6.995Y3127+
 7.683Y3128+6.3Y3216+5.693Y3227+6.253Y3228+5.653Y3327+6.209Y3328+3.78Y4116+
 3.416Y4127+3.752Y4128+2.34Y4216+2.115Y4227+2.323Y4228+2.074Y4327+2.278Y4328+
 3.78Y5116+3.416Y5127+3.752Y5128+2.34Y5216+2.115Y5227+2.323Y5228+2.074Y5327+
 2.278Y5328+1.476Y6116+1.334Y6127+1.465Y6128+2.79Y6216+2.521Y6227+2.769Y6228+
 2.481Y6327+2.725Y6328+1.143Y7116+1.033Y7127+1.135Y7128+0.63Y7216+0.569Y7227+
 0.625Y7228+0.529Y7327+0.581Y7328+3.96Y8116+3.579Y8127+3.931Y8128+2.52Y8216
 +2.277Y8227+2.501Y8228+2.237Y8327+2.457Y8328+3.96Y9116+3.579Y9127+3.931Y9128+2.52Y9216+
 2.277Y9227+2.501Y9228+2.237Y9327+2.457Y9328+3.825Y10116+3.457Y10127+3.797Y10128+3.555Y10
 216+3.213Y10227+3.529Y10228+3.172Y10327+3.484Y10328+
 0.732Y11427+0.804Y11428+n1-p1=14000

! RESTRIÇÕES DURAS

! VOLUME EXTRAÍDO=VOLUME TRANSPORTADO

X1111+X1121+X2211+X2221+X3311+X3321+X4411+X4421+X5511+X5521+X6611+X6621+X7711+X7
 721+X8811+X8821+X9911+X9921+X101011+X101021+X1112+X1122+X2212+X2222+X3312+X3322+X
 4412+X4422+X5512+X5522+X6612+X6622+X7712+X7722+X8812+X8822+X9912+X9922+X101012+X1
 01022+X1113+X1123+X2213+X2223+X3313+X3323+X4413+X4423+X5513+X5523+X6613+X6623+X77
 13+X7723+X8813+X8823+X9913+X9923+X101013+X101023+X1114+X1124+X2214+X2224+X3314+X3
 324+X4414+X4424+X5514+X5524+X6614+X6624+X7714+X7724+X8814+X8824+X9914+X9924+X1010
 14+X101024+X1115+X1125+X2215+X2225+X3315+X3325+X4415+X4425+X5515+X5525+X6615+X662
 5+X7715+X7725+X8815+X8825+X9915+X9925+X101015+X101025-Y1116-Y1216- Y2116-Y2216-
 Y3116-Y3216- Y4116- Y4216-Y5116-Y5216- Y6116- Y6216 -Y7116- Y7216-Y8116-Y8216- Y9116 - Y9216
 - Y10116-Y10216 - Y1127-Y1227-Y1327-Y2127- Y2227- Y2327- Y3127- Y3227- Y3327-Y4127- Y4227-
 Y4327- Y5127-Y5227- Y5327 -Y6127- Y6227-Y6327 -Y7127-Y7227- Y7327- Y8127 -Y8227 -Y8327 -
 Y9127 -Y9227- Y9327- Y10127 -Y10227-Y10327 -Y1128-Y1228-Y1328-Y2128-Y2228-Y2328-Y3128-

Y3228-Y3328-Y4128-Y4228-Y4328-Y5128-Y5228-Y5328-Y6128-Y6228-Y6328-Y7128-Y7228-Y7328-Y8128-Y8228-Y8328-Y9128-Y9228-Y9328-Y10128-Y10228-Y10328=0

! SATISFAÇÃO DA DEMANDA DE MADEIRA NAS UNIDADES DE TRANSFORMAÇÃO PRIMÁRIA EM MAIS OU MENOS 90%

X1111+X1121+X2211+X2221+X3311+X3321+X4411+X4421+X5511+X5521+X6611+X6621+X7711+X7721+X8811+X8821+X9911+X9921+X101011+X101021+X1112+X1122+X2212+X2222+X3312+X3322+X4412+X4422+X5512+X5522+X6612+X6622+X7712+X7722+X8812+X8822+X9912+X9922+X101012+X101022+X1113+X1123+X2213+X2223+X3313+X3323+X4413+X4423+X5513+X5523+X6613+X6623+X7713+X7723+X8813+X8823+X9913+X9923+X101013+X101023+X1114+X1124+X2214+X2224+X3314+X3324+X4414+X4424+X5514+X5524+X6614+X6624+X7714+X7724+X8814+X8824+X9914+X9924+X101014+X101024+X1115+X1125+X2215+X2225+X3315+X3325+X4415+X4425+X5515+X5525+X6615+X6625+X7715+X7725+X8815+X8825+X9915+X9925+X101015+X101025 <=4111.58

X1111+X1121+X2211+X2221+X3311+X3321+X4411+X4421+X5511+X5521+X6611+X6621+X7711+X7721+X8811+X8821+X9911+X9921+X101011+X101021+X1112+X1122+X2212+X2222+X3312+X3322+X4412+X4422+X5512+X5522+X6612+X6622+X7712+X7722+X8812+X8822+X9912+X9922+X101012+X101022+X1113+X1123+X2213+X2223+X3313+X3323+X4413+X4423+X5513+X5523+X6613+X6623+X7713+X7723+X8813+X8823+X9913+X9923+X101013+X101023+X1114+X1124+X2214+X2224+X3314+X3324+X4414+X4424+X5514+X5524+X6614+X6624+X7714+X7724+X8814+X8824+X9914+X9924+X101014+X101024+X1115+X1125+X2215+X2225+X3315+X3325+X4415+X4425+X5515+X5525+X6615+X6625+X7715+X7725+X8815+X8825+X9915+X9925+X101015+X101025 >=3364.02

! GARANTIR QUE A MADEIRA LEVADA AO TORNO É IGUAL A MADEIRA TRANSPORTADA PARA A PLANTA DE IMPREGNAÇÃO

Y1327+Y2327+Y3327+Y4327+Y5327+Y6327+Y7327+Y8327+Y9327+Y10327+Y1328+Y2328+Y3328+Y4328+Y5328+Y6328+Y7328+Y8328+Y9328+Y10328-Y11427-Y11428=0

