

IVALDO DA SILVA TAVARES JÚNIOR

**APRENDIZAGEM DE MÁQUINA: MODELAGEM DO INCREMENTO EM
DIÂMETRO DE ÁRVORES INDIVIDUAIS EM FRAGMENTOS DE MATA
ATLÂNTICA**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Magister Scientiae*.

Orientador: Carlos Moreira Miquelino Eleto
Torres

Coorientador: Helio Garcia Leite

**VIÇOSA – MINAS GERAIS
2019**

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

T Tavares Júnior, Ivaldo da Silva, 1991-
Aprendizagem de máquina : modelagem do incremento em
diâmetro de árvores individuais em fragmentos de Mata
T231a Atlântica / Ivaldo da Silva Tavares Júnior. – Viçosa, MG, 2019.
2019 106 f. : il. (algumas color.) ; 29 cm.

Inclui apêndices.

Orientador: Carlos Moreira Miquelino Eieto Torres.
Dissertação (mestrado) - Universidade Federal de Viçosa.
Referências bibliográficas: f. 68-78.

1. Florestas - Medição. 2. Redes neurais (Computação).
3. Aprendizado por computador. 4. Florestas - Classificação.
5. Florestas - Manejo. 6. Máquinas de vetores de suporte.
7. Florestas - Métodos estatísticos. I. Universidade Federal de
Viçosa. Departamento de Engenharia Florestal. Programa de
Pós-Graduação em Ciência Florestal. II. Título.

CDO adapt. CDD 22. ed. 634.952

IVALDO DA SILVA TAVARES JÚNIOR

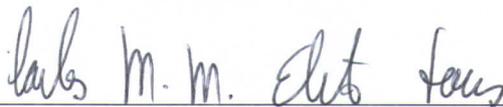
**APRENDIZAGEM DE MÁQUINA: MODELAGEM DO INCREMENTO EM
DIÂMETRO DE ÁRVORES INDIVIDUAIS EM FRAGMENTOS DE MATA
ATLÂNTICA**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Magister Scientiae*.

APROVADA: 30 de julho de 2019.



Ivaldo da Silva Tavares Júnior
Autor



Carlos Moreira Miquelino Eleto Torres
Orientador

Este trabalho é dedicado à minha família e amigos, em especial meus pais Maria Lucia Pereira Tavares e Ivaldo da Silva Tavares. Dedico também a uma pessoa que foi e sempre será um exemplo de caráter e dignidade, meu avô Ursinato Sumé Tavares (*in memoriam*).

AGRADECIMENTOS

Primeiramente a Deus pelo dom da vida e por ter me dado saúde para superar as dificuldades até o presente momento.

Aos meus pais Maria Lucia Pereira Tavares e Ivaldo da Silva Tavares pelo amor, carinho, atenção e ensinamentos durante toda a vida.

Ao meu orientador Prof. Carlos Moreira Miquelino Eieto Torres e coorientador Prof. Helio Garcia Leite pela amizade, apoio, dedicação e orientações para realização deste trabalho.

Ao Prof. Carlos Pedro Boechat Soares pelas suas ideias que ajudaram a complementar este trabalho.

Aos grandes amigos, originais e comportados: Jadson Abreu, Gabriela Costa, Fernanda Lambrecht, Lucas Lopes, Júlia Silveira, Gabriel Soares, Duberlí Gonzáles, Cátia Silva, Sindy Abranches, Epifanía Vega, Debora Christo, Gustavo Abreu, Bruna Guirardi, Thales Martins e Agust Sales, que foram minha grande família em Viçosa.

Ao Prof. Ângelo Augusto Ebling, Prof. Jonas Elias Castro da Rocha e Prof^a Gládis de Oliveira Jucoski pela amizade e apoio fundamental no início desta caminhada.

Ao amigo Wendelo Silva Costa pelo apoio e acolhimento fundamental durante as primeiras semanas em Viçosa.

Ao amigo Samuel Rocha pelo grande incentivo na busca de novas ferramentas para o manejo de florestas nativas e pela ajuda na realização deste trabalho.

Ao amigo Nero Lemos pela grande ajuda na implementação de ferramentas utilizadas neste trabalho.

Ao Grupo de Estudos em Economia Ambiental e Manejo Florestal (GEEA) pelo engrandecimento na formação profissional e pessoal durante as reuniões.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão de bolsa para realização da pesquisa.

A todos os funcionários do departamento de Engenharia Florestal, em especial Alexandre, Dilson, Chiquinho da floresta e Elizabeth por ajudarem sempre que precisamos, e a Universidade Federal de Viçosa por proporcionar toda a estrutura necessária.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

A todos o meu MUITO OBRIGADO.

“Talvez não tenha conseguido fazer o melhor,
mas lutei para que o melhor fosse feito. Não
sou o que deveria ser, mas Graças a Deus, não
sou o que era antes”. (Marthin Luther King)

RESUMO

TAVARES JÚNIOR, Ivaldo da Silva, M.Sc., Universidade Federal de Viçosa, julho de 2019. **Aprendizagem de máquina: modelagem do incremento em diâmetro de árvores individuais em fragmentos de Mata Atlântica.** Orientador: Carlos Moreira Miquelino Eleto Torres. Coorientador: Helio Garcia Leite.

Modelos de crescimento em nível individual permitem a descrição mais detalhada da dinâmica da floresta do que os modelos em nível de povoamento. Contudo, muitos ajustes por meio de modelos estatísticos têm apresentado baixo desempenho em povoamentos inequidistantes devido a variação entre os incrementos das diferentes árvores ou espécies e até entre indivíduos de uma mesma espécie. Neste estudo avaliou-se a acurácia das predições do incremento periódico anual em diâmetro (IPA_{dap} ; cm ano^{-1}) de árvores individuais empregando três técnicas de aprendizagem de máquina: rede neural artificial (RNA); regressão vetorial de suporte (SVR); e *random forest* (RF). O estudo foi realizado em cinco fragmentos de Mata Atlântica: Lagoa do Piauí – LP (2 matas), São José – SJ, Cachoeira das Pombas – CP e Mata da Silvicultura – MS, localizados, respectivamente, nos municípios de Caratinga, Coronel Fabriciano, Guanhães e Viçosa, no Estado de Minas Gerais. Na MS, 10 parcelas com 0,1 ha cada foram alocadas. Em LP, SJ e CP foram alocadas 22, 12 e 20 parcelas, respectivamente, com 0,05 ha cada. Os dados: circunferência a 1,30 m de altura (cap ; cm), altura total (Ht ; m) e nomes científicos das árvores com $cap > 15$ cm foram coletados nos anos 1994, 1997, 2000, 2004, 2008, 2010, 2013 e 2016 na MS, e nos anos 2002, 2007, 2012 e 2017 nos demais fragmentos. Três índices de competição semi-independente da distância foram calculados: Glover e Hool, Stage e adaptado de Glover e Hool. Em cada fragmento, as espécies foram agrupadas em cinco grupos de IPA_{dap} por meio da análise de cluster. Os dados foram divididos em conjunto de treinamento e validação por meio do particionamento balanceado, com 70% das observações de cada espécie em cada período para o treinamento e o restante para validação. A seleção da melhor configuração de cada técnica foi por meio das estatísticas de correlação entre os incrementos observados e preditos (r_{yy}), raiz quadrada do erro quadrático médio ($RMSE$), erro absoluto médio (EAM), valor ponderado (VP), gráficos de dispersão do IPA_{dap} observado e predito e gráficos de dispersão dos resíduos padronizados em função do diâmetro a 1,30 m de altura (dap). Após selecionar a melhor configuração de cada técnica em cada fragmento, a validação cruzada foi aplicada com 10 partições e 50 repetições, com exceção da MS devido ao grande número de observações. Médias de $RMSE$ foram calculadas para cada das 50 repetições da validação cruzada. Os

testes não paramétricos de Friedman e Nemenyi foram aplicados para avaliar qual a melhor técnica em cada fragmento, com base nas médias de *RMSE* da validação cruzada. Na MS a RNA apresentou os melhores resultados estatísticos, com $r_{\hat{y}y} = 0,5003$; $RMSE = 0,3591$; e $EAM = 0,1743$. Na validação cruzada dos demais fragmentos, a RNA apresentou as menores médias de *RMSE* (0,1382–0,4155) e a SVR as maiores (0,1672–0,4453). No teste de Nemenyi, a distância da RNA para a RF e SVR em todos os fragmentos (CP, LP e SJ) foi maior que a distância crítica de 0,47. Portanto, a RNA foi a técnica que apresentou a maior eficiência para prever o incremento em diâmetro de árvores em fragmentos de Mata Atlântica.

Palavras-chave: Biometria florestal. Inteligência artificial. Manejo florestal.

ABSTRACT

TAVARES JÚNIOR, Ivaldo da Silva, M.Sc., Universidade Federal de Viçosa, July, 2019. **Machine learning: modeling the diameter increment of individual trees in Atlantic Forest fragments.** Adviser: Carlos Moreira Miquelino Eleto Torres. Co-adviser: Helio Garcia Leite.

Growth models at individual levels allow a more detailed description of the dynamics of the forests than the models at the stand level. However, many fittings by means of statistical models have shown low performance in native forests due to variation between the increments of different trees or species and even within the same species. In this study we evaluated the accuracy of predictions of annual periodic increment in diameter (IPA_{dap} ; cm year^{-1}) of individual trees in the Atlantic Forest using three machine learning techniques: artificial neural network (ANN); support vector regression (SVR); and random forest (RF). The study was carried out in five fragments of Atlantic Forest: Lagoa do Piau – LP (2 forests), São José – SJ, Cachoeira das Pombas – CP and Mata da Silvicultura – MS, located respectively in the municipalities of Caratinga, Coronel Fabriciano, Guanhães and Viçosa, Minas Gerais state. In the MS, 10 plots with 0.1 ha each were allocated. In LP, SJ and CP were allocated 22, 12 and, 20 plots, respectively, with 0.05 ha each. The data: circumference at 1.30 m in height (cbh ; cm), total height (Ht ; m) and scientific names of trees with $cbh > 15$ cm were collected in the years 1994, 1997, 2000, 2004, 2008, 2010, 2013 and 2016 in the MS, and in the years 2002, 2007, 2012 and 2017 in the other fragments. Three semi-independent competition indexes were calculated: Glover and Hool, Stage and adapted from Glover and Hool. In each fragment, the species were grouped into five API_{dbh} groups through cluster analysis. The data were divided into training and validation set through balanced partitioning, with 70% of the observations of each species in each period for the training and the rest for validation. The selection of the best configuration of each technique was through the statistics of correlation between the observed and predicted increments (r_{yy}), root mean square error ($RMSE$), mean absolute error (MAE), weighted value (WV), observed and predicted API_{dbh} scatter plots and scatter plots of the standardized residuals as a function of diameter at the height of 1.30 m (dbh). After selecting the best configuration of each technique in each fragment, cross-validation was applied with 10 partitions and 50 repetitions, except the MS due to a large number of observations. In MS, ANN presented the best statistical results, with $r_{yy} = 0.5003$; $RMSE = 0.3591$; and $MAE = 0.1743$. In cross-validation of the other fragments, ANN presented the lowest mean $RMSE$ (0.1382–0.4155) and the largest SVR (0.1672–0.4453). In

the Nemenyi test, the distance from ANN to RF and SVR on all fragments (CP, LP, and SJ) was greater than the critical distance of 0.47. Therefore, ANN was the technique that presented the greatest efficiency to predict the increase in the diameter of trees in fragments of Atlantic Forest.

Key words: Forest biometrics. Artificial intelligence. Forest management.

LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo de um neurônio dentro de uma rede neural artificial MLP.....	21
Figura 2 – Máquina de vetor de suporte linear	22
Figura 3 – Representação de uma <i>random forest</i> para regressão	24
Figura 4 – Mapa de localização dos fragmentos de Mata Atlântica no Estado de Minas Gerais, Brasil.....	26
Figura 5 – Temperatura média e precipitação anual no fragmento Cachoeira das Pombas, município de Guanhães – MG.....	27
Figura 6 – Temperatura média e precipitação anual no fragmento Lagoa do Piau, município de Caratinga – MG.....	28
Figura 7 – Temperatura média e precipitação anual no fragmento São José, município de Coronel Fabriciano – MG.....	29
Figura 8 – Temperatura média e precipitação anual na Mata da Silvicultura, município de Viçosa – MG.....	30
Figura 9 – Ferramentas implementadas no programa ArcGIS: criação das zonas de competição com raio de 3 m (A); cálculo dos índices de competição para as árvores–objeto dentro das zonas (B)	33
Figura 10 – Representação das zonas de competição criadas pela ferramenta implementada no ArcGIS.....	33
Figura 11 – Resumo da metodologia aplicada no estudo: cálculo do incremento periódico anual em diâmetro (IPA_{dap} ; cm ano^{-1}) nos períodos de incremento em cada fragmento (A); teste dos métodos de ligação hierárquicos e formação dos grupos de espécie para cada fragmento e em todos os fragmentos, menos Mata da Silvicultura (B); criação das zonas de competição dentro das parcelas dos fragmentos e cálculo dos índices de competição para as árvores–objeto dentro das zonas (C); treinamento das RNA, SVR e RF com as variáveis preditoras em diferentes abordagens e avaliação das melhores configurações selecionadas de cada técnica (D)	41
Figura 12 – Dendrogramas da análise de cluster pelo método da ligação média com as distâncias euclidianas no eixo das ordenadas. A linha tracejada horizontal representa a interceptação dos ramos para a formação de grupos com as espécies dos fragmentos Cachoeira das Pombas, Lagoa do Piau, São José, Mata da Silvicultura e todos os fragmentos juntos.	43

Figura 13 – Médias de incremento periódico anual em diâmetro (IPA_{dap}) por grupo de espécie em cada fragmento: MS = Mata da Silvicultura; CP = Cachoeira das Pombas; SJ = São José; LP = Lagoa do Piau	44
Figura 14 – Correlação entre os índices de competição (IC_1 , IC_2 e IC_3), diâmetro a 1,30 m de altura (dap) e incremento periódico anual em diâmetro (IPA_{dap}) no fragmento Cachoeira das Pombas	47
Figura 15 – Correlação entre os índices de competição (IC_1 , IC_2 e IC_3), diâmetro a 1,30 m de altura (dap) e incremento periódico anual em diâmetro (IPA_{dap}) no fragmento Lagoa do Piau	47
Figura 16 – Correlação entre os índices de competição (IC_1 , IC_2 e IC_3), diâmetro a 1,30 m de altura (dap) e incremento periódico anual em diâmetro (IPA_{dap}) no fragmento São José	48
Figura 17 – Correlação entre os índices de competição (IC_1 , IC_2 e IC_3), diâmetro a 1,30 m de altura (dap) e incremento periódico anual em diâmetro (IPA_{dap}) no fragmento Mata da Silvicultura	48
Figura 18 – Correlação entre os índices de competição (IC_1 , IC_2 e IC_3), diâmetro a 1,30 m de altura (dap) e incremento periódico anual em diâmetro (IPA_{dap}) em todos os fragmentos, menos Mata da Silvicultura (-MS).	49
Figura 19 – Dispersão do incremento periódico anual em diâmetro (IPA_{dap}) observado e predito, e dos resíduos padronizados em função do diâmetro a 1,30 m de altura (dap) no fragmento Cachoeira das Pombas	53
Figura 20 – Dispersão do incremento periódico anual em diâmetro (IPA_{dap}) observado e predito, e dos resíduos padronizados em função do diâmetro a 1,30 m de altura (dap) no fragmento Lagoa do Piau.....	54
Figura 21 – Dispersão do incremento periódico anual em diâmetro (IPA_{dap}) observado e predito, e dos resíduos padronizados em função do diâmetro a 1,30 m de altura (dap) no fragmento São José.....	55
Figura 22 – Dispersão do incremento periódico anual em diâmetro (IPA_{dap}) observado e predito, e dos resíduos padronizados em função do diâmetro a 1,30 m de altura (dap) no fragmento Mata da Silvicultura	56
Figura 23 – Dispersão do incremento periódico anual em diâmetro (IPA_{dap}) observado e predito, e dos resíduos padronizados em função do diâmetro a 1,30 m de altura (dap) em todos os fragmentos, menos Mata da Silvicultura.....	57
Figura 24 – Importância relativa das variáveis preditoras das melhores configurações selecionadas por técnica em cada fragmento. Rede neural artificial – RNA: Garson;	

regressão vetorial de suporte – SVR: raiz quadrada do erro quadrático médio (<i>RMSE</i>); e <i>random forest</i> – RF: aumento no <i>MSE</i> , em porcentagem	59
Figura 25 – Média do incremento periódico anual em diâmetro (IPA_{dap}) por período de incremento: fragmentos Cachoeira das Pombas – CP, Lagoa do Piau – LP e São José – SJ (A); e fragmento Mata da Silvicultura – MS (B).....	60
Figura 26 – Raiz quadrada do erro quadrático médio (<i>RMSE</i>) da rede neural artificial (RNA), regressão vetorial de suporte (SVR) e <i>random forest</i> (RF) na validação cruzada do fragmento Cachoeira das Pombas	61
Figura 27 – Raiz quadrada do erro quadrático médio (<i>RMSE</i>) da rede neural artificial (RNA), regressão vetorial de suporte (SVR) e <i>random forest</i> (RF) na validação cruzada do fragmento Lagoa do Piau.....	61
Figura 28 – Raiz quadrada do erro quadrático médio (<i>RMSE</i>) da rede neural artificial (RNA), regressão vetorial de suporte (SVR) e <i>random forest</i> (RF) na validação cruzada do fragmento São José.....	62
Figura 29 – Médias no teste de Nemenyi para rede neural artificial (RNA), regressão vetorial de suporte (SVR) e <i>random forest</i> (RF) nos fragmentos Cachoeira das Pombas, Lagoa do Piau e São José	63

LISTA DE TABELAS

Tabela 1 – Estatísticas descritivas e número de espécies em todos os anos de coleta nos fragmentos Cachoeira das Pombas (CP), Lagoa do Piau (LP), São José (SJ) e Mata da Silvicultura (MS).....	31
Tabela 2 – Índices de competição testados.....	34
Tabela 3 – Variáveis preditoras das abordagens testadas.....	35
Tabela 4 – Funções kernel testadas nos treinamentos das regressões vetoriais de suporte.....	37
Tabela 5 – Coeficiente de correlação cofenético (r_{cof}) dos métodos de ligação hierárquicos testados para formação dos grupos de espécies nos fragmentos: CP = Cachoeira das Pombas; LP = Lagoa do Piau; SJ = São José; MS = Mata da Silvicultura	42
Tabela 6 – Média (e desvio padrão) do diâmetro a 1,30 m de altura (dap), altura total (Ht) e incremento periódico anual em diâmetro (IPA_{dap}) por grupo de espécie em fragmentos de Mata Atlântica: Cachoeira das Pombas (CP); Lagoa do Piau (LP); São José (SJ); e Mata da Silvicultura (MS)	45
Tabela 7 – Número de espécies por grupo de espécie e grupo ecológico: Pioneira (PI); Secundária inicial (SI); Secundária tardia (ST); Climáxica (C); e Sem classificação (SC), em fragmentos de Mata Atlântica: Cachoeira das Pombas (CP); Lagoa do Piau (LP); São José (SJ); e Mata da Silvicultura (MS).....	46
Tabela 8 – Estatísticas de correlação entre o incremento periódico anual em diâmetro observado e predito (r_{yy}), raiz quadrada do erro quadrático médio ($RMSE$) e erro absoluto médio (EAM) das configurações selecionadas de cada técnica em cada fragmento	51
Tabela 9 – Significância da correlação entre os valores observados e preditos (r_{yy}) por técnica em cada fragmento pelo teste t ($\alpha = 5\%$).....	52
Tabela A1 – Grupo de espécie e média do incremento periódico anual em diâmetro (IPA_{dap}) por espécie no fragmento Cachoeira das Pombas	79
Tabela A2 – Grupo de espécie e média do incremento periódico anual em diâmetro (IPA_{dap}) por espécie no fragmento Lagoa do Piau	82
Tabela A3 – Grupo de espécie e média do incremento periódico anual em diâmetro (IPA_{dap}) por espécie no fragmento São José.....	85
Tabela A4 – Grupo de espécie e média do incremento periódico anual em diâmetro (IPA_{dap}) por espécie no fragmento Mata da Silvicultura.....	88

Tabela A5 – Grupo de espécie e média do incremento periódico anual em diâmetro (IPA_{dap}) por espécie em todos os fragmentos (Cachoeira das Pombas, Lagoa do Piau e São José)	91
Tabela B1 – Estatísticas de correlação entre o incremento periódico anual em diâmetro observado e predito (r_{yy}), raiz quadrada do erro quadrático médio ($RMSE$), erro absoluto médio (EAM) e valor ponderado (VP) das configurações selecionadas de cada técnica por abordagem no fragmento Cachoeira das Pombas.....	99
Tabela B2 – Estatísticas de correlação entre o incremento periódico anual em diâmetro observado e predito (r_{yy}), raiz quadrada do erro quadrático médio ($RMSE$), erro absoluto médio (EAM) e valor ponderado (VP) das configurações selecionadas de cada técnica por abordagem no fragmento Lagoa do Piau.....	100
Tabela B3 – Estatísticas de correlação entre o incremento periódico anual em diâmetro observado e predito (r_{yy}), raiz quadrada do erro quadrático médio ($RMSE$), erro absoluto médio (EAM) e valor ponderado (VP) das configurações selecionadas de cada técnica por abordagem no fragmento São José	101
Tabela B4 – Estatísticas de correlação entre o incremento periódico anual em diâmetro observado e predito (r_{yy}), raiz quadrada do erro quadrático médio ($RMSE$), erro absoluto médio (EAM) e valor ponderado (VP) das configurações selecionadas de cada técnica por abordagem no fragmento Mata da Silvicultura	102
Tabela B5 – Estatísticas de correlação entre o incremento periódico anual em diâmetro observado e predito (r_{yy}), raiz quadrada do erro quadrático médio ($RMSE$), erro absoluto médio (EAM) e valor ponderado (VP) das configurações selecionadas de cada técnica por abordagem em todos os fragmentos	103
Tabela C1 – Médias da raiz quadrada do erro quadrático médio ($RMSE$) e desvio padrão (DP) na validação cruzada no fragmento Cachoeira das Pombas	104
Tabela C2 – Médias da raiz quadrada do erro quadrático médio ($RMSE$) e desvio padrão (DP) na validação cruzada no fragmento Lagoa do Piau	105
Tabela C3 – Médias da raiz quadrada do erro quadrático médio ($RMSE$) e desvio padrão (DP) na validação cruzada no fragmento São José	106

SUMÁRIO

1	INTRODUÇÃO	17
2	OBJETIVOS	18
2.1	Objetivo geral	18
2.2	Objetivos específicos	18
3	REVISÃO DE LITERATURA	18
3.1	Dinâmica Florestal	18
3.2	Técnicas de aprendizagem de máquina para aproximação de funções	20
3.2.1	Redes neurais artificiais	20
3.2.2	Máquina de vetor de suporte e regressão vetorial de suporte	21
3.2.3	<i>Random forest</i>	23
3.2.4	Aplicação das técnicas de aprendizagem de máquina nas florestas.....	24
4	MATERIAL E MÉTODOS	26
4.1	Caracterização das áreas de estudo	26
4.1.1	Cachoeira das Pombas (CP)	26
4.1.2	Lagoa do Piau (LP)	27
4.1.3	São José (SJ).....	28
4.1.4	Mata da Silvicultura (MS).....	29
4.2	Coleta dos dados	30
4.2.1	Dados de Lagoa do Piau, São José e Cachoeira das Pombas.....	30
4.2.2	Dados da Mata da Silvicultura	31
4.3	Análise de cluster	31
4.4	Cálculo dos índices de competição	32
4.5	Variáveis preditoras nos treinamentos das técnicas	34
4.6	Treinamento das redes neurais artificiais (RNA)	35
4.7	Treinamento das regressões vetoriais de suporte (SVR)	36
4.8	Treinamento das <i>random forests</i> (RF)	37
4.9	Seleção das melhores configurações	38
4.10	Seleção das variáveis preditoras mais importantes	39
4.11	Validação cruzada	39
4.11.1	Testes de Friedman e Nemenyi	40
5	RESULTADOS	42
5.1	Grupos de espécies	42

5.2	Correlações dos índices de competição.....	46
5.3	Melhor configuração de cada técnica	49
5.4	Importância relativa das variáveis preditoras	58
5.5	Melhores configurações na validação cruzada	60
5.6	Comparação das técnicas pelos testes de Friedman e Nemenyi.....	62
6	DISCUSSÃO	64
7	CONCLUSÕES	67
	REFERÊNCIAS	68
	APÊNDICE A – Médias de IPA_{dap} por espécie em cada fragmento	79
	APÊNDICE B – Configurações e estatísticas das técnicas de aprendizagem de máquina selecionadas na validação	99
	APÊNDICE C – Médias de $RMSE$ na validação cruzada	104

1 INTRODUÇÃO

A Mata Atlântica, com mais de 20.000 espécies de plantas vasculares, é considerada um *hotspot* devido sua riqueza e endemismo (MYERS et al., 2000). Contudo, a urbanização e expansão agrícola reduziu drasticamente a área de floresta deste bioma para menos de 12% de sua cobertura original (FEREZ et al., 2015). Apesar disso, os fragmentos florestais restantes possuem uma importância para a sociedade por fornecer amplo conjunto de serviços ecossistêmicos, como a mitigação das mudanças climáticas pela estocagem de carbono na sua biomassa (CHAPLIN-KRAMER et al., 2015; MAGNAGO et al., 2015). Assim, as medições biométricas periódicas de longo prazo oferecem subsídios para investigar a contribuição da floresta para as emissões de carbono e seu potencial para a neutralização do mesmo (CURTIS, P. S. et al., 2002; McDOWELL et al., 2015; RAJASHEKAR et al., 2018).

A dinâmica florestal é impulsionada pelo equilíbrio entre quatro mudanças demográficas florestais: crescimento, recrutamento, mortalidade e composição florestal (VANCLAY, 1994; PRETZSCH, 2010), variando com a idade, espécies e condições edafoclimáticas (VANDERWEL et al., 2013). A estimativa do crescimento da floresta é essencial para avaliar a produtividade, sequestro de carbono e a resposta das florestas às mudanças nas condições ambientais (GSCHWANTNER et al., 2016; THURNHER; KLOPF; HASENAUER, 2017; MORAIS JÚNIOR et al., 2019). Essa estimativa pode ser realizada por meio de modelos de árvores individuais, que permitem a descrição mais detalhada da dinâmica da floresta do que os modelos em nível de povoamento (ADAME et al., 2008; MABVURIRA; MIINA, 2002). Contudo, as condições ambientais, diferenças de idades, variabilidade genética e também a competição entre os indivíduos afetam os incrementos nas dimensões das árvores (STEPKA et al., 2012), dificultando a modelagem.

Assim, a modelagem do incremento de uma variável em nível individual requer a escolha de uma abordagem adequada para estimar os parâmetros dos modelos. As duas principais abordagens utilizadas são os modelos de regressão e as técnicas de aprendizagem de máquina (BREIMAN, 2001), sendo mais comum o emprego de redes neurais artificiais (RNA), seguido da regressão vetorial de suporte (SVR) e *random forests* (RF) (JACHOWSKI et al., 2013).

Quando a precisão da predição é o objetivo final, as técnicas de aprendizagem de máquina geralmente são superiores as técnicas tradicionais pois fazem menos suposições sobre os dados (DIAMANTOPOULOU, 2005; WESTREICH; LESSLER; FUNK, 2010; GARCÍA-GUTIÉRREZ et al., 2015). A aprendizagem de máquina é uma área de estudo em

rápido crescimento que deve se tornar mais comum para a modelagem em nível de árvore individual devido ao seu potencial para produzir modelos melhores do que as abordagens tradicionais de modelagem de dados (ZHAO et al., 2011; GLEASON; IM, 2012; JACHOWSKI et al., 2013). Desse modo, é sempre importante testar diferentes técnicas de modelagem e selecionar a de melhor desempenho (JACHOWSKI et al., 2013).

2 OBJETIVOS

2.1 Objetivo geral

Predizer o incremento individual do diâmetro de árvores em fragmentos florestais de Mata Atlântica utilizando técnicas de aprendizagem de máquina.

2.2 Objetivos específicos

- Identificar as variáveis preditoras mais importantes para cada modelo de aprendizagem de máquina (rede neural artificial, regressão vetorial de suporte e *random forest*).
- Identificar a melhor técnica de aprendizagem de máquina para prever o incremento individual do diâmetro de árvores em fragmentos florestais de Mata Atlântica.

3 REVISÃO DE LITERATURA

3.1 Dinâmica Florestal

Analisar as mudanças temporais na quantidade e configuração da floresta é essencial para melhor projetar o futuro manejo florestal (COSTA et al., 2017). A dinâmica da floresta é um fenômeno altamente dimensional que não é totalmente entendido teoricamente (LIÉNARD; GRAVEL; STRIGUL, 2015). O conhecimento dos fatores que controlam a dinâmica da vegetação é essencial para melhorar o monitoramento do ecossistema. Por isso, analisar as transições da vegetação pode fornecer informações importantes (VIDAL-MACUA et al., 2017).

A dinâmica florestal inclui quatro elementos: recrutamento de novas árvores, mortalidade, crescimento e composição da floresta (VANCLAY, 1994; PRETZSCH, 2010). O recrutamento e mortalidade de árvores são eventos binários altamente variáveis,

complicados e em grande parte estocásticos, afetando a futura dinâmica do suporte florestal (XIANG; LEI; ZHANG, 2016).

A modelagem do recrutamento através do método de mínimos quadrados é desafiadora. Isso ocorre devido os dados de recrutamento incluírem uma grande proporção de contagens zero e, assim, não possuem a distribuição de Gauss, resultando em estimativas tendenciosas (SHIFLEY et al., 1993). O uso do modelo de mistura binomial negativo (ZHANG et al., 2012), binomial negativo inflado de zeros (XIANG; LEI; ZHANG, 2016), e a transformação dos dados são algumas alternativas para diminuir a tendenciosidade das estimativas. Ainda, o recrutamento pode ser afetado por fatores ambientais, como o estresse hídrico e limitações relacionadas à estrutura da floresta e fatores bióticos, como a competição, facilitação e complementaridade de nicho (CEQUINEL et al., 2018).

A mortalidade da árvore é um processo fundamental nos ecossistemas e tem grande importância nas respostas do ecossistema florestal à mudança ambiental global (McDOWELL et al., 2011; ANDEREGG; BERRY; FIELD, 2012). A mudança climática foi associado ao aumento da taxa de distúrbios vegetais e mortalidade, promovendo mudanças nas condições dos ecossistemas florestais (McDOWELL et al., 2015). Ainda, a mortalidade excessiva reduz a absorção fotossintética, fazendo com que os ecossistemas se tornem fonte de CO₂ para a atmosfera por algum período de tempo (McDOWELL et al., 2008). Um dos problemas na modelagem da mortalidade é que vários fatores aleatórios podem causar a morte das árvores (REIS et al., 2018; ROCHA et al., 2018). Para prever a mortalidade com precisão, a utilização de um banco de dados com grande e representativa quantidade de árvores é uma possível solução. Assim, a mortalidade pode ser observada com maior frequência, aumentando a probabilidade de acerto na classificação (MONSERUD; STERBA, 1999).

O crescimento é um processo caracterizado pelo aumento nas dimensões da árvore em um determinado período de tempo (CAMPOS; LEITE, 2013). Uma forma de estimar o crescimento do diâmetro das árvores é com o emprego de modelos de incremento em diâmetro (LHOTKA; LOEWENSTEIN, 2011). Esses modelos podem projetar o desenvolvimento e produção da floresta para diversas alternativas de manejo (LHOTKA; LOEWENSTEIN, 2011; HAN et al., 2016; ALBAUGH et al., 2017). As informações sobre o incremento em diâmetro e padrões de crescimento de árvores individuais também são importantes na seleção de espécies arbóreas para exploração madeireira ou proteção (ADAME et al., 2008).

3.2 Técnicas de aprendizagem de máquina para aproximação de funções

As principais técnicas de aprendizagem de máquina para aproximação de funções são: redes neurais artificiais (RNA), regressão vetorial de suporte (SVR) e *random forest* (RF).

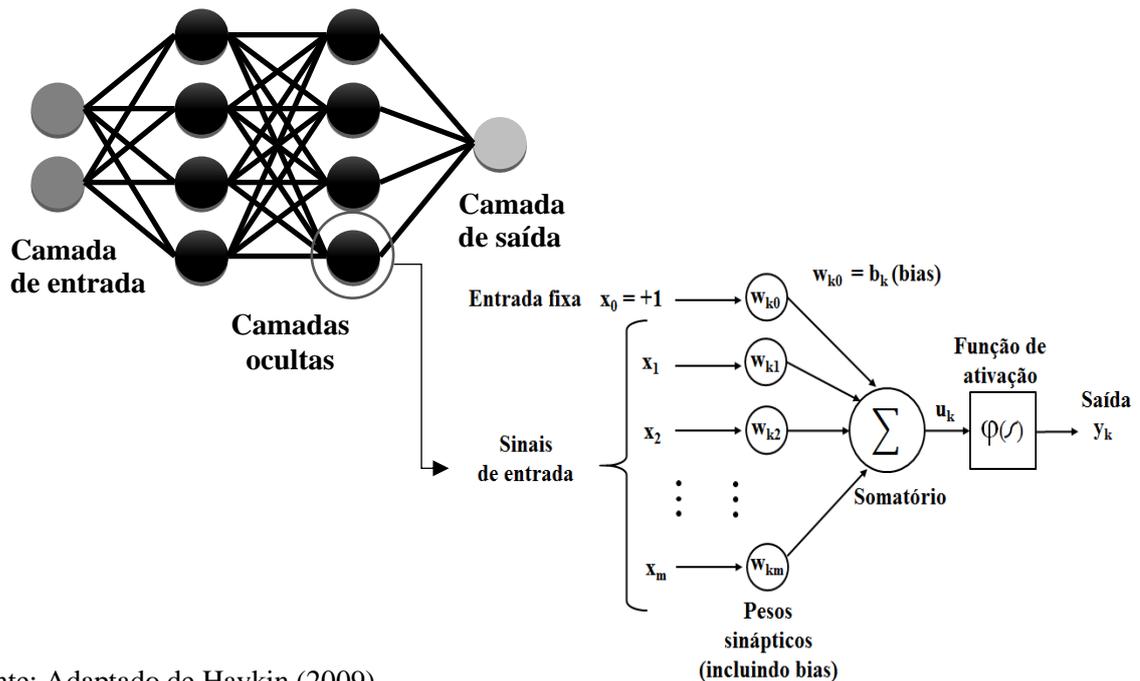
3.2.1 Redes neurais artificiais

As RNA são sistemas de processamento de informações massivamente distribuídos em paralelo, que simulam o funcionamento de neurônios no cérebro humano (HAYKIN, 2009). O neurônio artificial é a unidade básica de processamento de informação da RNA. O primeiro modelo de neurônio artificial foi proposto por McCulloch e Pitts, como tentativa de se aproximar de um neurônio biológico (McCULLOCH; PITTS, 1943; HAYKIN, 2009).

As RNA são alternativas para a predição e classificação de problemas complexos, devido não ser necessário pressuposições sobre as relações entre as variáveis utilizadas no treinamento, ficando a cargo da rede treinada a tarefa de modelar as relações lineares e não lineares (DIAMANTOPOULOU; MILIOS, 2010; ÖZÇELIK et al., 2010; NUNES; GÖRGENS, 2016).

As redes utilizam a aprendizagem artificial com base no conceito de auto ajuste dos parâmetros de controle interno (pesos). As estruturas matemáticas contidas nos processos das redes são flexíveis e capazes de identificar relações complexas não lineares entre conjuntos de dados de entrada e saída (MELESSE; HANLEY, 2005). O neurônio artificial em uma arquitetura típica de RNA recebe um conjunto de entradas ou sinais (x_m) com pesos (w_{km}), calcula uma soma ponderada deles (u_k) usando a função de soma e então usa alguma função de ativação (φ) para produzir uma saída (y_k) (HAYKIN, 2009; RUSSELL; NORVIG, 2010; LIU et al., 2018) (Figura 1).

Figura 1 – Exemplo de um neurônio dentro de uma rede neural artificial MLP



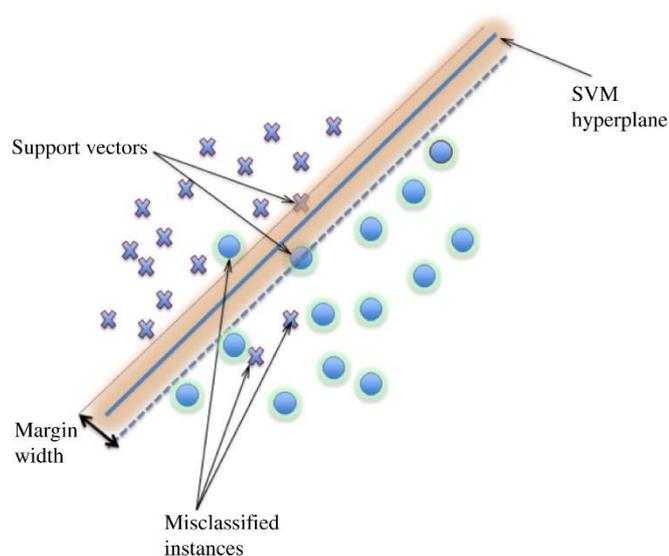
Fonte: Adaptado de Haykin (2009).

3.2.2 Máquina de vetor de suporte e regressão vetorial de suporte

As máquinas de vetores de suporte (SVM) constituem uma técnica embasada na teoria do aprendizado estatístico (VAPNIK, 1995). A SVM é uma técnica poderosa para classificação e regressão de dados. A SVM minimiza o risco estrutural pesquisando o *trade-off* ideal entre o erro de treinamento e a complexidade do modelo, em que o risco estrutural é a probabilidade de erro previsto em um vetor de dados anteriormente desconhecido (HAO, 2017).

Na classificação de padrões lineares, a ideia principal de uma máquina de vetor de suporte é construir um hiperplano como superfície de decisão de tal forma que a margem de separação entre exemplos positivos e negativos seja máxima (HAYKIN, 2009; MOUNTRAKIS; IM; OGOLE, 2011) (Figura 2).

Figura 2 – Máquina de vetor de suporte linear



Fonte: Mountrakis et al. (2011), adaptado de Burges (1998).

Os hiperplanos são recursos que existem no espaço de recursos, que é um espaço multidimensional construído a partir de eixos que representam cada variável de entrada. A SVM desenvolve hiperplanos para separar esses grupos e usa "vetores de suporte" para atribuir a cada observação um espaço adequadamente segmentado (HAYKIN, 2009). A SVM atribui iterativamente esses hiperplanos entre os dados e, em seguida, ajusta-os com base nos erros associados a cada um, chegando a uma solução que converge em direção ideal (GLEASON; IM, 2012).

Para problemas não lineares, a função kernel foi introduzida (FENG; LIAO, 2017; TSIRIKOGLU et al., 2017). A função projeta os dados de aprendizagem originais ou não lineares em um espaço de recursos de grande dimensão, onde todos os dados podem ser apresentados linearmente (CHENG et al., 2017). As SVM usam um mapeamento implícito Φ dos dados de entrada em um espaço de recurso de alta dimensão definido por uma função kernel, que retorna o produto interno $\langle \Phi(x), \Phi(x') \rangle$ entre dois pontos de dados x, x' no espaço de características (KARATZOGLU; MEYER; HORNIK, 2006).

