

MARIANA RODRIGUES MAGALHÃES

**PROGNOSE DO VOLUME DE MADEIRA EM FLORESTAS EQUIÂNEAS
POR MEIO DE MODELOS AGROMETEOROLÓGICOS DE REDES NEURAIAS
ARTIFICIAIS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Doctor Scientiae*.

VIÇOSA
MINAS GERAIS – BRASIL
2017

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

T

M118p
2017

Magalhães, Mariana Rodrigues, 1984-

Prognose do volume de madeira em florestas equiâneas por meio de modelos agrometeorológicos de redes neurais artificiais : . / Mariana Rodrigues Magalhães. – Viçosa, MG, 2017.
ix, 62f. : il. (algumas color.) ; 29 cm.

Inclui anexo.

Orientador: Aristides Ribeiro.

Tese (doutorado) - Universidade Federal de Viçosa.

Referências bibliográficas: f.36-41.

1. Madeira - Medição. 2. Meteorologia agrícola - Modelos matemáticos. 3. Produtividade agrícola. I. Universidade Federal de Viçosa. Departamento de Engenharia Agrícola. Doutorado em Engenharia Agrícola. II. Título.


CDD 22 ed. 634.952


MARIANA RODRIGUES MAGALHÃES

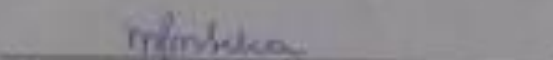
PROGNOSE DO VOLUME DE MADEIRA EM FLORESTAS EQUIÂNEAS
POR MEIO DE MODELOS AGROMETEOROLÓGICOS
DE REDES NEURAIS ARTIFICIAIS

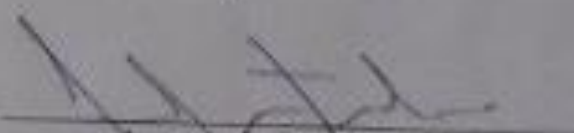
Tese apresentada à Universidade Federal de
Viçosa, como parte das exigências do Programa
de Pós-Graduação em Engenharia Agrícola, para
obtenção do título de *Doctor Scientiarum*.

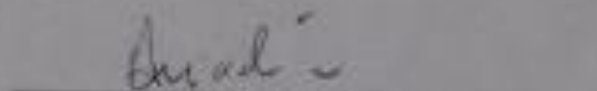
APROVADA: 24 de julho de 2017.


Francisca Zenaide de Lima


Aline Edwiges Mazon de Alcântara


Mayra Luiza Marques da Silva Binoti


Leonardo Bonato Felix
(Coorientador)


Aristides Ribeiro
(Orientador)

AOS MEUS QUERIDOS PAIS ANA MARIA E GERALDO,
AOS MEUS IRMÃOS, ISABELA E DANILO,
AO MEU AVÔ JOÃO (*in memoriam*).

Às pessoas que sempre estiveram presentes em minha vida
Nos momentos felizes e difíceis,
Sempre com palavras de incentivo.

AO MEU AMADO NOIVO,
REGINALDO
Por toda cumplicidade e amor.

OFEREÇO

AGRADECIMENTOS

Agradeço a Deus pelas oportunidades que me proporcionou, por me ensinar a ter paciência e perseverança.

Aos meus Pais, Ana Maria e Geraldo, pelo apoio, incentivo constante, amor incondicional e compreensão.

Aos meus Irmãos Isabela e Danilo pelo carinho, amizade e paciência.

Ao meu noivo Reginaldo, pelo companheirismo, carinho, compreensão, apoio e paciência nos momentos mais críticos da finalização desta etapa acadêmica,

A toda minha família e amigos pelo incentivo e por sempre estarem ao meu lado.

À Júnia pela amizade e auxílio nos momentos críticos.

Ao meu orientador Professor Aristides, pela oportunidade e confiança depositada em meu trabalho.

Ao meu coorientador Professor Leonardo Bonato pela paciência, solicitude e apoio na realização deste trabalho.

À Aylen por acreditar nas minhas ideias quase impossíveis e me ajudar a colocá-las em prática.

À Graça pela amizade, solicitude e carinho.

À Aline Alcântara, pelos dados cedidos e solicitude.

À Professora Mayra pela solicitude e paciência.