! RESTRIÇÃO DE DISPONIBILIDADE DE MADEIRA NAS ORIGENS

X1111+X1112+X1113+X1114+X1115+X1121+X1122+X1123+X1124+X1125 <=462.4
 X2211+X2212+X2213+X2214+X2215+X2221+X2222+X2223+X2224+X2225 <=218.6
 X3311+X3312+X3313+X3314+X3315+X3321+X3322+X3323+X3324+X3325 <=251.6
 X4411+X4412+X4413+X4414+X4415+X4421+X4422+X4423+X4424+X4425 <=639
 X5511+X5512+X5513+X5514+X5515+X5521+X5522+X5523+X5524+X5525 <=491.4
 X6611+X6612+X6613+X6614+X6615+X6621+X6622+X6623+X6624+X6625 <=636.5
 X7711+X7712+X7713+X7714+X7715+X7721+ X7722+ X7723+ X7724+X7725 <=158.2
 X8811+X8812+X8813+X8814+X8815+X8821+X8822+X8823+X8824+X8825 <=159
 X9911+X9912+X9913+X9914+X9915+X9921+X9922+X9923+X9924+X9925 <=466.1
 X101011+X101012+X101013+X101014+X101015+X101021+X101022+X101023+X101024+X101025 <=255

! VOLUME EXTRAÍDO EM UM PONTO É IGUAL AO VOLUME TRANSPORTADO DESDE ESSE PONTO

X1111+X1112+X1113+X1114+X1115+X1121+X1122+X1123+X1124+X1125-Y1116-Y1127- Y1128 - Y1216- Y1227-Y1228-Y1327- Y1328=0
 X2211+X2212+X2213+X2214+X2215+X2221+X2222+X2223+X2224+X2225-Y2116-Y2127- Y2128- Y2216-Y2227- Y2228-Y2327- Y2328=0

X3311+X3312+X3313+X3314+X3315+X3321+X3322+X3323+X3324+X3325-Y3116-Y3127- Y3128- Y3216 - Y3227- Y3228-Y3327- Y3328=0
 X4411+X4412+X4413+X4414+X4415+X4421+X4422+X4423+X4424+X4425-Y4116-Y4127- Y4128- Y4216-Y4227-Y4228-Y4327- Y4328=0
 X5511+X5512+X5513+X5514+X5515+X5521+X5522+X5523+X5524+X5525-Y5116-Y5127-Y5128- Y5216-Y5227-Y5228-Y5327 -Y5328=0
 X6611+X6612+X6613+X6614+X6615+X6621+X6622+X6623+X6624+X6625-Y6116-Y6127- Y6128- Y6216 -Y6227- Y6228-Y6327-Y6328=0
 X7711+X7712+X7713+X7714+X7715+X7721+X7722+X7723+X7724+X7725-Y7116-Y7127- Y7128- Y7216- Y7227- Y7228-Y7327- Y7328=0
 X8811+X8812+X8813+X8814+X8815+X8821+X8822+X8823+X8824+X8825-Y8116-Y8127-Y8128- Y8216- Y8227 -Y8228-Y8327 -Y8328=0
 X9911+X9912+X9913+X9914+X9915+X9921+X9922+X9923+X9924+X9925-Y9116-Y9127-Y9128- Y9216 - Y9227- Y9228-Y9327- Y9328=0
 X101011+X101012+X101013+X101014+X101015+X101021+X101022+X101023+X101024+ X101025 -Y10116 -Y10127 -Y10128-Y10216- Y10227-Y10228-Y10327 -Y10328=0

! DISPONIBILIDADE GERAL DE MADEIRA NAS ORIGENS DE TRANSBORDO

X1111+X1121+X2211+X2221+X3311+X3321+X4411+X4421+X5511+X5521+X6611+X6621+X7711+X7 721+X8811+X8821+X9911+X9921+X101011+X101021+X1112+X1122+X2212+X2222+X3312+X3322+X 4412+X4422+X5512+X5522+X6612+X6622+X7712+X7722+X8812+X8822+X9912+X9922+X101012+X1 01022+X1113+X1123+X2213+X2223+X3313+X3323+X4413+X4423+X5513+X5523+X6613+X6623+X77 13+X7723+X8813+X8823+X9913+X9923+X101013+X101023+X1114+X1124+X2214+X2224+X3314+X3 324+X4414+X4424+X5514+X5524+X6614+X6624+X7714+X7724+X8814+X8824+X9914+X9924+X101 014+X101024+X1115+X1125+X2215+X2225+X3315+X3325+X4415+X4425+X5515+X5525+X6615+X66 5+X7715+X7725+X8815+X8825+X9915+X9925+X101015+X101025<=3737.8

! RESTRIÇÃO DE COMPATIBILIDADE ENTRE OS SISTEMAS DE UTILIZADOS EM AMBAS AS FASES DE TRANSBORDO DE MADEIRA

X1111+X1112+X1113+X1114+X1115 -Y1116-Y1216<=0
 X1121+X1122+X1123+X1124+X1125 -Y1127- Y1128 - Y1227- Y1228-Y1327- Y1328>= 0
 X2211+X2212+X2213+X2214+X2215-Y2116- Y2216<=0
 X2221+X2222+X2223+X2224+X2225-Y2127- Y2128-Y2227- Y2228-Y2327- Y2328>=0
 X3311+X3312+X3313+X3314+X3315-Y3116-Y3216<=0
 X3321+X3322+X3323+X3324+X3325-Y3127- Y3128- Y3227- Y3228-Y3327- Y3328>=0
 X4411+X4412+X4413+X4414+X4415-Y4116- Y4216<=0
 X4421+X4422+X4423+X4424+X4425-Y4127-Y4128-Y4227-Y4228-Y4327- Y4328>=0
 X5511+X5512+X5513+X5514+X5515-Y5116- Y5216<=0
 X5521+ X5522+X5523+X5524+X5525-Y5127-Y5128-Y5227- Y5228-Y5327 -Y5328>=0
 X6611+X6612+X6613+X6614+X6615-Y6116 -Y6216 <=0
 X6621+X6622+X6623+X6624+X6625-Y6127- Y6128-Y6227-Y6228-Y6327 -Y6328>=0
 X7711+X7712+X7713+X7714+X7715-Y7116 - Y7216<=0
 X7721+ X7722+ X7723+X7724+X7725-Y7127- Y7128- Y7227-Y7228-Y7327-Y7328>=0
 X8811+X8812+X8813+X8814+X8815-Y8116 -Y8216<=0
 X8821+X8822+X8823+X8824+X8825-Y8127 -Y8128-Y8227 -Y8228-Y8327 -Y8328>=0
 X9911+X9912+X9913+X9914+X9915-Y9116 -Y9216<=0
 X9921+X9922+X9923+X9924+X9925-Y9127-Y9128- Y9227- Y9228-Y9327- Y9328>=0
 X101011+X101012+X101013+X101014+X101015-Y10116 -Y10216<=0
 X101021+X101022+X101023+X101024+X101025-Y10127-Y10128-Y10227-Y10228-Y10327-Y10328>=0

p1=0

! META2: METAS RELACIONADAS A PRODUTIVIDADES E TEMPOS

! GARANTIR A PRODUTIVIDADE DO J-80A

$X1111+X1121+X2211+X2221+X3311+X3321+X4411+X4421+X5511+X5521+X6611+X6621+X7711+X7721+X8811+X8821+X9911+X9921+X101011+X101021+n2-p2=3068.16$