O objetivo das funções de kernel é projetar os vetores de características de entrada em um espaço de características de alta dimensão para classificação de problemas que se encontram em espaços não linearmente separáveis (SUYKENS; SIGNORETTO; ARGYRIOU, 2015). Isso ocorre devido à medida que se aumenta o espaço da dimensão do

problema, maior a probabilidade de se tornar linearmente separável em relação a um espaço de baixa dimensão (CUENTAS; PEÑABAENA-NIEBLES; GARCIA, 2017).

Em problemas de regressão, o objetivo é encontrar uma função $f(x)$ que tenha no máximo ε desvio dos alvos efetivamente obtidos y_i para todos os dados de treinamento. A ligação dos pontos de x real e y predito gera uma linha. Esta deve ser semelhante, ou, o mais próximo possível da linha que é gerada pela ligação dos pontos x e y reais (SMOLA; SCHÖLKOPF, 2004).

A regressão vetorial de suporte (SVR) é uma ferramenta de previsão artificial inteligente baseada na teoria do aprendizado estatístico e no princípio de minimização do risco estrutural (LU, 2014). Pode ser expresso como a seguinte equação: $f(x) = [w \times \Phi(x)] + b$, em que: w é vetor de peso, x é o modelo de entrada, b é um viés e Φ é uma função do kernel que usa uma função não-linear para transformar a entrada não-linear em modo linear em um espaço de característica de alta dimensão (WERE et al., 2015).

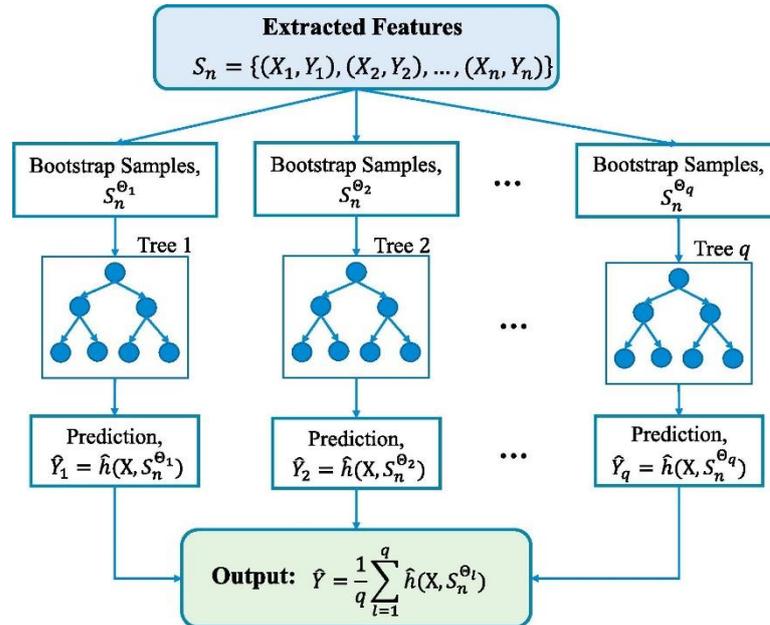
Assim, as SVR tem se mostrado como alternativa interessante para a modelagem de problemas complexos (WANG et al., 2012; MLADENOVIC et al., 2016; HUANG; ZHAO, 2018).

3.2.3 *Random forest*

As *random forests* (RF) foram introduzidas por Breiman (2001) e são baseadas em árvores de decisão combinadas com ideias de agregação e inicialização. Essa técnica é um poderoso método estatístico não paramétrico que permite considerar problemas de regressão e de classificação de duas ou multi-classes, em uma estrutura única e versátil (GENUER et al., 2017).

A RF consiste no conjunto de preditores de árvores simples. Cada árvore é capaz de produzir uma resposta com um conjunto de valores preditores. Nos problemas de classificação, a resposta da árvore assume a forma de uma associação de classe que associa um conjunto de valores preditores independentes a uma das categorias apresentadas na variável dependente (BREIMAN, 2001). Assim, o conjunto de árvores simples vota para a classe mais popular. Em problemas de regressão, a resposta da árvore é uma estimativa da variável dependente dada pelos preditores. Nesse caso, a média dos resultados dos preditores gera a estimativa da variável dependente (Figura 3) (YU et al., 2017).

Figura 3 – Representação de uma *random forest* para regressão



Fonte: Li et al. (2018).

O modelo de RF usa um algoritmo de aprendizagem de árvore modificado, que seleciona a cada ramificação um subconjunto aleatório de atributos ao longo do processo de aprendizagem (BREIMAN, 2001). Esse processo também é conhecido como *feature bagging*.

Ao usar a técnica de *bagging* para construir um conjunto de árvores de decisão/regressão, as RF alcançam menor variação. No entanto, no *bagging* tradicional, as árvores constituintes podem acabar sendo altamente correlacionadas, pois os mesmos atributos tendem a ser usados repetidamente para dividir as amostras (NAGALLA; POTHUGANTI; PAWAR, 2017). Ao modificar o algoritmo de aprendizagem para escolher subconjuntos aleatórios, a correlação entre as árvores que compõem o conjunto é reduzida. Desta forma, florestas aleatórias tendem a atingir um desempenho superior (NAGALLA; POTHUGANTI; PAWAR, 2017).

3.2.4 Aplicação das técnicas de aprendizagem de máquina nas florestas

A aplicação da aprendizagem de máquina vem sendo utilizada para melhorar as estimativas locais, regionais e globais em ecossistemas complexos, como as florestas (VAHEDI, 2016). Nas florestas nativas, a complexidade é encontrada na sua estrutura, dinâmica e manejo. Muitas das técnicas tradicionais não fornecem resultados adequados para

a tomada de decisões relacionadas a dinâmica dessas florestas. Desse modo, novas técnicas que visem a melhoria da precisão de parâmetros relativos as florestas são necessárias.

Dentre as técnicas citadas anteriormente, a RNA é a mais utilizada em diversas situações, como na modelagem das respostas de crescimento dos anéis de árvores a variáveis climáticas (ZHANG et al., 2000), predição da altura de árvores individuais (ÖZÇELIK et al., 2013), distribuição diamétrica (DIAMANTOPOULOU et al., 2015), predição de biomassa acima do solo (VAHEDI, 2016), prognose do volume de árvores (BINOTI et al., 2015), prognose do diâmetro de árvores (REIS et al., 2016), volume de fustes e galhos (RIBEIRO et al., 2016) e modelagem da sobrevivência e mortalidade de árvores (ROCHA et al., 2018). O fluxo de CO₂ em diferentes ecossistemas (floresta, pastagem e terras agrícolas) também já foi simulado com o uso de RNA (MELESSE; HANLEY, 2005), em que os autores acreditam que futuras estratégias de mitigação de carbono e políticas de mudança climática se beneficiarão de estudos similares.

A caracterização da estrutura do dossel da floresta foi realizada com o auxílio de métricas de lidar e SVM por Zhao et al. (2011). Os autores mostraram que a SVM em conjunto com lidar foi superior a técnicas tradicionais, como o classificador de máxima verossimilhança e os modelos de regressão linear. A biomassa acima do solo em manguezais na Tailândia estimada por meio de SVR e regressão tradicional, mostrou resultados mais precisos com a MVS no estudo conduzido por Jachowski et al. (2013). Pham e Brabyn (2017) monitoraram a mudança de biomassa em florestas de manguezais no Vietnã usando modelo de RF, identificando o tipo de vegetação como a variável explicativa mais importante. Esses autores demonstraram que o algoritmo de RF é adequado para estimar a biomassa em florestas de mangue, ambiente em que os tamanhos das amostras são geralmente pequenos devido à dificuldade na coleta de dados de campo.

A comparação das técnicas de aprendizagem de máquina não tem sido limitada aos modelos de regressão tradicionais, mas também entre as próprias técnicas de aprendizagem de máquina. Modelos lineares de efeitos mistos, RF e SVR foram comparados na estimativa de biomassa em floresta moderadamente densa (40-60% do fechamento do dossel) tanto em nível de árvore, quanto de parcela (GLEASON; IM, 2012). Essa comparação mostrou que o uso da SVR forneceu as estimativas mais precisas em relação as outras técnicas. A RNA e RF também foram comparadas na modelagem taper em mosaico de vegetação complexa no Cerrado brasileiro, em que as RNA se mostraram mais precisas (NUNES; GÖRGENS, 2016). As RNA conseguiram modelar dados de árvores com diferentes formas de caule e variações de arquiteturas complexas. No entanto, essa pesquisa apontou que esforços para integrar

ferramentas de inteligência artificial em sistemas de decisão de suporte florestal atuais devem ser realizados.

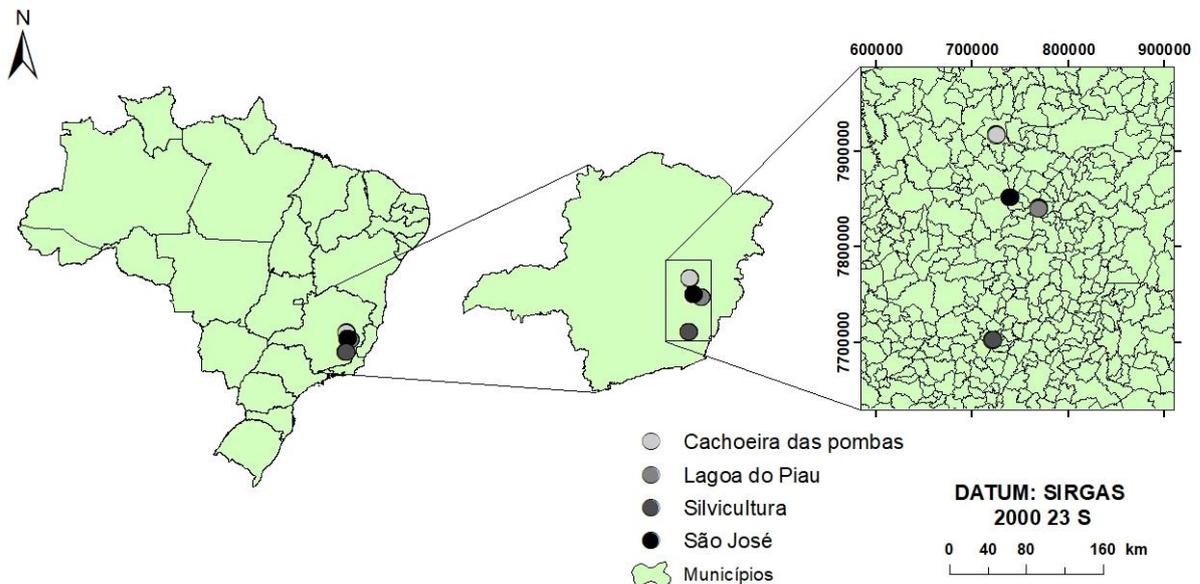
Portanto, estudos podem ser desenvolvidos com a aplicação das técnicas de aprendizagem de máquina, de forma individual ou em conjunto, principalmente em problemas complexos de florestas nativas.

4 MATERIAL E MÉTODOS

4.1 Caracterização das áreas de estudo

As bases de dados do estudo foram provenientes de cinco fragmentos florestais de Mata Atlântica: Cachoeira das Pombas, Lagoa do Piau (2 matas), São José e Mata da Silvicultura (Figura 4).

Figura 4 – Mapa de localização dos fragmentos de Mata Atlântica no Estado de Minas Gerais, Brasil



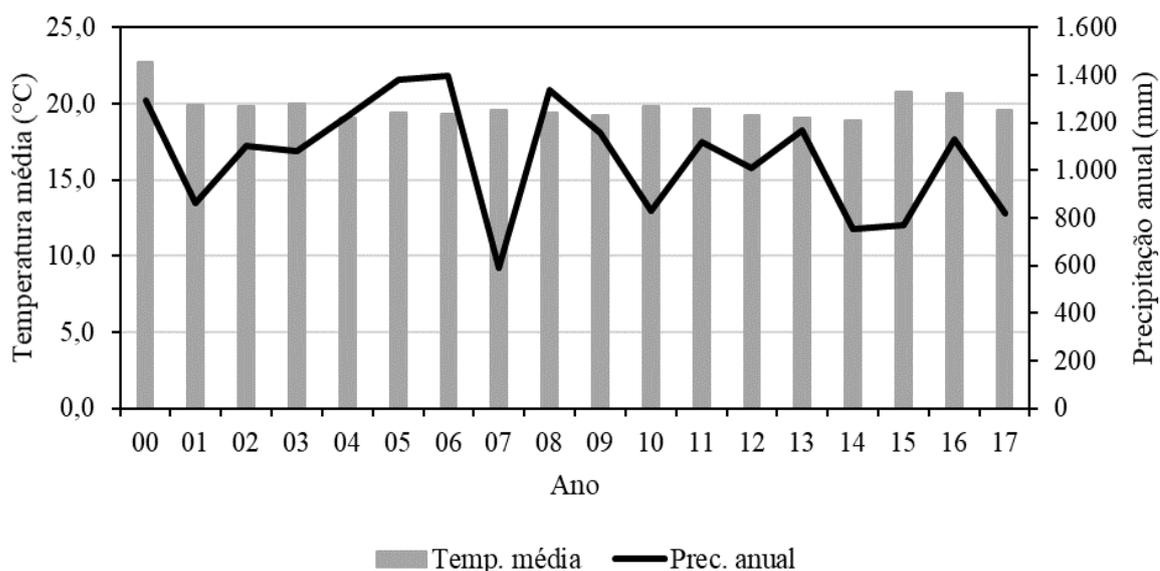
Fonte: Rocha (2019).

4.1.1 Cachoeira das Pombas (CP)

A área é uma reserva legal, localizada na região de Guanhães, município de Guanhães, Minas Gerais, Brasil. A cobertura vegetal pertence à região fitoecológica da Floresta Estacional Semidecidual Montana (IBGE, 2004; VELOSO et al., 1991), sendo que a altitude local varia de 800 a 1.162 m.

O clima predominante na região, segundo a classificação climática de Köppen, é o Cwa – tropical de altitude, com chuvas de verão e verões quentes. A temperatura e precipitação pluviométrica média anual, no período de 2000 a 2017 foi de 19,8 °C e 1.057 mm ano⁻¹, respectivamente (Figura 5). A evapotranspiração potencial anual varia entre 850 e 1.050 mm, conforme registros de uma estação meteorológica localizada em Guanhães – longitude de 42° 58’, latitude de 18° 48’ e altitude de 801 m (SIF, 2008).

Figura 5 – Temperatura média e precipitação anual no fragmento Cachoeira das Pombas, município de Guanhães – MG



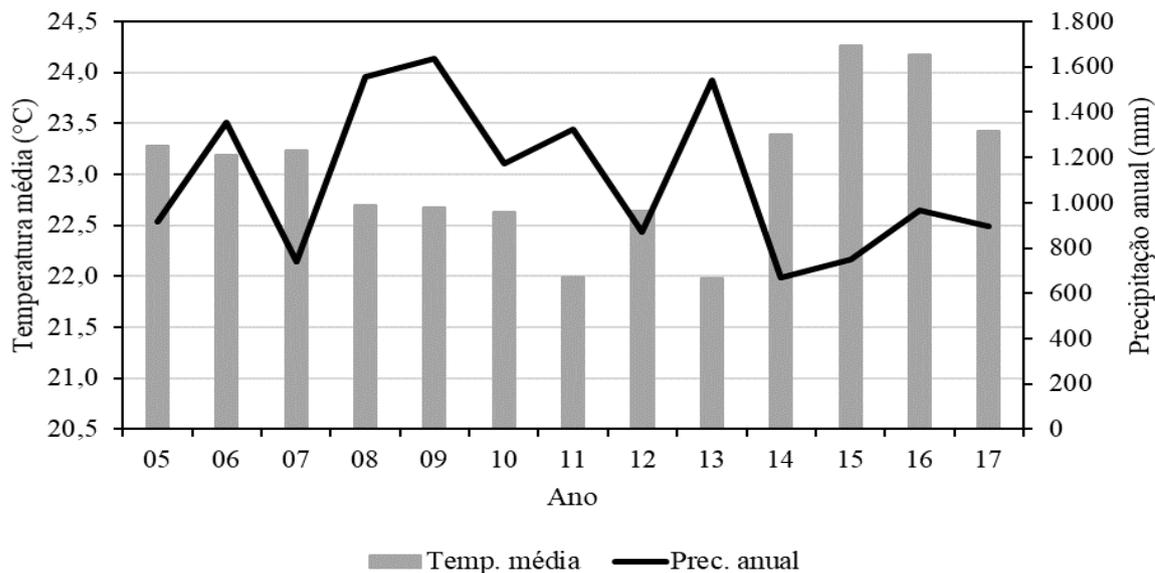
Fonte: Adaptado CENIBRA S.A. (2018).

4.1.2 Lagoa do Piau (LP)

A área de LP está inserida na região de Ipaba, município de Caratinga, Minas Gerais. Duas matas foram selecionadas para o estudo: Mata 1, com altitude local de 200 até 450 m; e Mata 2, com altitude local de 150 a 300 m. Os dados das duas matas foram unidos para obter maior número de observações e possibilitar a realização das etapas seguintes.

A vegetação original pertence à região fitoecológica da Floresta Estacional Semidecidual Submontana (VELOSO et al., 1991; IBGE, 2004). O clima predominante nessa região pela classificação climática de Köppen é o Aw - Clima tropical úmido, com inverno seco e verão chuvoso. A temperatura e precipitação pluviométrica média anual, no período de 2005 a 2017 foi de 23 °C e 1.107 mm ano⁻¹, respectivamente (Figura 6). A evapotranspiração potencial anual varia entre 950 e 1.200 mm (SIF, 2008).

Figura 6 – Temperatura média e precipitação anual no fragmento Lagoa do Piau, município de Caratinga – MG



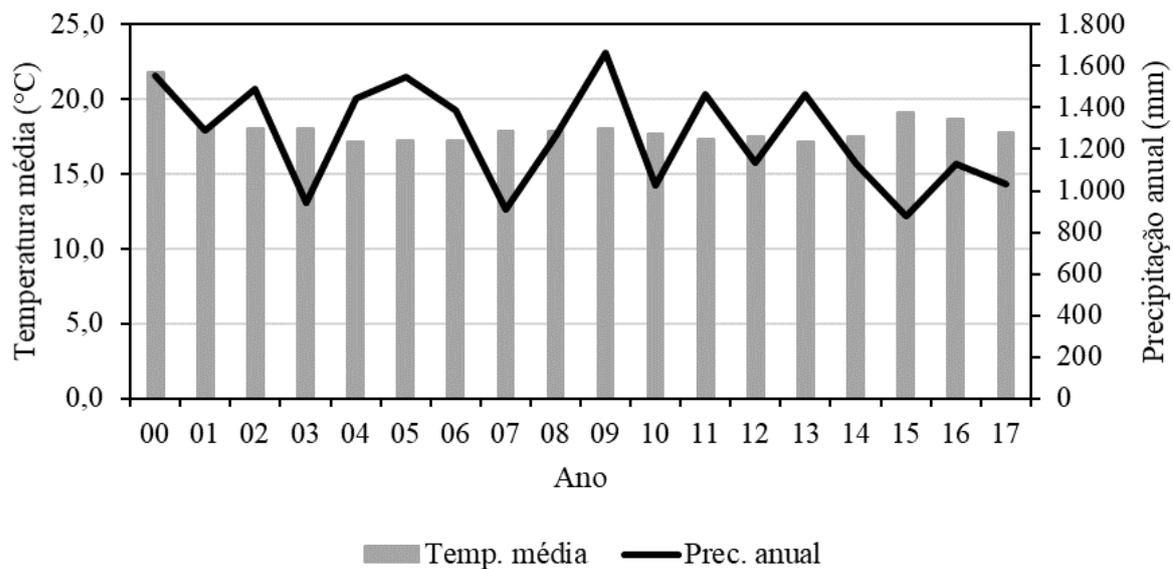
Fonte: Adaptado CENIBRA S.A. (2018).

4.1.3 São José (SJ)

A área de SJ está localizada na região de Cocais, no município de Coronel Fabriciano, Minas Gerais, com altitude local variando de 450 m a 950 m. A cobertura vegetal original insere-se na região fitoecológica da Floresta Estacional Semidecidual Montana (IBGE, 2004; VELOSO et al., 1991) e a vegetação secundária remanescente é um mosaico de estágios de sucessão inicial, médio e avançado, com presença de afloramentos rochosos, grande variação altitudinal, locais com solos rasos, profundos, úmidos e secos.

O clima predominante na região, pela classificação climática de Köppen, é o Cwb - tropical de altitude. A temperatura e precipitação pluviométrica média anual, no período de 2000 a 2017 foi de 18,01 °C e 1.265 mm ano⁻¹, respectivamente (Figura 7). A evapotranspiração potencial anual varia entre 750 e 950 mm, conforme registros de uma estação meteorológica localizada no município de Antônio Dias (longitude de 42° 51', latitude de 19° 27' e altitude de 950 m). A temperatura e precipitação média, no período de 2000 a 2017 foi de 18 °C e 1.265 mm ano⁻¹.

Figura 7 – Temperatura média e precipitação anual no fragmento São José, município de Coronel Fabriciano – MG

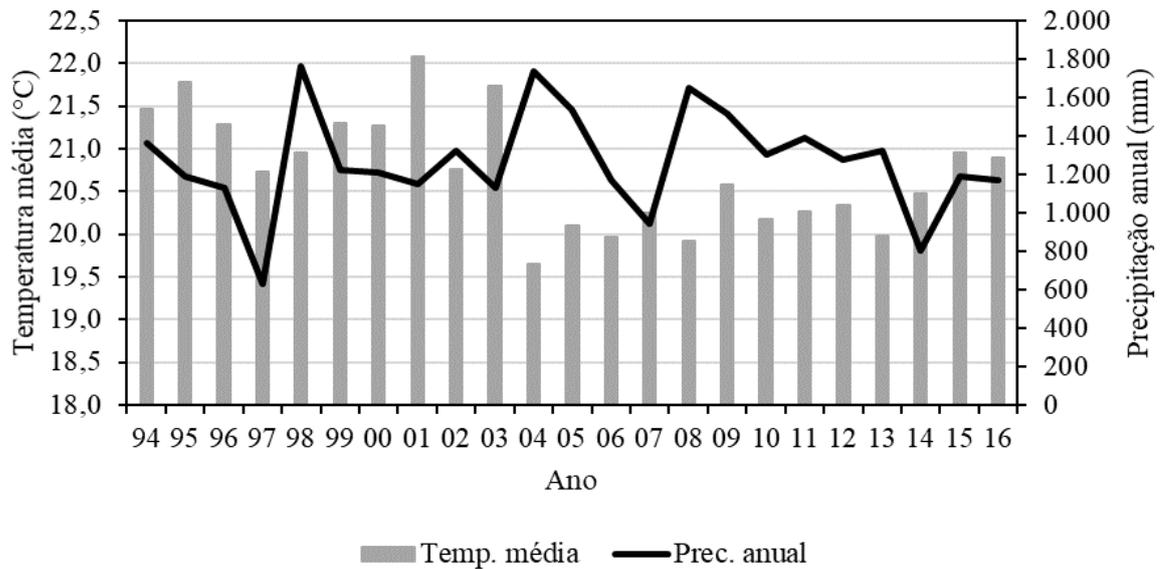


Fonte: Adaptado CENIBRA S.A. (2018).

4.1.4 Mata da Silvicultura (MS)

A MS é um fragmento regenerado de Mata Atlântica, com 17 ha, na cidade de Viçosa, Minas Gerais. A vegetação é classificada como Floresta Estacional Semidecidual Montana (IBGE, 2004). O clima local, segundo a classificação de Köppen, é do tipo Cwa, com média da temperatura e precipitação pluviométrica anual para o período de 1994 a 2016 de 20,7 °C e 1.266 mm, respectivamente (Figura 8). A topografia local é acidentada, apresentando relevo forte ondulado e montanhoso, com vales estreitos e úmidos. A área possui altitudes entre 670 e 730 m.

Figura 8 – Temperatura média e precipitação anual na Mata da Silvicultura, município de Viçosa – MG



Fonte: Adaptado UFV (2016).

4.2 Coleta dos dados

4.2.1 Dados de Lagoa do Piau, São José e Cachoeira das Pombas

Parcelas permanentes retangulares de área fixa com 10×50 m (0,05 ha) foram distribuídas de forma a contemplar os diferentes estádios de sucessão. As parcelas foram marcadas para facilitar a localização das árvores em futuras ocasiões de monitoramentos e coleta de material botânico. Cada parcela foi dividida em 20 setores de inventário de 5×5 m e as árvores com circunferência a 1,30 m de altura (*cap*; cm) ≥ 15 cm foram mapeadas.

Nos fragmentos LP, SJ e CP foram alocadas 22, 12 e 20 parcelas, respectivamente. Das 22 parcelas em LP, 16 foram na Mata 1 e 6 na Mata 2. O nome científico das espécies, a *cap* (cm) e a altura total – *Ht* (m) em árvores com *cap* ≥ 15 cm foram coletados nos anos de 2002, 2007, 2012 e 2017, em cada fragmento. O *cap* posteriormente foi convertido em diâmetro a 1,30 m de altura (*dap*; cm).

4.2.2 Dados da Mata da Silvicultura

Dez parcelas permanentes, com 20×50 m (0,1 ha) cada, foram alocadas aleatoriamente na área. O nome científico das espécies, a *cap* (cm) e a *Ht* (m) das árvores com *cap* > 15,7 cm foram coletados nos anos de 1994, 1997, 2000, 2004, 2008, 2010, 2013 e 2016. O *cap* foi convertido em *dap* (cm).

Um resumo das estatísticas descritivas de cada fragmento pode ser visualizado na Tabela 1.

Tabela 1 – Estatísticas descritivas e número de espécies em todos os anos de coleta nos fragmentos Cachoeira das Pombas (CP), Lagoa do Piau (LP), São José (SJ) e Mata da Silvicultura (MS)

Fragmento	Variável	Mínimo	Média	Máximo	Desvio padrão	Nº espécies
CP	<i>q</i> (cm)		10,84			135
	<i>dap</i> (cm)	4,77	9,01	70,03	5,98	
	<i>Ht</i> (m)	1,70	7,87	32,00	3,02	
	IPA_{dap} (cm ano ⁻¹)	0,0064	0,1630	1,9735	0,1678	
LP	<i>q</i> (cm)		11,00			125
	<i>dap</i> (cm)	4,77	9,83	41,06	4,94	
	<i>Ht</i> (m)	2,00	9,10	22,00	2,96	
	IPA_{dap} (cm ano ⁻¹)	0,0057	0,3911	5,3476	0,5418	
SJ	<i>q</i> (cm)		13,25			132
	<i>dap</i> (cm)	4,77	11,37	64,94	6,81	
	<i>Ht</i> (m)	2,50	9,87	30,00	3,64	
	IPA_{dap} (cm ano ⁻¹)	0,0127	0,1811	2,2918	0,1979	
MS	<i>q</i> (cm)		16,93			125
	<i>dap</i> (cm)	5,03	13,43	91,35	10,31	
	<i>Ht</i> (m)	2,40	12,75	39,20	5,99	
	IPA_{dap} (cm ano ⁻¹)	0,0053	0,2662	8,9763	0,4854	

em que: *q* = diâmetro médio; *dap* = diâmetro a 1,30 m de altura; *Ht* = altura total; IPA_{dap} = incremento periódico anual em diâmetro.

4.3 Análise de cluster

As espécies foram agrupadas com base no incremento periódico anual médio em *dap* (IPA_{dap} ; cm ano⁻¹), para inserir na modelagem as espécies com poucos indivíduos: $IPA_{dap} = (dap_f - dap_i)/P$, em que $dap_f = dap$ no final do período de crescimento avaliado (cm); $dap_i = dap$ no início do período de crescimento avaliado (cm); e *P* = intervalo de medição. A distância euclidiana (MESQUITA et al., 2017) foi a medida de dissimilaridade usada para distinguir os grupos. Os métodos de ligação completo, média, simples e Ward foram as

técnicas hierárquicas aglomerativa testadas. A distância euclidiana foi calculada com a função *dist* e os métodos de ligação foram implementados com a função *hclust*, ambas do pacote “*stats*” no programa *R* versão 3.5.1 (R CORE TEAM, 2018). A eficiência dos métodos de ligação foi avaliada com o coeficiente de correlação cofenético – r_{cof} (Equação 1) (FARRIS, 1969), calculado com o auxílio da função *cophenetic* no *R*. Uma linha horizontal tracejada entre os ramos foi plotada no dendrograma resultante, formando os grupos de espécies.

$$r_{cof} = \frac{\sum_{i=j}^{n-1} \sum_{j=i+1}^n (c_{ij} - \bar{c}) (d_{ij} - \bar{d})}{\sqrt{\sum_{i=j}^{n-1} \sum_{j=i+1}^n (c_{ij} - \bar{c})^2} \sqrt{\sum_{i=j}^{n-1} \sum_{j=i+1}^n (d_{ij} - \bar{d})^2}} \quad (1)$$

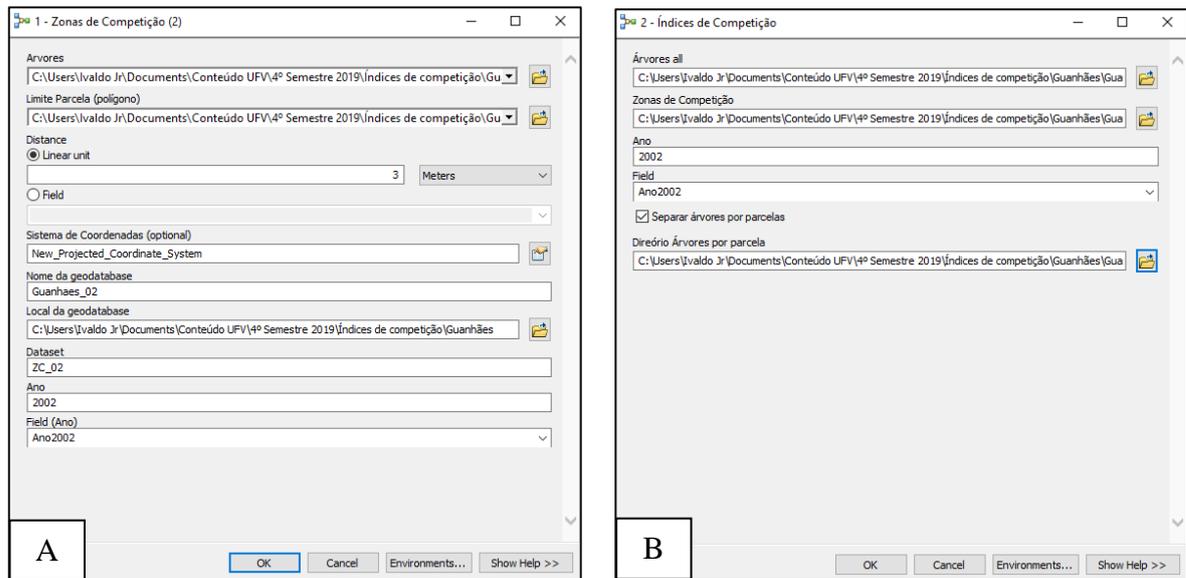
Em que: r_{cof} = coeficiente de correlação cofenética; c_{ij} = valor de dissimilaridade entre as espécies i e j , obtidos a partir da matriz cofenética; d_{ij} = valor de dissimilaridade entre as espécies i e j , obtidos a partir da matriz de dissimilaridade original.

Após a formação dos grupos, as espécies foram classificadas por grupo ecológico por meio de consulta em diversas literaturas (SWAINE; WHITMORE, 1988; OLIVEIRA-FILHO 1994; GANDOLFI; LEITÃO FILHO; BEZERRA, 1995; TABARELLI; MANTOVANI, 1997; FONSECA; RODRIGUES, 2000; SILVA et al., 2003; PAULA et al., 2004; CATHARINO et al., 2006). Assim, a quantidade de espécies por grupo ecológico e grupo de espécies foi obtida para cada fragmento. Os grupos ecológicos foram: Pioneira (PI); Secundária inicial (SI); Secundária tardia (ST); e Climática (CL). As espécies que não foram achadas informações sobre o grupo ecológico foram denominadas sem classificação (SC).

4.4 Cálculo dos índices de competição

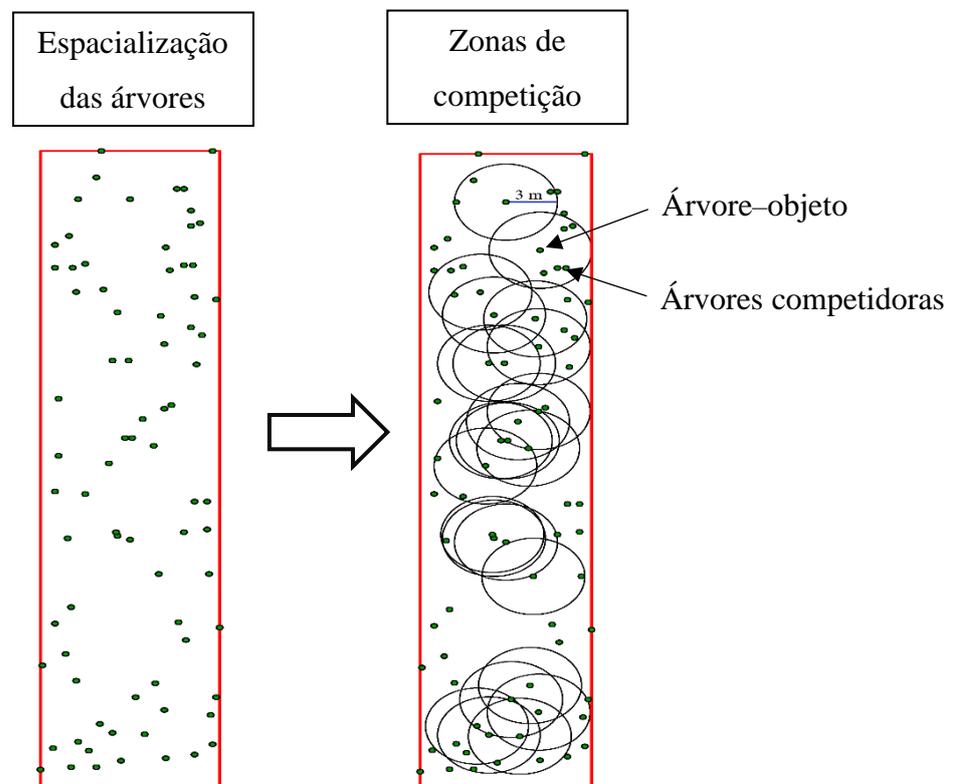
Em cada parcela de cada fragmento, as árvores foram especializadas a partir das coordenadas locais X e Y. A criação das zonas de competição e dos cálculos dos índices de competição foi possível por meio de duas ferramentas implementadas dentro do ambiente de automatização em fluxograma denominado *Model Builder* no programa ArcGIS 10.6 (Figura 9). A primeira ferramenta foi utilizada para delimitar as zonas, e a segunda para o cálculo dos índices dentro das zonas para cada árvore–objeto (Figura 10). Devido a menor largura das parcelas em CP, LP e SJ (10 m), um raio de competição muito grande resultaria na extrapolação das bordas da parcela. Assim, o raio de competição das zonas em todas as parcelas foi de 3 m, diminuindo a extrapolação das parcelas pelas zonas e aumentando o número de árvores–objeto. As árvores que possuíam uma zona cujo o limite não ultrapassava as bordas da parcela foram denominadas árvores–objeto, e as demais de árvores competidoras.

Figura 9 – Ferramentas implementadas no programa ArcGIS: criação das zonas de competição com raio de 3 m (A); cálculo dos índices de competição para as árvores–objeto dentro das zonas (B)



Fonte: O autor (2019).

Figura 10 – Representação das zonas de competição criadas pela ferramenta implementada no ArcGIS



Fonte: O autor (2019).

Os índices de competição calculados em todos os períodos de medição foram os semi-independente da distância, também testados por Castro et al., (2014) (Tabela 2). As correlações entre os índices com o IPA_{dap} e com o dap foram calculadas para avaliar a influência da competição no crescimento das árvores.

Tabela 2 – Índices de competição testados

Nº	Autor	Índice
1	Glover e Hool (1979)	$IC_1 = d_i^2 / \bar{D}_n^2$
2	Stage (1973)	$IC_2 = AS_i^2 / ASq_n^2$
3	Adaptado Glover e Hool (1979)	$IC_3 = d_i^2 Ht_i / \bar{D}_n^2 \bar{Ht}_n$

em que: d_i = diâmetro da i -ésima árvore-objeto, medido a 1,30 m ; \bar{D}_n = média aritmética dos diâmetros das n árvores competidoras na parcela da árvore-objeto; AS_i = área seccional da i -ésima árvore-objeto; ASq_n = área seccional correspondente ao diâmetro médio (q) das n árvores competidoras da árvore-objeto; Ht_i = altura total da i -ésima árvore-objeto; \bar{Ht}_n = média aritmética das alturas totais das n árvores competidoras da árvore-objeto.

As ferramentas implementadas foram eficientes no cálculo dos índices de competição, com o tempo médio de 2 minutos para a determinação das zonas de competição e de 8 minutos para os cálculos dos índices de competição. Essas ferramentas permitem ao manejador florestal uma alternativa na modelagem em nível de árvore individual. Ainda, com o uso das ferramentas é possível obter a garantia de que o cálculo do índice está sendo computado para a árvore-objeto e não para as competidoras. Assim, o viés dessa etapa foi reduzido.

4.5 Variáveis preditoras nos treinamentos das técnicas

As variáveis preditoras contínuas para modelar o incremento em diâmetro das árvores individuais foram dap (cm) e índice de competição (IC), e as categóricas foram grupo de espécies (GE), período de incremento (P) e o fragmento (F). A variável de saída foi o IPA_{dap} . A variável P foi introduzida como variável *proxy* nos modelos, representando as mudanças ambientais ocorridas nos períodos, como precipitação pluviométrica, déficit hídrico, temperatura média, dentre outras. Os períodos de incremento foram os seguintes: 2002–2007, 2007–2012 e 2012–2017 para CP, LP e SJ, e 1994–1998, 1998–2000, 2000–2004, 2004–2008, 2008–2010, 2010–2013 e 2013–2016 para MS.

A modelagem foi realizada por fragmento, e para efeito de comparação, a modelagem com os dados de CP, LP e SJ juntos foi realizada. Os dados da MS não foram unidos com os demais fragmentos por possuir muitos e diferentes períodos de incremento em relação aos demais, o que iria aumentar ainda mais a complexidade dos modelos. Por questão prática, a abordagem com a unificação dos fragmentos CP, LP e SJ será referida pelo termo “todos os fragmentos”, estando implícito que não foi utilizado a MS.

Cinco abordagens foram testadas com diferentes combinações das variáveis preditoras: 1 - com *GE* e *IC*; 2 – com *GE* e sem *IC*; 3 – sem *GE* e com *IC*; 4 – sem *GE* e sem *IC*; 5 – com *F*, *GE* e *IC* (Tabela 3). A última abordagem foi utilizada para os dados de todos os fragmentos.