Aos membros da banca de defesa da tese, pelas valiosas contribuições.

Aos colegas de departamento pela amizade e troca de conhecimento.

À Universidade do Federal de Viçosa - UFV, em especial ao Programa de Pós-Graduação em Engenharia Agrícola pela oportunidade concedida.

Ao Conselho Nacional de Pesquisa – CNPq pela concessão da bolsa de pesquisa.

A todos que compartilharam dessa caminhada.

BIOGRAFIA

Mariana Rodrigues Magalhães, filha de Geraldo Antônio de Magalhães e Ana Maria Rodrigues Magalhães, nasceu na cidade de Curvelo, estado de Minas Gerais, em 9 de outubro de 1984.

Em março de 2006, ingressou no curso de Engenharia Florestal na Universidade Federal dos Vales do Jequitinhonha e Mucuri (UFVJM), graduando-se em julho de 2011. Foi monitora voluntária da disciplina de Desenho Técnico e monitora remunerada da disciplina de Meteorologia e Climatologia.

Em agosto de 2011, iniciou o curso de Mestrado em Ciência Florestal, na área de Conservação e Restauração de Ecossistemas Florestais, no Departamento de Engenharia Florestal da UFVJM, defendendo a dissertação em julho de 2013.

Em agosto de 2013, iniciou o Doutorado em Engenharia Agrícola, na área de Recursos Hídricos e Ambientais, no Departamento de Engenharia Agrícola da UFV, defendendo a tese em julho de 2017. Foi premiada por trabalhos apresentados no XVIII Congresso Brasileiro de Agrometeorologia (2013) e XVIII CBMET - Congresso Brasileiro de Meteorologia (2014).

SUMÁRIO

RESUMO	vi
ABSTRACT	viii
1. INTRODUÇÃO	01
1.1 – Objetivo geral	03
1.2- Objetivos específicos	04
2. MATERIAL E MÉTODOS	05
2.1 – Dados do Inventário Florestal Contínuo (IFC)	05
2.2 – Dados Meteorológicos	05
2.3 – Neuro AgroClimate – NAC	06
2.4 – Organização dos dados para o input do modelo	07
2.5 – Ordenação das variáveis do input	08
2.6 – Construção e seleção dos modelos agrometeorológicos	13
3. RESULTADOS E DISCUSSÃO	20
3.1 – Ordenação da importância relativa das variáveis do input.....	20
3.2 – Seleção dos modelos agrometeorológicos	24
4. CONSIDERAÇÕES FINAIS	35
5. REFERÊNCIAS BIBLIOGRÁFICAS	36
6. ANEXO	42

RESUMO

MAGALHÃES, Mariana Rodrigues, D.Sc., Universidade Federal de Viçosa, julho de 2017. **Prognose do volume de madeira em florestas equiâneas por meio de modelos agrometeorológicos de redes neurais artificiais.** Orientador: Aristides Ribeiro. Coorientador: Leonardo Bonato Felix.

O manejo florestal sustentável requer estimativas precisas de estoque de crescimento, uma vez que essas informações auxiliam a tomada de decisão na análise econômica dos projetos florestais. A proposta de inclusão de novas metodologias ou modelos que estimem o estoque volumétrico da madeira é necessária em função dos custos do inventário florestal, bem como a importância desta na exatidão das estimativas volumétricas. Diversas ferramentas computacionais e de modelagem matemática tem sido utilizadas com êxito em situações de tomada de decisão no setor florestal, destacando-se as Redes Neurais Artificiais (RNA). Diante do exposto, o trabalho visa elucidar as seguintes questões: i) A redução do número de variáveis por meio de métodos de ordenação pode otimizar a construção de modelos de redes neurais para estimação da prognose do volume de madeira? ii) Existe diferença significativa entre prognoses realizadas por meio de diferentes métodos? iii) Qual o modelo mais eficiente para a realização da prognose do inventário florestal para a região do leste de Minas Gerais? Utilizou-se duas metodologias, Correlação de Pearson e Método de Garson, para ordenação das 21 variáveis do input dos modelos agrometeorológicos estudados. Para a construção dos modelos agrometeorológicos foram utilizadas 3 metodologias: i) modelos construídos de acordo com a ordenação da Correlação de Pearson; ii) modelos construídos de acordo com a ordenação do Método de Garson; e iii) modelos construídos de acordo com a fusão das metodologias da ordenação da Correlação de Pearson e Método de Garson, denominada de metodologia do Modelo Híbrido. A seleção dos modelos ocorreu por meio do menor valor da raiz do erro quadrático médio (RMSE) do teste (%) e gráficos do volume futuro estimado versus volume futuro observado. Todos os processamentos foram realizados no software Neuro AgroClimate, desenvolvido para esta tese. Na ordenação pela metodologia da Correlação de Pearson destacaram-se as variáveis de inventário florestal, já na metodologia do Método de Garson