$p2=0$

! GARANTIR A PRODUTIVIDADE DO John Deere

$X1112+X1122+X2212+X2222+X3312+X3322+X4412+X4422+X5512+X5522+X6612+X6622+X7712+X7722+X8812+X8822+X9912+X9922+X101012+X101022+n3-p3=3302.4$

$p3=0$

! GARANTIR A PRODUTIVIDADE DA JUNTA DE BOIS

$X1113+X1123+X2213+X2223+X3313+X3323+X4413+X4423+X5513+X5523+X6613+X6623+X7713+X7723+X8813+X8823+X9913+X9923+X101013+X101023+n4-p4=758.4$

$p4=0$

! GARANTIR A PRODUTIVIDADE DO J-80A + Boi

$X1114+X1124+X2214+X2224+X3314+X3324+X4414+X4424+X5514+X5524+X6614+X6624+X7714+X7724+X8814+X8824+X9914+X9924+X101014+X101024+n5-p5=3826.56$

$p5=0$

! GARANTIR A PRODUTIVIDADE DO John Deere + Boi

$X1115+X1125+X2215+X2225+X3315+X3325+X4415+X4425+X5515+X5525+X6615+X6625+X7715+X7725+X8815+X8825+X9915+X9925+X101015+X101025+n6-p6=4060.8$

$p6=0$

! GARANTIR A PRODUTIVIDADE DO KRAZ- 257

$Y1116+Y1216+ Y2116+ Y2216+Y3116+ Y3216+ Y4116+ Y4216+Y5116+ Y5216+ Y6116+ Y6216+Y7116+Y7216+Y8116+Y8216+Y9116 +Y9216 + Y10116+Y10216+n7-p7=3075.84$

$p7=0$

! GARANTIR A PRODUTIVIDADE DO KAMAZ-4310

$Y1127+Y1227+Y1327+Y2127+ Y2227+ Y2327+ Y3127+ Y3227+ Y3327+ Y4127+ Y4227+Y4327+Y5127+Y5227+ Y5327 +Y6127+ Y6227+Y6327 +Y7127+ Y7227+ Y7327+ Y8127 +Y8227 +Y8327 +Y9127 +Y9227+ Y9327+ Y10127 +Y10227+Y10327 +Y11427+n8-p8=3753.6$

$p8=0$

! GARANTIR A PRODUTIVIDADE DO URAL-4320

$Y1128+Y1228+Y1328+Y2128+Y2228+Y2328+Y3128+Y3228+Y3328+Y4128+Y4228+Y4328+Y5128+Y5228+Y5328+Y6128+Y6228+Y6328+Y7128+Y7228+Y7328+Y8128+Y8228+Y8328+Y9128+Y9228+Y9328+Y10128+Y10228+Y10328+Y11428+n9-p9=3367.68$

$p9=0$

!META3: SATISFACER DEMANDAS DE MADEIRA NAS UNIDADES DE TRANSFORMAÇÃO PRIMÁRIA

! GARANTIR A DEMANDA DE MADEIRA NA SERRARIA ISABEL RUBIO

$$Y_{1116}+Y_{2116}+Y_{3116}+Y_{4116}+Y_{5116}+Y_{6116}+Y_{7116}+Y_{8116}+Y_{9116}+Y_{10116}+Y_{1127}+Y_{2127}+Y_{3127}+Y_{4127}+Y_{5127}+Y_{6127}+Y_{7127}+Y_{8127}+Y_{9127}+Y_{10127}+Y_{1128}+Y_{2128}+Y_{3128}+Y_{4128}+Y_{5128}+Y_{6128}+Y_{7128}+Y_{8128}+Y_{9128}+Y_{10128}+n_{10}-p_{10}=500$$

$$n_{10}=0$$

! GARANTIR A DEMANDA DE MADEIRA NA SERRARIA COMBATE DE TENERÍAS

$$Y_{1216}+Y_{2216}+Y_{3216}+Y_{4216}+Y_{5216}+Y_{6216}+Y_{7216}+Y_{8216}+Y_{9216}+Y_{10216}+Y_{1227}+Y_{2227}+Y_{3227}+Y_{4227}+Y_{5227}+Y_{6227}+Y_{7227}+Y_{8227}+Y_{9227}+Y_{10227}+Y_{1228}+Y_{2228}+Y_{3228}+Y_{4228}+Y_{5228}+Y_{6228}+Y_{7228}+Y_{8228}+Y_{9228}+Y_{10228}+n_{11}-p_{11}=2300$$

$$n_{11}=0$$

! GARANTIR A DEMANDA DE MADEIRA NO TORNO

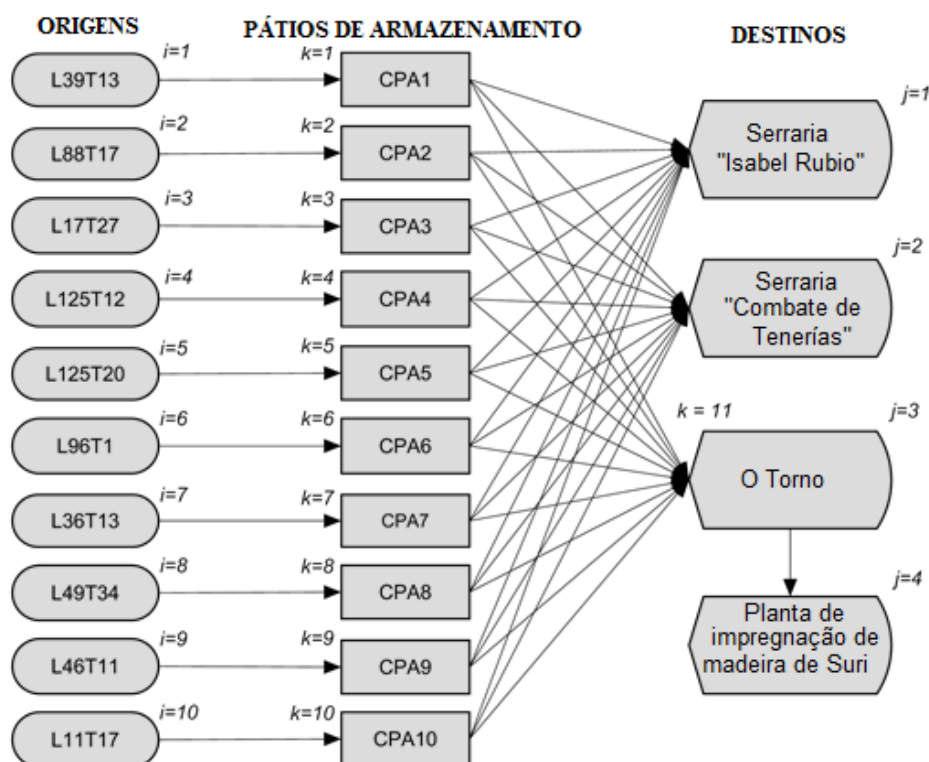
$$Y_{1327}+Y_{2327}+Y_{3327}+Y_{4327}+Y_{5327}+Y_{6327}+Y_{7327}+Y_{8327}+Y_{9327}+Y_{10327}+Y_{1328}+Y_{2328}+Y_{3328}+Y_{4328}+Y_{5328}+Y_{6328}+Y_{7328}+Y_{8328}+Y_{9328}+Y_{10328}+n_{12}-p_{12}=875$$