Tabela 3 – Variáveis preditoras das abordagens testadas

Abordagem	Variáveis preditoras
Com <i>GE</i> e <i>IC</i>	<i>GE</i> , <i>P</i> , <i>dap</i> , <i>IC</i> ₁
	<i>GE</i> , <i>P</i> , <i>dap</i> , <i>IC</i> ₂
	<i>GE</i> , <i>P</i> , <i>dap</i> , <i>IC</i> ₃
Com <i>GE</i> e sem <i>IC</i>	<i>GE</i> , <i>P</i> , <i>dap</i>
Sem <i>GE</i> e com <i>IC</i>	<i>P</i> , <i>dap</i> , <i>IC</i> ₁
	<i>P</i> , <i>dap</i> , <i>IC</i> ₂
	<i>P</i> , <i>dap</i> , <i>IC</i> ₃
Sem <i>GE</i> e <i>IC</i>	<i>P</i> , <i>dap</i>
Com <i>F</i> , <i>GE</i> e <i>IC</i>	<i>F</i> , <i>GE</i> , <i>P</i> , <i>dap</i> , <i>IC</i> ₁
	<i>F</i> , <i>GE</i> , <i>P</i> , <i>dap</i> , <i>IC</i> ₂
	<i>F</i> , <i>GE</i> , <i>P</i> , <i>dap</i> , <i>IC</i> ₃

em que: *GE* = Grupo de espécie; *P* = Período de incremento; *dap* = diâmetro a 1,30 m de altura, em cm; *IC*₁, *IC*₂ e *IC*₃ = índices de competição; e *F* = fragmento.

Para acelerar a taxa de convergência e reduzir o processo de iteração nos treinamentos, as variáveis quantitativas *dap* e índices de competição foram padronizadas: $Z_i = (x_i - \bar{x})/\sigma$; em que: Z_i = valor padronizado da *i*-ésima observação; x_i = valor da *i*-ésima observação; \bar{x} = média dos valores observados; σ = desvio padrão.

4.6 Treinamento das redes neurais artificiais (RNA)

As RNA treinadas foram do tipo *perceptron* de múltiplas camadas, conhecidas também como *multilayer perceptron* (MLP), com uma camada oculta. O intervalo do número de neurônios nessa camada foi definido pelo método de Fletcher-Gloss (SILVA et al., 2010): $2 \times n^{0,5} + n_2 \leq n_1 \leq 2 \times n + 1$; em que n = número de entradas da rede; n_1 = quantidade de neurônios na camada oculta; e n_2 = quantidade de neurônios na camada de saída.

As funções de ativação testadas foram a exponencial, identidade, logística e tangente hiperbólica. Os algoritmos de treinamento utilizados foram o *resilient propagation* (Rprop) e o *scaled conjugate gradient* (SCG). Os pesos iniciais das RNA foram gerados aleatoriamente e o número de iterações máximo foi 100 devido ao erro se tornar constante antes desse número. No total, 3584 RNA foram treinadas, sendo para os fragmentos CP, LP e SJ 672 cada, 480 para todos os fragmentos e 1088 para MS. As RNA foram implementadas com a função *mlp* do pacote “*RSNNS*” no *R* (BERGMEIR; BENITEZ, 2012).

Os dados dos fragmentos foram particionados aleatoriamente de forma balanceada, com 70% das observações de cada espécie em cada período para o treinamento e o restante para validação. Para isso, o nome da espécie e período de incremento foram concatenados nos bancos de dados para codificação e posterior divisão dos conjuntos de dados. Assim, as espécies foram representadas em todos os períodos de incremento no conjunto de dados de treinamento. No banco de dados com todos os fragmentos, o nome do fragmento foi inserido na codificação.

4.7 Treinamento das regressões vetoriais de suporte (SVR)

Nos treinamentos das SVR foram utilizadas quatro configurações, representadas por quatro funções kernel, em que a seguinte função de erro foi otimizada:

$$\text{minimize } \frac{1}{2} \|w\|^2 + \frac{C}{m} \sum_{i=1}^m (\xi_i + \xi_i^*)$$

$$\text{sujeito a } (\langle \Phi(x_i), w \rangle + b) - y_i \leq \epsilon - \xi_i^*$$

$$y_i - (\langle \Phi(x_i), w \rangle + b) \leq \epsilon - \xi_i$$

$$\xi_i \geq 0 \quad (i = 1, \dots, m)$$

em que: w = vetor de coeficientes; C = parâmetro de penalidade do erro; ξ_i, ξ_i^* = variáveis de folga que caracterizam o erro acima e abaixo do ϵ -tubo, respectivamente; i = casos de treinamento; m = número total de casos de treinamento; $\Phi(x_i)$ = kernel utilizado; b = bias; y_i = dados de saída e; ϵ = erro máximo admitido.

As funções kernel avaliadas foram as do tipo: linear, polinomial, base radial e sigmoide (Tabela 4).

Tabela 4 – Funções kernel testadas nos treinamentos das regressões vetoriais de suporte

Tipo de kernel	Função
Linear	$u' \times v$
Polinomial	$(\gamma \times u' \times v + coef0)^d$
Base radial	$e^{(-\gamma \times u-v ^2)}$
Sigmoidal	$\tanh(\gamma \times u' \times v + coef0)$

em que: γ = parâmetro de forma necessário para todos os kernels, exceto linear [padrão: $1/(\text{dimensão de dados})$]; d = grau do polinômio; $coef0$ = parâmetro de penalidade do erro; \tanh = tangente hiperbólica.

No total, 140 SVR foram treinadas, sendo 32 para cada fragmento e 12 para todos os fragmentos. Os conjuntos de dados de treinamento e validação foram os mesmos utilizados para as RNA. A função utilizada para os treinamentos das SVR foi a *svm* do pacote “*e1071*” no *R* (MEYER et al., 2018).

4.8 Treinamento das *random forests* (RF)

A RF para regressão é uma técnica de modelagem em conjunto onde a floresta consiste em um grande número de árvores de regressão. Cada árvore é construída a partir de uma amostra aleatória dos dados de treinamento com substituições (BREIMAN, 2001). Em cada nó nas árvores, um subconjunto aleatório das variáveis preditoras é usado para identificar a divisão mais eficiente. A divisão mais eficiente é definida pela identificação da variável preditora e do ponto de divisão que resulta na maior redução na soma de quadrados residual entre as observações da amostra e a média do nó. Todas as árvores são cultivadas ao máximo, controlado pelo tamanho do nó definido pelo usuário. O resultado é um conjunto (floresta) de baixa polarização e árvores de regressão de alta variância, onde as previsões finais são obtidas pela média das predições das árvores individuais (BREIMAN, 2001).

No treinamento das RF foram configurados três parâmetros importantes: o número de árvores de regressão aleatória (*ntree*), no qual foram testados de 20 a 100 árvores; o número de variáveis de divisão (*mtry*), usado para determinar o número de variáveis disponíveis para dividir em cada nó da árvore, sendo que o número padrão de 1/3 das variáveis independentes foi utilizado; e o tamanho mínimo de nós terminais (*nodesize*), cujo valor foi 5.

No total, 2832 RF foram treinadas, sendo 648 para cada fragmento e 240 para todos os fragmentos. Os conjuntos de dados de treinamento e validação também foram os mesmos das RNA. A função *randomForest* do pacote de mesmo nome no *R* foi utilizada para os treinamentos das RF (LIAW; WIENER, 2002).

4.9 Seleção das melhores configurações

As RNA, SVR e RF treinadas em cada abordagem foram aplicadas nos conjuntos de dados de validação para selecionar a melhor configuração de cada técnica. A seleção foi com base no coeficiente de correlação entre o IPA_{dap} observado e predito – $r_{y\hat{y}}$ (Equação 2); raiz quadrada do erro quadrático médio – $RMSE$ (Equação 3); erro absoluto médio – EAM (Equação 4); valor ponderado (THOMAS et al., 2006) – VP (Equação 5); gráficos de dispersão do IPA_{dap} observado e predito; e gráficos de dispersão dos resíduos padronizados – RP (Equação 6) em função do dap .

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

$$RMSE = \sum_{i=1}^n \sqrt{\frac{(\hat{y}_i - y_i)^2}{n}} \quad (3)$$

$$EAM = \frac{1}{n} \times \sum_{i=1}^n |\hat{y}_i - y_i| \quad (4)$$

$$VP = \sum_{i=1}^n Nr_i \times P_i \quad (5)$$

$$RP = \frac{\hat{y}_i - y_i}{\sqrt{\frac{\sum_{i=1}^n e_i - \bar{e}}{n - 1}}} \quad (6)$$

Em que: s^2 = variância; cov = covariância; $y_i = IPA_{dap}$ observado da i -ésima árvore, em $cm \text{ ano}^{-1}$; e $\hat{y}_i = IPA_{dap}$ predito da i -ésima árvore, em $cm \text{ ano}^{-1}$; Nr_i = número de registros que obtiveram a i -ésima colocação; P_i = peso da i -ésima colocação; e_i = diferença entre o IPA_{dap} observado e predito da i -ésima árvore; e \bar{e} = média da diferença entre o IPA_{dap} observado e predito.

O VP consiste em ordenar as estatísticas de acordo com a sua eficiência, na qual é sugerido atribuir peso 1 para a equação mais eficiente, 2 para a segunda e assim sucessivamente, formando um *ranking*. Após essa classificação individual, é efetuado o somatório da pontuação para cada modelo, sendo que o modelo que recebe a menor soma é o que obteve os melhores resultados estatísticos. Esse método foi aplicado em todos os modelos gerados, resultando em uma classificação geral para cada técnica em cada fragmento. Com essa classificação foram selecionadas as configurações com os menores VP das abordagens descritas na Tabela 3. Ao obter as melhores configurações de cada abordagem, novamente os

VP foram calculados e classificados, para seleção final da melhor configuração para a RNA, SVR e RF em cada fragmento.

4.10 Seleção das variáveis preditoras mais importantes

Os modelos de cada técnica selecionados na etapa anterior foram submetidos a avaliação da importância relativa dos preditores em cada fragmento. Os métodos utilizados para cada técnica foram diferentes, pois a escolha de um método único para todas as técnicas não fornece quais as principais variáveis preditoras para o modelo treinado, e sim, para a configuração. Isso ocorre pois o treinamento da RNA com uma mesma configuração, por exemplo, resulta em diferentes predições devido a inicialização aleatória dos pesos. A SVR foi a exceção, em que ao treinar uma nova SVR com as mesmas configurações para os mesmos dados, o resultado será o mesmo. Dessa forma, a escolha das variáveis preditoras mais importantes para SVR foi através da avaliação do aumento do *RMSE* a partir da permutação de uma variável e manutenção das outras variáveis fixas.

Para a RNA, a importância relativa foi avaliada por meio da aplicação do algoritmo de Garson (GARSON, 1991). A função *garson* do pacote “*NeuralNetTools*” no *R* foi utilizada (BECK, 2018).

A importância relativa dos modelos de RF foi determinada através do quanto o aumento percentual do erro quadrático médio (Aum. no *MSE* – %) foi alterado quando uma variável preditora foi permutada aleatoriamente. A função utilizada nessa etapa foi a *varImp* do pacote “*caret*” no *R*.

4.11 Validação cruzada

A melhor configuração selecionada de cada técnica foi avaliada por meio da validação cruzada *k*-fold. Esta abordagem envolve dividir aleatoriamente as observações no conjunto de dados em *k* partições de tamanho aproximadamente igual. A cada iteração uma partição foi tratada como conjunto de validação e o restante como conjunto de treinamento (*k* menos uma partição). Em seguida, a média de *RMSE* para cada partição foi calculada, em que o modelo com a menor quantidade de erro é selecionado.

Nesta etapa, os dados de cada fragmento foram divididos em 10 partições, sendo o cálculo da média de *RMSE* para as 10 partições repetido 50 vezes. Para maior robustez da avaliação, as observações foram selecionadas aleatoriamente em cada uma das 50 repetições,

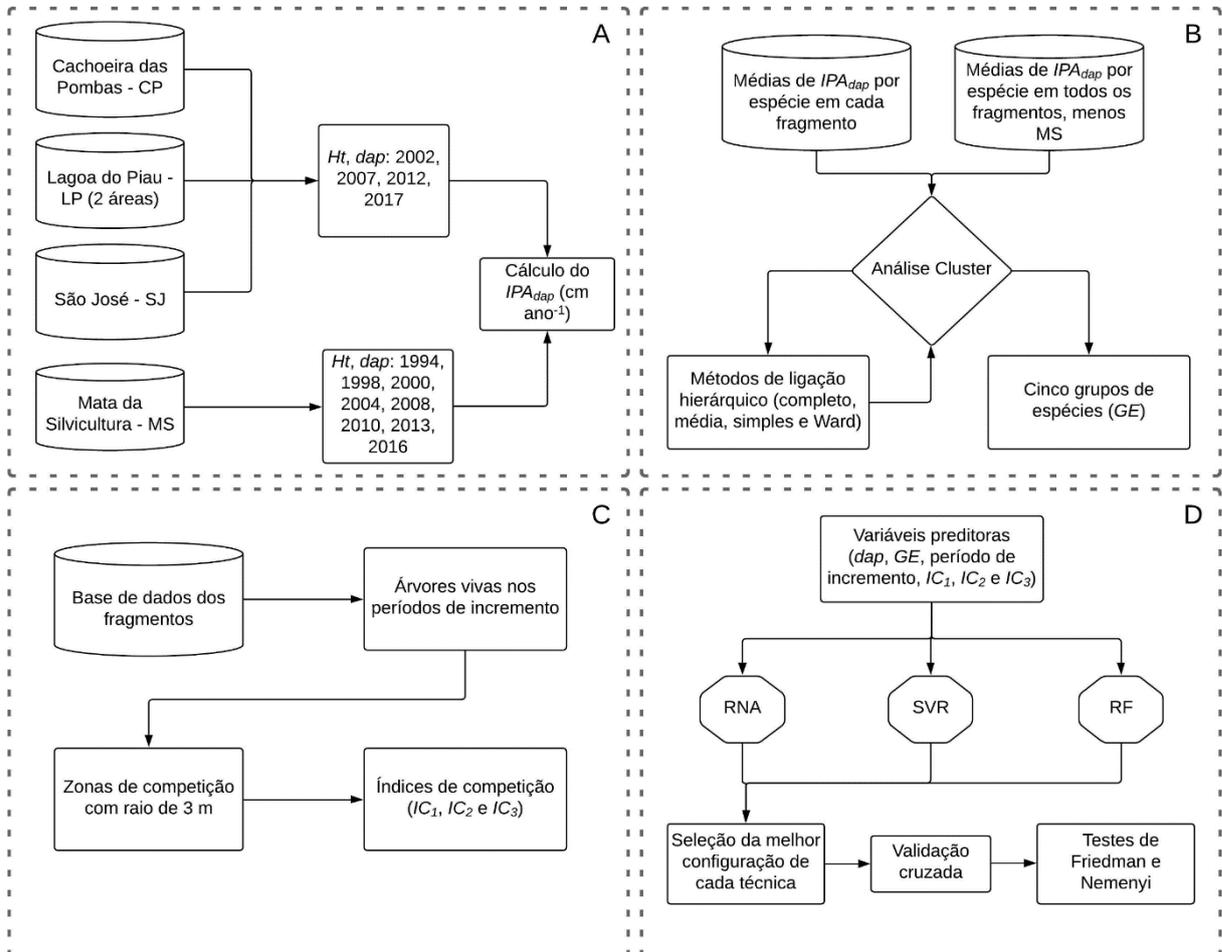
resultando em diferentes conjuntos de dados. A MS e todos os fragmentos juntos não foram inseridos na validação cruzada, devido à grande quantidade de observações. Quanto maior o número de observações, maior a probabilidade da população estar bem representada nos conjuntos de dados, tornando a validação cruzada menos eficiente. Além disso, grandes quantidades de observações tornam o processo de validação cruzada computacionalmente caro, aumentando a complexidade de tempo.

4.11.1 Testes de Friedman e Nemenyi

Os testes não paramétricos de Friedman e Nemenyi foram utilizados para comparação da RNA, SVR e RF em cada fragmento, com base nas médias de *RMSE* da validação cruzada (FRIEDMAN, 1940; NEMENYI, 1963). A hipótese nula do teste de Friedman é que todos os algoritmos são equivalentes. Caso a hipótese nula seja rejeitada, o teste *post hoc* de Nemenyi é aplicado para relatar as diferenças significativas entre as técnicas. O desempenho das técnicas se difere quando o *RMSE* médio em pelo menos um diferença crítica calculada (DC) se difere: $DC = q_{\alpha} \times [k(k+1)/6N]^{0.5}$. Em que: q_{α} = valor crítico baseado na estatística de intervalo de Studentized (HARTER, 1960) dividido por $\sqrt{2}$; k = número de algoritmos sendo comparados; e N = número de conjuntos de dados. Para esta etapa, a função *nemenyi* do pacote “*TStools*” no *R* foi utilizada.

Um resumo dos métodos aplicados no estudo pode ser visualizado na Figura 11.

Figura 11 – Resumo da metodologia aplicada no estudo: cálculo do incremento periódico anual em diâmetro (IPA_{dap} ; cm ano^{-1}) nos períodos de incremento em cada fragmento (A); teste dos métodos de ligação hierárquicos e formação dos grupos de espécie para cada fragmento e em todos os fragmentos, menos Mata da Silvicultura (B); criação das zonas de competição dentro das parcelas dos fragmentos e cálculo dos índices de competição para as árvores–objeto dentro das zonas (C); treinamento das RNA, SVR e RF com as variáveis predictoras em diferentes abordagens e avaliação das melhores configurações selecionadas de cada técnica (D)



Fonte: O autor (2019).

5 RESULTADOS

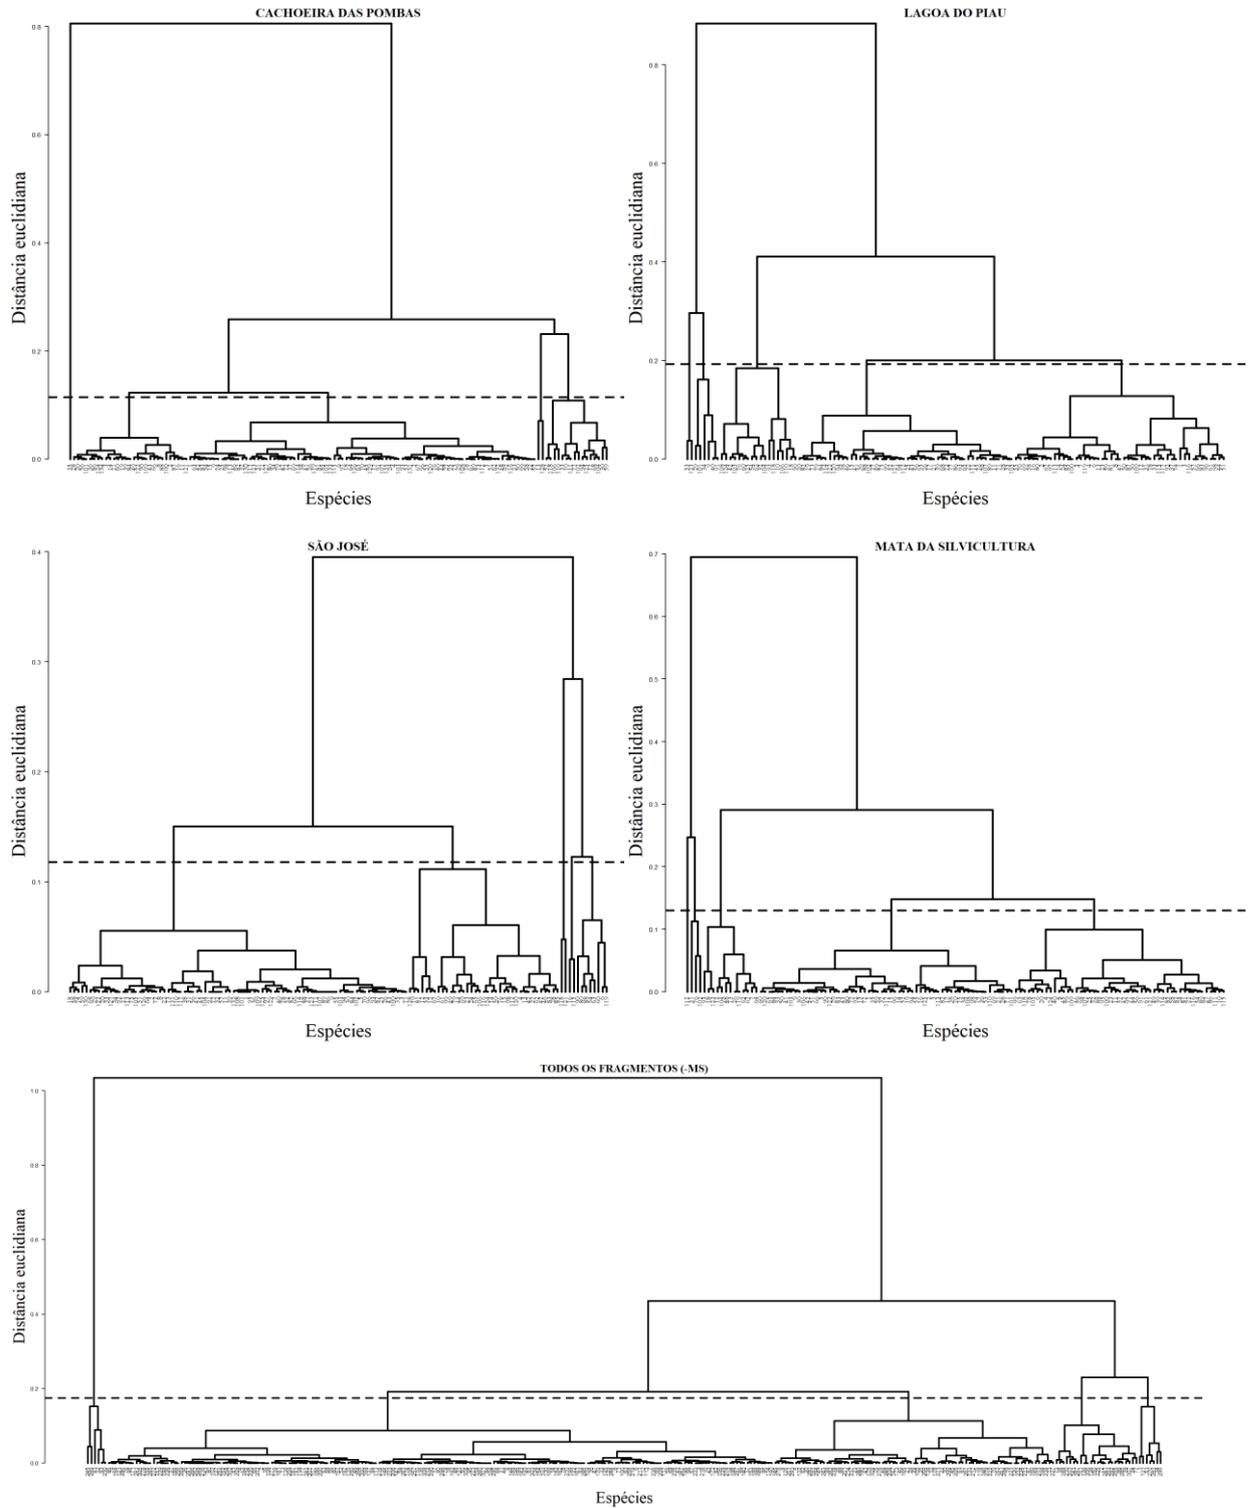
5.1 Grupos de espécies

Os valores de coeficiente de correlação cofenética (r_{cof}) no teste dos métodos de ligação da análise de cluster das espécies foram maiores para o método de ligação média, variando de 0,8731 a 0,9203 (Tabela 5). Assim, esse método foi selecionado para formar os grupos de espécies. A linha tracejada interceptou os ramos dos dendrogramas resultantes na distância euclidiana que configurasse a formação de cinco grupos de espécies (Figura 12).

Tabela 5 – Coeficiente de correlação cofenético (r_{cof}) dos métodos de ligação hierárquicos testados para formação dos grupos de espécies nos fragmentos: CP = Cachoeira das Pombas; LP = Lagoa do Piau; SJ = São José; MS = Mata da Silvicultura

Fragmento	Completo	Média	Simples	Ward
CP	0,8315	0,8873	0,7892	0,5459
LP	0,8831	0,9001	0,8946	0,7186
SJ	0,8688	0,8731	0,8571	0,6009
MS	0,8195	0,9088	0,8387	0,6638
Todos (-MS)	0,7593	0,9203	0,8546	0,5258

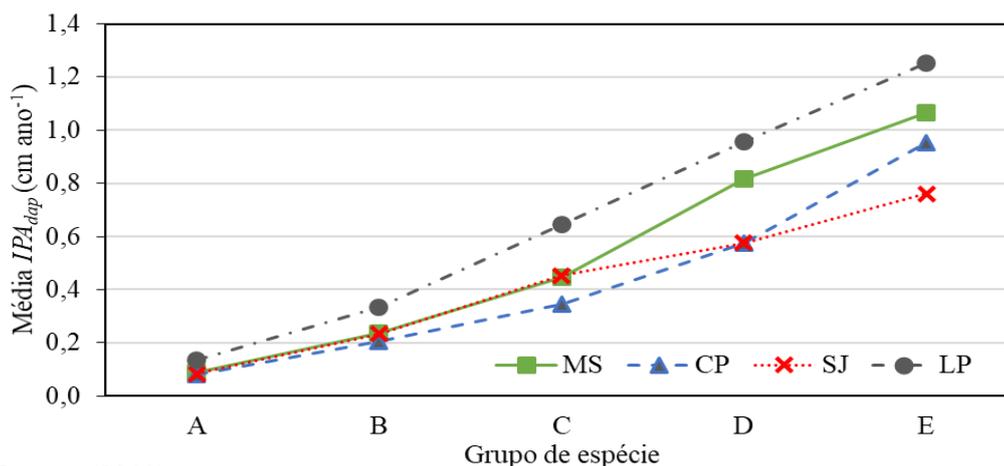
Figura 12 – Dendrogramas da análise de cluster pelo método da ligação média com as distâncias euclidianas no eixo das ordenadas. A linha tracejada horizontal representa a interceptação dos ramos para a formação de grupos com as espécies dos fragmentos Cachoeira das Pombas, Lagoa do Piauí, São José, Mata da Silvicultura e todos os fragmentos juntos



Fonte: O autor (2019).

Os grupos de espécies formados foram denominados como “A”, “B”, “C”, “D” e “E”, de acordo com as médias crescentes de IPA_{dap} (APÊNDICE A). Assim, as menores médias de IPA_{dap} foram no grupo “A”, e as maiores no grupo “E” (Figura 13).

Figura 13 – Médias de incremento periódico anual em diâmetro (IPA_{dap}) por grupo de espécie em cada fragmento: MS = Mata da Silvicultura; CP = Cachoeira das Pombas; SJ = São José; LP = Lagoa do Piau



Fonte: O autor (2019).

As médias de IPA_{dap} por grupo de espécie com todas as observações apresentaram a mesma tendência de crescimento do incremento do grupo “A” para o “E” (Tabela 6). A exceção foi o grupo “D” no fragmento LP, em que a média de IPA_{dap} foi maior que o grupo E. As médias de dap e Ht variaram ao longo dos grupos, mas no geral as dimensões continuaram crescentes do grupo “A” ao “E”.

Tabela 6 – Média (e desvio padrão) do diâmetro a 1,30 m de altura (dap), altura total (Ht) e incremento periódico anual em diâmetro (IPA_{dap}) por grupo de espécie em fragmentos de Mata Atlântica: Cachoeira das Pombas (CP); Lagoa do Piau (LP); São José (SJ); e Mata da Silvicultura (MS)

Fragmento	Grupo de espécie	dap (cm)	Ht (m)	IPA_{dap} (cm ano ⁻¹)	n
CP	A	8,26 (±5,59)	7,53 (±2,67)	0,1195 (±0,1083)	1237
	B	9,35 (±4,17)	8,00 (±2,79)	0,2204 (±0,1703)	336
	C	15,10 (±9,57)	10,84 (±4,77)	0,3385 (±0,2554)	121
	D	12,28 (±3,92)	8,80 (±0,92)	0,6048 (±0,2592)	10
	E	19,92 (±7,17)	14,00 (±4,1)	0,9528 (±0,2401)	6
LP	A	9,24 (±4,29)	8,96 (±2,84)	0,2053 (±0,3137)	517
	B	9,77 (±4,98)	9,16 (±3,07)	0,3916 (±0,5026)	855
	C	11,07 (±5,67)	9,14 (±2,81)	0,6234 (±0,6564)	283
	D	7,54 (±2,71)	8,10 (±2,41)	1,3369 (±0,8562)	5
	E	10,60 (±4,97)	9,38 (±3,07)	1,2603 (±1,2687)	29
SJ	A	9,94 (±5,97)	9,46 (±3,69)	0,1001 (±0,0723)	444
	B	12,23 (±6,35)	10,00 (±3,44)	0,2266 (±0,1612)	361
	C	14,77 (±7,19)	11,61 (±2,68)	0,4689 (±0,3277)	44
	D	12,62 (±6,14)	9,43 (±3,75)	0,5751 (±0,1423)	6
	E	30,92 (±18,68)	17,00 (±3,7)	0,8475 (±0,9119)	8
MS	A	9,66 (±5,38)	10,16 (±4,25)	0,1753 (±0,2899)	1781
	B	16,77 (±12,46)	15,11 (±6,36)	0,3157 (±0,4673)	1743
	C	16,39 (±10,14)	15,09 (±6,47)	0,5981 (±1,2523)	149
	D	24,87 (±12,86)	16,88 (±5,77)	0,7840 (±0,7729)	38
	E	17,17 (±3,85)	14,45 (±0,52)	1,8641 (±3,4262)	4

em que: n = número de observações.

A classificação em grupos ecológicos apontou que as espécies climáticas se concentraram nos grupos “A”, “B” e “C”, enquanto que as pioneiras e secundárias iniciais foram encontradas em quase todos os grupos de espécies (Tabela 7). As espécies climáticas não foram observadas no fragmento MS.

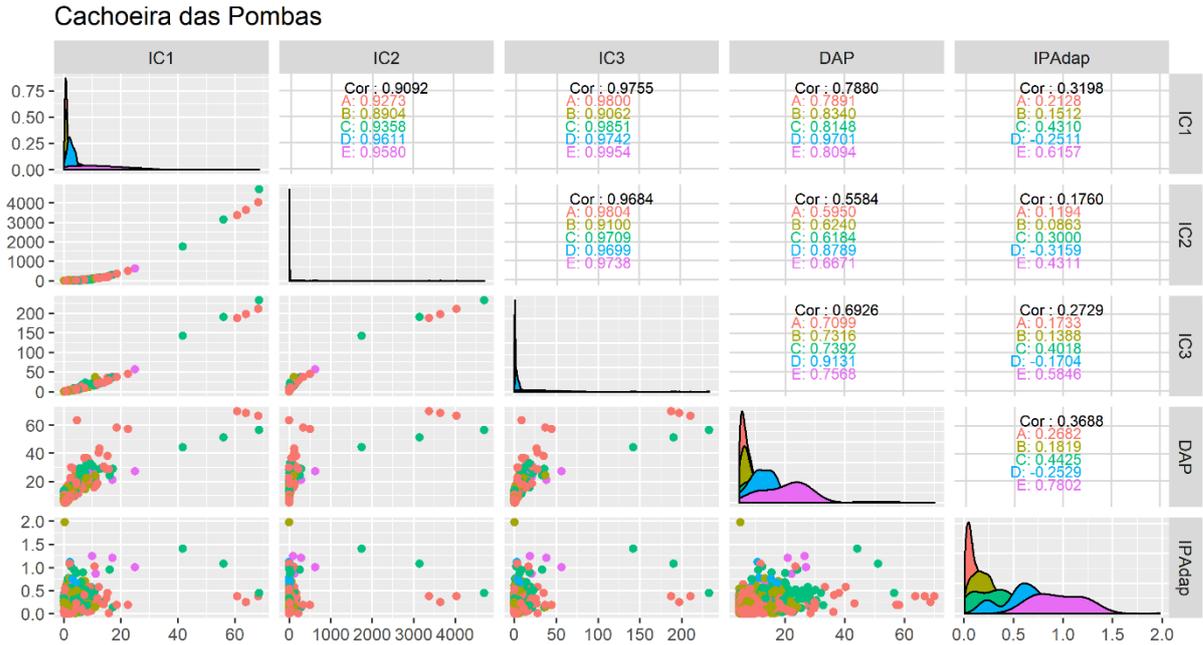
Tabela 7 – Número de espécies por grupo de espécie e grupo ecológico: Pioneira (PI); Secundária inicial (SI); Secundária tardia (ST); Climática (C); e Sem classificação (SC), em fragmentos de Mata Atlântica: Cachoeira das Pombas (CP); Lagoa do Piau (LP); São José (SJ); e Mata da Silvicultura (MS)

Fragmento	Grupo de espécie	Grupo ecológico				
		P	SI	ST	CL	SC
CP	A	13	34	17	5	18
	B	1	9	5	1	13
	C	6	3	1	1	5
	D		1			1
	E	1				
LP	A	5	15	9	2	19
	B	5	22	10	1	11
	C	4	4	4	3	3
	D		1			1
	E	1	1		2	2
SJ	A	11	30	10	11	21
	B	3	14	9	2	10
	C	1	2	2	1	1
	D	1		1		
	E		1			1
MS	A	6	32	18		2
	B	4	27	14		4
	C	2	4	4		3
	D	1	1	1		
	E	1				

5.2 Correlações dos índices de competição

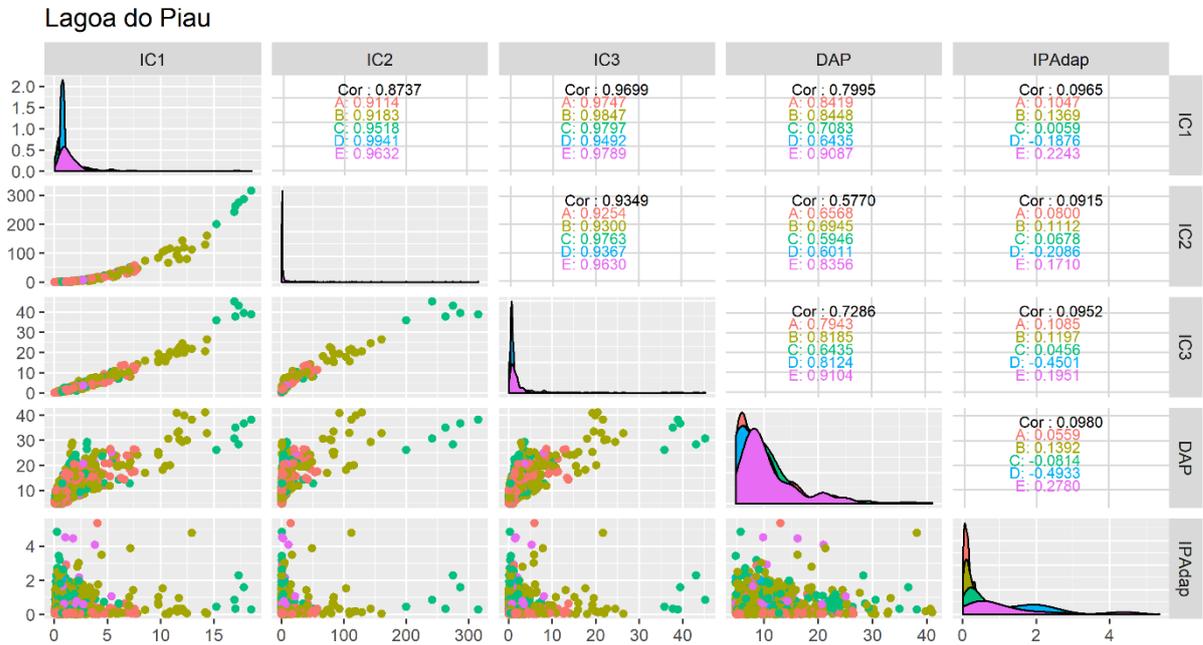
As correlações entre os índices de competição e *dap* com o IPA_{dap} , embora relativamente baixas em todos os fragmentos, foram significativas ($p < 0,05$) (Figura 14, 15, 16, 17 e 18). Na maioria dos fragmentos, as correlações dos índices de competição com IPA_{dap} foram negativas principalmente nos grupos de espécies com maior crescimento, como o grupo “D”. A exceção foi o fragmento SJ, em que a correlação do IC_2 com IPA_{dap} foi negativa apenas para o grupo “A”. As correlações dos índices de competição com o *dap* foram maiores que 0,40. Isso foi devido ao *dap* estar presente nas funções dos índices, direta ou indiretamente, aumentando o grau de relação entre essas variáveis.

Figura 14 – Correlação entre os índices de competição (IC_1 , IC_2 e IC_3), diâmetro a 1,30 m de altura (dap) e incremento periódico anual em diâmetro (IPA_{dap}) no fragmento Cachoeira das Pombas



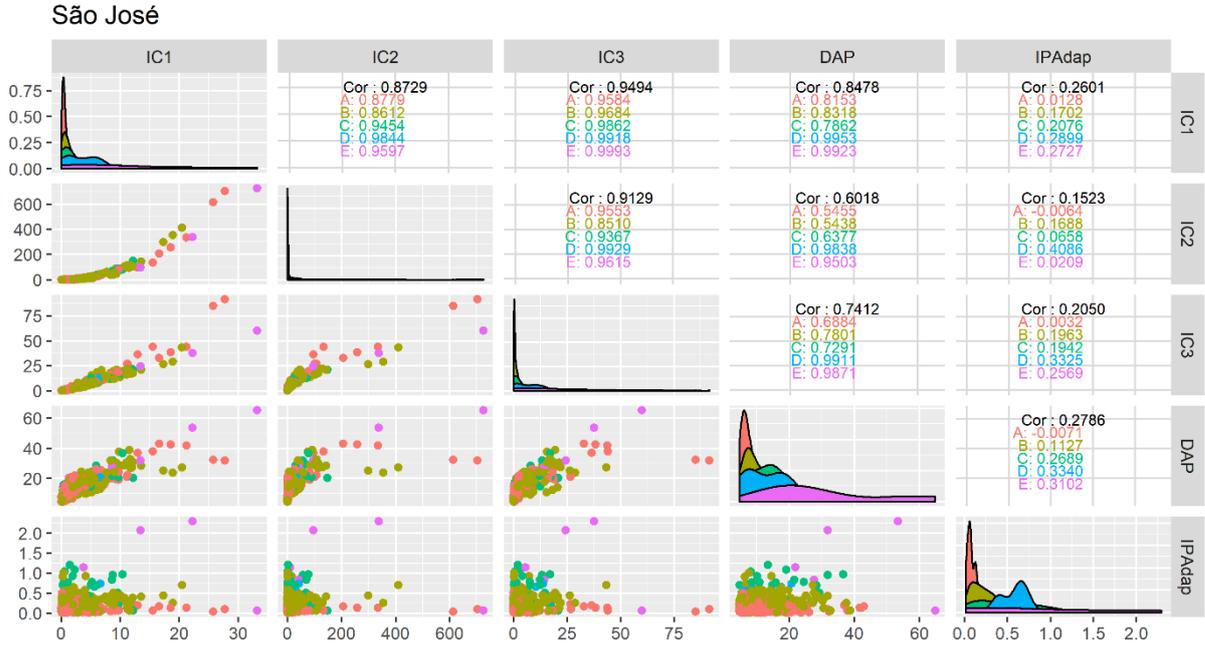
Fonte: O autor (2019).