destacaram-se as variáveis ecofisiológicas. Os valores do RMSE do teste (%) entre as três metodologias analisadas foram próximos, sendo: 6,24 do modelo 12 da metodologia da Correlação de Pearson; 6,42 do modelo 16 da metodologia do Método de Garson; e 6,61 do modelo 9 da metodologia do Modelo Híbrido. Houve diferença significativa entre os três modelos analisado, e a rede que apresentou o menor valor do RMSE do teste (%) foi o modelo 12 da metodologia da Correlação de Pearson. A seleção das variáveis dependentes foi eficaz ao otimizar o tempo de processamento das redes por se conhece as variáveis do input.

ABSTRACT

MAGALHÃES, Mariana Rodrigues, D.Sc., Universidade Federal de Viçosa, July, 2017. **Prognosis of wood volume in the planted forests by means of agrometeorological models of artificial neural networks.** Adviser: Aristides Ribeiro. Co-adviser: Leonardo Bonato Felix.

Sustainable forest management requires accurate estimates of growth stock, once this information helps decision-making process in the economic analysis of forestry projects. The proposal on inclusion of new methodologies or models that estimate the volumetric stock of wood is necessary in function of the costs of the forest inventory, as well as its importance in the accuracy of the volumetric estimates. Several computational tools and mathematical modeling have been used successfully in decision-making situations in the forestry sector, with emphasis on Artificial Neural Networks (RNA). In view of the above, the paper aims at elucidating the following questions: i) Can the reduction of the number of variables by ordering methods optimize the construction of neural network models to estimate the prognosis of the wood volume? ii) Is there a significant difference between prognoses performed using different methods? iii) What is the most efficient model for the prognosis of the forest inventory for the eastern region of Minas Gerais? Two methodologies, Pearson Correlation and Garson Method, were used to order the 21 input variables of the studied agrometeorological models. For the construction of the agrometeorological models, three methodologies were used: i) models constructed according to the order of the Pearson Correlation; ii) models constructed according to the ordering of the Garson Method; and iii) models constructed according to the fusion of the methodologies of the ordering of the Pearson Correlation and Garson Method, denominated methodology of the Hybrid Model. The selection of the models was done by means of the lowest root mean square error (RMSE) of the test (%) and graph the estimated future volume versus future volume observed. All the processes were performed in the software Neuro AgroClimate, developed for this thesis. By ordering using Pearson correlation, variables of forest inventory were highlighted whereas by using Garson Method, it was ecophysiological variables who come to the fore. The RMSE values of the test (%) among the three methodologies analyzed were close, being: 6.24 of the

model 12 of the Pearson Correlation methodology; 6.42 of the model 16 the Garson Method methodology; and 6.61 of the model 9 the Hybrid Model methodology. There was a significant difference between the three models analyzed, and the network that presented the lowest RMSE of the test value (%) was model 12 of the Pearson Correlation methodology. The selection of the dependent variables was effective in optimizing the processing time of the networks when knowing the input variables.

1. INTRODUÇÃO

A eucaliptocultura no Brasil é uma das mais avançadas do mundo servindo de referência para outros países como a Austrália que é seu país de origem (Montagu *et al.*, 2003; Santos *et al.*, 2012), devido às suas características como crescimento rápido e plasticidade em relação ao estresse hídrico (Brown, 2000; Sacramento Neto, 2001).

O setor florestal brasileiro possui grande potencial a ser explorado devido às suas extensões de terras apropriadas, mão de obra abundante, clima e solo favoráveis, tecnologia silvicultural avançada (Soares *et al.*, 2009).