$$n_{12}=0$$

! META4: GARANTIR A DEMANDA DE MADEIRA NA PLANTA DE IMPREGNAÇÃO

$$Y_{11427}+Y_{11428}+n_{13}-p_{13}=875$$

Apêndice 3.2 – Estrutura de transbordo de madeira na EFI Macurije para o cenário considerado

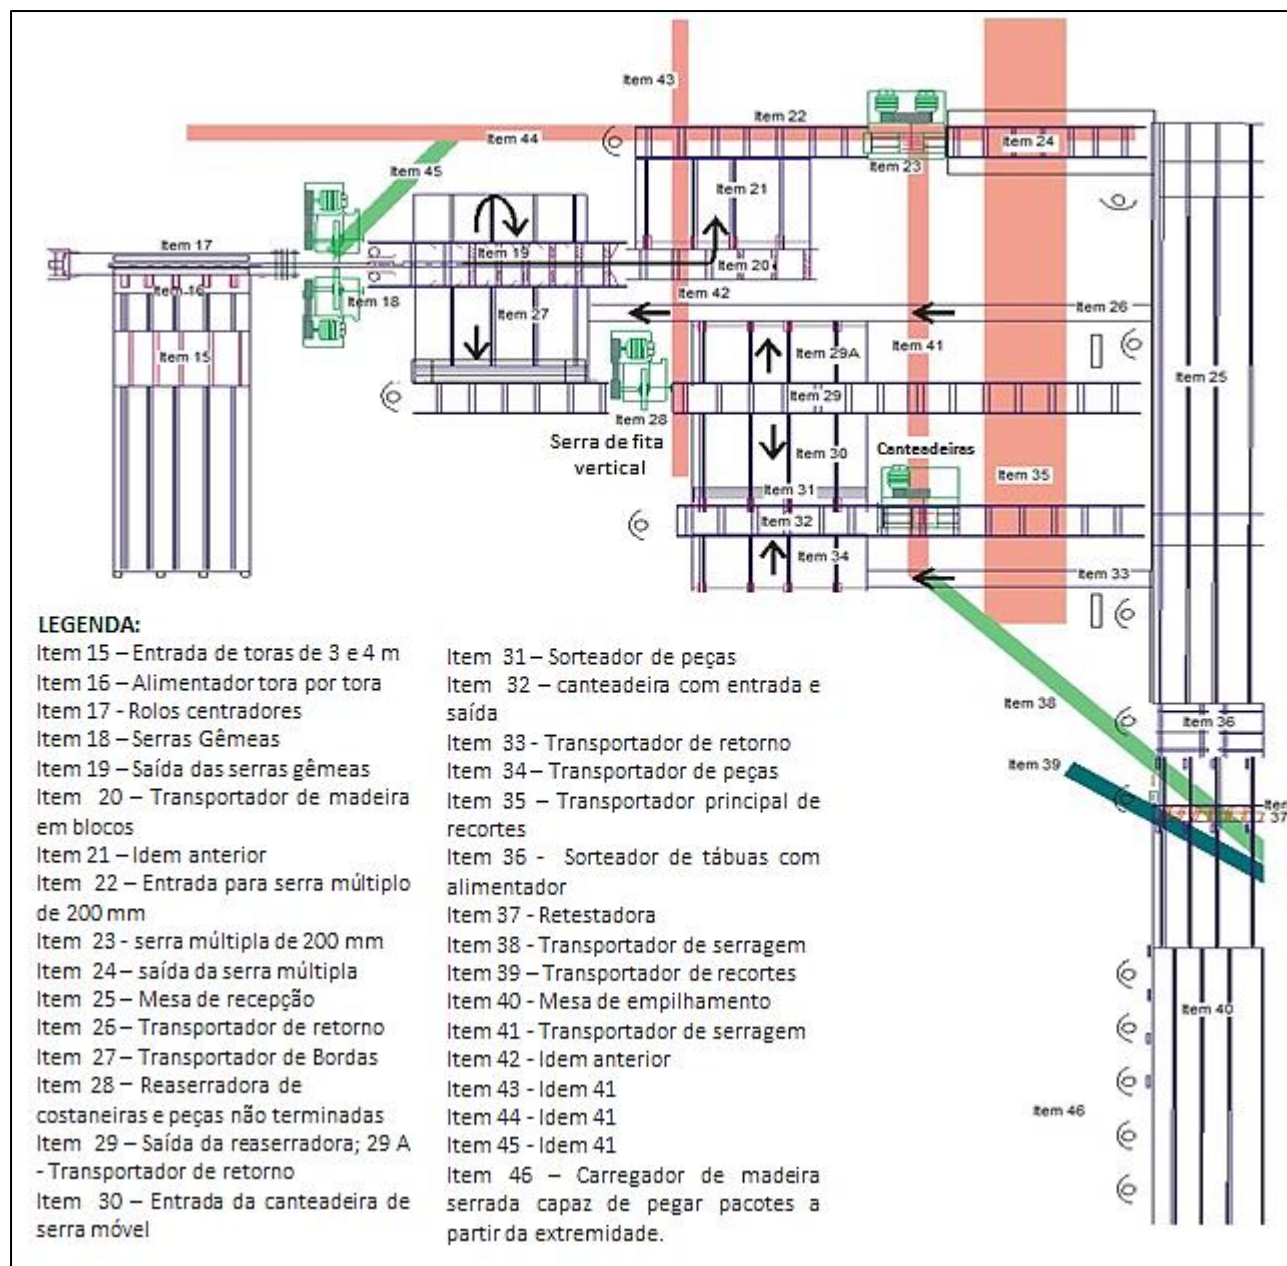


LEGENDA:

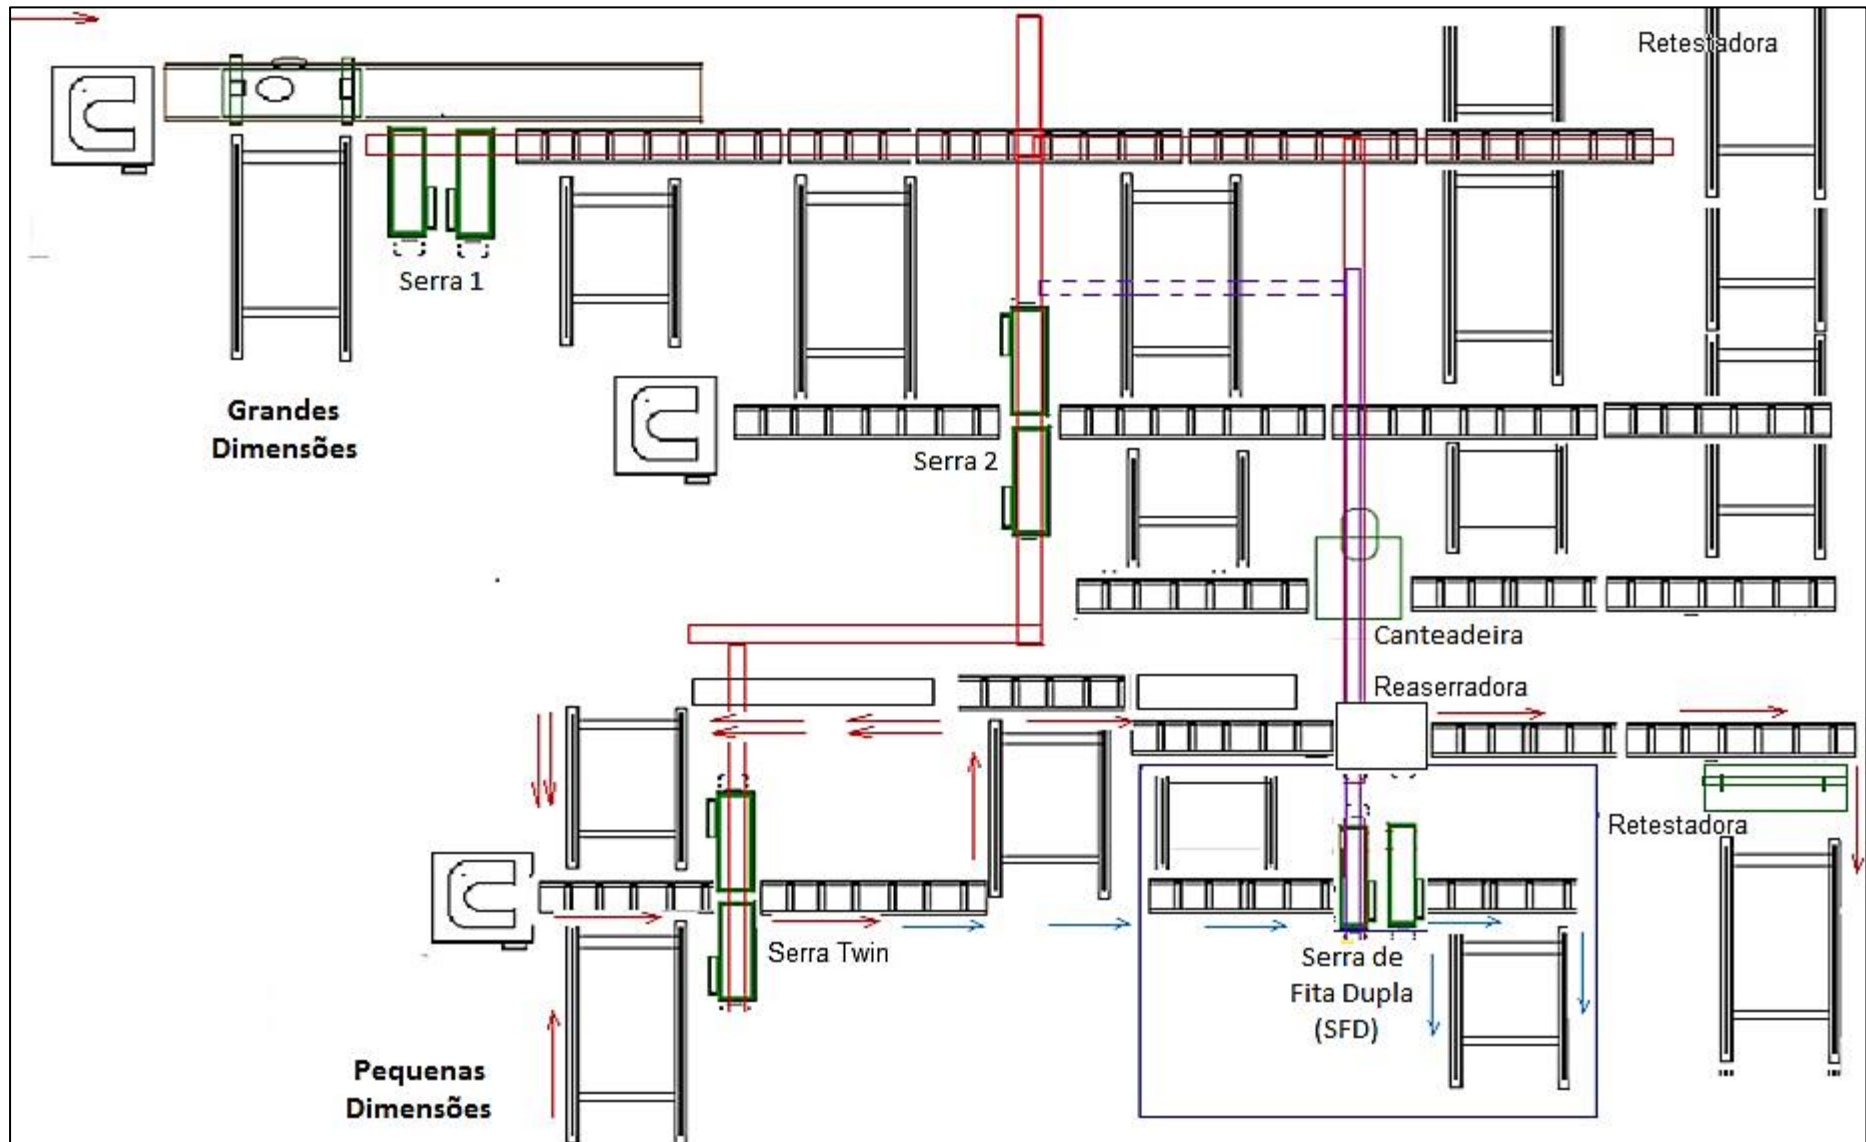
L=Lote; T=Talhão; CPA=Conjunto de Pátios de Armazenamento associados a determinada origem