Figura 15 – Correlação entre os índices de competição (IC_1 , IC_2 e IC_3), diâmetro a 1,30 m de altura (dap) e incremento periódico anual em diâmetro (IPA_{dap}) no fragmento Lagoa do Piauí



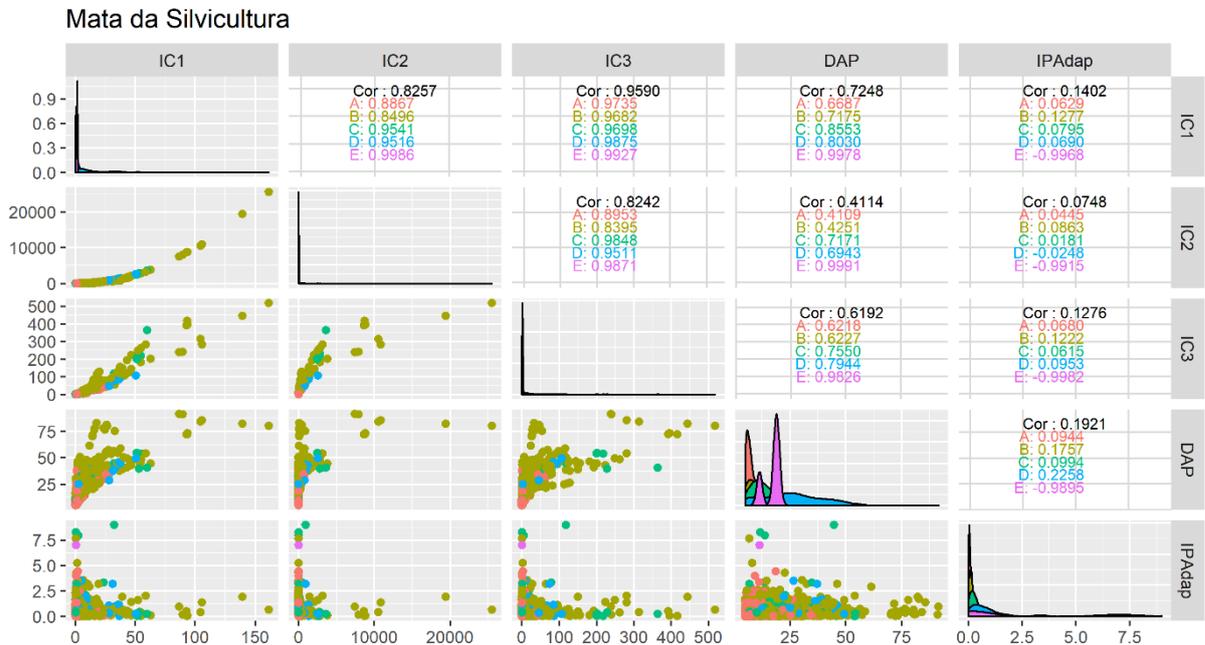
Fonte: O autor (2019).

Figura 16 – Correlação entre os índices de competição (IC_1 , IC_2 e IC_3), diâmetro a 1,30 m de altura (dap) e incremento periódico anual em diâmetro (IPA_{dap}) no fragmento São José



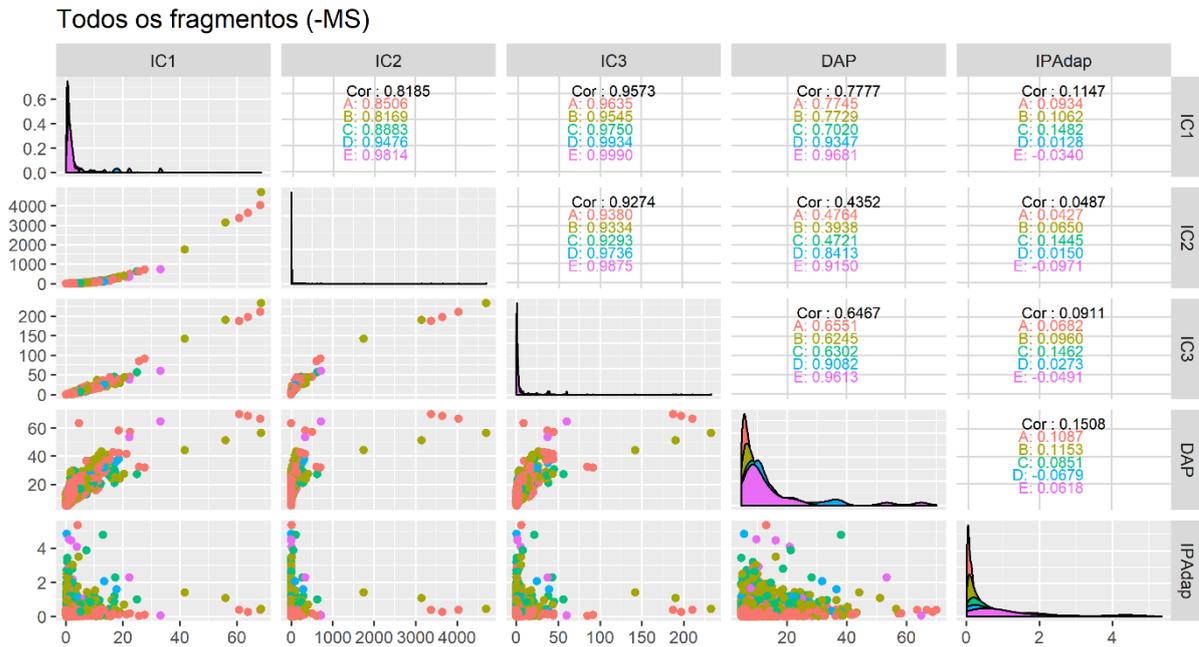
Fonte: O autor (2019).

Figura 17 – Correlação entre os índices de competição (IC_1 , IC_2 e IC_3), diâmetro a 1,30 m de altura (dap) e incremento periódico anual em diâmetro (IPA_{dap}) no fragmento Mata da Silvicultura



Fonte: O autor (2019).

Figura 18 – Correlação entre os índices de competição (IC_1 , IC_2 e IC_3), diâmetro a 1,30 m de altura (dap) e incremento periódico anual em diâmetro (IPA_{dap}) em todos os fragmentos, menos Mata da Silvicultura (-MS)



Fonte: O autor (2019).

5.3 Melhor configuração de cada técnica

Na seleção das melhores configurações por abordagem de cada técnica, o número de neurônios na camada oculta das RNA variou de 5–15 no fragmento CP, 6–20 em LP, 5–20 em SJ, 8–28 na MS e de 9–22 para todos os fragmentos (APÊNDICE B). O algoritmo mais frequente foi o *resilient propagation* (Rprop), com exceção da MS que foi o *scaled conjugate gradient* (SCG). A função de ativação mais frequente foi a logística, com exceção de LP que foi a tangente hiperbólica. O número de árvores da RF variou de 24–84 em CP, 22–81 em LP, 24–94 em SJ, 28–100 na MS e de 28–70 para todos os fragmentos. A função kernel mais frequente da SVR foi a polinomial em CP, linear em SJ e base radial em LP, MS e todos os fragmentos.

Após o conhecimento das melhores configurações por abordagem de cada técnica, os menores valores ponderados (VP) apontaram para as melhores configurações entre todas as abordagens para cada técnica (Tabela 8). O valor da correlação entre o IPA_{dap} observado e predito ($r_{\hat{y}y}$) e da raiz quadrada do erro quadrático médio ($RMSE$) da SVR em relação a RNA e RF foi maior e menor, respectivamente, no fragmento CP. Nos demais fragmentos a $r_{\hat{y}y}$ foi maior e a $RMSE$ menor para RNA. O erro absoluto médio (EAM) da SVR foi menor em todos os fragmentos em relação às outras técnicas, com exceção de SJ.

As variáveis preditoras das técnicas da abordagem com grupos de espécie e índices de competição foram as que obtiveram os melhores desempenhos estatísticos em CP, LP e SJ. A exceção foi a MS, em que a abordagem sem os grupos de espécies foi melhor.

Na análise da significância da correlação das melhores configurações de cada técnica em cada fragmento, o valor de t calculado foi maior que o tabelado para todas as técnicas em todos os fragmentos. Assim, a hipótese de que a correlação entre os valores observados e preditos de IPA_{dap} é diferente de zero foi aceita (Tabela 9).

Tabela 8 – Estatísticas de correlação entre o incremento periódico anual em diâmetro observado e predito (r_{yy}), raiz quadrada do erro quadrático médio ($RMSE$) e erro absoluto médio (EAM) das configurações selecionadas de cada técnica em cada fragmento

Fragmento	Técnica	Entrada	Neur./Árv. ¹	Função ²	Algoritmo	r_{yy}	$RMSE$	EAM
CP	RNA	GE, P, dap, IC_2	9	Tangente Hiperbólica	Rprop	0,6320	0,1146	0,0866
	SVR	GE, P, dap, IC_3		Polinomial		0,6467	0,1144	0,0846
	RF	GE, P, dap, IC_1	43			0,5685	0,1241	0,0896
LP	RNA	GE, P, dap, IC_2	12	Tangente Hiperbólica	Rprop	0,6088	0,4024	0,2451
	SVR	GE, P, dap, IC_3		Base Radial		0,5660	0,4286	0,2317
	RF	GE, P, dap, IC_2	58			0,5706	0,4174	0,2568
SJ	RNA	GE, P, dap, IC_3	20	Logística	SCG	0,6322	0,1411	0,1058
	SVR	GE, P, dap, IC_1		Linear		0,5712	0,1544	0,1069
	RF	GE, P, dap, IC_1	25			0,5413	0,1539	0,1108
MS	RNA	P, dap, IC_3	8	Exponencial	SCG	0,5003	0,3591	0,1743
	SVR	P, dap, IC_1		Base Radial		0,4916	0,3789	0,1649
	RF	P, dap	28			0,4779	0,3642	0,1907
Todos (-MS)	RNA	F, GE, P, dap, IC_2	9	Tangente Hiperbólica	Rprop	0,6036	0,3036	0,1718
	SVR	F, GE, P, dap, IC_1		Base Radial		0,5481	0,3250	0,1650
	RF	F, GE, P, dap, IC_1	42			0,5946	0,3111	0,1764

em que: CP = Cachoeira das Pombas; LP = Lagoa do Piauí; SJ = São José; MS = Mata da Silvicultura; -MS = menos Mata da Silvicultura; GE = Grupo de espécie; P = Período de incremento; dap = diâmetro a 1,30 m de altura, em cm; IC_1 , IC_2 e IC_3 = índices de competição; Rprop = *resilient propagation*; SCG = *scaled conjugate gradient*; RNA = rede neural artificial; SVR = regressão vetorial de suporte; RF = *random forest*. ¹Número de neurônios na camada oculta da RNA ou de árvores da RF. ²Função de ativação da camada oculta da RNA ou função kernel da SVR.

Tabela 9 – Significância da correlação entre os valores observados e preditos (r_{yy}) por técnica em cada fragmento pelo teste t ($\alpha = 5\%$)

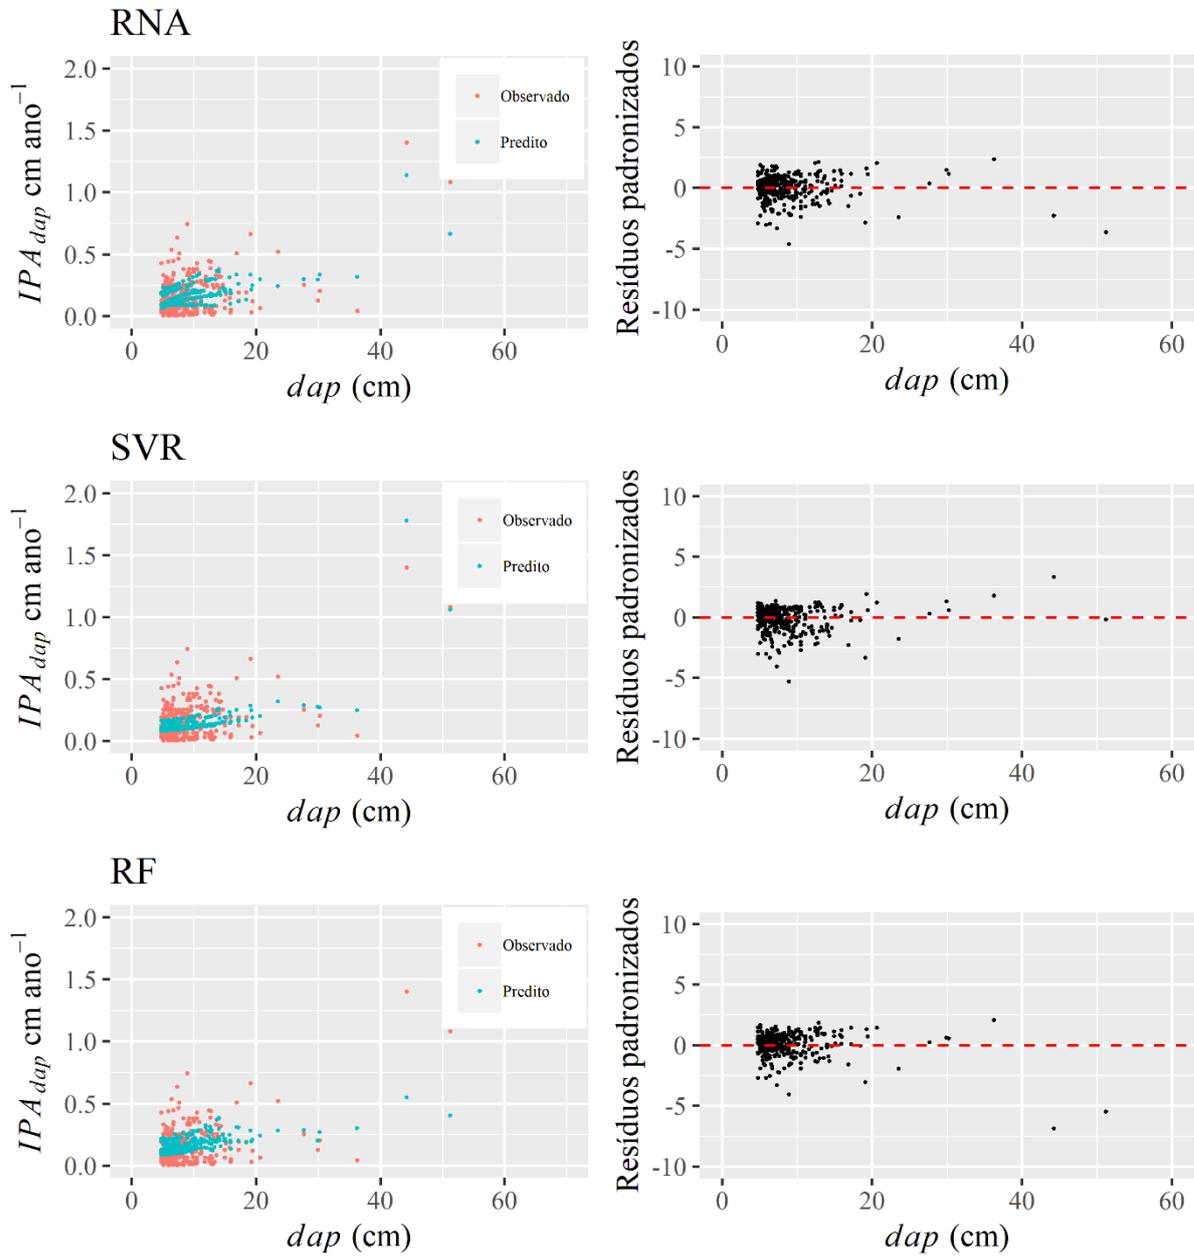
Fragmento	t_{tab}	gl	RNA		SVR		RF	
			r_{yy}	t_{cal}	r_{yy}	t_{cal}	r_{yy}	t_{cal}
CP	1,97	360	0,6320*	15,48	0,6467*	16,09	0,5685*	13,11
LP	1,97	355	0,6088*	14,46	0,5660*	12,94	0,5706*	13,09
SJ	1,99	90	0,6322*	7,74	0,5712*	6,60	0,5413*	6,11
MS	1,96	796	0,5003*	16,30	0,4916*	15,93	0,4779*	15,35
Todos (-MS)	1,96	809	0,6036*	21,54	0,5481*	18,64	0,5946*	21,03

em que: CP = Cachoeira das Pombas; LP = Lagoa do Piau; SJ = São José; MS = Mata da Silvicultura; -MS = menos Mata da Silvicultura; t_{tab} = valor de t tabelado ($\alpha = 5\%$); t_{cal} = valor de t calculado; gl = grau de liberdade; RNA = rede neural artificial; SVR = regressão vetorial de suporte; RF = *random forest*. * $p < 0,05$.

A variação nos valores observados de IPA_{dap} foi maior nos menores valores de dap e menor nos maiores valores, em todos os fragmentos (Figuras 19, 20, 21, 22 e 23). Os valores preditos de IPA_{dap} seguiram a mesma tendência, com maior variação nos menores valores de dap . Os resíduos padronizados se concentraram em torno da reta média ao longo da dispersão e a variação também foi maior nos menores valores de dap em todos os fragmentos, com presença de alguns outliers na dispersão.

Figura 19 – Dispersão do incremento periódico anual em diâmetro (IPA_{dap}) observado e predito, e dos resíduos padronizados em função do diâmetro a 1,30 m de altura (dap) no fragmento Cachoeira das Pombas

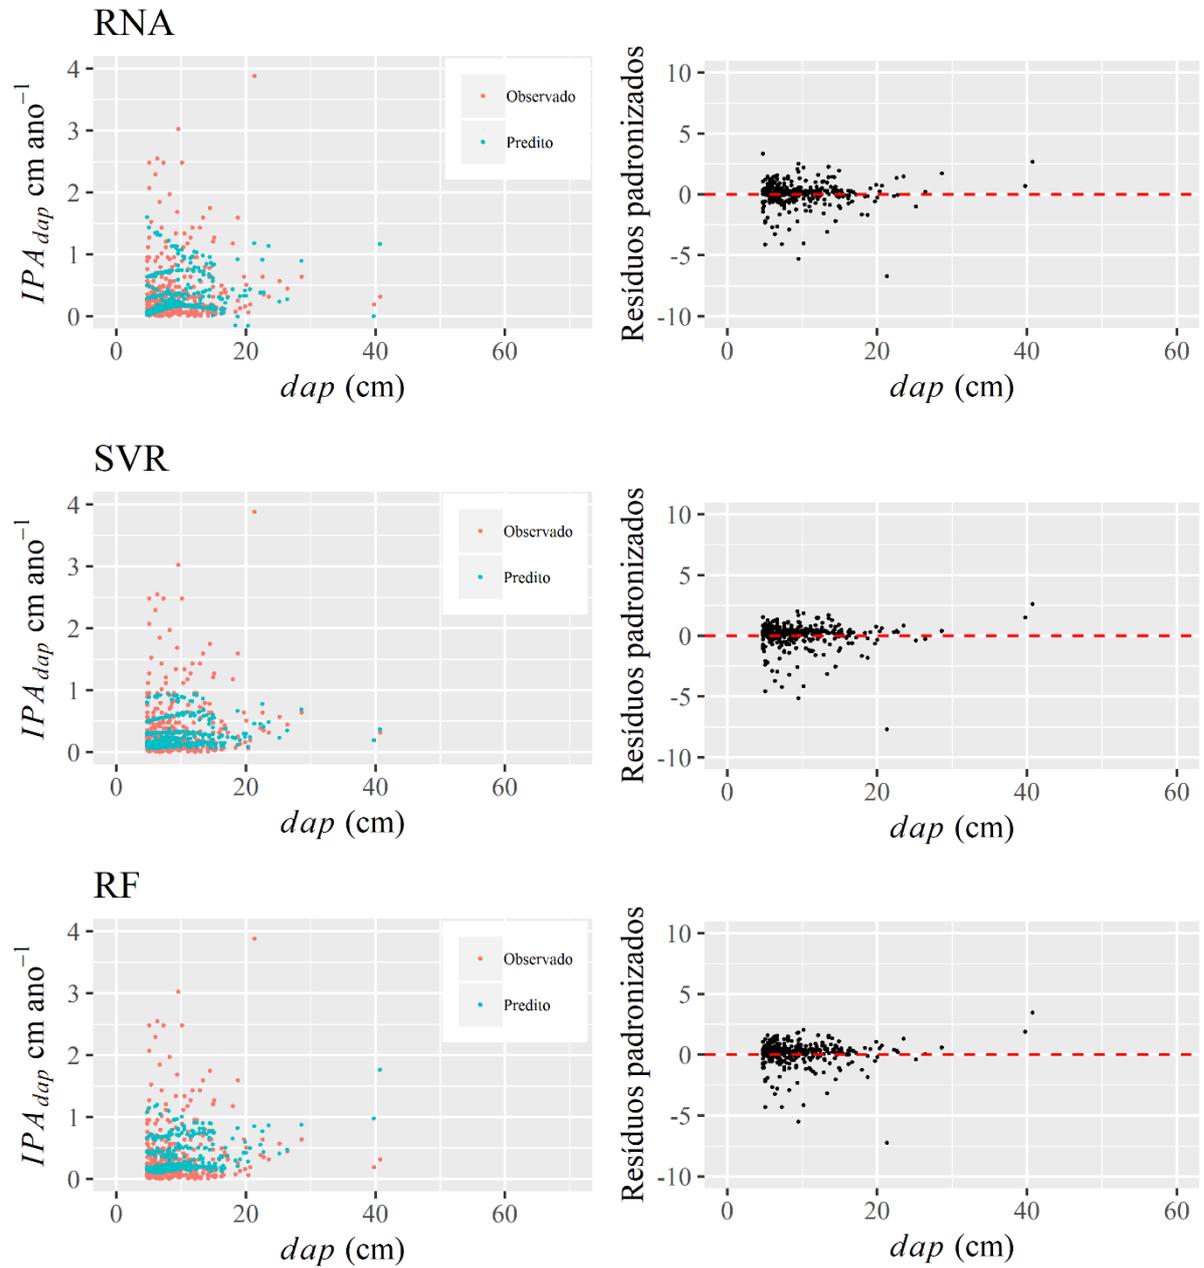
Cachoeira das Pombas



Fonte: O autor (2019).

Figura 20 – Dispersão do incremento periódico anual em diâmetro (IPA_{dap}) observado e predito, e dos resíduos padronizados em função do diâmetro a 1,30 m de altura (dap) no fragmento Lagoa do Piau

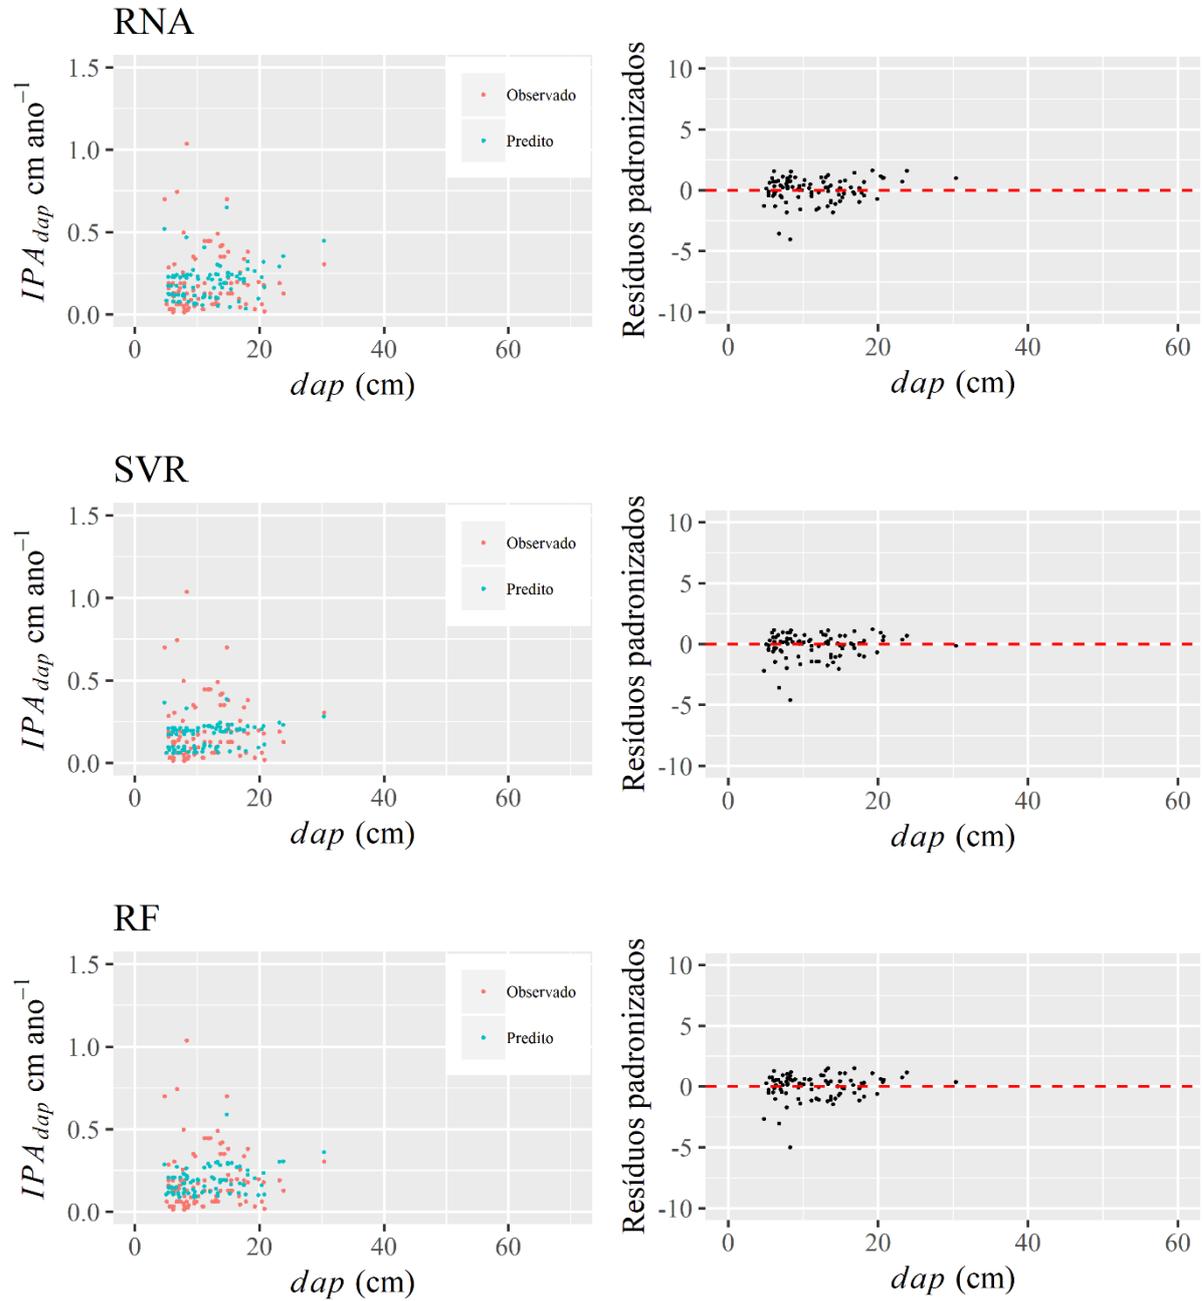
Lagoa do Piau



Fonte: O autor (2019).

Figura 21 – Dispersão do incremento periódico anual em diâmetro (IPA_{dap}) observado e predito, e dos resíduos padronizados em função do diâmetro a 1,30 m de altura (dap) no fragmento São José

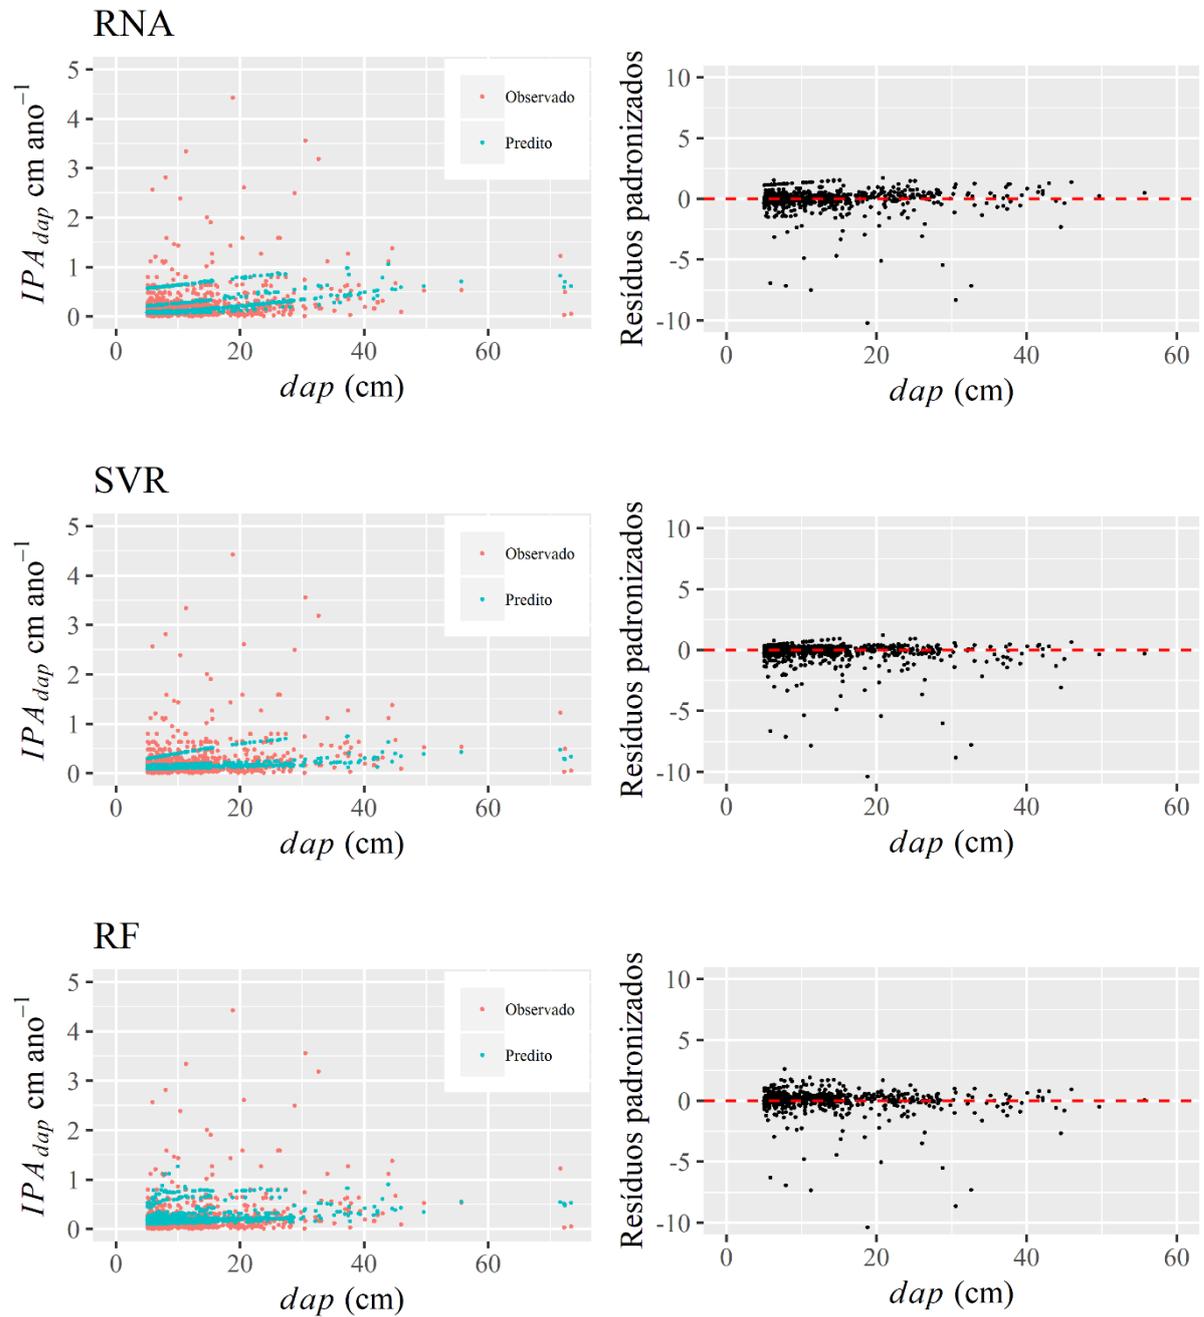
São José



Fonte: O autor (2019).

Figura 22 – Dispersão do incremento periódico anual em diâmetro (IPA_{dap}) observado e predito, e dos resíduos padronizados em função do diâmetro a 1,30 m de altura (dap) no fragmento Mata da Silvicultura

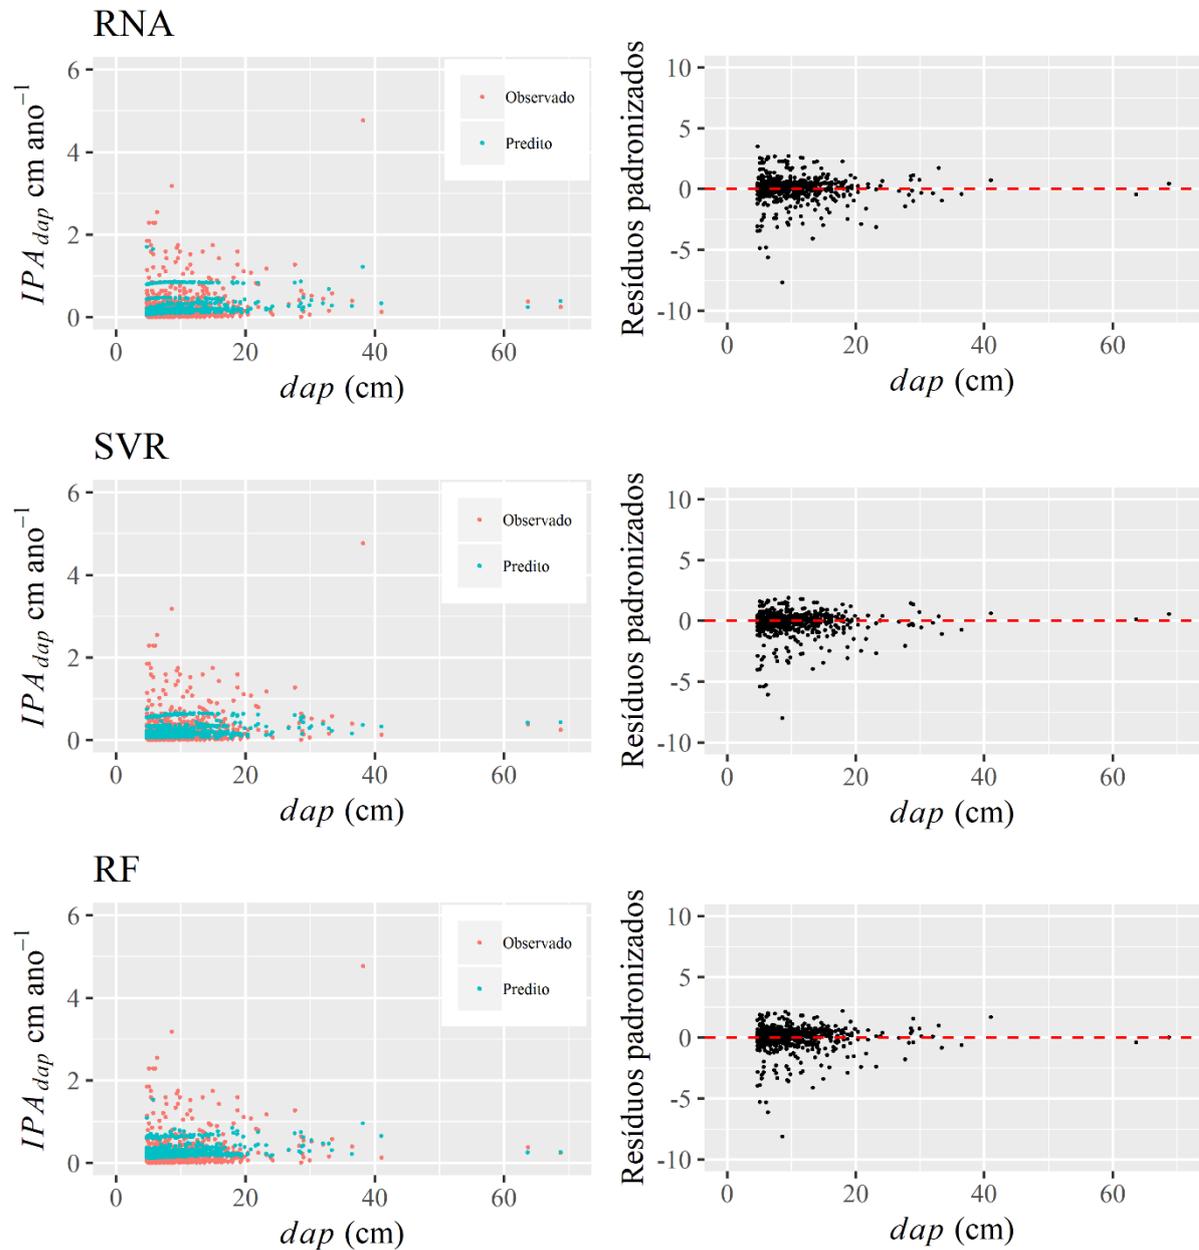
Mata da Silvicultura



Fonte: O autor (2019).