A produtividade das florestas de eucalipto e a área plantada no Brasil são importantes para o crescimento da produção nacional, e por isso é necessário estudar detalhadamente a área plantada (Soares, *et al.* 2009; Carvalho *et al.*, 2012). Os autores afirmam ainda que estudos nesse sentido são de grande importância para o planejamento da produção, comercialização, previsão e formulação de políticas para o segmento e, conseqüentemente, para melhorar o desempenho da economia brasileira.

O manejo florestal sustentável requer estimativas precisas de estoque de crescimento, uma vez que essas informações auxiliam a tomada de decisão pelos gestores florestais na análise econômica dos projetos florestais, bem como na geração e confecção de planos de manejo (Binoti, *et al.*, 2014; Gorgens *et al.*, 2014).

A proposta de inclusão de novas metodologias ou modelos que estimem o estoque volumétrico da madeira é necessária em função dos custos que essa etapa representa para o inventário florestal, bem como a importância desta na exatidão das estimativas volumétricas (Binoti, *et al.*, 2014).

Diversas ferramentas computacionais e de modelagem matemática tem sido utilizadas com êxito em situações de tomada de decisão no setor florestal, destacando-se as Redes Neurais Artificiais (RNA) (Leite *et al.*, 2016).

As características mais atrativas das RNAs consistem de suas habilidades em mapear sistemas não-lineares, aprendendo os comportamentos envolvidos a partir de informações (medidas, amostras ou padrões) fornecidas (Silva *et al.*, 2010). Essas características são ideais para trabalhar com sistemas dinâmicos como os plantios equiâneos.

Uma das vantagens das RNAs sobre os métodos convencionais de modelagem é que elas não requerem informação detalhada sobre os processos físicos, químicos ou biológicos do sistema a ser modelado, mas apenas um banco de dados representativo do mesmo (Sudheer *et al.*, 2003).

Silva *et al.*, (2009) verificaram que modelos de redes neurais artificiais apresentaram resultados similares ao estimar o volume de árvores de eucalipto utilizando o modelo consolidado de Schumacher e Hall.

As variáveis do inventário florestal que interferem no volume de madeira, como idade, espaçamento, solo, apresentam na maioria das vezes relações complexas e tendências muitas vezes não lineares dificultando o ajuste de modelos volumétricos (Binoti *et al.*, 2014). Ao acrescentar variáveis biofísicas a complexidade das relações aumenta devido ao caráter dinâmico dessas variáveis ao longo do espaço e do tempo.

Diante do exposto, o trabalho visa elucidar as seguintes questões: i) A redução do número de variáveis por meio de métodos de ordenação pode otimizar a construção de modelos de redes neurais para estimação da prognose? ii) Existe diferença significativa entre as prognoses realizadas por meio dos diferentes métodos analisados? iii) Qual o modelo mais eficiente para a realização da prognose do inventário florestal para a região do leste de Minas Gerais?

1.1- Objetivo geral

Propor uma nova metodologia para elaboração de modelos agrometeorológicos de Redes Neurais Artificiais (RNAs) para prognose de volume de madeira por meio de técnicas de discriminação e ordenação das variáveis do input.

1.2 - Objetivos específicos

- i) Desenvolver um sistema computacional para ordenar variáveis do input de modelos agrometeorológicos e processar prognoses por meio de Redes Neurais Artificiais (RNAs);
- ii) Ordenar variáveis do input dos modelos agrometeorológicos por meio da Correlação de Pearson e Método de Garson;
- iii) Construir, testar e validar modelos agrometeorológicos gerados por meio da ordenação da Correlação de Pearson e Método de Garson;
- iv) Selecionar o melhor modelo para a prognose do volume de madeira para o leste do estado de MG.

2. MATERIAL E MÉTODOS

Este estudo foi desenvolvido em áreas pertencentes a uma empresa florestal situada na região leste do estado de Minas Gerais com altitude entre 527 e 852 metros. Foram analisados 156 talhões divididos em 1882 parcelas.

O clima, segundo Köppen, é caracterizado como Aw-tropical chuvoso de savana (inverno seco e chuvas máximas no verão) e apresenta as médias anuais de precipitação igual a 1212 mm e temperatura média igual a 22,2 °C (Souza *et al.*, 2006).