ANEXOS E APÊNDICES DO CAPÍTULO IV

Anexo 4.1 – Layout da serra Combate de Tenerías (Fonte: Adaptado de GARCÍA, 2011)



Anexo 4.2 – Linhas de produção atuais da serraria Combate de Tenerías (Fonte: Adaptado de GARCÍA, 2011)



Anexo 4.3 - Dimensões dos principais produtos da serraria "Combate de Tenerias"

| Espessura (mm) | Largura (mm) | Comprimento (m) | Espessura (mm) | Largura (mm) | Comprimento (m) |
|---------------------------|-------------------------|----------------------------|---------------------------|-------------------------|----------------------------|
| 20 | 100 | 3,0 | 50 | 150 | 4,0 |
| 25 | 75 | 3,5 | 50 | 175 | 4,0 |
| 25 | 100 | 4,0 | 50 | 200 | 4,0 |
| 25 | 100 | 3,5 | 50 | 225 | 4,0 |
| 25 | 125 | 3,5 | 50 | 75 | 3,0 |
| 25 | 150 | 3,5 | 50 | 100 | 3,0 |
| 25 | 175 | 3,5 | 50 | 125 | 3,0 |
| 25 | 200 | 4,0 | 50 | 150 | 3,0 |
| 25 | 225 | 4,0 | 50 | 100 | 3,5 |
| 25 | 75 | 3,0 | 50 | 125 | 3,5 |
| 25 | 100 | 3,5 | 50 | 150 | 3,5 |
| 25 | 125 | 3,5 | 50 | 175 | 3,5 |
| 25 | 150 | 3,5 | 50 | 200 | 3,5 |
| 25 | 175 | 3,5 | 50 | 225 | 3,5 |
| 25 | 100 | 4,0 | 50 | 100 | 4,0 |
| 25 | 100 | 3,0 | 50 | 125 | 4,0 |
| 25 | 125 | 3,0 | 50 | 150 | 4,0 |
| 25 | 125 | 4,0 | 50 | 175 | 4,0 |
| 25 | 150 | 4,0 | 50 | 200 | 4,0 |
| 25 | 175 | 4,0 | 50 | 225 | 4,0 |
| 25 | 200 | 4,0 | 50 | 75 | 3,0 |
| 30 | 75 | 3,0 | 75 | 100 | 3,0 |
| 30 | 100 | 3,0 | 75 | 125 | 3,0 |
| 30 | 125 | 3,0 | 75 | 75 | 3,5 |
| 38 | 100 | 4,0 | 75 | 100 | 3,5 |
| 38 | 125 | 4,0 | 75 | 125 | 3,5 |
| 38 | 150 | 4,0 | 75 | 150 | 3,5 |
| 38 | 175 | 4,0 | 75 | 175 | 3,5 |
| 38 | 200 | 4,0 | 75 | 150 | 3,5 |
| 38 | 225 | 4,0 | 75 | 75 | 3,0 |
| 38 | 100 | 4,0 | 75 | 100 | 3,0 |
| 38 | 125 | 4,0 | 75 | 125 | 3,0 |
| 38 | 150 | 4,0 | 75 | 100 | 4,0 |
| 38 | 175 | 4,0 | 75 | 125 | 4,0 |
| 38 | 200 | 4,0 | 75 | 150 | 4,0 |
| 38 | 225 | 4,0 | 75 | 175 | 4,0 |
| 50 | 100 | 3,0 | 100 | 100 | 3,5 |
| 50 | 125 | 3,0 | 100 | 125 | 3,5 |
| 50 | 150 | 3,0 | 100 | 150 | 3,5 |
| 50 | 100 | 3,5 | 100 | 125 | 4,0 |
| 50 | 125 | 3,5 | 100 | 150 | 4,0 |
| 50 | 150 | 3,5 | 100 | 175 | 4,0 |
| 50 | 175 | 3,5 | 100 | 100 | 3,0 |
| 50 | 200 | 3,5 | 100 | 100 | 4,0 |
| 50 | 225 | 3,5 | 100 | 125 | 4,0 |
| 50 | 100 | 4,0 | 100 | 150 | 4,0 |
| 50 | 125 | 4,0 | 100 | 175 | 4,0 |

Apêndice 4.1 – Modelos de Rendimento baseados em Equações diferenciais Ordinárias.

Hipóteses de base dos modelos:

H₀₁: Uma diminuição na conicidade tende a proporcionar um aumento no rendimento em madeira serrada (FERREIRA, 2003)

H₀₂: Maiores diâmetros em árvores proporcionam menor conicidade e por conseqüências maiores rendimento de desdobro da madeira.

Seja a relação funcional baseada na hipótese H₀₁:

$$\frac{dR}{dCon} = \theta R Con^\alpha \tag{01}$$

$$\Rightarrow \frac{dR}{R} = \theta Con^\alpha dCon$$

$$\Rightarrow \int \frac{1}{R} dR = \int \theta Con^\alpha dCon$$

$$\Rightarrow LnR = \theta \frac{Con^{\alpha+1}}{\alpha + 1} + C (d)$$

$\frac{\theta}{\alpha+1}$ e $\alpha + 1$ sendo constantes, pode-se escrever: $\frac{\theta}{\alpha+1} = \beta$ e $\alpha + 1 = \delta$

Substituindo-os na relação (d) tem-se:

$$\Rightarrow LnR = \beta Con^\delta + C$$

$$\Rightarrow e^{LnR} = e^{\beta Con^\delta + C}$$

$$\Rightarrow R = e^{\beta Con^\delta} * e^C ; e^C = constante = k$$

$$R = ke^{\beta Con^\delta} \text{ (Modelo I)}$$

Seja a relação funcional baseada na hipótese H₀₂:

$$\frac{dR}{dD} = \theta R D^\alpha \tag{02}$$

$$\Rightarrow \frac{dR}{R} = \theta D^\alpha dD$$

$$\Rightarrow \int \frac{1}{R} dR = \int \theta D^\alpha dD$$

$$\Rightarrow LnR = \theta \frac{D^{\alpha+1}}{\alpha + 1} + C (e)$$

$\frac{\theta}{\alpha+1}$ e $\alpha + 1$ sendo constantes, pode-se escrever:

$$\frac{\theta}{\alpha+1} = \beta \text{ e } \alpha + 1 = \delta$$

Substituindo-os na relação (e) tem-se:

$$\Rightarrow LnR = \beta D^\delta + C$$

$$\Rightarrow e^{LnR} = e^{\beta D^\delta + C}$$

$$\Rightarrow R = e^{\beta D^\delta} * e^C; e^C = \text{constante} = k$$

$$R = ke^{\beta D^\delta} \text{ (Modelo II)}$$

Seja a relação funcional baseada na hipótese H₀₂:

$$\frac{dR}{dDAP} = \theta R DAP^\alpha \tag{03}$$

$$\Rightarrow \frac{dR}{R} = \theta DAP^\alpha dDAP$$

$$\Rightarrow \int \frac{1}{R} dR = \int \theta DAP^\alpha dDAP$$

$$\Rightarrow \ln R = \theta \frac{DAP^{\alpha+1}}{\alpha+1} + C \text{ (f)}$$

$\frac{\theta}{\alpha+1}$ e $\alpha+1$ sendo constantes, pode-se escrever:

$$\frac{\theta}{\alpha+1} = \beta \text{ e } \alpha+1 = \delta$$

Substituindo-os na relação (f) tem-se:

$$\Rightarrow \ln R = \beta DAP^\delta + C$$

$$\Rightarrow e^{\ln R} = e^{\beta DAP^\delta + C}$$

$$\Rightarrow R = e^{\beta DAP^\delta} * e^C; e^C = \text{constante} = k$$

$$R = ke^{\beta DAP^\delta} \text{ (Modelo III)}$$

O aumento do número de variáveis em um modelo tende a aumentar a porcentagem da variância explicada da variável dependente traduzido pelo aumento do R². Nesse sentido, modelos de regressão múltiplos são elaborados combinando os modelos não lineares simples. O coeficiente k do modelo 1.1 (função da conicidade) é uma constante que pode ser substituída pelo modelo 1.2 e permitiria a obtenção do modelo 1.4.

$$R = k_2 e^{\beta_2 D^{\delta_2}} \text{ em } R = k_1 e^{\beta_1 Con^{\delta_1}} \Rightarrow R = k_2 e^{\beta_2 D^{\delta_2}} * e^{\beta_1 Con^{\delta_1}}$$

$$R = k_2 e^{(\beta_1 Con^{\delta_1} + \beta_2 D^{\delta_2})} \text{ (Modelo IV)}$$

O modelo 1.5 resultou da substituição do coeficiente k₂ do modelo 1.4 pelo modelo 1.3 como descrito a continuação:

$$R = k_3 e^{\beta_3 DAP^{\delta_3}} \text{ em (1.4)} \Rightarrow R = k_3 e^{\beta_3 DAP^{\delta_3}} * e^{\beta_1 Con^{\delta_1} + \beta_2 D^{\delta_2}} \text{ prodan}$$

$$R = ke^{(\beta_1 Con^{\delta_1} + \beta_2 D^{\delta_2} + \beta_3 DAP^{\delta_3})} \text{ (Modelo V)}$$

Apêndice 4.2 – Testes de normalidade dos resíduos para os modelos clássicos de rendimento

| Modelos | Shapiro-Wilk | | | Normalidade |
|---------|--------------|-----|------|-------------|
| | Estatístico | GL | Sig. | |
| 1 | ,946* | 104 | ,000 | Não |
| 2 | ,951* | 104 | ,001 | Não |
| 3 | ,952* | 104 | ,001 | Não |
| 4 | ,994 | 104 | ,911 | Sim |
| 5 | ,985 | 104 | ,272 | Sim |
| 6 | ,982 | 104 | ,165 | Sim |

*Teste significativo em um nível de significância de 5%

Apêndice 4.3 – Teste de White para os modelos clássicos de rendimento

| Modelos | LM | p-valor | Homocedasticidade |
|---------|----------|----------|-------------------|
| 1 | 3,170992 | 0,074957 | Sim |
| 2 | 3,636663 | 0,05652 | Sim |
| 3 | 3,637505 | 0,056492 | Sim |
| 4 | 0,891779 | 0,827411 | Sim |
| 5 | 1,802518 | 0,614387 | Sim |
| 6 | 2,865182 | 0,412882 | Sim |

Apêndice 4.4 – Teste de Durbin-Watson para os modelos clássicos de rendimento

| Modelos | d _L | d _U | 4 - d _U | 4 - d _L | DW | AS* |
|---------|----------------|----------------|--------------------|--------------------|-------|---------|
| 1 | 1, 661 | 1, 699 | 2,301 | 2,339 | 1,211 | Sim (+) |
| 2 | 1, 661 | 1, 699 | 2,301 | 2,339 | 1,313 | Sim (+) |
| 3 | 1, 641 | 1, 719 | 2,281 | 2,359 | 1,288 | Sim (+) |
| 4 | 1, 621 | 1, 740 | 2,260 | 2,379 | 1,871 | Não |
| 5 | 1, 621 | 1, 740 | 2,260 | 2,379 | 1,878 | Não |
| 6 | 1, 581 | 1, 782 | 2,218 | 2,419 | 1,921 | Não |

* Autocorrelação serial.

Apêndice 4.5 – Teste de normalidade dos resíduos para o modelo stepwise

| Modelo | Shapiro-Wilk | | | Normalidade |
|----------|--------------|-----|------|-------------|
| | Estatístico | GL | Sig. | |
| Stepwise | ,991 | 104 | ,710 | Sim |

*Teste significativo em um nível de significância de 5%

Apêndice 4.6 – Teste de White para o modelo stepwise

| Modelo | LM | p-valor | Homocedasticidade |
|----------|-------|---------|-------------------|
| Stepwise | 1,730 | 0,421 | Sim |

Apêndice 4.7 – Teste de Durbin-Watson para para o modelo stepwise

| Modelo | d _L | d _U | 4 - d _U | 4 - d _L | DW | AS* |
|----------|----------------|----------------|--------------------|--------------------|-------|-----|
| Stepwise | 1, 641 | 1, 719 | 2,281 | 2,359 | 1,787 | Não |

* Autocorrelação serial.

Apêndice 4.8 – Testes de normalidade para os modelos de rendimento baseados nas EDOs

| Modelos | Shapiro-Wilk | | | Normalidade |
|---------|--------------|-----|------|-------------|
| | Estatístico | GL | Sig. | |
| I | ,994 | 104 | ,911 | Sim |
| II | ,985 | 104 | ,273 | Sim |
| III | ,982 | 104 | ,164 | Sim |
| IV | ,981 | 104 | ,143 | Sim |
| V | ,984 | 104 | ,236 | Sim |

*Teste significativo em um nível de significância de 5%

Apêndice 4.9 – Teste de White para os modelos de rendimento baseados nas EDOs

| Modelos | LM | p-valor | Homocedasticidade |
|---------|----------|-------------|-------------------|
| I | 1,961377 | 0,161366 | Sim |
| II | 4,208627 | 0,040219 | Não |
| III | 0,9892 | 0,319938 | Sim |
| IV | 26,15541 | 2,09134E-06 | Não |
| V | 0,533843 | 0,911396 | Sim |

Apêndice 4.10 – Teste de Durbin-Watson para autocorrelação serial dos resíduos para os modelos de rendimento baseados nas EDOs

| Modelos | d _L | d _U | 4 - d _U | 4-d _L | DW | AS* |
|---------|----------------|----------------|--------------------|------------------|-------|---------|
| I | 1,641 | 1,719 | 2,281 | 2,359 | 1,753 | Não |
| II | 1,641 | 1,719 | 2,281 | 2,359 | 1,175 | Sim (+) |
| III | 1,641 | 1,719 | 2,281 | 2,359 | 1,217 | Sim (+) |
| IV | 1,601 | 1,761 | 2,239 | 2,399 | 1,174 | Sim (+) |
| V | 1,561 | 1,804 | 2,196 | 2,439 | 1,871 | Não |

* Autocorrelação serial.