Figura 23 – Dispersão do incremento periódico anual em diâmetro (IPA_{dap}) observado e predito, e dos resíduos padronizados em função do diâmetro a 1,30 m de altura (dap) em todos os fragmentos, menos Mata da Silvicultura

Todos os fragmentos (-MS)

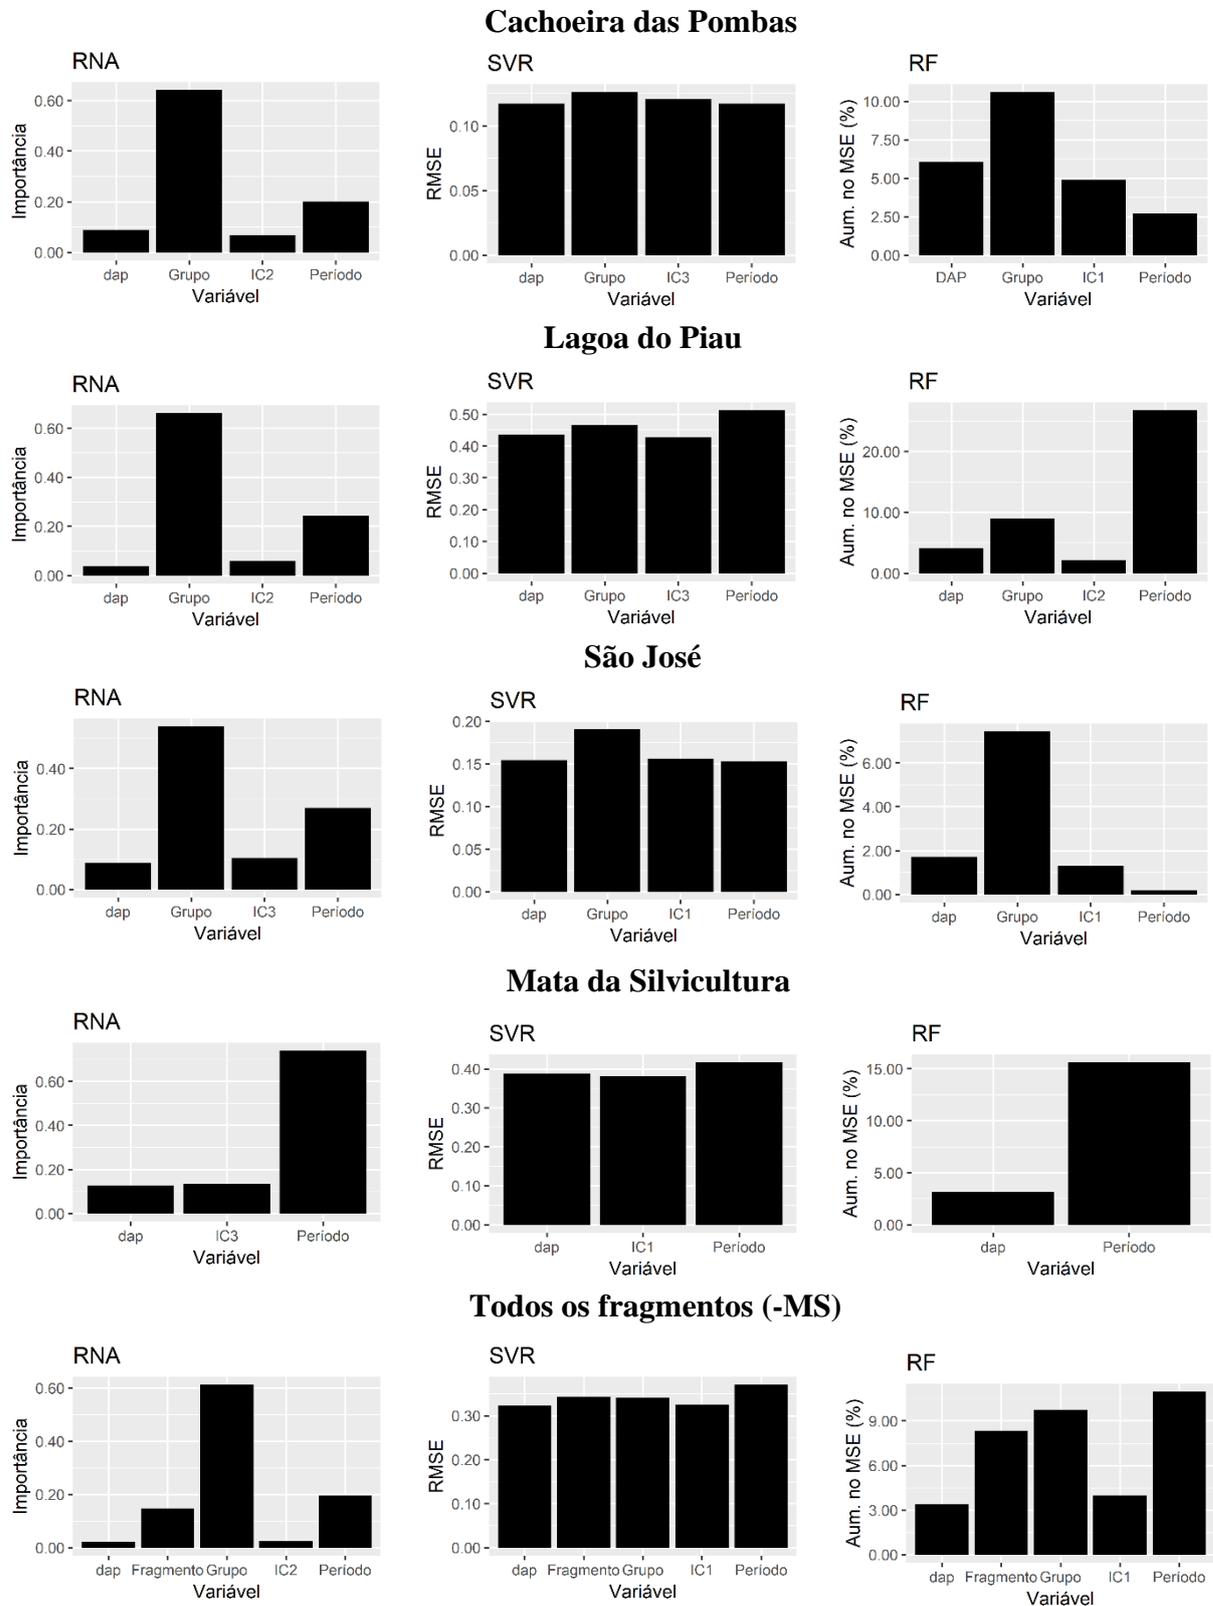


Fonte: O autor (2019).

5.4 Importância relativa das variáveis preditoras

Na avaliação da importância relativa das variáveis preditoras dentro das melhores configurações em cada fragmento, o grupo de espécie foi a que obteve a maior importância para a RNA, SVR e RF no fragmento CP (Figura 24). Em LP, a variável mais importante para a SVR e RF foi o período de incremento, enquanto que para RNA foi o grupo de espécie. Em SJ, novamente a variável mais importante para todas as técnicas foi o grupo de espécie. Na MS a variável mais importante para todas as técnicas, diferentemente dos outros fragmentos, foi o período de incremento. Para todos os fragmentos (CP, LP e SJ) a variável mais importante para a SVR e RF foi o período de incremento, e para a RNA o grupo de espécie.

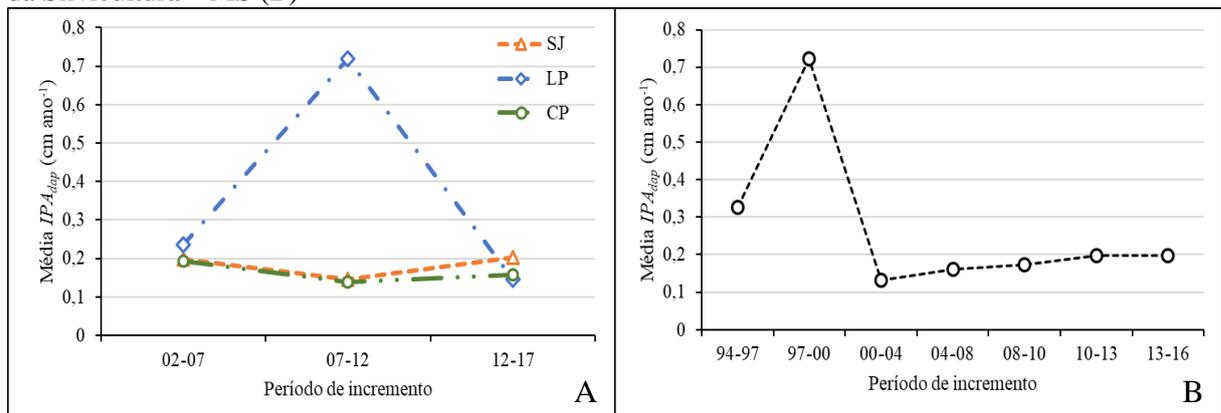
Figura 24 – Importância relativa das variáveis predictoras das melhores configurações selecionadas por técnica em cada fragmento. Rede neural artificial – RNA; regressão vetorial de suporte – SVR; raiz quadrada do erro quadrático médio (*RMSE*); e *random forest* – RF: aumento no *MSE*, em porcentagem



Fonte: O autor (2019).

Com base nos resultados da importância relativa das variáveis predictoras, a média do IPA_{dap} por período de incremento foi verificada (Figura 25). As médias de IPA_{dap} dos fragmentos CP e SJ diminuíram no período 2007–2012. O oposto aconteceu em LP, em que a média aumentou nesse mesmo período. Na MS, a média de IPA_{dap} aumentou no período 1997–2000 e diminuiu no período seguinte.

Figura 25 – Média do incremento periódico anual em diâmetro (IPA_{dap}) por período de incremento: fragmentos Cachoeira das Pombas – CP, Lagoa do Piauí – LP e São José – SJ (A); e fragmento Mata da Silvicultura – MS (B)

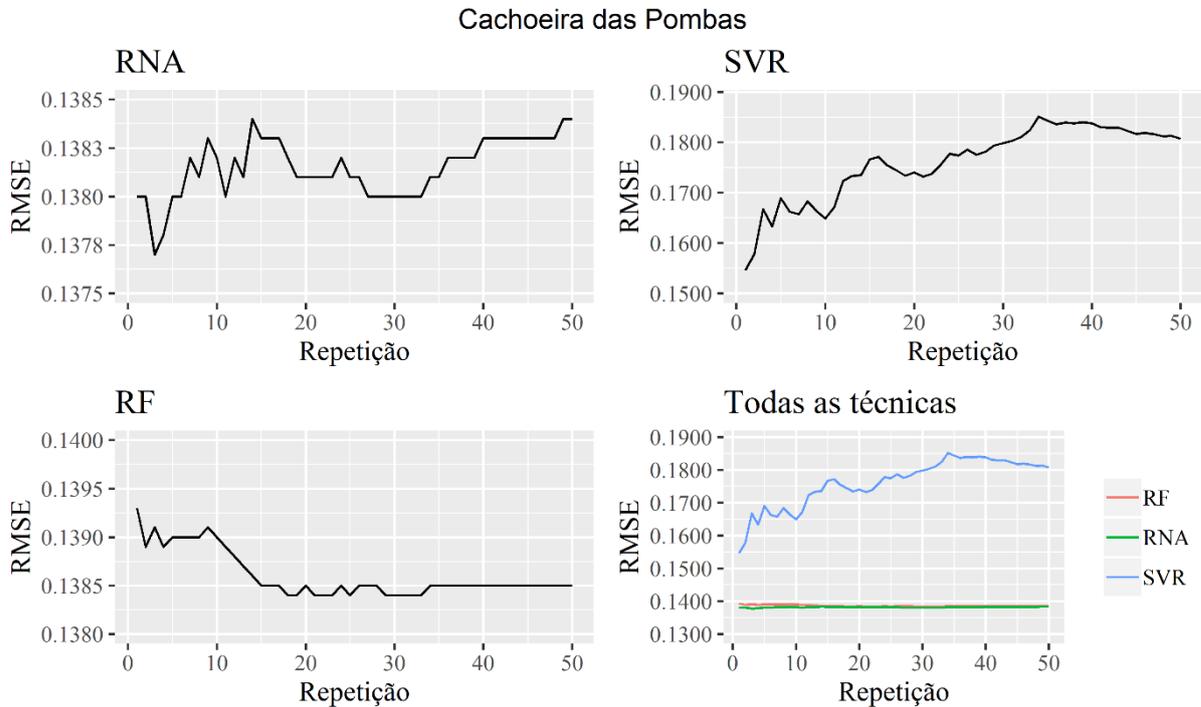


Fonte: O autor (2019).

5.5 Melhores configurações na validação cruzada

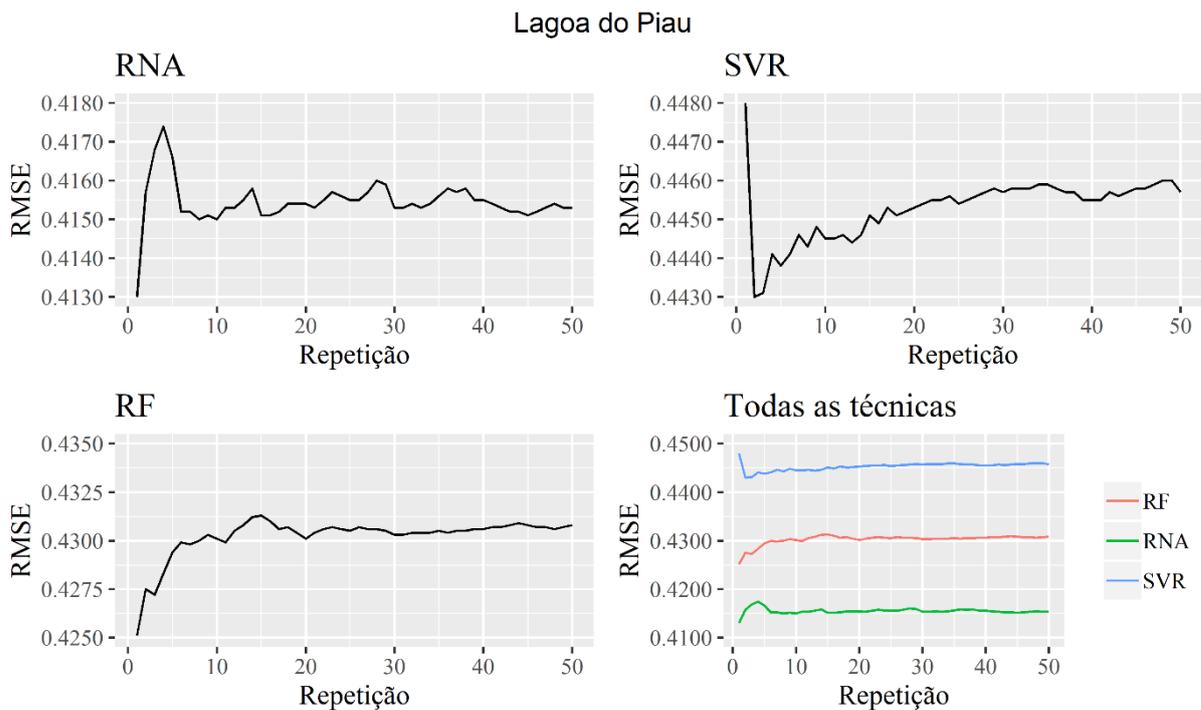
A tendência das médias de $RMSE$ ao longo das repetições variou para cada técnica. As médias de $RMSE$ da RNA e da RF foram próximas em CP, com erros menores que 0,1390 (Figura 26). Contudo, a RNA obteve os menores valores na maioria das repetições. Em LP, a RNA se destacou novamente, com médias de $RMSE$ menores que 0,4180, RF ficando em segundo e a SVR em terceiro lugar com maiores erros (Figura 27). No fragmento SJ a RNA manteve os menores erros, com médias de $RMSE$ menores que 0,1660 (Figura 28). As médias de $RMSE$ com os respectivos desvios padrões por repetição podem ser visualizados no APÊNDICE C.

Figura 26 – Raiz quadrada do erro quadrático médio (*RMSE*) da rede neural artificial (RNA), regressão vetorial de suporte (SVR) e *random forest* (RF) na validação cruzada do fragmento Cachoeira das Pombas



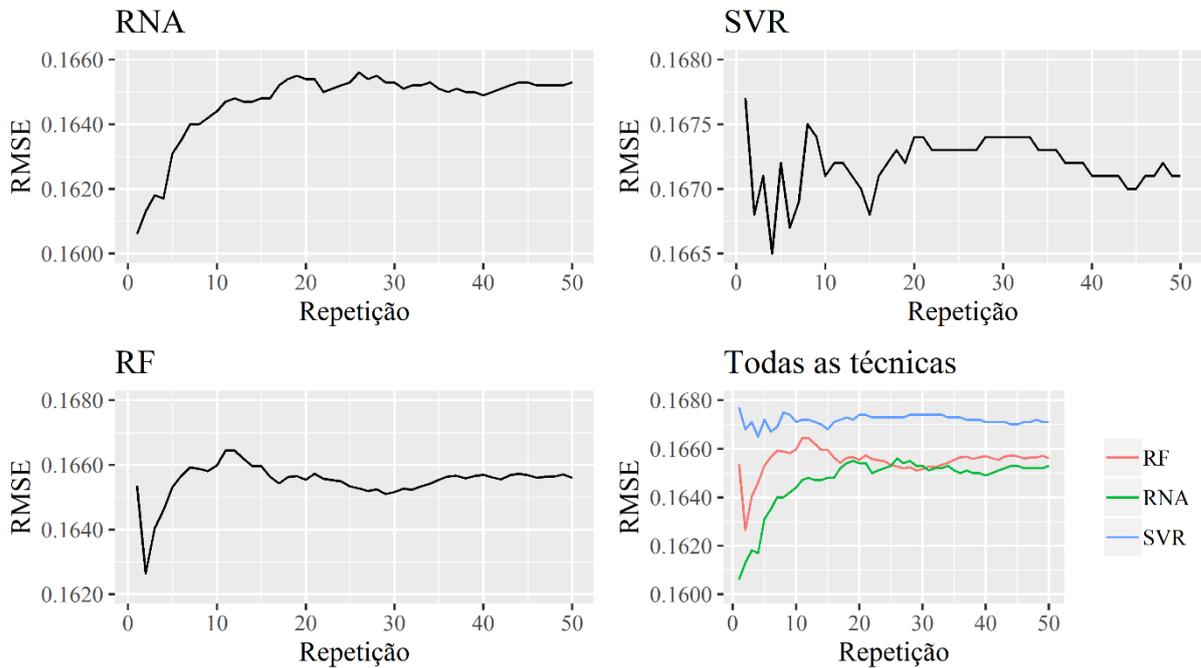
Fonte: O autor (2019).

Figura 27 – Raiz quadrada do erro quadrático médio (*RMSE*) da rede neural artificial (RNA), regressão vetorial de suporte (SVR) e *random forest* (RF) na validação cruzada do fragmento Lagoa do Piauí



Fonte: O autor (2019).

Figura 28 – Raiz quadrada do erro quadrático médio (*RMSE*) da rede neural artificial (RNA), regressão vetorial de suporte (SVR) e *random forest* (RF) na validação cruzada do fragmento São José

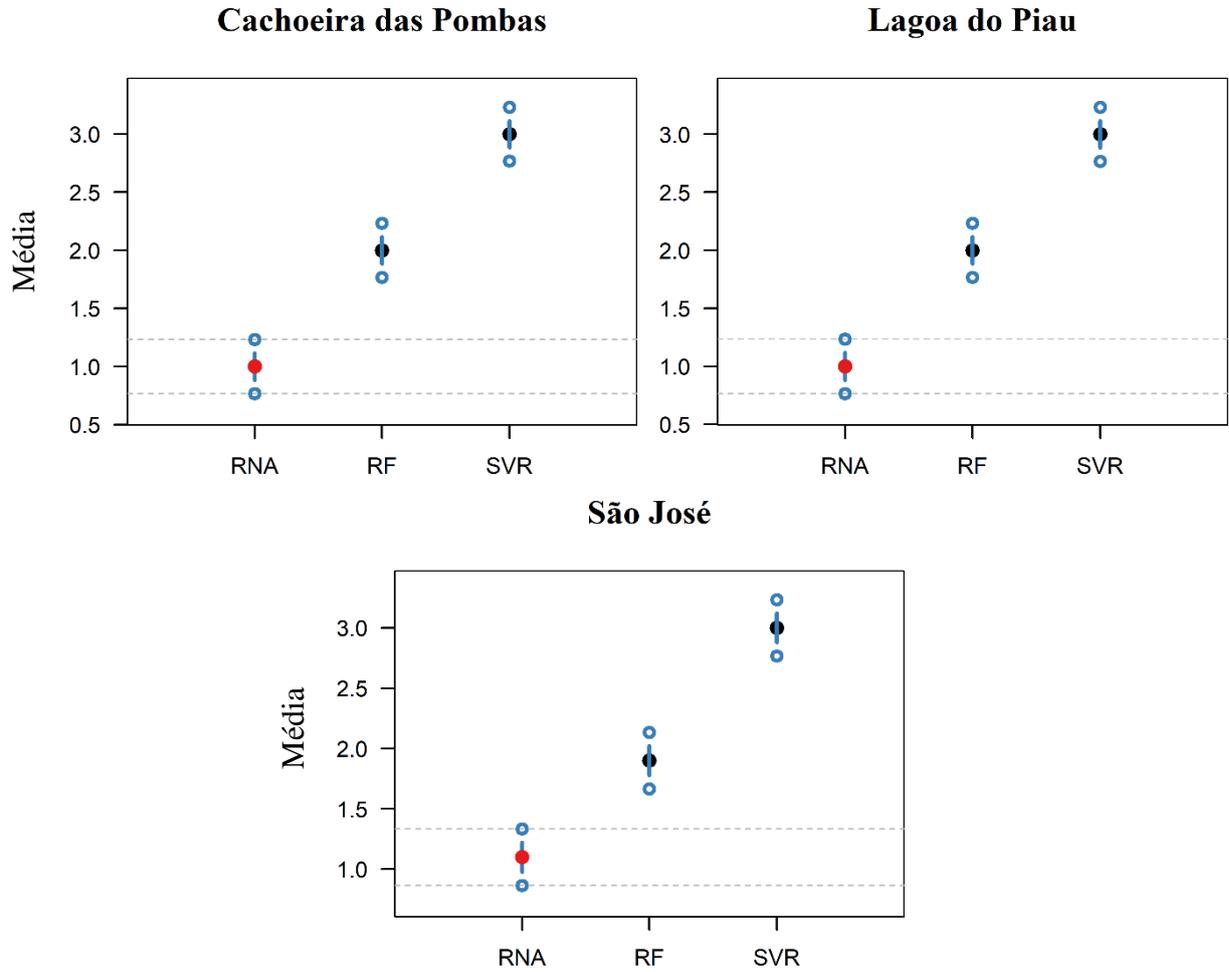


Fonte: O autor (2019).

5.6 Comparação das técnicas pelos testes de Friedman e Nemenyi

O teste de Friedman com as médias de *RMSE* da validação cruzada mostrou que as predições de IPA_{dap} entre as técnicas diferiram ($p < 0,05$). Assim, a hipótese de que pelo menos uma média de uma das técnicas se difere das demais foi aceita. O teste de Nemenyi apontou que a diferença entre a RNA para as demais técnicas foi maior que diferença crítica calculada (DC) de 0,46 (Figura 29). Assim, a RNA foi a técnica que obteve os menores erros na validação cruzada.

Figura 29 – Médias no teste de Nemenyi para rede neural artificial (RNA), regressão vetorial de suporte (SVR) e *random forest* (RF) nos fragmentos Cachoeira das Pombas, Lagoa do Piau e São José



Fonte: O autor (2019).

6 DISCUSSÃO

Modelos de crescimento radial do fuste (*dap*) têm sido reconhecidos como úteis para projetar o crescimento de árvores individuais (BURKHART; TOMÉ, 2012; MORENO et al., 2017). Neste estudo foram obtidos modelos para três das técnicas de aprendizagem de máquina mais utilizadas (RNA, SVR e RF) para prever o IPA_{dap} com configurações simples. O estudo também demonstrou que a modelagem do IPA_{dap} pode ser abordada agrupando espécies e incluindo o período de incremento e índices de competição nos modelos.

Na avaliação do melhor método de ligação na análise de cluster, os maiores valores de correlação cofenética (0,8731 a 0,9203) do método de ligação média reforçam a necessidade de testar mais de um método, pois o resultado pode variar dependendo dos dados (SARAÇLI; DOĞAN; DOĞAN, 2013). Os altos valores de correlação cofenética do método de ligação média em todos os fragmentos ($>0,87$) indicam boa representação da matriz de dissimilaridade na forma de dendrograma (ALBUQUERQUE et al., 2016). Desse modo, a análise de cluster foi adequada e eficaz para agregar espécies de Mata Atlântica em grupos.

As espécies com menores médias de IPA_{dap} para o grupo “A” foram as que obtiveram maior variação, com maior número de observações. Essa tendência no grupo “A” pode ser explicada pela concentração de espécies de todos os grupos ecológicos, o que resultou na maior variação de incremento entre as espécies. Por outro lado, as espécies dos grupos “D” e “E” foram as de menor número de observações, contudo foram as espécies responsáveis por grande parte dos altos valores de IPA_{dap} . Esses altos valores de IPA_{dap} dos grupos “D” e “E” se deve, principalmente, a presença de espécies pioneiras e secundárias iniciais, em que as taxas de crescimento são geralmente maiores que as espécies tardias e climáticas (LÔBO et al., 2011; LUSK; SENDALL; KOOYMAN, 2011; TABARELLI; PERES; MELO, 2012).

Analisando as correlações dos índices de competição com o IPA_{dap} , os valores negativos de correlação com o IPA_{dap} , principalmente para os grupos de espécie “D” e “E”, sugerem que ao aumentar a competição entre as árvores, o incremento reduz para algumas espécies de rápido crescimento, enquanto que para as espécies tolerantes a sombra o efeito da competição no incremento é menor. Apesar de geralmente a presença de árvores competidoras com diâmetros maiores reduzir a taxa de crescimento das árvores vizinhas (VAN BREUGEL et al., 2012; CASTRO et al., 2014; REIS et al., 2016), os resultados do presente estudo reforçam que a competição pode não ser o único fator que afeta o incremento (SHIMAMOTO; BOTOSSO; MARQUES, 2014). Desse modo, árvores com maior porte podem não diminuir o incremento de algumas espécies dentro dos grupos. Isso se relaciona

com a distribuição dos grupos ecológicos dentro dos grupos de espécies, sendo que árvores maiores proporcionam o sombreamento para as espécies tolerantes se desenvolverem (ROZENDAAL; CHADZON, 2015; CUNHA; FINGER; HASENAUER, 2016; SWINFIELD et al., 2016; WHEELER et al., 2016; ORELLANA; VANCLAY, 2018).

A importância dos grupos de espécie foi refletida na seleção das melhores configurações de todas as técnicas. Todos os fragmentos, com exceção da MS, apresentaram o grupo de espécie como uma das variáveis preditoras nos modelos, indicando que a inclusão dessa variável melhora a precisão das previsões (RUSLANDI; CROPPER; PUTZ, 2017). A presença de espécies exigentes de luz nos grupos de menor IPA_{dap} , como as pioneiras, sugere que estas sofreram redução no ritmo do crescimento devido ao sombreamento de outras espécies (SÁNCHEZ-GALLEN; ÁLVAREZ-SÁNCHEZ; BENÍTEZ-MALVIDO, 2010). Além disso, algumas das espécies tolerantes a sombra apresentaram maior taxa média de IPA_{dap} do que a maioria do mesmo grupo ecológico, indicando que o avanço do fechamento do dossel favoreceu essas espécies (DIONISIO et al., 2018). Assim, os grupos de espécies foram importantes para detectar as diferenças nas taxas de crescimento até dentro dos grupos ecológicos.

A variação do número de neurônios na camada oculta das redes neurais entre os fragmentos foi devido à grande variação dos dados e a mudança no número de variáveis preditoras nas abordagens. O aumento ou diminuição do número de neurônios na camada oculta está ligado a complexidade dos dados e ao número de nós de entrada (GORGENS et al., 2014; VIEIRA et al., 2018). Assim, o número de neurônios na camada oculta deve ser aumentado em problemas mais complexos (HAYKIN, 2009). Isso vale também para as RF, em que quanto mais complexo os dados, maior deverá ser o número de árvores para modelagem (MELLOR et al., 2015).

Os valores de correlação entre o IPA_{dap} observado e predito (r_{yy}) acima de 0,60 para a RNA e SVR em alguns fragmentos foram maiores que os encontrados com uso de modelos estatísticos tradicionais por Stepka et al., (2012) para *Araucaria angustifolia* ($r_{yy}<0,35$), Anderson et al., (2018) para *Picea mariana* ($r_{yy}<0,56$) e Roik et al., (2018) para um fragmento florestal de araucária ($r_{yy}<0,50$). Isso reforça que a utilização de novas técnicas pode ajudar a aumentar a precisão das previsões do crescimento de árvores (DIAMANTOPOULOU et al., 2015; VIEIRA et al., 2018; ÖZÇELIK; DIAMANTOPOULOU; TRINCADO, 2019). Os valores de r_{yy} da RNA em todos os fragmentos (CP, LP e SJ) foi semelhante aos obtidos por cada fragmento separadamente (Tabela 8), corroborando que os dados podem ser modelados de forma geral com as RNA (TAVARES JÚNIOR et al., 2019). A significância da r_{yy} para

todas as técnicas em todos os fragmentos pelo teste t comprova que existe associação linear positiva entre os valores preditos e observados de IPA_{dap} . Os valores de $RMSE$ foram inversamente proporcionais a r_{yy} , em que a técnica com as maiores r_{yy} foram as de menores $RMSE$ em cada fragmento. Os menores valores de EAM da SVR em quase todos os fragmentos sugere que a combinação de métricas, incluindo a $RMSE$ muitas vezes é necessária para avaliar o desempenho dos modelos. Como o $RMSE$ e o EAM são definidos de maneira diferente, é esperado que os resultados sejam diferentes (CHAI; DRAXLER, 2014).

Analisando as variáveis preditoras das melhores configurações, a inclusão dos grupos de espécies e dos índices de competição resultou nas melhores estatísticas para RNA, SVR e RF em todos os fragmentos, com exceção da MS. Isso indica que existe um padrão nos incrementos dentro dos grupos de espécies e que a competição pode influenciar algumas espécies (BEC et al., 2015; CANETTI et al., 2016; CABRERA et al., 2019). O melhor desempenho de um índice de competição em relação ao outro não foi observado. Em geral, os índices variaram entre as técnicas e os fragmentos. Assim, o teste prévio de mais de um índice de competição é recomendado para avaliar o que resulta em melhor desempenho (MARTINS et al., 2011; CUNHA; FINGER; HASENAUER, 2016; KUEHNE; WEISKITTEL; WASKIEWICZ, 2019).

A ampla dispersão dos valores preditos de IPA_{dap} foi devido à grande variação dos valores observados. As espécies arbóreas tropicais apresentam comportamento distinto sob diferentes condições, mesmo para as mesmas espécies (SILVA et al., 2002). Desse modo, a criação dos grupos de espécies é uma estratégia para reduzir a variação do IPA_{dap} dentro dos grupos (RUSLANDI; CROPPER; PUTZ, 2017; ROIK et al., 2018). As RNA, SVR e RF buscaram o ajuste por grupo de espécie e período de incremento, resultando em diferentes tendências para os diferentes grupos ou períodos. A presença de outliers nos gráficos de resíduos padronizados foi esperada devido à grande variação no IPA_{dap} para determinados valores de dap .

Em termos de importância relativa dos preditores dentro dos melhores modelos, os resultados mostraram que as variáveis grupo de espécie e período de incremento foram as mais importantes na modelagem. Essas variáveis podem ser introduzidas nos modelos para aumentar a precisão na predição do IPA_{dap} em fragmentos de Mata Atlântica, sendo ainda muito utilizado apenas o diâmetro em muitos modelos (STEPKA et al., 2012; KUEHNE; WEISKITTEL; WASKIEWICZ, 2019). Nos fragmentos MS e LP a variável que se destacou foi o período de incremento. O aumento médio do IPA_{dap} nos períodos 1997–2000 na MS e 2007–2012 em LP pode estar relacionado com o aumento da precipitação nos anos de 2007 a

2009 em LP (Figura 6) e de 1997 a 1998 na MS (Figura 8), causando o aumento da fotossíntese e do crescimento das árvores (GUSTAFSON et al., 2017). Além disso, o fragmento da MS possui maior tempo de observação, o que resultou em maior variação dos incrementos por período.

Os resultados da validação cruzada demonstraram que a RNA superou a SVR e RF em todos os fragmentos testados devido a maior estabilidade na variação do *RMSE* e menores valores desta estatística ao longo das repetições. Isso sugere que o melhor desempenho da SVR em CP foi devido ao conjunto de validação obter uma combinação de observações que foi relativamente mais fácil de prever com essa técnica (TU, 1996; CHEN; ROLLINS, 2000). Ao ser apresentada a novas combinações de observações na validação cruzada, a SVR aumentou o erro. A diferença nas médias de *RMSE* entre as técnicas foi detectada com o teste de Friedman. No teste de Nemenyi, o resultado comprovou que a RNA foi mais eficiente que a SVR e RF para prever o *IPA_{dap}*.

7 CONCLUSÕES

As variáveis mais importantes para prever o incremento periódico anual em diâmetro (*IPA_{dap}*) utilizando aprendizagem de máquina são o grupo de espécie e o período de incremento.

O *IPA_{dap}* predito ao utilizar os dados dos fragmentos de forma geral é uma alternativa para reduzir o tempo de processamento, com a ressalva dos dados possuírem métodos semelhantes de coleta dos dados.

A RNA é mais eficiente que a SVR e RF para prever o *IPA_{dap}* nos fragmentos de Mata Atlântica.

REFERÊNCIAS

- ADAME, P.; HYNYNEN, J.; CAÑELLAS, I.; DEL RÍO, M. Individual-tree diameter growth model for rebollo oak (*Quercus pyrenaica* Willd.) coppices. **Forest Ecology and Management**, v. 255, n. 3–4, p. 1011–1022, 2008.
- ALBAUGH, T. J.; FOX, T. R.; RUBILAR, R. A.; COOK, R. L.; AMATEIS, R. L.; BURKHART, H. E. Post-thinning density and fertilization affect *Pinus taeda* stand and individual tree growth. **Forest Ecology and Management**, v. 396, p. 207–216, 2017.
- ALBUQUERQUE, M. A. de; BARROS, K. N. N. de O.; GOUVEIA, J. F.; FERREIRA, R. L. C. Determination and validation of group numbers in a cluster analysis: A case study applied to forestry science. **Acta Scientiarum. Technology**, v. 38, n. 3, p. 339, 2016.
- ANDEREGG, W. R. L.; BERRY, J. A.; FIELD, C. B. Linking definitions, mechanisms, and modeling of drought-induced tree death. **Trends in Plant Science**, v. 17, n. 12, p. 693–700, 2012.
- ANDERSON, B. D.; RUSSELL, M. B.; WINDMULLER-CAMPIONE, M. A.; PALIK, B. J.; KASTENDICK, D. N. Development and evaluation of black spruce (*Picea mariana* (Miller) B.S.P.) diameter increment models across silvicultural treatments in northern Minnesota, USA. **Forests**, v. 9, n. 12, 2018.
- BEC, J. L.; COURBAUD, B.; MOGUÉDEC, G. Le; PÉLISSIER, R. Characterizing tropical tree species growth strategies: Learning from inter-individual variability and scale invariance. **PLoS ONE**, v. 10, n. 3, p. 1–18, 2015.
- BECK, M. W. NeuralNetTools : visualization and analysis tools for neural networks. **Journal of Statistical Software**, v. 85, n. 11, p. 1–20, 2018.
- BERGMEIR, C.; BENITEZ, J. M. Neural networks in R using the Stuttgart Neural Network Simulator: RSNNS. **Journal of Statistical Software**, v. 46, n. 7, p. 1–26, 2012.
- BINOTI, M. L. M. da S.; LEITE, H. G.; BINOTI, D. H. B.; GLERIANI, J. M. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Cerne**, v. 21, n. 1, p. 97–105, 2015.
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.
- BURGES, C. J. C. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge Discovery**, v. 2, n. 2, p. 121–167, 1998.
- BURKHART, H. E.; TOMÉ, M. **Modeling forest trees and stands**. New York: Springer, 2012.
- CABRERA, O.; FRIES, A.; HILDEBRANDT, P.; GÜNTER, S.; MOSANDL, R. Early growth response of nine timber species to release in a tropical Mountain Forest of Southern Ecuador. **Forests**, v. 10, n. 3, p. 254, 2019.

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

CANETTI, A.; DE MATTOS, P. P.; BRAZ, E. M.; RICKEN, P.; PELLICO NETTO, S. Retrospective analysis of competition in a forest remnant: A case study of *Podocarpus lambertii* in the *Araucaria* Forest. **Dendrochronologia**, v. 40, p. 43–49, 2016.

CASTRO, R.; SOARES, C.; LEITE, H.; SOUZA, A.; MARTINS, F.; NOGUEIRA, G.; OLIVEIRA, M.; SILVA, F. Competição em nível de árvore individual em uma Floresta Estacional Semidecidual. **Silva Lusitana**, v. 22, n. 1, p. 43–66, 2014.

CATHARINO, E. L. M.; BERNACCI, L. C.; FRANCO, G. A. D. C.; DURIGAN, G.; METZGER, J. P. Aspectos da composição e diversidade do componente arbóreo das florestas da Reserva Florestal do Morro Grande, Cotia, SP. **Biota Neotropica**, v. 6, n. 2, p. 1–28, 2006.

CEQUINEL, A.; CAPELLESSO, E. S.; MARCILIO-SILVA, V.; CARDOSO, F. C. G.; MARQUES, M. C. M. Determinism in tree turnover during the succession of a tropical forest. **Perspectives in Plant Ecology, Evolution and Systematics**, v. 34, p. 120–128, 2018.

CHAI, T.; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)? - Arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, v. 7, n. 3, p. 1247–1250, 2014.

CHAPLIN-KRAMER, R.; RAMLER, I.; SHARP, R.; HADDAD, N. M.; GERBER, J. S.; WEST, P. C.; MANDLE, L.; ENGSTROM, P.; BACCINI, A.; SIM, S.; MUELLER, C.; KING, H. Degradation in carbon stocks near tropical forest edges. **Nature Communications**, v. 6, p. 1–6, 2015.

CHEN, V. C. P.; ROLLINS, D. K. Issues regarding artificial neural network modeling for reactors and fermenters. **Bioprocess Engineering**, v. 22, n. 1, p. 85–93, 2000.

CHENG, K.; LU, Z.; WEI, Y.; SHI, Y.; ZHOU, Y. Mixed kernel function support vector regression for global sensitivity analysis. **Mechanical Systems and Signal Processing**, v. 96, p. 201–214, 2017.

COSTA, R. L.; PREVEDELLO, J. A.; DE SOUZA, B. G.; CABRAL, D. C. Forest transitions in tropical landscapes: A test in the Atlantic Forest biodiversity hotspot. **Applied Geography**, v. 82, p. 93–100, 2017.

CUENTAS, S.; PEÑABAENA-NIEBLES, R.; GARCIA, E. Support vector machine in statistical process monitoring: a methodological and analytical review. **International Journal of Advanced Manufacturing Technology**, v. 91, n. 1–4, p. 485–500, 2017.

CUNHA, T. A. da; FINGER, C. A. G.; HASENAUER, H. Tree basal area increment models for *Cedrela*, *Amburana*, *Copaifera* and *Swietenia* growing in the Amazon rain forests. **Forest Ecology and Management**, v. 365, p. 174–183, 2016.

CURTIS, P. S., HANSON, P. J., BOLSTAD, P., BARFORD, C., RANDOLPH, J.C., SCHMID, H.P., WILSON, K. B. Biometric and eddy covariance based estimates of annual carbon storage in five eastern North American deciduous forests. **Agricultural and Forest**

Meteorology, v. 113, p. 3–19, 2002.

DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and Electronics in Agriculture**, v. 48, n. 3, p. 235–244, 2005.

DIAMANTOPOULOU, M. J. Assessing a reliable modeling approach of features of trees through neural network models for sustainable forests. **Sustainable Computing: Informatics and Systems**, v. 2, n. 4, p. 190–197, 2012.

DIAMANTOPOULOU, M. J.; MILIOS, E. Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural network models. **Biosystems Engineering**, v. 105, n. 3, p. 306–315, 2010.

DIAMANTOPOULOU, M. J.; ÖZÇELİK, R.; CRECENTE-CAMPO, F.; ELER, Ü. Estimation of Weibull function parameters for modelling tree diameter distribution using least squares and artificial neural networks methods. **Biosystems Engineering**, v. 133, p. 33–45, 2015.

DIONISIO, L. F. S.; SCHWARTZ, G.; LOPES, J. do C.; OLIVEIRA, F. de A. Growth, mortality, and recruitment of tree species in an Amazonian rainforest over 13 years of reduced impact logging. **Forest Ecology and Management**, v. 430, p. 150–156, 2018.

FARRIS, J. S. On the cophenetic correlation coefficient. **Systematic Zoology**, v. 18, n. 3, p. 279–285, 1969.

FENG, C.; LIAO, S. Scalable gaussian kernel support vector machines with sublinear training time complexity. **Information Sciences**, v. 418–419, p. 480–494, 2017.

FEREZ, A. P. C.; CAMPOE, O. C.; MENDES, J. C. T.; STAPE, J. L. Silvicultural opportunities for increasing carbon stock in restoration of Atlantic forests in Brazil. **Forest Ecology and Management**, v. 350, p. 40–45, 2015.

FONSECA, R. C. B.; RODRIGUES, R. R. Análise estrutural e aspectos do mosaico sucessional de uma floresta semidecídua em Botucatu, SP. **Scientia Florestalis**, Piracicaba, v. 57, p. 27–43, 2000.

FRIEDMAN, M. A comparison of alternative tests of significance for the problem of m rankings. **The Annals of Mathematical Statistics**, v. 11, n. 1, 86–92, 1940.

GANDOLFI, S.; LEITÃO-FILHO, H. F.; BEZERRA, C. L. F. Levantamento florístico e caráter sucessional das espécies arbustivos-arbóreas de uma floresta mesófila semidecídua no município de Guarulhos, SP, **Revista Brasileira de Biologia**, v. 55, n. 4, p. 753–767, 1995.