O relevo oscila entre suave e forte ondulado e os solos são descritos como profundos, argilosos, pouco férteis e classificados como Latossolo (Leite *et al.*, 1997; Brito, 2004; Souza *et al.*, 2006).

2.1 - Dados do Inventário Florestal Contínuo (IFC)

Os dados utilizados no estudo são oriundos de parcelas permanentes de Inventários Florestais Contínuos (IFC) realizados anualmente e conduzidos em uma empresa florestal situada na região leste do estado de Minas Gerais.

O banco de dados é composto por florestas equiâneas cujo plantios foram realizados entre os anos de 1989 e 2011 com áreas das parcelas entre 2,70 a 118,90 ha.

As variáveis de inventário trabalhadas foram: área basal (m²), altura dominante (m), volume atual (m³/ha), volume futuro (m³/ha), idade atual (meses) e idade futura (meses).

2.2 - Dados Meteorológicos

Os dados meteorológicos são constituídos por dados diários de 1980 a 2013 (Xavier *et al.*, 2016) e as variáveis utilizadas foram: temperaturas mínima, máxima e média (°C), umidade relativa do ar (%), radiação solar (MJ/m²), velocidade do vento (m/s), precipitação (mm) e temperatura do ponto de orvalho (°C).

Foram incluídas ao banco de dados meteorológico o cálculo da soma mensal do número de dias com precipitação acima de 1 e 5 mm, o déficit de pressão de vapor (DPV) (kPa) e o índice ecofisiológico dado pela razão (DPV*T)/Rg.

O índice ecofisiológico, $(DPV \cdot T)/R_g$, foi assim chamado por ter uma correlação direta com a resistência do dossel à difusão de vapor de água (Carneiro *et al.*, 2008; Souza *et al.*, 2006).

2.3 - Neuro AgroClimate – NAC

A premissa básica da criação do Neuro AgroClimate (BR512016000503-3) foi criar uma rotina computacional eficiente com uma interface de fácil manipulação para atender à necessidade dos processamentos propostos na tese e que pudesse ser utilizada posteriormente por outros usuários.

A primeira versão do Neuro AgroClimate oferece:

- a) importação e exportação dos dados no formato ".xls" e ".xlsx" com opção de seleção da planilha desejada para a importação;
- b) opções de configurações da arquitetura da rede para aproximação de funções e série temporal;
- c) os resultados podem ser exportados no mesmo formato do item "i" e são separados em planilhas – sumário, predição e pesos;
- d) opção de editar os dados dentro da interface e, se desejado, salvar as correções no formato ".xls" e ".xlsx";
- e) possibilidade de treinar várias redes no mesmo processamento e salvar quantas forem desejadas;
- f) ao utilizar a rede salva para outro banco de dados, opção de analisar se as variáveis estão dentro da amplitude da rede treinada;
- g) gráficos da saída estimada versus saída observada;
- h) cálculo da "Correlação de Pearson" e "Correlação de Spearman" e
- i) cálculo do "Método de Garson".

2.4 – Organização dos dados para o input do modelo

Para a espacialização dos dados meteorológicos, dividiu-se a regional em 10 subáreas por meio da sobreposição entre as coordenadas das parcelas do Inventário Florestal Contínuo (IFC) e as coordenadas da grade meteorológica (tabela 1).

O primeiro IFC é realizado após 12 meses do plantio, mas para otimizar a logística das empresas florestais existe uma tolerância adotada neste caso de 3 meses. Foram retirados do banco de dados as parcelas que no primeiro IFC apresentaram valores de idade inferior a 9 meses e superior a 15 meses. Essa padronização foi necessária devido a parte dos dados apresentarem mensuração de áreas com grande discrepância dos valores da idade no primeiro IFC.

Os dados meteorológicos foram inseridos ao banco de dados de acordo com os intervalos de mensuração dos IFC. Para o primeiro IFC, as variáveis meteorológicas foram organizadas entre a data de plantio e o primeiro IFC. Já para o segundo IFC, as variáveis foram organizadas entre a data de plantio e o segundo IFC. Os cálculos foram feitos sucessivamente até o último IFC trabalhado.