Apêndice 4.11 – Testes de normalidade dos resíduos para as RNAs na predição do rendimento

| RNAs | Shapiro-Wilk | | | Normalidade |
|------|--------------|-----|------|-------------|
| | Estatístico | GL | Sig. | |
| I | ,951* | 104 | ,001 | Não |
| II | ,951* | 104 | ,001 | Não |
| III | ,988 | 104 | ,459 | Sim |
| IV | ,989 | 104 | ,536 | Sim |
| V | ,978 | 104 | ,084 | Sim |
| VI | ,974 | 104 | ,040 | Não |

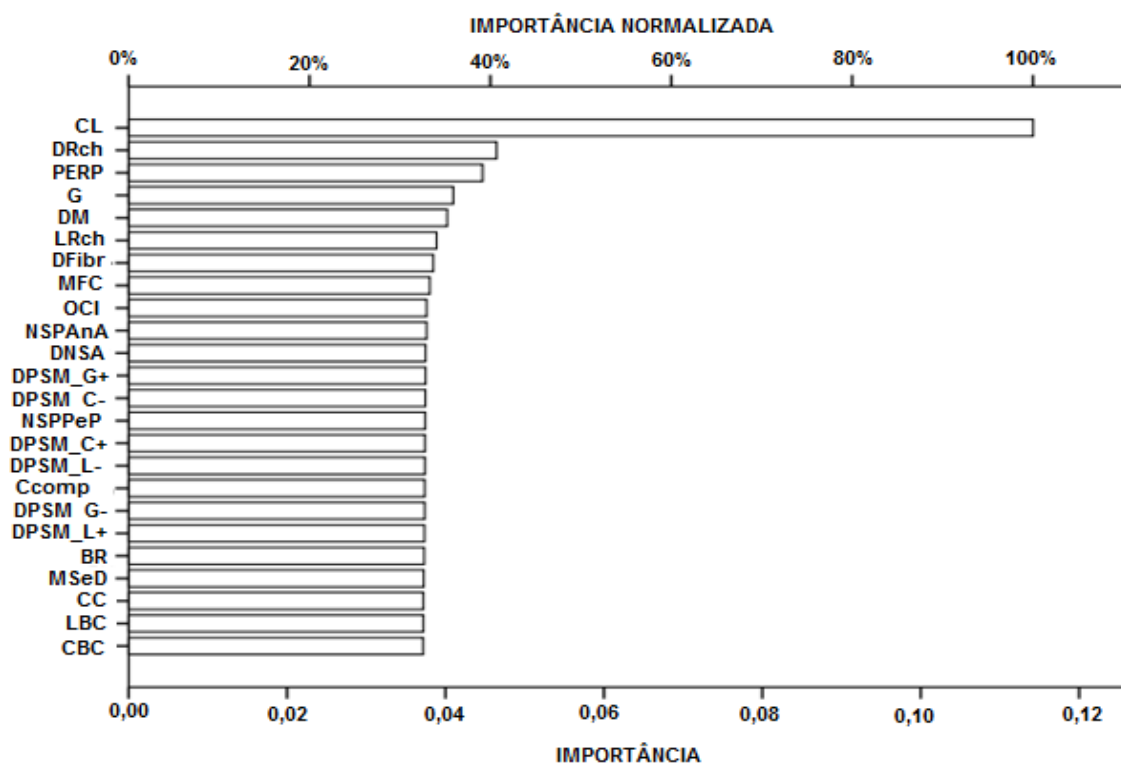
*Teste significativo em um nível de significância de 5%

APÊNDICES DO CAPÍTULO V

Apêndice 5.1 - Análise do tipo II (Variável QUALIDADE)

| Fonte | GL | Qui-quadrado (Wald) | Pr > Wald | Qui-quadrado (LR) | Pr > LR |
|----------------|----------|---------------------|--------------|-------------------|--------------------|
| DNSA | 3 | 0,000 | 1,000 | -0,025 | > 0,01 |
| NSPAnA | 3 | 0,001 | 1,000 | -0,025 | > 0,01 |
| NSPPeP | 3 | 0,002 | 1,000 | -0,025 | > 0,01 |
| DRch | 3 | 0,012 | 1,000 | -0,025 | > 0,01 |
| LRch | 3 | 0,003 | 1,000 | -0,025 | > 0,01 |
| DFibr | 3 | 0,002 | 1,000 | -0,025 | > 0,01 |
| MSeD | 3 | 0,002 | 1,000 | -0,025 | > 0,01 |
| BR | 3 | 0,001 | 1,000 | -0,025 | > 0,01 |
| LBC | 3 | 0,002 | 1,000 | -0,025 | > 0,01 |
| CC | 3 | 0,000 | 1,000 | -0,025 | > 0,01 |
| PERP | 3 | 0,020 | 0,999 | -0,020 | > 0,01 |
| MFC | 3 | 0,004 | 1,000 | -0,025 | > 0,01 |
| OCI | 3 | 0,003 | 1,000 | -0,025 | > 0,01 |
| DM | 3 | 0,004 | 1,000 | -0,025 | > 0,01 |
| G | 3 | 0,006 | 1,000 | -0,025 | > 0,01 |
| CBC | 3 | 0,002 | 1,000 | -0,025 | > 0,01 |
| CL | 3 | 0,001 | 1,000 | -0,025 | > 0,01 |
| Ccomp | 3 | 0,002 | 1,000 | -0,025 | > 0,01 |
| DPSM_C+ | 3 | 0,001 | 1,000 | 218,375 | < 0,0001 |
| DPSM_C- | 3 | 0,001 | 1,000 | -0,022 | > 0,01 |
| DPSM_L- | 3 | 0,002 | 1,000 | 0,007 | 1,000 |
| DPSM_G- | 3 | 0,001 | 1,000 | -0,018 | > 0,01 |

Apêndice 5.2 - Importância das variáveis predictoras da qualidade da madeira serrada de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.



APÊNDICES – CONSIDERAÇÕES FINAIS

Apêndice 6.1– Relação entre as diferentes ferramentas propostas nas diferentes fases do PPF