GARCÍA-GUTIÉRREZ, J.; MARTÍNEZ-ÁLVAREZ, F.; TRONCOSO, A.; RIQUELME, J. C. A comparison of machine learning regression techniques for LiDAR-derived estimation of forest variables. **Neurocomputing**, v. 167, p. 24–31, 2015.

GARSONG., D. Interpreting neural-network connection weights. **AI Expert**, v. 6, p. 47–51, 1991.

GENUER, R.; POGGI, J. M.; TULEAU-MALOT, C.; VILLA-VIALANEIX, N. Random Forests for Big Data. **Big Data Research**, v. 9, p. 28–46, 2017.

GLEASON, C. J.; IM, J. Forest biomass estimation from airborne LiDAR data using machine learning approaches. **Remote Sensing of Environment**, v. 125, p. 80–91, 2012.

GLOVER, G. R., HOOL, J. N. A basal area ratio predictor of loblolly pine plantation mortality. **Forest Science.**, v. 25, p. 275–282, 1979.

GORGENS, E. B.; LEITE, H. G.; GLERIANI, J. M.; SOARES, C. P. B.; CEOLIN, A. Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. **Revista Árvore**, v. 38, n. 2, p. 289–295, 2014.

GSCHWANTNER, T.; LANZ, A.; VIDAL, C.; BOSELA, M.; DI COSMO, L.; FRIDMAN, J.; GASPARINI, P.; KULIEŠIS, A.; TOMTER, S.; SCHADAUER, K. Comparison of methods used in European National Forest Inventories for the estimation of volume increment: towards harmonisation. **Annals of Forest Science**, v. 73, n. 4, p. 807–821, 2016.

GUSTAFSON, E. J.; MIRANDA, B. R.; DE BRUIJN, A. M. G.; STURTEVANT, B. R.; KUBISKE, M. E. Do rising temperatures always increase forest productivity? Interacting effects of temperature, precipitation, cloudiness and soil texture on tree species growth and competition. **Environmental Modelling and Software**, v. 97, p. 171–183, 2017.

HAN, Y.-yun; WU, B.-guo; WANG, K.-yi; GUO, E.-ying; DONG, C.; WANG, Z.-bin. Individual-tree form growth models of visualization simulation for managed *Larix principis-rupprechtii* plantation. **Computers and Electronics in Agriculture**, v. 123, p. 341–350, 2016.

HAO, P. Y. Pairing support vector algorithm for data regression. **Neurocomputing**, v. 225, p. 174–187, 2017.

HARTER, H. L. Tables of range and studentized range. **The Annals of Mathematical Statistics**, 1122–1147, 1960.

HAYKIN, S. **Neural networks and learning machines**. New Jersey: Prentice Hall, 2009.

HUANG, Y.; ZHAO, L. Review on landslide susceptibility mapping using support vector machines. **Catena**, v. 165, p. 520–529, 2018.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. Mapa de vegetação do Brasil. 3ª edição. Rio de Janeiro: IBGE, 2004.

JACHOWSKI, N. R. A.; QUAK, M. S. Y.; FRIESS, D. A.; DUANGNAMON, D.; WEBB, E. L.; ZIEGLER, A. D. Mangrove biomass estimation in Southwest Thailand using machine learning. **Applied Geography**, v. 45, p. 311–321, 2013.

JOSÉ VIDAL-MACUA, J.; NINYEROLA, M.; ZABALA, A.; DOMINGO-MARIMON, C.; PONS, X. Factors affecting forest dynamics in the Iberian Peninsula from 1987 to 2012. The role of topography and drought. **Forest Ecology and Management**, v. 406, p. 290–306,

2017.

KARATZOGLU, A.; MEYER, D.; HORNIK, K. Support vector algorithm in R. **Journal of Statistical Software**, v. 15, n. 9, p. 1–28, 2006.

KUEHNE, C.; WEISKITTEL, A. R.; WASKIEWICZ, J. Comparing performance of contrasting distance-independent and distance-dependent competition metrics in predicting individual tree diameter increment and survival within structurally-heterogeneous, mixed-species forests of Northeastern United States. **Forest Ecology and Management**, v. 433, p. 205–216, 2019.

LHOTKA, J. M.; LOEWENSTEIN, E. F. An individual-tree diameter growth model for managed uneven-aged oak-shortleaf pine stands in the Ozark Highlands of Missouri, USA. **Forest Ecology and Management**, v. 261, n. 3, p. 770–778, 2011.

LI, Y.; ZOU, C.; BERECIBAR, M.; NANINI-MAURY, E.; CHAN, J. C.; BOSSCHE, P. van den; VAN MIERLO, J.; OMAR, N. Random forest regression for online capacity estimation of lithium-ion batteries. **Applied Energy**, v. 232, p. 197–210, 2018.

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

LIÉNARD, J. F.; GRAVEL, D.; STRIGUL, N. S. Data-intensive modeling of forest dynamics. **Environmental Modelling and Software**, v. 67, p. 138–148, 2015.

LIU, R.; YANG, B.; ZIO, E.; CHEN, X. Artificial intelligence for fault diagnosis of rotating machinery: A review. **Mechanical Systems and Signal Processing**, v. 108, p. 33–47, 2018.

LÔBO, D.; LEÃO, T.; MELO, F. P. L.; SANTOS, A. M. M.; TABARELLI, M. Forest fragmentation drives Atlantic forest of northeastern Brazil to biotic homogenization. **Diversity and Distributions**, v. 17, n. 2, p. 287–296, 2011.

LU, C. Neurocomputing Sales forecasting of computer products based on variable selection scheme and support vector regression. **Neurocomputing**, v. 128, p. 491–499, 2014.

LUSK, C. H.; SENDALL, K.; KOOYMAN, R. Latitude, solar elevation angles and gap-regenerating rain forest pioneers. **Journal of Ecology**, v. 99, n. 2, p. 491–502, 2011.

MABVURIRA, D.; MIINA, J. Individual-tree growth and mortality models for *Eucalyptus grandis* (Hill) Maiden plantations in Zimbabwe. **Forest Ecology and Management**, v. 161, n. 1–3, p. 231–245, 2002.

MAGNAGO, L. F. S.; MAGRACH, A.; LAURANCE, W. F.; MARTINS, S. V.; MEIRANETO, J. A. A.; SIMONELLI, M.; EDWARDS, D. P. Would protecting tropical forest fragments provide carbon and biodiversity cobenefits under REDD+? **Global Change Biology**, v. 21, n. 9, p. 3455–3468, 2015.

MARTINS, F. B.; SOARES, C. P. B.; LEITE, H. G.; SOUZA, A. L. de; CASTRO, R. V. O. Índices de competição em árvores individuais de eucalipto. **Pesquisa Agropecuária Brasileira**, v. 46, n. 9, p. 1089–1098, 2011.

McCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, v. 5, n. 4, p. 115–133, 1943.

McDOWELL, N. G.; BEERLING, D. J.; BRESHEARS, D. D.; FISHER, R. A.; RAFFA, K. F.; STITT, M. The interdependence of mechanisms underlying climate-driven vegetation mortality. **Trends in Ecology and Evolution**, v. 26, n. 10, p. 523–532, 2011.

McDOWELL, N. G.; COOPS, N. C.; BECK, P. S. A.; CHAMBERS, J. Q.; GANGODAGAMAGE, C.; HICKE, J. A.; HUANG, C. ying; KENNEDY, R.; KROFCHECK, D. J.; LITVAK, M.; MEDDENS, A. J. H.; MUSS, J.; NEGRÓN-JUAREZ, R.; PENG, C.; SCHWANTES, A. M.; SWENSON, J. J.; VERNON, L. J.; WILLIAMS, A. P.; XU, C.; ZHAO, M.; RUNNING, S. W.; ALLEN, C. D. Global satellite monitoring of climate-induced vegetation disturbances. **Trends in Plant Science**, v. 20, n. 2, p. 114–123, 2015.

McDOWELL, N.; POCKMAN, W. T.; ALLEN, C. D.; BRESHEARS, D. D.; COBB, N.; KOLB, T.; PLAUT, J.; SPERRY, J.; WEST, A.; WILLIAMS, D. G.; YEPEZ, E. A.; MCDOWELL, N.; POCKMAN, W. T.; ALLEN, C. D.; DAVID, D.; MCDOWELL, N.; COBB, N.; KOLB, T.; PLAUT, J.; SPERRY, J. Mechanisms of plant survival and mortality during drought: why do some plants survive while others succumb to drought? **New Phytologist**, v. 178, n. 4, p. 719–739, 2008.

MELESSE, A. M.; HANLEY, R. S. Artificial neural network application for multi-ecosystem carbon flux simulation. **Ecological Modelling**, v. 189, n. 3–4, p. 305–314, 2005.

MELLOR, A.; BOUKIR, S.; HAYWOOD, A.; JONES, S. Exploring issues of training data imbalance and mislabelling on random forest performance for large area land cover classification using the ensemble margin. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 105, p. 155–168, 2015.

MESQUITA, D. P. P.; GOMES, J. P. P.; SOUZA JUNIOR, A. H.; NOBRE, J. S. Euclidean distance estimation in incomplete datasets. **Neurocomputing**, v. 248, p. 11–18, 2017.

MEYER, D.; DIMITRIADOU, E.; HORNIK, K.; WEINGESSEL, A.; LEISCH, F. **e1071**: Misc functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien. 2018.

MLADENOVIĆ, I.; SOKOLOV-MLADENOVIĆ, S.; MILOVANČEVIĆ, M.; MARKOVIĆ, D.; SIMEUNOVIĆ, N. Management and estimation of thermal comfort, carbon dioxide emission and economic growth by support vector machine. **Renewable and Sustainable Energy Reviews**, v. 64, p. 466–476, 2016.

MONSERUD, R. A.; STERBA, H. Modeling individual tree mortality for Austrian forest species. **Forest Ecology and Management**, v. 113, n. 2–3, p. 109–123, 1999.

MORAIS JÚNIOR, V. T. M. de; JACOVINE, L. A. G.; TORRES, C. M. M. E.; ALVES, E. B. B. M.; PAIVA, H. N. de; CRUZ, R. A. de la; ZANUNCIO, J. C. Early assessment of tree species with potential for carbon offset plantations in degraded area from the southeastern Brazil. **Ecological Indicators**, v. 98, p. 854–860, 2019.

MORENO, P. C.; PALMAS, S.; ESCOBEDO, F. J.; CROPPER, W. P.; GEZAN, S. A. Individual-tree diameter growth models for mixed *Nothofagus* second growth forests in Southern Chile. **Forests**, p. 1–19, 2017.

MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 3, p. 247–259, 2011.

MYERS, N.; MITTERMEIER, R. A.; MITTERMEIER, C. G.; DA FONSECA, G. A. B.; KENT, J. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 6772, p. 853–858, 2000.

NAGALLA, R.; POTHUGANTI, P.; PAWAR, D. S. Analyzing gap acceptance behavior at unsignalized intersections using support vector machines, decision tree and random forests. **Procedia Computer Science**, v. 109, n. 2016, p. 474–481, 2017.

NEMENYI, P. B. **Distribution-Free Multiple Comparisons** (Ph.D. thesis), Princeton University, 1963.

NUNES, M. H.; GÖRGENS, E. B. Artificial intelligence procedures for tree taper estimation within a complex vegetation mosaic in Brazil. **PLoS ONE**, v. 11, n. 5, p. 1–16, 2016.

OLIVEIRA-FILHO, A. T. Estudos ecológicos da vegetação como subsídios para programas de revegetação com espécies nativas: uma proposta metodológica. **Cerne**, v. 1, p. 64–72, 1994.

ORELLANA, E.; VANCLAY, J. K. Competition and dominance between angiosperms and *Araucaria angustifolia* (Bert.) O. Kuntze in the Atlantic Forest in southern Brazil. **Forest Ecology and Management**, v. 425, p. 119–125, 2018.

ÖZÇELİK, R.; DIAMANTOPOULOU, M. J.; BROOKS, J. R.; WIANT, H. V. 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.; CRECENTE-CAMPO, F.; ELER, U. Estimating *Crimean juniper* tree height using nonlinear regression and artificial neural network models. **Forest Ecology and Management**, v. 306, p. 52–60, 2013.

ÖZÇELİK, R.; DIAMANTOPOULOU, M. J.; TRINCADO, G. Evaluation of potential modeling approaches for Scots pine stem diameter prediction in north-eastern Turkey. **Computers and Electronics in Agriculture**, v. 162, p. 773–782, 2019.

PAULA, A.; SILVA, A. F.; MARCO-JÚNIOR, P.; SANTOS, F. A. M.; SOUZA, A. L. Sucessão ecológica da vegetação arbórea em uma floresta estacional semidecidual, Viçosa, MG, Brasil. **Acta Botanica Brasilica**, v. 18, p. 407–423, 2004.

PHAM, L. T. H.; BRABYN, L. Monitoring mangrove biomass change in Vietnam using SPOT images and an object-based approach combined with machine learning algorithms. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 128, p. 86–97, 2017.

PRETZSCH, H. **Forest dynamics, growth and yield**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010.

R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria, 2018.

RAJASHEKAR, G.; FARARODA, R.; REDDY, R. S.; JHA, C. S.; GANESHIAIAH, K. N.; SINGH, J. S.; DADHWAL, V. K. Spatial distribution of forest biomass carbon (Above and below ground) in Indian forests. **Ecological Indicators**, v. 85, p. 742–752, 2018.

REIS, L. P.; DE SOUZA, A. L.; DOS REIS, P. C. M.; MAZZEI, L.; SOARES, C. P. B.; MIQUELINO ELETO TORRES, C. M.; DA SILVA, L. F.; RUSCHEL, A. R.; RÊGO, L. J. S.; LEITE, H. G. Estimation of mortality and survival of individual trees after harvesting wood using artificial neural networks in the amazon rain forest. **Ecological Engineering**, v. 112, p. 140–147, 2018.

REIS, L. P.; DE SOUZA, A. L.; MAZZEI, L.; DOS REIS, P. C. M.; LEITE, H. G.; SOARES, C. P. B.; TORRES, C. M. M. E.; DA SILVA, L. F.; RUSCHEL, A. R. Prognosis on the diameter of individual trees on the eastern region of the amazon using artificial neural networks. **Forest Ecology and Management**, v. 382, p. 161–167, 2016.

RIBEIRO, R. B. da S.; GAMA, J. R. V.; SOUZA, A. L. de; LEITE, H. G.; SOARES, C. P. B.; SILVA, G. F. da. Métodos para estimar o volume de fustes e e galhos na Floresta Nacional do Tapajós. **Revista Árvore**, v. 40, n. 1, p. 81–88, 2016.

ROCHA, S. J. S. S. da; TORRES, C. M. M. E.; JACOVINE, L. A. G.; LEITE, H. G.; GELCER, E. M.; NEVES, K. M.; SCHETTINI, B. L. S.; VILLANOVA, P. H.; SILVA, L. F. da; REIS, L. P.; ZANUNCIO, J. C. Artificial neural networks: Modeling tree survival and mortality in the Atlantic Forest biome in Brazil. **Science of the Total Environment**, v. 645, p. 655–661, 2018.

ROIK, M.; MACHADO, S. do A.; FIGUEIREDO FILHO, A.; SANQUETTA, C. R.; ROVEDA, M.; STEPKA, T. F. Diameter increment modeling in an *Araucaria* forest fragment using cluster analysis. **Floresta e Ambiente**, v. 25, n. 3, 2018.

ROZENDAAL, D. M. A.; CHADZON, R. L. Demographic drivers of tree biomass change during secondary succession in northeastern Costa Rica. **Ecological Applications**, v. 25, n. 2, p. 506–516, 2015.

RUSLANDI; CROPPER, W. P.; PUTZ, F. E. Tree diameter increments following silvicultural treatments in a dipterocarp forest in Kalimantan, Indonesia: A mixed-effects modelling approach. **Forest Ecology and Management**, v. 396, p. 195–206, 2017.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: A modern approach**. 3. ed. New Jersey: Prentice Hall, 2010.

SÁNCHEZ-GALLEN, I.; ÁLVAREZ-SÁNCHEZ, F. J.; BENÍTEZ-MALVIDO, J. Structure of the advanced regeneration community in tropical rain forest fragments of Los Tuxtlas, Mexico. **Biological Conservation**, v. 143, n. 9, p. 2111–2118, 2010.

SARAÇLI, S.; DOĞAN, N.; DOĞAN, I. Comparison of hierarchical cluster analysis methods by cophenetic correlation. **Journal of Inequalities and Applications**, v. 2013, p. 1–8, 2013.

SHIFLEY, S. R.; EK, A. R.; BURK, T. E. A generalized methodology for estimating forest ingrowth at multiple threshold diameters. **Forest Science**, v. 38, p. 776–798, 1993.

SHIMAMOTO, C. Y.; BOTOSSO, P. C.; MARQUES, M. C. M. How much carbon is sequestered during the restoration of tropical forests? Estimates from tree species in the Brazilian Atlantic forest. **Forest Ecology and Management**, v. 329, p. 1–9, 2014.

SILVA, R. P. da; SANTOS, J. dos; TRIBUZY, E. S.; CHAMBERS, J. Q.; NAKAMURA, S.; HIGUCHI, N. Diameter increment and growth patterns for individual tree growing in Central Amazon, Brazil. **Forest Ecology and Management**, v. 166, n. 1–3, p. 295–301, 2002.

SILVA, I. N.; SPATTI, D. H.; FLAUZIN, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010. 396 p.

SILVA, F. V.; VENTURIN, N.; OLIVEIRA-FILHO, A. T.; MACEDO, R. L. G.; CARVALHO, W. A. C.; VAN DEN BERG, E. Caracterização estrutural de um fragmento de floresta semidecídua no município de Ibiturama, MG. **Cerne**, v. 9, p. 92–106, 2003.

SMOLA, a J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and Computing**, v. 14, p. 199–222, 2004.

SOCIEDADE DE INVESTIGAÇÕES FLORESTAIS – SIF. **Monitoramento da flora em áreas preservadas pela CELULOSE NIPO-BRASILEIRA S.A. – CENIBRA**. Viçosa – MG: 2008. 395 p.

STAGE, A. **Prognosis model for stand development**. USDA for Serv. Res. Pap. INT-137. Washington, DC., 1973.

STEPKA, T. F.; DIAS, A. N.; FILHO, A. F.; MACHADO, S. do A.; SAWCZUK, A. R. Modelagem do incremento em diâmetro da *Araucaria angustifolia* em uma floresta ombrófila mista no centrosul do paraná. **Floresta**, v. 42, n. 3, p. 607–620, 2012.

SUYKENS, J. A. K.; SIGNORETTO, M.; ARGYRIOU, A. **Regularization, optimization, kernels, and support vector machines**. Chapman and Hall/CRC, 2015.

SWAINE, M. D.; WHITMORE, T. C. On the definition of the ecological species groups in tropical rain forests. **Vegetatio**, v. 75, p. 81–86, 1988.

SWINFIELD, T.; AFRIANDI, R.; ANTONI, F.; HARRISON, R. D. Accelerating tropical forest restoration through the selective removal of pioneer species. **Forest Ecology and Management**, v. 381, n. 2016, p. 209–216, 2016.

TABARELLI, M.; MANTOVANI, W. Colonização de clareiras naturais na floresta atlântica no sudeste do Brasil. **Revista Brasileira de Botânica**, v. 20, p. 57–66, 1997.

TABARELLI, M.; PERES, C. A.; MELO, F. P. L. The “few winners and many losers” paradigm revisited: Emerging prospects for tropical forest biodiversity. **Biological**

Conservation, v. 155, p. 136–140, 2012.

TAVARES JÚNIOR, I. da S.; ROCHA, J. E. C. da; EBLING, Â. A.; CHAVES, A. de S.; ZANUNCIO, J. C.; FARIAS, A. A.; LEITE, H. G. Artificial neural networks and linear regression reduce sample intensity to predict the commercial volume of *Eucalyptus* clones. **Forests**, v. 10, n. 3, 2019.

THOMAS, C.; ANDRADE, C. M.; SCHNEIDER, P. R.; FINGER, C. A. G. Comparação de equações volumétricas ajustadas com dados de cubagem e análise de tronco. **Ciência Florestal**, v. 16, p. 319–327, 2006.

THURNHER, C.; KLOPF, M.; HASENAUER, H. MOSES – A tree growth simulator for modelling stand response in Central Europe. **Ecological Modelling**, v. 352, p. 58–76, 2017.

TSIRIKOGLOU, P.; ABRAHAM, S.; CONTINO, F.; LACOR, C.; GHORBANIASL, G. A hyperparameters selection technique for support vector regression models. **Applied Soft Computing Journal**, v. 61, p. 139–148, 2017.

TU, J. V. Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. **Journal of Clinical Epidemiology**, v. 49, n. 11, p. 1225–1231, 1996.

UNIVERSIDADE FEDERAL DE VIÇOSA – UFV. Departamento de Engenharia Agrícola. Estação Climatológica Principal de Viçosa. **Boletim meteorológico 2016**. Viçosa, 2016.

VAHEDI, A. A. Artificial neural network application in comparison with modeling allometric equations for predicting above-ground biomass in the Hyrcanian mixed-beech forests of Iran. **Biomass and Bioenergy**, v. 88, p. 66–76, 2016.

VAN BREUGEL, M.; VAN BREUGEL, P.; JANSEN, P. A.; MARTÍNEZ-RAMOS, M.; BONGERS, F. The relative importance of above- versus belowground competition for tree growth during early succession of a tropical moist forest. **Plant Ecology**, v. 213, n. 1, p. 25–34, 2012.

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

VANDERWEL, M. C.; COOMES, D. A.; PURVES, D. W. Quantifying variation in forest disturbance, and its effects on aboveground biomass dynamics, across the eastern United States. **Global Change Biology**, v. 19, n. 5, p. 1504–1517, 2013.

VAPNIK, V. N. **The nature of statistical learning theory**. New York: Springer, 1995.

VELOSO, H. P.; RANGEL FILHO, A. L. R.; LIMA, J. C. A. **Classificação da vegetação brasileira, adaptada a um sistema universal**. Instituto Brasileiro de Geografia e Estatística (IBGE), Rio de Janeiro, 1991. 123p.

VIEIRA, G. C.; DE MENDONÇA, A. R.; DA SILVA, G. F.; ZANETTI, S. S.; DA SILVA, M. M.; DOS SANTOS, A. R. Prognoses of diameter and height of trees of eucalyptus using artificial intelligence. **Science of the Total Environment**, v. 619–620, p. 1473–1481, 2018.

WANG, J.; LI, L.; NIU, D.; TAN, Z. An annual load forecasting model based on support vector regression with differential evolution algorithm. **Applied Energy**, v. 94, p. 65–70, 2012.

WERE, K.; BUI, D. T.; DICK, Ø. B.; SINGH, B. R. A comparative assessment of support vector regression, artificial neural networks, and random forests for predicting and mapping soil organic carbon stocks across an Afromontane landscape. **Ecological Indicators**, v. 52, p. 394–403, 2015.

WESTREICH, D.; LESSLER, J.; FUNK, M. J. Propensity score estimation: neural networks, support vector machines, decision trees (CART), and meta-classifiers as alternatives to logistic regression. **Journal of Clinical Epidemiology**, v. 63, n. 8, p. 826–833, 2010.

WHEELER, C. E.; OMEJA, P. A.; CHAPMAN, C. A.; GLIPIN, M.; TUMWESIGYE, C.; LEWIS, S. L. Carbon sequestration and biodiversity following 18 years of active tropical forest restoration. **Forest Ecology and Management**, v. 373, p. 44–55, 2016.

XIANG, W.; LEI, X.; ZHANG, X. Modelling tree recruitment in relation to climate and competition in semi-natural *Larix-Picea-Abies* forests in northeast China. **Forest Ecology and Management**, v. 382, p. 100–109, 2016.

XU, B.; PAN, Y.; PLANTE, A. F.; JOHNSON, A.; COLE, J.; BIRDSEY, R. Decadal change of forest biomass carbon stocks and tree demography in the Delaware River Basin. **Forest Ecology and Management**, v. 374, p. 1–10, 2016.

YU, P. S.; YANG, T. C.; CHEN, S. Y.; KUO, C. M.; TSENG, H. W. Comparison of random forests and support vector machine for real-time radar-derived rainfall forecasting. **Journal of Hydrology**, v. 552, p. 92–104, 2017.

ZHANG, Q. B.; HEBDA, R. J.; ZHANG, Q. J.; ALFARO, R. I. Modeling tree-ring growth responses to climatic variables using artificial neural networks. **Forest Science**, v. 46, n. 2, p. 229–239, 2000.

ZHANG, X.; LEI, Y.; CAI, D.; LIU, F. Predicting tree recruitment with negative binomial mixture models. **Forest Ecology and Management**, v. 270, p. 209–215, 2012.

ZHAO, K.; POPESCU, S.; MENG, X.; PANG, Y.; AGCA, M. Characterizing forest canopy structure with lidar composite metrics and machine learning. **Remote Sensing of Environment**, v. 115, n. 8, p. 1978–1996, 2011.

APÊNDICE A – Médias de IPA_{dap} por espécie em cada fragmento

Tabela A1 – Grupo de espécie e média do incremento periódico anual em diâmetro (IPA_{dap}) por espécie no fragmento Cachoeira das Pombas

Nº	Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
1	<i>Acacia glomerosa</i> Benth.	0,0598	A
2	<i>Allophylus</i> sp. 2	0,2334	B
3	<i>Amaioua guianensis</i> Aubl.	0,1695	B
4	<i>Anadenanthera colubrina</i> (Vell.) Brenan	0,1266	A
5	<i>Anadenanthera macrocarpa</i> (Benth.) Brenan	0,0796	A
6	<i>Anadenanthera peregrina</i> (L.) Speg.	0,1507	A
7	<i>Annona cacans</i> Warm.	0,1019	A
8	<i>Annona dolabripetala</i> Raddi	0,2207	B
9	<i>Annona neosericea</i> H.Rainer	0,0562	A
10	<i>Apuleia leiocarpa</i> (Vogel) J.F.Macbr.	0,2690	C
11	<i>Aspidosperma discolor</i> A.DC.	0,2379	B
12	<i>Aspidosperma</i> sp. 2	0,3374	C
13	<i>Astronium concinnum</i> Schott ex Spreng.	0,6119	D
14	<i>Astronium fraxinifolium</i> Schott	0,1719	B
15	<i>Bathysa nicholsonii</i> K. Schum.	0,0558	A
16	<i>Brosimum guianense</i> (Aubl.) Huber	0,2393	B
17	<i>Byrsonima crassifolia</i> (L.) Kunth	0,1304	A
18	<i>Cabrlea canjerana</i> (Vell.) Mart.	0,1401	A
19	<i>Casearia arborea</i> (Rich.) Urb.	0,1775	B
20	<i>Casearia commersoniana</i> Cambess.	0,1895	B
21	<i>Casearia decandra</i> Jacq.	0,1812	B
22	<i>Casearia obliqua</i> Spreng.	0,0934	A
23	<i>Casearia</i> sp. 1	0,0955	A
24	<i>Casearia sylvestris</i> Sw.	0,1252	A
25	<i>Clarisia ilicifolia</i> (Spreng.) Lanj. & Rossberg	0,0658	A
26	<i>Clethra scabra</i> Pers.	0,0149	A
27	<i>Cordia sellowiana</i> Cham.	0,1146	A
28	<i>Coutarea hexandra</i> (Jacq.) K. Schum.	0,1861	B
29	<i>Croton floribundus</i> Spreng.	0,1125	A
30	<i>Croton urucurana</i> Baill.	0,3820	C
31	<i>Cupania oblongifolia</i> Mart.	0,0446	A
32	<i>Cupania</i> sp. 1	0,0724	A
33	<i>Cybistax antisiphilitica</i> (Mart.) Mart.	0,2631	C
34	<i>Dalbergia foliolosa</i> Benth.	0,0307	A
35	<i>Dalbergia nigra</i> (Vell.) Allemão ex Benth.	0,9528	E
36	<i>Dictyoloma vandellianum</i> A. Juss.	0,1952	B
37	<i>Diospyros hispida</i> A. DC.	0,0361	A
38	<i>Diospyros</i> sp. 1	0,0212	A
39	<i>Diploptropis ferruginea</i> Benth.	0,1787	B

Nº	Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
40	<i>Eremanthus erythropappus</i> (DC.) MacLeish	0,1106	A
41	<i>Eriotheca macrophylla</i> (K.Schum.) A.Robyns	0,0212	A
42	<i>Eugenia glazioviana</i> Kiaersk.	0,0547	A
43	<i>Eugenia itajurensis</i> Cambess.	0,2152	B
44	<i>Eugenia sonderiana</i> O.Berg	0,1098	A
45	<i>Eugenia</i> sp. 5	0,1316	A
46	<i>Ficus</i> sp.	0,0637	A
47	<i>Guapira opposita</i> (Vell.) Reitz	0,0318	A
48	<i>Guatteria sellowiana</i> Schltldl.	0,0983	A
49	<i>Heteropterys byrsonimifolia</i> A.Juss.	0,2058	B
50	<i>Himatanthus bracteatus</i> (A.DC.) Woodson	0,0912	A
51	<i>Himatanthus phagedaenicus</i> (Mart.) Woodson	0,0796	A
52	<i>Hortia brasiliiana</i> Vand. ex DC.	0,4414	C
53	<i>Hyptidendron asperrimum</i> (Epling) Harley	0,1060	A
54	<i>Ilex dumosa</i> Reissek	0,0573	A
55	<i>Ilex grandis</i> Reissek	0,1167	A
56	<i>Ilex</i> sp. 1	0,1910	B
57	<i>Inga cylindrica</i> (Vell.) Mart.	0,0934	A
58	<i>Inga subnuda subesp. Subnuda</i> Salzm. ex Benth.	0,0934	A
59	<i>Inga uruguensis</i> Hook. & Arn.	0,3608	C
60	<i>Jacaranda macrantha</i> Cham.	0,1825	B
61	<i>Jacaranda</i> sp. 2	0,0762	A
62	<i>Kielmeyera</i> sp. 1	0,0806	A
63	<i>Lacistema pubescens</i> Mart.	0,0531	A
64	<i>Lafoensia pacari</i> A.St.-Hil	0,1379	A
65	<i>Laplacea tomentosa</i> (Mart.) G.Don	0,1369	A
66	<i>Lauraceae</i> - indeterminada.	0,2228	B
67	<i>Leucochloron incuriale</i> (Vell.) Barneby & J.W.Grimes	0,1040	A
68	<i>Licania kunthiana</i> Hook.f.	0,3470	C
69	<i>Licania spicata</i> Hook. f.	0,0340	A
70	<i>Lonchocarpus</i> sp. 1	0,1358	A
71	<i>Luehea grandiflora</i> Mart.	0,0424	A
72	<i>Lytocaryum weddellianum</i> (H. Wendl.) Toledo	0,0318	A
73	<i>Mabea fistulifera</i> Mart.	0,0828	A
74	<i>Machaerium aculeatum</i> Raddi	0,0566	A
75	<i>Machaerium brasiliense</i> Vogel	0,1121	A
76	<i>Machaerium nyctitans</i> (Vell.) Benth.	0,1086	A
77	<i>Machaerium</i> sp. 1	0,3024	C
78	<i>Machaerium triste</i> Vogel	0,0769	A
79	<i>Machaerium villosum</i> Vogel	0,0325	A
80	<i>Maclura tinctoria</i> (L.) D. Don ex Steud.	0,0271	A
81	<i>Marlierea clauseniana</i> (O.Berg) Kiaersk.	0,0170	A
82	<i>Matayba elaeagnoides</i> Radlk.	0,0637	A
83	<i>Matayba guianensis</i> Aubl.	0,0549	A

Nº	Espécie	IPA_{dap} (cm ano^{-1})	Grupo de espécie
84	<i>Maytenus</i> sp. 2	0,1793	B
85	<i>Maytenus</i> sp. 3	0,0170	A
86	<i>Maytenus</i> sp. 4	0,1947	B
87	<i>Melanoxylon brauna</i> Schott	0,2417	B
88	<i>Miconia</i> sp. 5	0,2186	B
89	<i>Mollinedia</i> sp. 2	0,0764	A
90	<i>Molopanthera paniculata</i> Turcz.	0,2092	B
91	<i>Myrcia amazonica</i> DC.	0,1293	A
92	<i>Myrcia mutabilis</i> (O.Berg) N.Silveira	0,0891	A
93	<i>Myrcia obovata</i> (O.Berg) Nied.	0,1072	A
94	<i>Myrcia</i> sp. 2	0,3289	C
95	<i>Myrcia splendens</i> (Sw.) DC.	0,1130	A
96	<i>Myrcia tomentosa</i> (Aubl.) DC.	0,1040	A
97	<i>Myrsine coriacea</i> (Sw.) R.Br. ex Roem. & Schult.	0,1496	A
98	<i>Myrsine umbellata</i> Mart.	0,0658	A
99	<i>Ocotea corymbosa</i> (Meisn.) Mez	0,0926	A
100	<i>Ocotea pulchella</i> (Nees & Mart.) Mez	0,2506	B
101	<i>Ocotea</i> sp. 9	0,1910	B
102	<i>Pera heteranthera</i> (Schrank) I.M. Johnst.	0,2890	C
103	<i>Phyllostemonodaphne geminiflora</i> (Mez) Kosterm.	0,1273	A
104	<i>Piptadenia gonoacantha</i> (Mart.) J.F. Macbr.	0,3438	C
105	<i>Pithecolobium incuriale</i> (Vell.) Benth.	0,0191	A
106	<i>Plathymentia reticulata</i> Benth.	0,4216	C
107	<i>Platypodium elegans</i> Vogel	0,1287	A
108	<i>Pouteria</i> sp. 3	0,1125	A
109	<i>Pouteria</i> sp. 4	0,2087	B
110	<i>Pouteria torta</i> (Mart.) Radlk.	0,4032	C
111	<i>Protium</i> sp.	0,2706	C
112	<i>Psidium rufum</i> Mart. ex DC.	0,0796	A
113	<i>Rapanea</i> sp.	0,0637	A
114	<i>Roupala montana</i> Aubl.	0,0085	A
115	<i>Simira</i> sp. 1	0,1570	A
116	<i>Simira viridiflora</i> (Allemão & Saldanha) Steyerem.	0,0891	A
117	<i>Siparuna guianensis</i> Aubl.	0,0395	A
118	<i>Sorocea bonplandii</i> (Baill.) W.C. Burger, Lanj. & Wess. Boer	0,4393	C
119	<i>Styrax</i> sp. 1	0,0170	A
120	<i>Swartzia apetala</i> Raddi	0,1197	A
121	<i>Symplocos pubescens</i> Klotzsch ex Benth.	0,2384	B
122	<i>Symplocos</i> sp. 2	0,2108	B
123	<i>Tabebuia chrysotricha</i> (Mart. ex A. DC.) Standl.	0,0382	A
124	<i>Tabernaemontana solanifolia</i> A. DC.	0,2012	B
125	<i>Tachigali rugosa</i> (Mart. ex Benth.) Zarucchi & Pipoly	0,3250	C
126	<i>Tapirira guianensis</i> Aubl.	0,1385	A
127	<i>Tapirira obtusa</i> (Benth.) J.D.Mitch.	0,0430	A

Nº	Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
128	<i>Tibouchina</i> sp. 1	0,5411	D
129	<i>Toulicia laevigata</i> Radlk.	0,1325	A
130	<i>Trichilia pallida</i> Sw.	0,0700	A
131	<i>Vismia brasiliensis</i> Choisy	0,1061	A
132	<i>Vismia guianensis</i> (Aubl.) Choisy	0,0802	A
133	<i>Vitex polygama</i> Cham.	0,0184	A
134	<i>Zanthoxylum rhoifolium</i> Lam.	0,1989	B
135	<i>Zeyheria tuberculosa</i> (Vell.) Bureau	0,1231	A

*Número correspondente no dendrograma da Figura 12.