Para a estruturação do banco de dados, calculou-se a média das variáveis temperaturas (°C) (máxima, mínima e média), umidade relativa do ar (%), radiação solar (MJ/m²), velocidade do vento (m/s), déficit de pressão de vapor (kPa), $(DPV \cdot T)/R_g$ e temperatura do ponto de orvalho (°C). Para as variáveis precipitação (mm) e dias com precipitação acima de 1 e 5 mm, calculou-se a soma.

2.5 – Ordenação das variáveis do input

Esta etapa do trabalho é inédita nesse tipo de estudo e foi preconizada pensando nas premissas do trabalho de otimizar o processamento das RNA e utilizar o menor número de variáveis de entrada, bem como utilizar elementos que permitam alguma explicação biofísica do desempenho comparativo entre as redes geradas. Para isso utilizou-se duas formas para a ordenação: a Correlação de Pearson e o Método de Garson.

i) Correlação de Pearson

A correlação é usada em trabalhos na área florestal para seleção de modelos por meio da correlação entre dados observados e estimados (Binoti *et al.*, 2015). Neste trabalho a correlação foi utilizada para ordenar as variáveis de entrada por meio do valor da correlação, do maior para o menor, entre a variável de saída “volume futuro m³/ha” e cada variável de entrada. Para a confecção dos modelos foi utilizada apenas a ordem das variáveis (os valores numéricos não foram utilizados).

O processamento foi realizado no software Neuro AgroClimate (BR512016000503-3), desenvolvido para esta tese por Magalhães, *et al.* (2016).

ii) Método de Garson

O Método de Garson permite perscrutar a importância das variáveis dependentes escolhidas na estruturação das redes segundo o peso composto na cadeia em que as redes são estruturadas. Em outras palavras, busca-se a seleção de atributos de maior importância.

Com o conhecimento prévio da importância de cada variável em cada modelo gerado pode-se remover variáveis com pequena contribuição que contribuem de forma negativa para as relações não-lineares modeladas (Silva, 2014). Com a retirada das variáveis de contribuição negativa, a convergência dos dados melhora.

Segundo Silva (2014), podemos resumir a escolha do Método de Garson pelos seguintes pontos: i) ser um método quantitativo, ou seja, não depende da interpretação do usuário; ii) permite interpretar grandes quantidades de atributos ao mesmo tempo de forma prática.

Após o processo de treinamento da rede, foram salvos os valores dos pesos sinápticos entre a camada de entrada e a camada intermediária, entre a camada intermediária e a camada de saída, e realizado o método do cálculo da contribuição de cada atributo, conforme feito por Garson (1991) e o resultado desse cálculo é o valor da contribuição relativa de cada atributo.

Os passos seguidos pelo método são descritos a seguir (Kaur *et al.*, 2005):

- a) Para cada neurônio i da camada intermediária, o valor absoluto do peso da conexão entre este neurônio e um da camada de saída é multiplicado pelo valor absoluto do peso da conexão entre o mesmo neurônio da camada intermediária e um neurônio da camada de entrada. Este cálculo deve ser feito para todos os j -ésimos neurônios da camada de entrada (P_{ij});
- b) Para cada neurônio da camada intermediária, dividiu-se cada P_{ij} obtido na etapa i) pela soma de todos os P_{ijs} para obter Q_{ijs} ;
- c) Para cada neurônio da camada de entrada, os valores de Q_{ijs} foram somados obtendo-se o valor de S_j ;
- d) Dividiu-se cada valor de S_j pela soma de todos os valores de S_j . Dessa forma foi obtida a importância relativa ou contribuição de cada um dos valores.

Para ordenar as variáveis de entrada (ou variáveis dependentes) por meio do Método de Garson, foram processadas redes do tipo Multilayer Perceptron (MLP) – Aproximação de Funções, utilizando todas as variáveis dependentes como variáveis de entrada (21 variáveis) e a variável independente “volume futuro” como a variável de saída.

Segundo Haykin (2001), os principais modelos de redes neurais utilizados para previsões de variáveis contínuas são as redes Multilayer Perceptron (MLP). Ainda segundo o autor, as redes MLP são caracterizadas pela presença de pelo menos uma camada intermediária de neurônios, situada entre a camada de entrada e a respectiva camada neural de saída. Consequentemente, as redes MLP possuem no mínimo duas camadas de neurônios, os quais estão distribuídos entre as camadas intermediárias e a camada de saída (Silva *et al.*, 2010).