Tabela A2 – Grupo de espécie e média do incremento periódico anual em diâmetro (IPA_{dap}) por espécie no fragmento Lagoa do Piau

Nº*	Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
1	<i>Abarema brachystachya</i> (DC.) Barneby & J.W.Grimes	0,5051	B
2	<i>Aniba firmula</i> (Nees & Mart.) Mez	0,2525	B
3	<i>Annona dolabripetala</i> Raddi	0,4881	B
4	<i>Apuleia leiocarpa</i> (Vogel) J.F. Macbr.	0,2782	B
5	<i>Aspidosperma parvifolium</i> A.DC.	0,2897	B
6	<i>Astronium fraxinifolium</i> Schott	0,2813	B
7	<i>Bixa arborea</i> Huber	0,2865	B
8	<i>Brosimum guianense</i> (Aubl.) Huber	0,3153	B
9	<i>Byrsonima laxiflora</i> Griseb.	1,2616	E
10	<i>Byrsonima sericea</i> DC.	0,7655	C
11	<i>Byrsonima</i> sp.	0,1273	A
12	<i>Campomanesia</i> sp.	0,3417	B
13	<i>Carpotroche brasiliensis</i> (Raddi) A. Gray	0,2801	B
14	<i>Casearia arborea</i> (Rich.) Urb.	0,2308	B
15	<i>Casearia decandra</i> Jacq.	0,1812	A
16	<i>Casearia</i> sp. 1	0,2610	B
17	<i>Casearia ulmifolia</i> Vahl ex Vent.	0,1379	A
18	<i>Cassia ferruginea</i> (Schrad.) Schrader ex DC.	0,7130	C
19	<i>Cecropia hololeuca</i> Miq.	0,0828	A
20	<i>Cecropia pachystachya</i> Trécul	0,0849	A
21	<i>Chrysophyllum gonocarpum</i> (Mart. & Eichler ex Miq.) Engl.	0,1379	A
22	<i>Connarus</i> sp.	0,1019	A
23	<i>Copaifera langsdorffii</i> Desf.	0,3027	B
24	<i>Cordia fusca</i> M.Stapf	0,2355	B
25	<i>Cordia sellowiana</i> Cham.	0,1427	A
26	<i>Cordia silvestris</i> Fresen.	0,1358	A
27	<i>Crepidospermum atlanticum</i> Daly	0,1974	A
28	<i>Cupania hirsuta</i> Radlk.	0,1210	A
29	<i>Cupania ludowigii</i> Somner & Ferrucci	1,1602	E
30	<i>Cupania oblongifolia</i> Mart.	0,3522	B
31	<i>Dalbergia nigra</i> (Vell.) Allemão ex Benth.	0,3465	B

Nº*	Espécie	IPA _{dap} (cm ano ⁻¹)	Grupo de espécie
32	<i>Eriotheca</i> sp.2	0,5949	C
33	<i>Erythroxylum pelleterianum</i> A. St.-Hil.	0,3825	B
34	<i>Eugenia</i> sp.	1,3751	E
35	<i>Eugenia</i> sp. 5	0,1225	A
36	<i>Eugenia</i> sp. 6	0,2069	A
37	<i>Eugenia</i> sp. 7	0,3714	B
38	<i>Eugenia</i> sp. 9	0,0509	A
39	<i>Eugenia</i> sp. 10	0,1485	A
40	<i>Eugenia</i> sp. 11	1,2987	E
41	<i>Euplassa legalis</i> (Vell.) I.M.Johnst.	0,1719	A
42	<i>Ficus gomelleira</i> Kunth & C.D. Bouché	0,5476	C
43	<i>Geissanthus ambiguus</i> (Mart.) G.Agostini	0,1448	A
44	<i>Guapira opposita</i> (Vell.) Reitz	0,4060	B
45	<i>Guarea macrophylla</i> Vahl	0,1146	A
46	<i>Guarea pendula</i> R.S.Ramalho. A.L. Pinheiro & T.D.Penn.	0,0477	A
47	<i>Guatteria campestris</i> R.E.Fr.	0,3151	B
48	<i>Handroanthus serratifolius</i> (Vahl) S.Grose	0,1188	A
49	<i>Hirtella hebeclada</i> Moric. ex DC.	0,1959	A
50	<i>Hortia brasiliiana</i> Vand. ex DC.	0,3544	B
51	<i>Humirastrum glaziovii</i> (Urb.) Cuatrec.	0,4098	B
52	<i>Ilex dumosa</i> Reissek	0,1910	A
53	<i>Ilex</i> sp. 1	0,9762	D
54	<i>Inga capitata</i> Desv.	0,5730	C
55	<i>Inga cylindrica</i> (Vell.) Mart.	0,2684	B
56	<i>Inga flagelliformis</i> (Vell.) Mart.	0,1443	A
57	<i>Inga stipularis</i> DC.	0,4456	B
58	<i>Lacistema pubescens</i> Mart.	0,2621	B
59	<i>Lecythis lurida</i> (Miers) S.A. Mori	0,3021	B
60	<i>Licania kunthiana</i> Hook.f.	0,5388	C
61	<i>Licania octandra</i> (Hoffmanns. ex Roem. & Schult.) Kuntze	0,4163	B
62	<i>Licania riedelii</i> Prance	0,5675	C
63	<i>Luehea grandiflora</i> Mart.	0,1592	A
64	<i>Mabea fistulifera</i> Mart.	0,1927	A
65	<i>Machaerium triste</i> Vogel	0,1592	A
66	<i>Maprounea guianensis</i> Aubl.	0,4456	B
67	<i>Matayba elaeagnoides</i> Radlk.	0,2568	B
68	<i>Maytenus</i> sp. 1	0,1514	A
69	<i>Melanoxylon brauna</i> Schott	0,2589	B
70	<i>Meliosma itatiaiae</i> Urb.	0,2653	B
71	<i>Miconia budlejoides</i> Triana	0,1273	A
72	<i>Miconia</i> sp. 4	0,1528	A
73	<i>Micropholis gardneriana</i> (A.DC.) Pierre	0,0828	A
74	<i>Myrcia amazonica</i> DC.	0,3714	B
75	<i>Myrcia guianensis</i> (Aubl.) DC.	0,1886	A

Nº*	Espécie	IPA_{dap} (cm ano^{-1})	Grupo de espécie
76	<i>Myrcia</i> sp. 2	0,5305	C
77	<i>Myrcia</i> sp. 3	0,1645	A
78	<i>Myrcia splendens</i> (Sw.) DC.	0,3451	B
79	Myrtaceae - indeterminada 3	0,0743	A
80	<i>Newtonia contorta</i> (DC.) Burkart	0,2600	B
81	<i>Ocotea lanata</i> (Nees & Mart.) Mez	0,3257	B
82	<i>Ocotea nitida</i> (Meisn.) Rohwer	0,0830	A
83	<i>Ocotea odorifera</i> (Vell.) Rohwer	0,4383	B
84	<i>Ocotea</i> sp.	0,0764	A
85	<i>Ocotea</i> sp. 4	0,2398	B
86	<i>Ouratea</i> sp. 2	0,1617	A
87	<i>Pera heteranthera</i> (Schrank) I.M. Johnst.	0,3509	B
88	<i>Persea major</i> (Meisn.) L.E.Kopp	0,2027	A
89	<i>Phyllostemonodaphne geminiflora</i> (Mez) Kosterm.	0,1273	A
90	<i>Piptocarpha macropoda</i> (DC.) Baker	0,7082	C
91	<i>Pourouma guianensis</i> Aubl.	1,2966	E
92	<i>Pouteria macrophylla</i> (Lam.) Eyma	0,3623	B
93	<i>Pouteria ramiflora</i> (Mart.) Radlk.	0,8340	C
94	<i>Pouteria</i> sp.	0,0446	A
95	<i>Pouteria</i> sp. 2	0,1403	A
96	<i>Pouteria torta</i> (Mart.) Radlk.	0,4406	B
97	<i>Protium heptaphyllum</i> (Aubl.) Marchand	0,2546	B
98	<i>Pseudopiptadenia contorta</i> (DC.) G.P.Lewis & M.P.Lima	0,4154	B
99	<i>Psidium</i> sp.	0,1885	A
100	<i>Psidium</i> sp. 2	0,2398	B
101	<i>Psychotria carthagenensis</i> Jacq.	1,1332	E
102	<i>Rollinia sylvatica</i> (A. St.-Hil.) Martius	0,2010	A
103	<i>Schefflera morototoni</i> (Aubl.) Maguire, Steyer. & Frodin	0,5441	C
104	<i>Senefeldera verticillata</i> (Vell.) Croizat	0,6005	C
105	<i>Siparuna guianensis</i> Aubl.	0,1227	A
106	<i>Siparuna reginae</i> (Tul.) A.DC.	0,7491	C
107	<i>Sloanea monosperma</i> Vell.	0,1167	A
108	<i>Solanum swartzianum</i> Roem. & Schult.	0,6366	C
109	<i>Sorocea bonplandii</i> (Baill.) W.C. Burger, Lanj. & Wess. Boer	0,3519	B
110	<i>Sterculia chicha</i> A. St.-Hil. ex Turpin	0,7321	C
111	<i>Stryphnodendron polyphyllum</i> Mart.	0,1082	A
112	<i>Swartzia myrtifolia</i> Sm.	0,1931	A
113	<i>Swartzia pilulifera</i> Benth.	0,2469	B
114	<i>Swartzia</i> sp. 1	0,0785	A
115	<i>Tapirira guianensis</i> Aubl.	0,3891	B
116	<i>Tapirira peckoltiana</i> Engl.	0,4775	B
117	<i>Toulicia laevigata</i> Radlk.	0,3908	B
118	<i>Trichilia lepidota</i> Mart.	0,7958	C
119	<i>Trichilia pallida</i> Sw.	0,2833	B

Nº*	Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
120	<i>Urbanodendron verrucosum</i> (Nees) Mez	0,0549	A
121	<i>Vismia guianensis</i> (Aubl.) Choisy	0,1910	A
122	<i>Vitex megapotamica</i> (Spreng.) Moldenke	0,0347	A
123	<i>Vitex sellowiana</i> Cham.	0,9390	D
124	<i>Xylopia aromatica</i> (Lam.) Mart.	0,6257	C
125	<i>Xylopia sericea</i> A.St.-Hil.	0,5364	C

*Número correspondente no dendrograma da Figura 12.

Tabela A3 – Grupo de espécie e média do incremento periódico anual em diâmetro (IPA_{dap}) por espécie no fragmento São José

Nº*	Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
1	<i>Alchornea glandulosa</i> Poepp.	0,0955	A
2	<i>Alchornea triplinervia</i> (Spreng.) Müll. Arg.	0,1117	A
3	<i>Amaioua guianensis</i> Aubl.	0,0764	A
4	<i>Anadenanthera colubrina</i> (Vell.) Brenan	0,1810	B
5	<i>Andira fraxinifolia</i> Benth.	0,0796	A
6	<i>Aniba</i> sp. 1	0,4244	C
7	<i>Annona cacans</i> Warm.	0,0856	A
8	<i>Aparisthium cordatum</i> (A. Juss.) Baill.	0,1082	A
9	<i>Apuleia leiocarpa</i> (Vogel) J.F. Macbr.	0,0637	A
10	<i>Aspidosperma subincanum</i> Mart. ex A. DC.	0,2706	B
11	<i>Bathysa australis</i> (A. St.-Hil.) Hook. f. ex K. Schum.	0,0280	A
12	<i>Brosimum glaziovii</i> Taub.	0,3204	B
13	<i>Byrsonima ligustrifolia</i> A.Juss.	0,1804	B
14	<i>Cabralea canjerana</i> (Vell.) Mart.	0,2165	B
15	<i>Calypttranthes brasiliensis</i> Spreng.	0,2016	B
16	<i>Cariniana estrellensis</i> (Raddi) Kuntze	0,5899	D
17	<i>Carpotroche brasiliensis</i> (Raddi) A. Gray	0,3077	B
18	<i>Casearia grandiflora</i> Cambess.	0,1350	A
19	<i>Casearia javitensis</i> Kunth	0,3395	B
20	<i>Casearia arborea</i> (Rich.) Urb.	0,1245	A
21	<i>Cecropia hololeuca</i> Miq.	0,1167	A
22	<i>Chrysophyllum lucentifolium</i> Cronquist	0,1061	A
23	<i>Citronella paniculata</i> (Mart.) R.A.Howard	0,2398	B
24	<i>Clethra scabra</i> Pers.	0,2286	B
25	<i>Copaifera langsdorffii</i> Desf.	0,0743	A
26	<i>Coussarea hydrangeifolia</i> (Benth.) Müll.Arg.	0,0743	A
27	<i>Coussarea nodosa</i> (Benth.) Müll.Arg.	0,1853	B
28	<i>Cupania ludowigii</i> Somner & Ferrucci	0,1613	B
29	<i>Dictyoloma vandellianum</i> A. Juss.	0,1231	A
30	<i>Diploon cuspidatum</i> (Hoehne) Cronquist	0,0700	A
31	<i>Eriotheca</i> sp. 1	0,0531	A
32	<i>Eugenia</i> sp. 4	0,0318	A
33	<i>Ferdinandusa speciosa</i> (Pohl) Pohl	0,1248	A

Nº*	Espécie	IPA _{dap} (cm ano ⁻¹)	Grupo de espécie
34	<i>Gomidesia</i> sp. 3	0,1273	A
35	<i>Guapira opposita</i> (Vell.) Reitz	0,0756	A
36	<i>Guarea pendula</i> R.S. Ramalho, A.L. Pinheiro & T.D. Penn.	0,0944	A
37	<i>Guatteria australis</i> A.St.-Hil.	0,0626	A
38	<i>Guatteria campestris</i> R.E.Fr.	0,0533	A
39	<i>Guatteria sellowiana</i> Schtdl.	0,0265	A
40	<i>Guatteria villosissima</i> A. St.-Hil.	0,0854	A
41	<i>Handroanthus serratifolius</i> (Vahl) S.Grose	0,0477	A
42	<i>Heisteria</i> sp. 1	0,1669	B
43	<i>Hirtella</i> sp. 1	0,0771	A
44	<i>Hortia brasiliana</i> Vand. ex DC.	0,2472	B
45	<i>Hymenolobium janeirense</i> Kuhlm.	0,0488	A
46	<i>Ilex grandis</i> Reissek	0,1698	B
47	<i>Ilex paraguariensis</i> A.St.-Hil.	0,1804	B
48	<i>Ilex cerasifolia</i> Reissek	0,0615	A
49	<i>Inga subnuda</i> Salzm. ex Benth.subesp. <i>subnuda</i>	0,2525	B
50	<i>Inga cylindrica</i> (Vell.) Mart.	0,2175	B
51	<i>Inga thibaudiana</i> DC.	0,1103	A
52	<i>Jacaranda macrantha</i> Cham.	0,0831	A
53	<i>Kielmeyera altissima</i> Saddi	0,3045	B
54	<i>Ladenbergia hexandra</i> (Pohl) Klotzsch	0,4732	C
55	<i>Lamanonia ternata</i> Vell.	0,0637	A
56	<i>Licaria armeniaca</i> (Nees) Kosterm.	0,0531	A
57	<i>Lytocaryum weddellianum</i> (H. Wendl.) Toledo	0,0318	A
58	<i>Machaerium brasiliense</i> Vogel	0,1401	A
59	<i>Machaerium nyctitans</i> (Vell.) Benth.	0,1490	A
60	<i>Machaerium aculeatum</i> Raddi	0,3820	C
61	<i>Maprounea guianensis</i> Aubl.	0,2766	B
62	<i>Matayba guianensis</i> Aubl.	0,1846	B
63	<i>Melanoxylon brauna</i> Schott	0,4838	C
64	<i>Melastomataceae</i> - indeterminada 1	0,1126	A
65	<i>Miconia budlejoides</i> Triana	0,2333	B
66	<i>Miconia</i> cf. <i>rufipila</i> Triana	0,0584	A
67	<i>Miconia cinnamomifolia</i> (DC.) Naudin	0,3066	B
68	<i>Miconia corallina</i> Spring	0,1210	A
69	<i>Miconia paucidens</i> DC.	0,2463	B
70	<i>Miconia</i> sp. 1	0,0796	A
71	<i>Miconia pusilliflora</i> (DC.) Naudin	0,0764	A
72	<i>Miconia sellowiana</i> Naudin	0,1114	A
73	<i>Myrcia guianensis</i> (Aubl.) DC.	0,0446	A
74	<i>Myrcia</i> sp.	0,1379	A
75	<i>Myrcia</i> sp. 2	0,1146	A
76	<i>Myrcia splendens</i> (Sw.) DC.	0,1954	B
77	<i>Myrcia anceps</i> O. Berg	0,0318	A

Nº*	Espécie	IPA _{dap} (cm ano ⁻¹)	Grupo de espécie
78	<i>Myrsine umbellata</i> Mart.	0,0817	A
79	<i>Myrtaceae</i> - indeterminada 1	0,2525	B
80	<i>Nectandra oppositifolia</i> Nees & Mart.	0,4647	C
81	<i>Ocotea aciphylla</i> (Nees & Mart.) Mez	0,3417	B
82	<i>Ocotea dispersa</i> (Nees & Mart.) Mez	0,0828	A
83	<i>Ocotea divaricata</i> (Nees) Mez	0,1687	B
84	<i>Ocotea glomerata</i> (Nees) Mez	0,0700	A
85	<i>Ocotea longifolia</i> Kunth	0,1638	B
86	<i>Ocotea</i> sp. 2	0,0637	A
87	<i>Parinari excelsa</i> Sabine	0,0743	A
88	<i>Persea major</i> (Meisn.) L.E.Kopp	0,4598	C
89	<i>Phyllostemonodaphne geminiflora</i> (Mez) Kosterm.	0,0637	A
90	<i>Piptocarpha macropoda</i> (DC.) Baker	0,5029	C
91	<i>Posoqueria latifolia</i> (Rudge) Schult.	0,0318	A
92	<i>Pouteria ramiflora</i> (Mart.) Radlk.	0,1273	A
93	<i>Pouteria</i> sp. 1	0,0743	A
94	<i>Pouteria torta</i> (Mart.) Radlk.	0,0700	A
95	<i>Psidium rufum</i> Mart. ex DC.	0,0955	A
96	<i>Psidium</i> sp. 2	0,0732	A
97	<i>Psychotria</i> sp.	0,0891	A
98	<i>Psychotria vellosiana</i> Benth.	0,1999	B
99	<i>Qualea gestasiana</i> A.St.-Hil.	0,2737	B
100	<i>Rapanea umbellata</i> (Mart.) Mez	0,0775	A
101	<i>Rollinia sylvatica</i> (A. St.-Hil.) Martius	0,0955	A
102	<i>Roupala montana</i> Aubl.	0,0785	A
103	<i>Schizocalyx cuspidatus</i> (A.St.-Hil.) Kainul. & B. Bremer	0,0688	A
104	<i>Senna macranthera</i> (DC. ex Collad.) H.S. Irwin & Barneby	0,0212	A
105	<i>Senna multijuga</i> (Rich.) H.S. Irwin & Barneby	0,1146	A
106	<i>Siparuna reginae</i> (Tul.) A.DC.	0,2346	B
107	<i>Siparuna</i> sp.	0,0637	A
108	<i>Siparuna guianensis</i> Aubl.	0,0955	A
109	<i>Sloanea retusa</i> Uittien	0,0934	A
110	<i>Solanaceae</i> - indeterminada	0,0424	A
111	<i>Solanum</i> sp. 2	0,0637	A
112	<i>Solanum swartzianum</i> Roem. & Schult.	0,2037	B
113	<i>Sorocea bonplandii</i> (Baill.) W.C. Burger, Lanj. & Wess. Boer	0,1167	A
114	<i>Sparattosperma leucanthum</i> (Vell.) K. Schum.	0,0594	A
115	<i>Stryphnodendron polyphyllum</i> Mart.	0,5602	D
116	<i>Swartzia oblata</i> R.S.Cowan	0,2115	B
117	<i>Syagrus</i> sp. 1	0,0424	A
118	<i>Tachigali friburgensis</i> (Harms) L.G.Silva & H.C.Lima	0,7374	E
119	<i>Tachigali rugosa</i> (Mart. ex Benth.) Zarucchi & Pipoly	0,4287	C
120	<i>Tapirira guianensis</i> Aubl.	0,2065	B
121	<i>Terminalia glabrescens</i> Mart.	0,7852	E

Nº*	Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
122	<i>Tetrastylidium grandifolium</i> (Baill.) Sleumer	0,1220	A
123	<i>Tibouchina</i> sp.	0,0637	A
124	<i>Tibouchina granulosa</i> (Desr.) Cogn.	0,2110	B
125	<i>Toulicia laevigata</i> Radlk.	0,0912	A
126	<i>Trichilia catigua</i> A.Juss.	0,1103	A
127	<i>Urbanodendron verrucosum</i> (Nees) Mez	0,1263	A
128	<i>Vernonia diffusa</i> Less.	0,3438	B
129	<i>Virola bicuhyba</i> (Schott ex Spreng.) Warb.	0,0877	A
130	<i>Vismia martiana</i> Reichardt	0,1436	A
131	<i>Vismia guianensis</i> (Aubl.) Choisy	0,0428	A
132	<i>Xylopia brasiliensis</i> Spreng.	0,0964	A

*Número correspondente no dendrograma da Figura 12.

Tabela A4 – Grupo de espécie e média do incremento periódico anual em diâmetro (IPA_{dap}) por espécie no fragmento Mata da Silvicultura

Nº*	Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
1	<i>Albizia polycephala</i> (Benth.) Killip ex Record	0,1340	A
2	<i>Alchornea glandulosa</i> Poepp. & Endl.	0,0159	A
3	<i>Alchornea iricurana</i> Casar.	0,0183	A
4	<i>Alchornea triplinervia</i> (Spreng.) Müll.Arg.	0,3102	B
5	<i>Allophylus edulis</i> (A.St.-Hil. et al.) Hieron. ex Niederl.	0,0970	A
6	<i>Amaioua guianensis</i> Aubl.	0,2945	B
7	<i>Anadenanthera colubrina</i> (Vell.) Brenan	0,3961	C
8	<i>Anadenanthera peregrina</i> (L.) Speng.	0,3204	B
9	<i>Andira fraxinifolia</i> Benth.	0,0893	A
10	<i>Aparisthium cordatum</i> (A.Juss.) Baill.	0,2134	B
11	<i>Apuleia leiocarpa</i> (Vogel) J.F.Macbr.	0,1662	B
12	<i>Aspidosperma pyriforme</i> Mart. & Zucc.	0,4490	C
13	<i>Attalea dubia</i> (Mart.) Burret	0,1442	A
14	<i>Bathysa nicholsonii</i> K.Schum.	0,1201	A
15	<i>Brosimum sellowii</i> Koehn.	0,1161	A
16	<i>Camelia sinensis</i> (L.) Kuntze	0,0228	A
17	<i>Campomanesia xanthocarpa</i> (Mart.) O.Berg	0,0707	A
18	<i>Cariniana estrellensis</i> (Raddi) Kuntze	0,5375	C
19	<i>Carpotroche brasiliensis</i> (Raddi) A Gray	0,1255	A
20	<i>Casearia arborea</i> (Rich.) Urb.	0,2917	B
21	<i>Casearia decandra</i> Jacq.	0,0492	A
22	<i>Casearia sylvestris</i> Sw.	0,2277	B
23	<i>Casearia ulmifolia</i> Vahl ex Vent.	0,1705	B
24	<i>Cecropia hololeuca</i> Miq.	0,2248	B
25	<i>Chrysophyllum gonocarpum</i> (Mart. & Eichler ex Miq.) Engl.	0,1965	B
26	<i>Citrus</i> sp.	0,3773	C
27	<i>Copaifera langsdorffii</i> Desf.	0,2098	B
28	<i>Cordia sellowiana</i> Cham.	0,0491	A

Nº*	Espécie	IPA _{dap} (cm ano ⁻¹)	Grupo de espécie
29	<i>Coussarea verticillata</i> Müll.Arg.	0,1079	A
30	<i>Coutarea hexandra</i> (Jacq.) K.Schum.	0,0906	A
31	<i>Croton urucurana</i> Baill.	0,8930	D
32	<i>Dalbergia nigra</i> (Vell.) Allemão ex Benth.	0,1952	B
33	<i>Endlicheria paniculata</i> (Spreng.) J.F.Macbr.	0,0846	A
34	<i>Eriotheca candolleana</i> (K.Schum.) A.Robyns	0,0604	A
35	<i>Erythroxylum pelleterianum</i> A.St.-Hil.	0,1316	A
36	<i>Eugenia diantha</i> O.Berg	0,0624	A
37	<i>Eugenia leptoclada</i> O.Berg	0,1130	A
38	<i>Guapira opposita</i> (Vell.) Reitz	0,0685	A
39	<i>Guatteria australis</i> A.St.-Hil.	0,2432	B
40	<i>Guatteria nigrescens</i> Mart.	0,3448	B
41	<i>Guatteria villosissima</i> A.St.-Hil.	0,0869	A
42	<i>Guettarda viburnoides</i> Cham. & Schltdl.	0,1003	A
43	<i>Heisteria silvianii</i> Schwacke	0,1480	A
44	<i>Hieronyma alchorneoides</i> Allemão	0,1785	B
45	<i>Hillia tubiflora</i> Cham.	0,3186	B
46	<i>Himatanthus phagedaenicus</i> (Mart.) Woodson	0,2005	B
47	<i>Hortia arborea</i> Engl.	0,1744	B
48	<i>Inga affinis</i> DC.	0,4605	C
49	<i>Inga alba</i> (Sw.) Willd.	0,2457	B
50	<i>Inga fagifolia</i> Willd. ex Benth.	0,0843	A
51	<i>Jacaranda macrantha</i> Cham.	0,1006	A
52	<i>Lacistema pubescens</i> Mart.	0,1215	A
53	<i>Lamanonia ternata</i> Vell.	0,0625	A
54	<i>Lauraceae</i> - indeterminada 1	0,2299	B
55	<i>Luehea grandiflora</i> Mart.	0,0068	A
56	<i>Luehea speciosa</i> Willd	0,1771	B
57	<i>Mabea fistulifera</i> Mart.	0,1679	B
58	<i>Machaerium brasiliense</i> Vogel	0,2544	B
59	<i>Machaerium floridum</i> (Mart. ex Benth.) Ducke	0,1323	A
60	<i>Machaerium stipitatum</i> Vogel	0,0928	A
61	<i>Maprounea guianensis</i> Aubl.	0,1855	B
62	<i>Marlierea</i> sp.	0,4124	C
63	<i>Matayba elaeagnoides</i> Radlk.	0,2812	B
64	<i>Maytenus robusta</i> Reissek	0,4030	C
65	<i>Melanoxylon brauna</i> Schott	0,0850	A
66	<i>Miconia candolleana</i> Triana	0,1008	A
67	<i>Miconia cinnamomifolia</i> (DC.) Naudin	0,4145	C
68	<i>Miconia sellowiana</i> Naudin	0,1936	B
69	<i>Mollinedia micrantha</i> Perkins	0,0495	A
70	<i>Myrcia anceps</i> (Spreng.) O.Berg	0,0573	A
71	<i>Myrcia fallax</i> (Rich.) DC.	0,0449	A
72	<i>Myrcia formosiana</i> DC.	0,1389	A

Nº*	Espécie	IPA _{dap} (cm ano ⁻¹)	Grupo de espécie
73	<i>Myrcia</i> sp.	0,4748	C
74	<i>Myrcia tomentosa</i> (Aubl.) DC.	0,0629	A
75	<i>Myrciaria</i> sp.	0,0584	A
76	<i>Nectandra lanceolata</i> Nees	0,7517	D
77	<i>Nectandra rigida</i> (Kunth) Nees	0,1525	A
78	<i>Nectandra</i> sp.	0,2971	B
79	<i>Newtonia contorta</i> (DC.) Burk	0,3256	B
80	<i>Ocotea corymbosa</i> (Meisn.) Mez	0,1483	A
81	<i>Ocotea dispersa</i> (Nees & Mart.) Mez	0,2314	B
82	<i>Ocotea odorifera</i> (Vell.) Rohwer	0,2536	B
83	<i>Ocotea pubescens</i> Nees	0,1088	A
84	<i>Palicourea guianensis</i> Aubl.	0,0850	A
85	<i>Persea pyrifolia</i> Nees & Mart.	0,2600	B
86	<i>Phyllostemonodaphne geminiflora</i> (Mez) Kosterm.	0,2175	B
87	<i>Pimenta pseudocaryophyllus</i> (Gomes) Landrum	0,0663	A
88	<i>Piptadenia gonoacantha</i> (Mart.) J.F.Macbr.	0,1948	B
89	<i>Platymiscium pubescens</i> Micheli	0,2291	B
90	<i>Platypodium elegans</i> Vogel	0,0988	A
91	<i>Prunus sellowii</i> Koehne	0,1818	B
92	<i>Psidium cattleyanum</i> Sabine	0,1512	A
93	<i>Psychotria carthagenensis</i> Jacq.	0,5028	C
94	<i>Psychotria</i> sp.	0,1273	A
95	<i>Qualea jundiahy</i> Warm.	0,1610	B
96	<i>Rapanea umbellata</i> (Mart.) Mez	0,1173	A
97	<i>Remijia</i> sp.	0,1751	B
98	<i>Rheedia gardneriana</i> Planch. & Triana	0,0634	A
99	<i>Rollinia laurifolia</i> Schldtl.	0,2838	B
100	<i>Rollinia sylvatica</i> (A.St.-Hil.) Mart.	0,1625	B
101	<i>Rudgea lanceolata</i> (Schldtl. & Cham.) Benth.	0,0464	A
102	<i>Schefflera morototoni</i> (Aubl.) Maguire et al.	0,8092	D
103	<i>Siparuna guianensis</i> Aubl.	0,0878	A
104	<i>Siparuna reginae</i> (Tul.) A.DC.	0,4418	C
105	<i>Sloanea monosperma</i> Vell.	0,2992	B
106	<i>Solanum leucodendron</i> Sendtn.	0,1017	A
107	<i>Sorocea bonplandii</i> (Baill.) W.C.Burger et al.	0,1931	B
108	<i>Sparattosperma leucanthum</i> (Vell.) K.Schum	0,0618	A
109	<i>Stryphnodendron guianense</i> (Aubl.) Benth.	0,3285	B
110	<i>Swartzia elegans</i> Schott	0,0371	A
111	<i>Swartzia myrtifolia</i> Sm.	0,2180	B
112	<i>Tabernaemontana fuchsiaefolia</i> A. DC	1,0652	E
113	<i>Tapirira guianensis</i> Aubl.	0,0177	A
114	<i>Tapirira peckoltiana</i> Engl.	0,2406	B
115	<i>Tibouchina granulosa</i> (Desr.) Cogn.	0,2152	B
116	<i>Tovomitopsis saldanhae</i> Engl.	0,2280	B

Nº*	Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
117	<i>Trattinnickia ferruginea</i> Kuhlms.	0,1125	A
118	<i>Trichilia catigua</i> A.Juss.	0,2787	B
119	<i>Trichilia clausenii</i> C.DC.	0,3780	C
120	<i>Trichilia lepidota</i> Mart.	0,0924	A
121	<i>Trichilia pallida</i> Sw.	0,1881	B
122	<i>Urbanodendron verrucosum</i> (Nees) Mez	0,1046	A
123	<i>Vernonia diffusa</i> Less.	0,5327	C
124	<i>Vitex sellowiana</i> Cham.	0,3045	B
125	<i>Zanthoxylum riedelianum</i> Engl.	0,0133	A

*Número correspondente no dendrograma da Figura 12.

Tabela A5 – Grupo de espécie e média do incremento periódico anual em diâmetro (IPA_{dap}) por espécie em todos os fragmentos (Cachoeira das Pombas, Lagoa do Piau e São José)

Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
<i>Abarema brachystachya</i> (DC.) Barneby & J.W.Grimes	0,9091	D
<i>Acacia glomerosa</i> Benth.	0,0748	A
<i>Alchornea glandulosa</i> Poepp.	0,1910	A
<i>Alchornea triplinervia</i> (Spreng.) Müll. Arg.	0,1365	A
<i>Allophylus</i> sp. 2	0,2334	B
<i>Amaioua guianensis</i> Aubl.	0,1643	A
<i>Anadenanthera colubrina</i> (Vell.) Brenan	0,1689	A
<i>Anadenanthera macrocarpa</i> (Benth.) Brenan	0,1592	A
<i>Anadenanthera peregrina</i> (L.) Speg.	0,2260	B
<i>Anadenanthera colubrina</i> (Vell.) Brenan	0,1900	A
<i>Andira fraxinifolia</i> Benth.	0,0796	A
<i>Aniba firmula</i> (Nees & Mart.) Mez	0,3067	B
<i>Aniba</i> sp. 1	0,4244	B
<i>Annona cacans</i> Warm.	0,1528	A
<i>Annona dolabripetala</i> Raddi	0,3544	B
<i>Annona neosericea</i> H.Rainer	0,0750	A
<i>Annona cacans</i> Warm.	0,1185	A
<i>Aparisthium cordatum</i> (A. Juss.) Baill.	0,1207	A
<i>Apuleia leiocarpa</i> (Vogel) J.F. Macbr.	0,3867	B
<i>Aspidosperma discolor</i> A.DC.	0,2379	B
<i>Aspidosperma parvifolium</i> A.DC.	0,2897	B
<i>Aspidosperma</i> sp. 2	0,3374	B
<i>Aspidosperma subincanum</i> Mart. ex A. DC.	0,2706	B
<i>Astronium concinnum</i> Schott ex Spreng.	0,6119	C
<i>Astronium fraxinifolium</i> Schott	0,3100	B
<i>Bathysa nicholsonii</i> K. Schum.	0,0632	A
<i>Bathysa australis</i> (A. St.-Hil.) Hook. f. ex K. Schum.	0,0280	A
<i>Bixa arborea</i> Huber	0,2865	B

Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
<i>Brosimum glaziovii</i> Taub.	0,3204	B
<i>Brosimum guianense</i> (Aubl.) Huber	0,3363	B
<i>Byrsonima crassifolia</i> (L.) Kunth	0,1351	A
<i>Byrsonima laxiflora</i> Griseb.	1,2616	E
<i>Byrsonima ligustrifolia</i> A.Juss.	0,1804	A
<i>Byrsonima sericea</i> DC.	0,7655	D
<i>Byrsonima</i> sp.	0,2546	B
<i>Cabralea canjerana</i> (Vell.) Mart.	0,1783	A
<i>Calypttranthes brasiliensis</i> Spreng.	0,2016	A
<i>Campomanesia</i> sp.	0,5125	C
<i>Cariniana estrellensis</i> (Raddi) Kuntze	0,5899	C
<i>Carpotroche brasiliensis</i> (Raddi) A. Gray	0,2939	B
<i>Casearia arborea</i> (Rich.) Urb.	0,2649	B
<i>Casearia commersoniana</i> Cambess.	0,1895	A
<i>Casearia decandra</i> Jacq.	0,1997	A
<i>Casearia grandiflora</i> Cambess.	0,1350	A
<i>Casearia javitensis</i> Kunth	0,3395	B
<i>Casearia obliqua</i> Spreng.	0,0934	A
<i>Casearia</i> sp. 1	0,1783	A
<i>Casearia sylvestris</i> Sw.	0,1252	A
<i>Casearia ulmifolia</i> Vahl ex Vent.	0,2759	B
<i>Casearia arborea</i> (Rich.) Urb.	0,1245	A
<i>Cassia ferruginea</i> (Schrad.) Schrader ex DC.	0,7130	D
<i>Cecropia hololeuca</i> Miq.	0,1035	A
<i>Cecropia pachystachya</i> Trécul	0,0849	A
<i>Cecropia hololeuca</i> Miq.	0,1167	A
<i>Chrysophyllum gonocarpum</i> (Mart. & Eichler ex Miq.) Engl.	0,2069	A
<i>Chrysophyllum lucentifolium</i> Cronquist	0,1061	A
<i>Citronella paniculata</i> (Mart.) R.A.Howard	0,2398	B
<i>Clarisia ilicifolia</i> (Spreng.) Lanj. & Rossberg	0,0846	A
<i>Clethra scabra</i> Pers.	0,1969	A
<i>Connarus</i> sp.	0,1019	A
<i>Copaifera langsdorffii</i> Desf.	0,3684	B
<i>Cordia fusca</i> M.Stapf	0,2355	B
<i>Cordia sellowiana</i> Cham.	0,1574	A
<i>Cordia silvestris</i> Fresen.	0,1358	A
<i>Coussarea hydrangeifolia</i> (Benth.) Müll.Arg.	0,0743	A
<i>Coussarea nodosa</i> (Benth.) Müll.Arg.	0,1853	A
<i>Coutarea hexandra</i> (Jacq.) K. Schum.	0,1861	A
<i>Crepidospermum atlanticum</i> Daly	0,1974	A
<i>Croton floribundus</i> Spreng.	0,1687	A
<i>Croton urucurana</i> Baill.	0,3820	B

Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
<i>Cupania hirsuta</i> Radlk.	0,1583	A
<i>Cupania ludowigii</i> Somner & Ferrucci	0,5539	C
<i>Cupania oblongifolia</i> Mart.	0,5020	C
<i>Cupania</i> sp.1	0,0724	A
<i>Cybistax antisiphilitica</i> (Mart.) Mart.	0,2631	B
<i>Dalbergia foliolosa</i> Benth.	0,0505	A
<i>Dalbergia nigra</i> (Vell.) Allemão ex Benth.	0,6263	C
<i>Dictyoloma vandellianum</i> A. Juss.	0,1471	A
<i>Diospyros hispida</i> A. DC.	0,0541	A
<i>Diospyros</i> sp.1	0,0637	A
<i>Diploon cuspidatum</i> (Hoehne) Cronquist	0,0700	A
<i>Diplostropis ferruginea</i> Benth.	0,1925	A
<i>Eremanthus erythropappus</i> (DC.) MacLeish	0,1428	A
<i>Eriotheca macrophylla</i> (K.Schum.) A.Robyns	0,1273	A
<i>Eriotheca</i> sp. 1	0,0531	A
<i>Eriotheca</i> sp.2	0,5949	C
<i>Erythroxyllum pelleterianum</i> A. St.-Hil.	0,3999	B
<i>Eugenia glazioviana</i> Kiaersk.	0,2546	B
<i>Eugenia itajurensis</i> Cambess.	0,2152	A
<i>Eugenia sonderiana</i> O.Berg	0,1198	A
<i>Eugenia</i> sp.	1,3751	E
<i>Eugenia</i> sp. 10	0,1485	A
<i>Eugenia</i> sp. 11	1,2987	E
<i>Eugenia</i> sp. 4	0,0955	A
<i>Eugenia</i> sp. 5	0,1264	A
<i>Eugenia</i> sp. 6	0,2069	A
<i>Eugenia</i> sp. 7	0,3714	B
<i>Eugenia</i> sp. 9	0,0509	A
<i>Euplassa legalis</i> (Vell.) I.M.Johnst.	0,2578	B
<i>Ferdinandusa speciosa</i> (Pohl) Pohl	0,1560	A
<i>Ficus gomelleira</i> Kunth & C.D. Bouché	0,6411	C
<i>Ficus</i> sp.	0,0637	A
<i>Geissanthus ambiguus</i> (Mart.) G.Agostini	0,1448	A
<i>Gomidesia</i> sp. 3	0,1273	A
<i>Guapira opposita</i> (Vell.) Reitz	0,3203	B
<i>Guarea macrophylla</i> Vahl	0,1146	A
<i>Guarea pendula</i> R.S.Ramalho. A.L. Pinheiro & T.D.Penn.	0,0828	A
<i>Guatteria australis</i> A.St.-Hil.	0,0751	A
<i>Guatteria campestris</i> R.E.Fr.	0,1783	A
<i>Guatteria sellowiana</i> Schldl.	0,1138	A
<i>Guatteria villosissima</i> A. St.-Hil.	0,0955	A
<i>Handroanthus serratifolius</i> (Vahl) S.Grose	0,1666	A

Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
<i>Heisteria</i> sp. 1	0,1706	A
<i>Heteropterys byrsonimifolia</i> A.Juss.	0,2058	A
<i>Himatanthus bracteatus</i> (A.DC.) Woodson	0,0912	A
<i>Himatanthus phagedaenicus</i> (Mart.) Woodson	0,0796	A
<i>Hirtella hebeclada</i> Moric. ex DC.	0,1959	A
<i>Hirtella</i> sp. 1	0,0867	A
<i>Hortia brasiliana</i> Vand. ex DC.	0,3532	B
<i>Humiriastrum glaziovii</i> (Urb.) Cuatrec.	0,4098	B
<i>Hymenolobium janeirense</i> Kuhlm.	0,0488	A
<i>Hyptidendron asperrimum</i> (Epling) Harley	0,1483	A
<i>Ilex dumosa</i> Reissek	0,1241	A
<i>Ilex grandis</i> Reissek	0,1432	A
<i>Ilex paraguariensis</i> A.St.-Hil.	0,1804	A
<i>Ilex</i> sp. 1	0,6621	C
<i>Ilex cerasifolia</i> Reissek	0,0615	A
<i>Inga capitata</i> Desv.	0,5730	C
<i>Inga cylindrica</i> (Vell.) Mart.	0,1751	A
<i>Inga flagelliformis</i> (Vell.) Mart.	0,1443	A
<i>Inga stipularis</i> DC.	0,8913	D
<i>Inga subnuda</i> Salzm. ex Benth. subesp. <i>subnuda</i>	0,2321	B
<i>Inga uruguensis</i> Hook. & Arn.	0,3608	B
<i>Inga cylindrica</i> (Vell.) Mart.	0,2175	A
<i>Inga thibaudiana</i> DC.	0,1103	A
<i>Jacaranda macrantha</i> Cham.	0,1135	A
<i>Jacaranda</i> sp. 2	0,0952	A
<i>Kielmeyera altissima</i> Saddi	0,3045	B
<i>Kielmeyera</i> sp. 1	0,0806	A
<i>Lacistema pubescens</i> Mart.	0,2142	A
<i>Ladenbergia hexandra</i> (Pohl) Klotzsch	0,4732	C
<i>Lafoensia pacari</i> A.St.-Hil	0,1379	A
<i>Lamanonia ternata</i> Vell.	0,0637	A
<i>Laplacea tomentosa</i> (Mart.) G.Don	0,1369	A
<i>Lauraceae</i> - indeterminada	0,2228	B
<i>Lecythis lurida</i> (Miers) S.A. Mori	0,3560	B
<i>Leucochloron incuriale</i> (Vell.) Barneby & J.W.Grimes	0,1170	A
<i>Licania kunthiana</i> Hook.f.	0,5093	C
<i>Licania octandra</i> (Hoffmanns. ex Roem. & Schult.) Kuntze	0,4461	B
<i>Licania riedelii</i> Prance	0,5675	C
<i>Licania spicata</i> Hook. f.	0,0340	A
<i>Licaria armeniaca</i> (Nees) Kosterm.	0,0682	A
<i>Lonchocarpus</i> sp. 1	0,2037	A
<i>Luehea grandiflora</i> Mart.	0,1432	A

Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
<i>Lytocaryum weddellianum</i> (H. Wendl.) Toledo	0,0424	A
<i>Mabea fistulifera</i> Mart.	0,1938	A
<i>Machaerium aculeatum</i> Raddi	0,1019	A
<i>Machaerium brasiliense</i> Vogel	0,1387	A
<i>Machaerium nycitans</i> (Vell.) Benth.	0,1276	A
<i>Machaerium</i> sp. 1	0,4032	B
<i>Machaerium triste</i> Vogel	0,1487	A
<i>Machaerium villosum</i> Vogel	0,1464	A
<i>Machaerium aculeatum</i> Raddi	0,3820	B
<i>Maclura tinctoria</i> (L.) D. Don ex Steud.	0,0541	A
<i>Maprounea guianensis</i> Aubl.	0,2935	B
<i>Marlierea clausseniana</i> (O.Berg) Kiaersk.	0,0255	A
<i>Matayba elaeagnoides</i> Radlk.	0,2780	B
<i>Matayba guianensis</i> Aubl.	0,0970	A
<i>Maytenus</i> sp. 1	0,1514	A
<i>Maytenus</i> sp. 2	0,1793	A
<i>Maytenus</i> sp. 3	0,0509	A
<i>Maytenus</i> sp. 4	0,1947	A
<i>Melanoxylon brauna</i> Schott	0,2792	B
<i>Melastomataceae</i> - indeterminada 1	0,1126	A
<i>Meliosma itatiaiae</i> Urb.	0,2653	B
<i>Miconia budlejoides</i> Triana	0,2292	B
<i>Miconia cinnamomifolia</i> (DC.) Naudin	0,0875	A
<i>Miconia corallina</i> Spring	0,3066	B
<i>Miconia paucidens</i> DC.	0,1210	A
<i>Miconia rufipila</i> Triana	0,2646	B
<i>Miconia</i> sp. 1	0,0796	A
<i>Miconia</i> sp. 4	0,1528	A
<i>Miconia</i> sp. 5	0,2459	B
<i>Miconia pusilliflora</i> (DC.) Naudin	0,0764	A
<i>Miconia sellowiana</i> Naudin	0,1114	A
<i>Micropholis gardneriana</i> (A.DC.) Pierre	0,0828	A
<i>Mollinedia</i> sp.2	0,0891	A
<i>Molopanthera paniculata</i> Turcz.	0,2092	A
<i>Myrcia amazonica</i> DC.	0,1378	A
<i>Myrcia guianensis</i> (Aubl.) DC.	0,2053	A
<i>Myrcia mutabilis</i> (O.Berg) N.Silveira	0,0891	A
<i>Myrcia obovata</i> (O.Berg) Nied.	0,1206	A
<i>Myrcia</i> sp.	0,1379	A
<i>Myrcia</i> sp. 2	0,4284	B
<i>Myrcia</i> sp. 3	0,1880	A
<i>Myrcia splendens</i> (Sw.) DC.	0,2171	A

Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
<i>Myrcia tomentosa</i> (Aubl.) DC.	0,1040	A
<i>Myrcia anceps</i> O. Berg	0,0318	A
<i>Myrsine coriacea</i> (Sw.) R.Br. ex Roem. & Schult.	0,1496	A
<i>Myrsine umbellata</i> Mart.	0,0859	A
<i>Myrtaceae</i> - indeterminada 1	0,2525	B
<i>Myrtaceae</i> - indeterminada 3	0,0743	A
<i>Nectandra oppositifolia</i> Nees & Mart.	0,4647	C
<i>Newtonia contorta</i> (DC.) Burkart	0,2817	B
<i>Ocotea aciphylla</i> (Nees & Mart.) Mez	0,3417	B
<i>Ocotea corymbosa</i> (Meisn.) Mez	0,1158	A
<i>Ocotea dispersa</i> (Nees & Mart.) Mez	0,0828	A
<i>Ocotea divaricata</i> (Nees) Mez	0,1687	A
<i>Ocotea glomerata</i> (Nees) Mez	0,0700	A
<i>Ocotea lanata</i> (Nees & Mart.) Mez	0,4886	C
<i>Ocotea longifolia</i> Kunth	0,1638	A
<i>Ocotea nitida</i> (Meisn.) Rohwer	0,1221	A
<i>Ocotea odorifera</i> (Vell.) Rohwer	0,4516	B
<i>Ocotea pulchella</i> (Nees & Mart.) Mez	0,2506	B
<i>Ocotea</i> sp.	0,1091	A
<i>Ocotea</i> sp. 2	0,0637	A
<i>Ocotea</i> sp. 4	0,3597	B
<i>Ocotea</i> sp. 9	0,1910	A
<i>Ouratea</i> sp. 2	0,1617	A
<i>Parinari excelsa</i> Sabine	0,0743	A
<i>Pera heteranthera</i> (Schrank) I.M. Johnst.	0,3866	B
<i>Persea major</i> (Meisn.) L.E.Kopp	0,3824	B
<i>Phyllostemonodaphne geminiflora</i> (Mez) Kosterm.	0,1910	A
<i>Piptadenia gonoacantha</i> (Mart.) J.F. Macbr.	0,3929	B
<i>Piptocarpha macropoda</i> (DC.) Baker	0,5512	C
<i>Pithecolobium incuriale</i> (Vell.) Benth.	0,0318	A
<i>Plathymenia reticulata</i> Benth.	0,4216	B
<i>Platypodium elegans</i> Vogel	0,1931	A
<i>Posoqueria latifolia</i> (Rudge) Schult.	0,0318	A
<i>Pourouma guianensis</i> Aubl.	1,2966	E
<i>Pouteria macrophylla</i> (Lam.) Eyma	0,3953	B
<i>Pouteria ramiflora</i> (Mart.) Radlk.	0,4100	B
<i>Pouteria</i> sp.	0,1114	A
<i>Pouteria</i> sp. 1	0,0743	A
<i>Pouteria</i> sp. 2	0,1984	A
<i>Pouteria</i> sp. 3	0,1687	A
<i>Pouteria</i> sp. 4	0,2683	B
<i>Pouteria torta</i> (Mart.) Radlk.	0,4295	B

Espécie	IPA_{dap} (cm ano ⁻¹)	Grupo de espécie
<i>Protium heptaphyllum</i> (Aubl.) Marchand	0,2546	B
<i>Protium</i> sp.	0,2706	B
<i>Pseudopiptadenia contorta</i> (DC.) G.P.Lewis & M.P.Lima	0,5539	C
<i>Psidium rufum</i> Mart. ex DC.	0,0875	A
<i>Psidium</i> sp.	0,2424	B
<i>Psidium</i> sp. 2	0,1732	A
<i>Psychotria carthagenensis</i> Jacq.	1,1332	E
<i>Psychotria</i> sp.	0,1485	A
<i>Psychotria vellosiana</i> Benth.	0,1999	A
<i>Qualea gestasiana</i> A.St.-Hil.	0,2737	B
<i>Rapanea</i> sp.	0,0637	A
<i>Rapanea umbellata</i> (Mart.) Mez	0,0929	A
<i>Rollinia sylvatica</i> (A. St.-Hil.) Martius	0,2281	B
<i>Roupala montana</i> Aubl.	0,0621	A
<i>Schefflera morototoni</i> (Aubl.) Maguire. Steyer. & Frodin	0,5441	C
<i>Schizocalyx cuspidatus</i> (A.St.-Hil.) Kainul. & B. Bremer	0,0688	A
<i>Senefeldera verticillata</i> (Vell.) Croizat	0,6005	C
<i>Senna macranthera</i> (DC. ex Collad.) H.S. Irwin & Barneby	0,0255	A
<i>Senna multijuga</i> (Rich.) H.S. Irwin & Barneby	0,1146	A
<i>Simira</i> sp.1	0,1570	A
<i>Simira viridiflora</i> (Allemão & Saldanha) Steyer.	0,0891	A
<i>Siparuna guianensis</i> Aubl.	0,1273	A
<i>Siparuna reginae</i> (Tul.) A.DC.	0,3890	B
<i>Siparuna</i> sp.	0,0637	A
<i>Sloanea monosperma</i> Vell.	0,1167	A
<i>Sloanea retusa</i> Uittien	0,0934	A
<i>Solanaceae</i> - indeterminada	0,0424	A
<i>Solanum</i> sp. 2	0,0637	A
<i>Solanum swartzianum</i> Roem. & Schult.	0,3480	B
<i>Sorocea bonplandii</i> (Baill.) W.C. Burger, Lanj. & Wess. Boer	0,3107	B
<i>Sparattosperma leucanthum</i> (Vell.) K. Schum.	0,0594	A
<i>Sterculia chicha</i> A. St.-Hil. ex Turpin	0,7321	D
<i>Stryphnodendron polyphyllum</i> Mart.	0,3342	B
<i>Styrax</i> sp. 1	0,0170	A
<i>Swartzia apetala</i> Raddi	0,1282	A
<i>Swartzia myrtifolia</i> Sm.	0,1931	A
<i>Swartzia oblata</i> R.S.Cowan	0,2211	B
<i>Swartzia pilulifera</i> Benth.	0,2614	B
<i>Swartzia</i> sp. 1	0,0785	A
<i>Syagrus</i> sp. 1	0,0424	A
<i>Symplocos pubescens</i> Klotzsch ex Benth.	0,3576	B
<i>Symplocos</i> sp.2	0,2371	B

Espécie	IPA_{dap} (cm ano^{-1})	Grupo de espécie
<i>Tabebuia chrysotricha</i> (Mart. ex A. DC.) Standl.	0,0382	A
<i>Tabernaemontana solanifolia</i> A. DC.	0,2587	B
<i>Tachigali friburgensis</i> (Harms) L.G.Silva & H.C.Lima	0,7374	D
<i>Tachigali rugosa</i> (Mart. ex Benth.) Zarucchi & Pipoly	0,3864	B
<i>Tapirira guianensis</i> Aubl.	0,5974	C
<i>Tapirira obtusa</i> (Benth.) J.D.Mitch.	0,0491	A
<i>Tapirira peckoltiana</i> Engl.	0,4775	C
<i>Tapirira guianensis</i> Aubl.	0,2065	A
<i>Terminalia glabrescens</i> Mart.	1,1777	E
<i>Tetrastylidium grandifolium</i> (Baill.) Sleumer	0,1220	A
<i>Tibouchina</i> sp.	0,0637	A
<i>Tibouchina</i> sp. 1	0,5411	C
<i>Tibouchina granulosa</i> (Desr.) Cogn.	0,2272	B
<i>Toulicia laevigata</i> Radlk.	0,2462	B
<i>Trichilia catigua</i> A.Juss.	0,1324	A
<i>Trichilia lepidota</i> Mart.	0,7958	D
<i>Trichilia pallida</i> Sw.	0,2122	A
<i>Urbanodendron verrucosum</i> (Nees) Mez	0,1197	A
<i>Vernonia diffusa</i> Less.	0,3438	B
<i>Virola bicuhyba</i> (Schott ex Spreng.) Warb.	0,0987	A
<i>Vismia brasiliensis</i> Choisy	0,1273	A
<i>Vismia guianensis</i> (Aubl.) Choisy	0,0709	A
<i>Vismia martiana</i> Reichardt	0,1436	A
<i>Vitex megapotamica</i> (Spreng.) Moldenke	0,1248	A
<i>Vitex polygama</i> Cham.	0,0451	A
<i>Xylopiia aromatica</i> (Lam.) Mart.	0,6618	C
<i>Xylopiia sericea</i> A.St.-Hil.	0,5846	C
<i>Xylopiia brasiliensis</i> Spreng.	0,1227	A
<i>Zanthoxylum rhoifolium</i> Lam.	0,2653	B
<i>Zeyheria tuberculosa</i> (Vell.) Bureau	0,1477	A

APÊNDICE B – Configurações e estatísticas das técnicas de aprendizagem de máquina selecionadas na validação

Tabela B1 – Estatísticas de correlação entre o incremento periódico anual em diâmetro observado e predito ($r_{\hat{y}y}$), raiz quadrada do erro quadrático médio (*RMSE*), erro absoluto médio (*EAM*) e valor ponderado (*VP*) das configurações selecionadas de cada técnica por abordagem no fragmento Cachoeira das Pombas

Técnica	Variáveis predictoras	Neur./Árv. ¹	Função ²	Algoritmo	$r_{\hat{y}y}$	<i>RMSE</i>	<i>EAM</i>	<i>VP</i>
RNA	<i>GE, P, dap, IC₁</i>	8	Logística	Rprop	0,6164	0,1175	0,0882	7
	<i>GE, P, dap, IC₂</i>	9	Tangente Hiperbólica	Rprop	0,6320	0,1146	0,0866	3
	<i>GE, P, dap, IC₃</i>	7	Exponencial	SCG	0,5920	0,1208	0,0892	12
	<i>GE, P, dap</i>	15	Logística	Rprop	0,5977	0,1187	0,0878	8
	<i>P, dap, IC₁</i>	9	Exponencial	Rprop	0,4965	0,1323	0,0977	19
	<i>P, dap, IC₂</i>	5	Tangente Hiperbólica	SCG	0,4824	0,1306	0,0982	21
	<i>P, dap, IC₃</i>	6	Logística	Rprop	0,5151	0,1285	0,0982	16
	<i>P, dap</i>	9	Identidade	Rprop	0,4905	0,1309	0,0999	22
SVR	<i>GE, P, dap, IC₁</i>		Polinomial		0,6234	0,1176	0,0854	9
	<i>GE, P, dap, IC₂</i>		Polinomial		0,6460	0,1153	0,0851	6
	<i>GE, P, dap, IC₃</i>		Polinomial		0,6467	0,1144	0,0846	3
	<i>GE, P, dap</i>		Linear		0,5645	0,1251	0,0860	14
	<i>P, dap, IC₁</i>		Polinomial		0,5714	0,1226	0,0892	13
	<i>P, dap, IC₂</i>		Base Radial		0,3458	0,1401	0,0931	24
	<i>P, dap, IC₃</i>		Base Radial		0,3595	0,1387	0,0927	21
	<i>P, dap</i>		Polinomial		0,4096	0,1360	0,0924	18
RF	<i>GE, P, dap, IC₁</i>	43			0,5685	0,1241	0,0896	3
	<i>GE, P, dap, IC₂</i>	57			0,4136	0,1361	0,0994	18
	<i>GE, P, dap, IC₃</i>	36			0,5678	0,1247	0,0897	6
	<i>GE, P, dap</i>	51			0,4933	0,1293	0,0908	9
	<i>P, dap, IC₁</i>	33			0,4325	0,1344	0,0993	13
	<i>P, dap, IC₂</i>	84			0,2871	0,1484	0,1133	24
	<i>P, dap, IC₃</i>	26			0,4195	0,1359	0,0994	17
	<i>P, dap</i>	24			0,3877	0,1372	0,0981	18

em que: CP = Cachoeira das Pombas; LP = Lagoa do Piau; SJ = São José; MS = Mata da Silvicultura; *GE* = Grupo de espécie; *P* = Período de incremento; *dap* = diâmetro a 1,30 m de altura, em cm; *IC₁*, *IC₂* e *IC₃* = índices de competição; Rprop = *resilient propagation*; SCG = *scaled conjugate gradient*; RNA = rede neural artificial; SVR = regressão vetorial de suporte; RF = *random forest*. ¹Número de neurônios na camada oculta da RNA ou de árvores da RF.

²Função de ativação da camada oculta da RNA ou função kernel da SVR.

Tabela B2 – Estatísticas de correlação entre o incremento periódico anual em diâmetro observado e predito (r_{yy}), raiz quadrada do erro quadrático médio (*RMSE*), erro absoluto médio (*EAM*) e valor ponderado (*VP*) das configurações selecionadas de cada técnica por abordagem no fragmento Lagoa do Piau

Técnica	Variáveis predictoras	Neur./Árv. ¹	Função ²	Algoritmo	r_{yy}	<i>RMSE</i>	<i>EAM</i>	<i>VP</i>
RNA	<i>GE, P, dap, IC₁</i>	7	Logística	Rprop	0,5839	0,4124	0,2474	12
	<i>GE, P, dap, IC₂</i>	12	Tangente Hiperbólica	Rprop	0,6088	0,4024	0,2451	5
	<i>GE, P, dap, IC₃</i>	20	Tangente Hiperbólica	Rprop	0,6004	0,4056	0,2440	6
	<i>GE, P, dap</i>	11	Tangente Hiperbólica	Rprop	0,5980	0,4065	0,2422	7
	<i>P, dap, IC₁</i>	9	Tangente Hiperbólica	Rprop	0,4888	0,4438	0,2824	18
	<i>P, dap, IC₂</i>	9	Tangente Hiperbólica	Rprop	0,4744	0,4480	0,2788	19
	<i>P, dap, IC₃</i>	11	Tangente Hiperbólica	Rprop	0,4874	0,4436	0,2789	17
	<i>P, dap</i>	6	Exponencial	SCG	0,4741	0,4481	0,2839	24
SVR	<i>GE, P, dap, IC₁</i>		Base Radial		0,5628	0,4299	0,2313	7
	<i>GE, P, dap, IC₂</i>		Base Radial		0,5577	0,4302	0,2332	12
	<i>GE, P, dap, IC₃</i>		Base Radial		0,5660	0,4286	0,2317	5
	<i>GE, P, dap</i>		Base Radial		0,5649	0,4272	0,2326	6
	<i>P, dap, IC₁</i>		Base Radial		0,4615	0,4621	0,2539	17
	<i>P, dap, IC₂</i>		Base Radial		0,4607	0,4645	0,2544	21
	<i>P, dap, IC₃</i>		Base Radial		0,4499	0,4662	0,2541	22
	<i>P, dap</i>		Base Radial		0,4667	0,4620	0,2575	18
RF	<i>GE, P, dap, IC₁</i>	22			0,5549	0,4224	0,2529	8
	<i>GE, P, dap, IC₂</i>	58			0,5706	0,4174	0,2568	5
	<i>GE, P, dap, IC₃</i>	61			0,5672	0,4190	0,2524	5
	<i>GE, P, dap</i>	28			0,5496	0,4236	0,2573	12
	<i>P, dap, IC₁</i>	49			0,4637	0,4518	0,2843	20
	<i>P, dap, IC₂</i>	52			0,4656	0,4516	0,2860	20
	<i>P, dap, IC₃</i>	68			0,4760	0,4467	0,2775	15
	<i>P, dap</i>	81			0,4559	0,4534	0,2847	23

em que: CP = Cachoeira das Pombas; LP = Lagoa do Piau; SJ = São José; MS = Mata da Silvicultura; *GE* = Grupo de espécie; *P* = Período de incremento; *dap* = diâmetro a 1,30 m de altura, em cm; *IC₁*, *IC₂* e *IC₃* = índices de competição; Rprop = *resilient propagation*; SCG = *scaled conjugate gradient*; RNA = rede neural artificial; SVR = regressão vetorial de suporte; RF = *random forest*. ¹Número de neurônios na camada oculta da RNA ou de árvores da RF.

²Função de ativação da camada oculta da RNA ou função kernel da SVR.

Tabela B3 – Estatísticas de correlação entre o incremento periódico anual em diâmetro observado e predito (r_{yy}), raiz quadrada do erro quadrático médio ($RMSE$), erro absoluto médio (EAM) e valor ponderado (VP) das configurações selecionadas de cada técnica por abordagem no fragmento São José

Técnica	Variáveis predictoras	Neur./Árv. ¹	Função ²	Algoritmo	r_{yy}	$RMSE$	EAM	VP
RNA	GE, P, dap, IC_1	19	Logística	SCG	0,5914	0,1471	0,1081	6
	GE, P, dap, IC_2	11	Logística	SCG	0,5764	0,1489	0,1098	10
	GE, P, dap, IC_3	20	Logística	SCG	0,6322	0,1411	0,1058	3
	GE, P, dap	13	Tangente Hiperbólica	Rprop	0,5705	0,1501	0,1096	11
	P, dap, IC_1	6	Tangente Hiperbólica	Rprop	0,2054	0,1837	0,1246	20
	P, dap, IC_2	5	Logística	Rprop	0,2457	0,1831	0,1213	17
	P, dap, IC_3	11	Exponencial	Rprop	0,3257	0,1845	0,1208	17
	P, dap	9	Logística	Rprop	0,0892	0,1855	0,1284	24
SVR	GE, P, dap, IC_1		Linear		0,5712	0,1544	0,1069	3
	GE, P, dap, IC_2		Linear		0,5476	0,1565	0,1093	12
	GE, P, dap, IC_3		Linear		0,5632	0,1550	0,1082	6
	GE, P, dap		Linear		0,5522	0,1561	0,1089	9
	P, dap, IC_1		Polinomial		0,2407	0,1869	0,1155	18
	P, dap, IC_2		Polinomial		0,1415	0,1925	0,1187	22
	P, dap, IC_3		Polinomial		0,3208	0,1811	0,1102	15
	P, dap		Linear		0,0801	0,1920	0,1194	23
RF	GE, P, dap, IC_1	25			0,5413	0,1539	0,1108	5
	GE, P, dap, IC_2	45			0,5120	0,1568	0,1079	9
	GE, P, dap, IC_3	66			0,5261	0,1556	0,1089	8
	GE, P, dap	67			0,5348	0,1555	0,1137	8
	P, dap, IC_1	86			0,1641	0,1825	0,1256	21
	P, dap, IC_2	94			0,2618	0,1797	0,1176	16
	P, dap, IC_3	24			0,2825	0,1800	0,1190	17
	P, dap	35			0,1335	0,1825	0,1272	24

em que: CP = Cachoeira das Pombas; LP = Lagoa do Piauí; SJ = São José; MS = Mata da Silvicultura; GE = Grupo de espécie; P = Período de incremento; dap = diâmetro a 1,30 m de altura, em cm; IC_1 , IC_2 e IC_3 = índices de competição; Rprop = *resilient propagation*; SCG = *scaled conjugate gradient*; RNA = rede neural artificial; SVR = regressão vetorial de suporte; RF = *random forest*. ¹Número de neurônios na camada oculta da RNA ou de árvores da RF.

²Função de ativação da camada oculta da RNA ou função kernel da SVR.

Tabela B4 – Estatísticas de correlação entre o incremento periódico anual em diâmetro observado e predito (r_{yy}), raiz quadrada do erro quadrático médio ($RMSE$), erro absoluto médio (EAM) e valor ponderado (VP) das configurações selecionadas de cada técnica por abordagem no fragmento Mata da Silvicultura

Técnica	Variáveis predictoras	Neur./Árv. ¹	Função ²	Algoritmo	r_{yy}	$RMSE$	EAM	VP
RNA	GE, P, dap, IC_1	17	Logística	SCG	0,4725	0,3663	0,1750	18
	GE, P, dap, IC_2	28	Logística	SCG	0,4742	0,3655	0,1766	17
	GE, P, dap, IC_3	26	Exponencial	SCG	0,4756	0,3652	0,1788	17
	GE, P, dap	22	Logística	SCG	0,4843	0,3631	0,1770	14
	P, dap, IC_1	10	Logística	SCG	0,4955	0,3594	0,1810	12
	P, dap, IC_2	14	Exponencial	SCG	0,4931	0,3600	0,1832	15
	P, dap, IC_3	8	Exponencial	SCG	0,5003	0,3591	0,1743	5
	P, dap	10	Tangente Hiperbólica	SCG	0,5014	0,3584	0,1854	10
SVR	GE, P, dap, IC_1		Base Radial		0,4731	0,3798	0,1641	11
	GE, P, dap, IC_2		Base Radial		0,4747	0,3800	0,1640	9
	GE, P, dap, IC_3		Base Radial		0,4614	0,3811	0,1648	21
	GE, P, dap		Base Radial		0,4703	0,3802	0,1642	15
	P, dap, IC_1		Base Radial		0,4916	0,3789	0,1649	8
	P, dap, IC_2		Base Radial		0,4903	0,3797	0,1648	8
	P, dap, IC_3		Base Radial		0,4733	0,3803	0,1654	18
	P, dap		Base Radial		0,4818	0,3806	0,1655	18
RF	GE, P, dap, IC_1	96			0,4704	0,3654	0,1828	14
	GE, P, dap, IC_2	34			0,4552	0,3696	0,1919	22
	GE, P, dap, IC_3	26			0,4702	0,3654	0,1825	12
	GE, P, dap	62			0,4741	0,3644	0,1828	9
	P, dap, IC_1	100			0,4741	0,3654	0,1896	11
	P, dap, IC_2	57			0,4796	0,3674	0,2092	16
	P, dap, IC_3	41			0,4804	0,3693	0,2089	15
	P, dap	28			0,4779	0,3642	0,1907	9

em que: CP = Cachoeira das Pombas; LP = Lagoa do Piau; SJ = São José; MS = Mata da Silvicultura; GE = Grupo de espécie; P = Período de incremento; dap = diâmetro a 1,30 m de altura, em cm; IC_1 , IC_2 e IC_3 = índices de competição; Rprop = *resilient propagation*; SCG = *scaled conjugate gradient*; RNA = rede neural artificial; SVR = regressão vetorial de suporte; RF = *random forest*. ¹Número de neurônios na camada oculta da RNA ou de árvores da RF.

²Função de ativação da camada oculta da RNA ou função kernel da SVR.

Tabela B5 – Estatísticas de correlação entre o incremento periódico anual em diâmetro observado e predito (r_{yy}), raiz quadrada do erro quadrático médio ($RMSE$), erro absoluto médio (EAM) e valor ponderado (VP) das configurações selecionadas de cada técnica por abordagem em todos os fragmentos

Técnica	Variáveis predictoras	Neur./Árv. ¹	Função ²	Algoritmo	r_{yy}	$RMSE$	EAM	VP
RNA	F, GE, P, dap, IC_1	16	Logística	Rprop	0,6009	0,3044	0,1711	5
	F, GE, P, dap, IC_2	9	Tangente Hiperbólica	Rprop	0,6036	0,3036	0,1718	4
	F, GE, P, dap, IC_3	22	Logística	Rprop	0,5969	0,3064	0,1721	9
SVR	F, GE, P, dap, IC_1		Base Radial		0,5481	0,3250	0,1650	5
	F, GE, P, dap, IC_2		Base Radial		0,5503	0,3253	0,1654	7
	F, GE, P, dap, IC_3		Base Radial		0,5460	0,3250	0,1646	6
RF	F, GE, P, dap, IC_1	42			0,5946	0,3111	0,1764	3
	F, GE, P, dap, IC_2	28			0,5866	0,3155	0,1791	8
	F, GE, P, dap, IC_3	70			0,5766	0,3145	0,1769	7

em que: CP = Cachoeira das Pombas; LP = Lagoa do Piau; SJ = São José; MS = Mata da Silvicultura; GE = Grupo de espécie; P = Período de incremento; dap = diâmetro a 1,30 m de altura, em cm; IC_1, IC_2 e IC_3 = índices de competição; Rprop = *resilient propagation*; SCG = *scaled conjugate gradient*; RNA = rede neural artificial; SVR = regressão vetorial de suporte; RF = *random forest*. ¹Número de neurônios na camada oculta da RNA ou de árvores da RF.

²Função de ativação da camada oculta da RNA ou função kernel da SVR.

APÊNDICE C – Médias de *RMSE* na validação cruzada

Tabela C1 – Médias da raiz quadrada do erro quadrático médio (*RMSE*) e desvio padrão (*DP*) na validação cruzada no fragmento Cachoeira das Pombas

Repetição	RNA		SVR		RF	
	<i>RMSE</i>	<i>DP</i>	<i>RMSE</i>	<i>DP</i>	<i>RMSE</i>	<i>DP</i>
1	0,1380	0,0303	0,1546	0,0297	0,1393	0,0268
2	0,1380	0,0291	0,1578	0,0401	0,1389	0,0245
3	0,1377	0,0285	0,1667	0,0675	0,1391	0,0244
4	0,1378	0,0280	0,1633	0,0599	0,1389	0,0242
5	0,1380	0,0279	0,1689	0,0684	0,1390	0,0235
6	0,1380	0,0277	0,1662	0,0631	0,1390	0,0226
7	0,1382	0,0275	0,1657	0,0601	0,1390	0,0222
8	0,1381	0,0275	0,1683	0,0700	0,1390	0,0221
9	0,1383	0,0276	0,1663	0,0669	0,1391	0,0219
10	0,1382	0,0275	0,1649	0,0641	0,1390	0,0221
11	0,1380	0,0273	0,1671	0,0710	0,1389	0,0226
12	0,1382	0,0273	0,1723	0,0861	0,1388	0,0225
13	0,1381	0,0275	0,1733	0,0864	0,1387	0,0229
14	0,1384	0,0275	0,1735	0,0855	0,1386	0,0228
15	0,1383	0,0275	0,1766	0,0989	0,1385	0,0230
16	0,1383	0,0274	0,1771	0,0997	0,1385	0,0231
17	0,1383	0,0273	0,1754	0,0972	0,1385	0,0229
18	0,1382	0,0273	0,1744	0,0949	0,1384	0,0229
19	0,1381	0,0272	0,1734	0,0926	0,1384	0,0231
20	0,1381	0,0272	0,1740	0,0931	0,1385	0,0231
21	0,1381	0,0272	0,1732	0,0912	0,1384	0,0231
22	0,1381	0,0273	0,1738	0,0908	0,1384	0,0230
23	0,1381	0,0275	0,1756	0,0962	0,1384	0,0230
24	0,1382	0,0274	0,1777	0,1044	0,1385	0,0229
25	0,1381	0,0274	0,1774	0,1027	0,1384	0,0230
26	0,1381	0,0273	0,1786	0,1051	0,1385	0,0231
27	0,1380	0,0273	0,1775	0,1034	0,1385	0,0231
28	0,1380	0,0273	0,1781	0,1030	0,1385	0,0231
29	0,1380	0,0273	0,1794	0,1084	0,1384	0,0231
30	0,1380	0,0273	0,1798	0,1096	0,1384	0,0231
31	0,1380	0,0272	0,1803	0,1104	0,1384	0,0232
32	0,1380	0,0272	0,1810	0,1119	0,1384	0,0233
33	0,1380	0,0272	0,1824	0,1178	0,1384	0,0231
34	0,1381	0,0272	0,1851	0,1242	0,1385	0,0230
35	0,1381	0,0272	0,1843	0,1226	0,1385	0,0229
36	0,1382	0,0273	0,1836	0,1210	0,1385	0,0229
37	0,1382	0,0273	0,1839	0,1216	0,1385	0,0230
38	0,1382	0,0273	0,1838	0,1212	0,1385	0,0230
39	0,1382	0,0272	0,1840	0,1214	0,1385	0,0230
40	0,1383	0,0273	0,1838	0,1205	0,1385	0,0230
41	0,1383	0,0272	0,1830	0,1191	0,1385	0,0229
42	0,1383	0,0272	0,1829	0,1189	0,1385	0,0229
43	0,1383	0,0272	0,1829	0,1185	0,1385	0,0229
44	0,1383	0,0272	0,1823	0,1172	0,1385	0,0229
45	0,1383	0,0272	0,1817	0,1161	0,1385	0,0229
46	0,1383	0,0272	0,1819	0,1163	0,1385	0,0228
47	0,1383	0,0273	0,1816	0,1153	0,1385	0,0227
48	0,1383	0,0273	0,1812	0,1144	0,1385	0,0227
49	0,1384	0,0272	0,1813	0,1142	0,1385	0,0227
50	0,1384	0,0272	0,1807	0,1131	0,1385	0,0227
Média	0,1382		0,1761		0,1386	

Tabela C2 – Médias da raiz quadrada do erro quadrático médio (*RMSE*) e desvio padrão (*DP*) na validação cruzada no fragmento Lagoa do Piau

Repetição	RNA		SVR		RF	
	<i>RMSE</i>	<i>DP</i>	<i>RMSE</i>	<i>DP</i>	<i>RMSE</i>	<i>DP</i>
1	0,4130	0,0819	0,4480	0,0812	0,4251	0,0978
2	0,4157	0,0757	0,4430	0,1078	0,4275	0,0942
3	0,4168	0,0773	0,4431	0,1070	0,4272	0,1033
4	0,4174	0,0765	0,4441	0,1012	0,4283	0,0958
5	0,4166	0,0820	0,4438	0,1023	0,4294	0,0953
6	0,4152	0,0835	0,4441	0,1001	0,4299	0,0942
7	0,4152	0,0825	0,4446	0,0983	0,4298	0,0930
8	0,4150	0,0820	0,4443	0,1002	0,4300	0,0920
9	0,4151	0,0802	0,4448	0,0973	0,4303	0,0911
10	0,4150	0,0797	0,4445	0,0988	0,4301	0,0909
11	0,4153	0,0782	0,4445	0,0984	0,4299	0,0909
12	0,4153	0,0763	0,4446	0,0979	0,4305	0,0891
13	0,4155	0,0758	0,4444	0,0984	0,4308	0,0874
14	0,4158	0,0747	0,4446	0,0974	0,4312	0,0860
15	0,4151	0,0770	0,4451	0,0953	0,4313	0,0849
16	0,4151	0,0772	0,4449	0,0961	0,4310	0,0844
17	0,4152	0,0775	0,4453	0,0940	0,4306	0,0851
18	0,4154	0,0768	0,4451	0,0950	0,4307	0,0852
19	0,4154	0,0768	0,4452	0,0947	0,4304	0,0872
20	0,4154	0,0765	0,4453	0,0943	0,4301	0,0879
21	0,4153	0,0766	0,4454	0,0935	0,4304	0,0872
22	0,4155	0,0769	0,4455	0,0930	0,4306	0,0863
23	0,4157	0,0770	0,4455	0,0928	0,4307	0,0864
24	0,4156	0,0786	0,4456	0,0928	0,4306	0,0861
25	0,4155	0,0793	0,4454	0,0935	0,4305	0,0861
26	0,4155	0,0794	0,4455	0,0931	0,4307	0,0854
27	0,4157	0,0789	0,4456	0,0928	0,4306	0,0857
28	0,4160	0,0782	0,4457	0,0920	0,4306	0,0856
29	0,4159	0,0782	0,4458	0,0916	0,4305	0,0858
30	0,4153	0,0793	0,4457	0,0922	0,4303	0,0866
31	0,4153	0,0788	0,4458	0,0916	0,4303	0,0863
32	0,4154	0,0789	0,4458	0,0917	0,4304	0,0855
33	0,4153	0,0791	0,4458	0,0917	0,4304	0,0852
34	0,4154	0,0789	0,4459	0,0912	0,4304	0,0852
35	0,4156	0,0784	0,4459	0,0912	0,4305	0,0850
36	0,4158	0,0784	0,4458	0,0918	0,4304	0,0848
37	0,4157	0,0781	0,4457	0,0923	0,4305	0,0851
38	0,4158	0,0780	0,4457	0,0921	0,4305	0,0849
39	0,4155	0,0784	0,4455	0,0931	0,4306	0,0844
40	0,4155	0,0782	0,4455	0,0930	0,4306	0,0846
41	0,4154	0,0786	0,4455	0,0926	0,4307	0,0848
42	0,4153	0,0786	0,4457	0,0919	0,4307	0,0843
43	0,4152	0,0785	0,4456	0,0922	0,4308	0,0842
44	0,4152	0,0785	0,4457	0,0916	0,4309	0,0838
45	0,4151	0,0788	0,4458	0,0912	0,4308	0,0838
46	0,4152	0,0784	0,4458	0,0911	0,4307	0,0846
47	0,4153	0,0782	0,4459	0,0907	0,4307	0,0850
48	0,4154	0,0781	0,4460	0,0901	0,4306	0,0855
49	0,4153	0,0781	0,4460	0,0902	0,4307	0,0852
50	0,4153	0,0781	0,4457	0,0913	0,4308	0,0849
Média	0,4155		0,4453		0,4302	

Tabela C3 – Médias da raiz quadrada do erro quadrático médio (*RMSE*) e desvio padrão (*DP*) na validação cruzada no fragmento São José

Repetição	RNA		SVR		RF	
	<i>RMSE</i>	<i>DP</i>	<i>RMSE</i>	<i>DP</i>	<i>RMSE</i>	<i>DP</i>
1	0,1606	0,0421	0,1677	0,0444	0,1654	0,0367
2	0,1613	0,0412	0,1668	0,0462	0,1626	0,0397
3	0,1618	0,0407	0,1671	0,0464	0,1640	0,0431
4	0,1617	0,0409	0,1665	0,0465	0,1646	0,0447
5	0,1631	0,0400	0,1672	0,0454	0,1653	0,0447
6	0,1635	0,0404	0,1667	0,0477	0,1656	0,0435
7	0,1640	0,0398	0,1669	0,0473	0,1659	0,0453
8	0,1640	0,0407	0,1675	0,0463	0,1659	0,0454
9	0,1642	0,0400	0,1674	0,0459	0,1658	0,0443
10	0,1644	0,0397	0,1671	0,0468	0,1660	0,0442
11	0,1647	0,0412	0,1672	0,0464	0,1664	0,0440
12	0,1648	0,0407	0,1672	0,0464	0,1664	0,0434
13	0,1647	0,0407	0,1671	0,0471	0,1662	0,0428
14	0,1647	0,0401	0,1670	0,0474	0,1660	0,0441
15	0,1648	0,0396	0,1668	0,0476	0,1660	0,0433
16	0,1648	0,0402	0,1671	0,0470	0,1656	0,0436
17	0,1652	0,0406	0,1672	0,0467	0,1654	0,0437
18	0,1654	0,0404	0,1673	0,0465	0,1656	0,0439
19	0,1655	0,0403	0,1672	0,0468	0,1656	0,0438
20	0,1654	0,0404	0,1674	0,0467	0,1655	0,0439
21	0,1654	0,0403	0,1674	0,0467	0,1657	0,0436
22	0,1650	0,0399	0,1673	0,0467	0,1656	0,0435
23	0,1651	0,0397	0,1673	0,0468	0,1655	0,0437
24	0,1652	0,0402	0,1673	0,0468	0,1655	0,0438
25	0,1653	0,0398	0,1673	0,0468	0,1653	0,0435
26	0,1656	0,0396	0,1673	0,0468	0,1653	0,0434
27	0,1654	0,0402	0,1673	0,0468	0,1652	0,0434
28	0,1655	0,0403	0,1674	0,0466	0,1652	0,0432
29	0,1653	0,0401	0,1674	0,0465	0,1651	0,0433
30	0,1653	0,0399	0,1674	0,0467	0,1652	0,0432
31	0,1651	0,0399	0,1674	0,0467	0,1653	0,0431
32	0,1652	0,0398	0,1674	0,0468	0,1652	0,0430
33	0,1652	0,0405	0,1674	0,0469	0,1653	0,0429
34	0,1653	0,0406	0,1673	0,0469	0,1654	0,0426
35	0,1651	0,0402	0,1673	0,0472	0,1655	0,0425
36	0,1650	0,0403	0,1673	0,0475	0,1656	0,0424
37	0,1651	0,0402	0,1672	0,0480	0,1657	0,0422
38	0,1650	0,0402	0,1672	0,0480	0,1656	0,0423
39	0,1650	0,0399	0,1672	0,0481	0,1657	0,0424
40	0,1649	0,0399	0,1671	0,0484	0,1657	0,0423
41	0,1650	0,0402	0,1671	0,0489	0,1656	0,0424
42	0,1651	0,0403	0,1671	0,0487	0,1655	0,0423
43	0,1652	0,0403	0,1671	0,0487	0,1657	0,0423
44	0,1653	0,0407	0,1670	0,0487	0,1657	0,0422
45	0,1653	0,0407	0,1670	0,0484	0,1657	0,0420
46	0,1652	0,0405	0,1671	0,0484	0,1656	0,0419
47	0,1652	0,0404	0,1671	0,0485	0,1656	0,0418
48	0,1652	0,0407	0,1672	0,0484	0,1656	0,0417
49	0,1652	0,0406	0,1671	0,0486	0,1657	0,0417
50	0,1653	0,0409	0,1671	0,0486	0,1656	0,0416
Média	0,1647		0,1672		0,1655	