A estrutura para modelagem dos dados foi organizada de acordo com Binoti *et al.* (2015): informações dos inventários pareadas, ou seja, o 1º IFC com o 2º IFC, o 2º IFC com o 3º IFC e, assim, sucessivamente.

O algoritmo de treinamento utilizado foi o Levenberg–Marquardt. Processamentos com um número elevado de variáveis pode exigir um elevado esforço computacional. Uma opção de algoritmo que reduz o tempo de convergência e diminui o esforço computacional requerido é o Levenberg-Marquardt (Silva *et al.*, 2010). Segundo Hagan e Menhaj (1994), o método de Levenberg-Marquardt consegue conduzir o treinamento de redes MLP na ordem de 10 a 100 vezes mais rápido que o algoritmo backpropagation convencional.

Na camada intermediária, a função de ativação utilizada foi a Tangente Hiperbólica e na camada de saída a função Identidade. A função de ativação é uma função matemática que ao ser aplicada à combinação linear entre as variáveis de entrada e os pesos que chegam ao neurônio, retorna à variável de saída. As entradas são limitadas a uma amplitude que varia de acordo com a função de ativação selecionada (Haykin, 2001; Silva *et al.*, 2010).

As demais configurações utilizadas foram: erro quadrático médio 10⁻⁴ e verificação da validação (validation checks) igual ao número de iterações; número de repetições igual a 5; taxa de aprendizado igual a 0,5. Para a escolha do número de iterações, testou-se os valores 300, 500 e 1000.

O banco de dados foi dividido em três seções: (i) um conjunto de dados de treinamento (70% do conjunto de dados total), (ii) um conjunto de dados de teste (15% do conjunto de dados total) e (iii) um conjunto de dados de validação (15% do conjunto de dados total). Uma maior porcentagem do banco de dados (70%) foi utilizada para o treinamento, uma vez que é o momento em que ocorre o processo de ajuste dos pesos sinápticos, por meio de um algoritmo de aprendizagem, que extrai características dos dados fornecidos e tem por objetivo gerar uma rede que desempenhe a tarefa de interesse (BRAGA *et al.*, 2007; Silva *et al.*, 2010; Binoti *et al.*, 2015).

Os padrões de dados foram extraídos aleatoriamente do arquivo de padrão completo e incorporados em cada uma das três seções. Antes de serem apresentados à rede, todos os dados foram primeiro normalizados por variável para um intervalo numérico de -1 a 1. A normalização foi realizada

para converter todas as variáveis para um intervalo numérico comum com o qual a rede neural poderia lidar efetivamente, além de reduzir o efeito de "outliers" nos dados (Ryan *et al.*, 2004).

A definição do número de neurônios na camada intermediária é de extrema importância para o desempenho dos modelos, principalmente no que se refere à sua capacidade de generalização (Braga *et al.*, 2007). Ainda segundo os autores, o número de neurônios determina a capacidade da rede em resolver problemas de determinada complexidade.

A camada intermediária (ou camada escondida) é aquela composta por neurônios que possuem a responsabilidade de extrair as características associadas ao processo ou sistema a ser inferido e quase todo o processamento interno da rede é realizado nessas camadas (Silva *et al.*, 2010).

O número de neurônios na camada intermediária é conhecido como a "caixa preta" da configuração das redes. De acordo com Silva *et al.*, (2010), no processo de determinação do número de neurônios, deve-se considerar que um número excessivo de neurônios pode acarretar a memorização dos dados de treinamento (overfitting) e por outro lado, um pequeno número de neurônios na camada escondida pode não ser suficiente para a realização da tarefa desejada, fenômeno conhecido como underfitting. O ideal é tentar trabalhar com um valor que fique entre o underfitting e o overfitting.

Utilizou-se os métodos de Kolmogorov e Fletcher-Gloss (Silva *et al.*, 2010) para a escolha do número de neurônios na camada intermediária (equações 1 e 2), considerando uma rede do tipo MLP constituída de apenas uma única camada intermediária.

Método de Kolmogorov

Equação 1

$$n_1 = 2 \cdot n + 1$$

Método de Fletcher-Gloss

Equação 2

$$2 \cdot \sqrt{n} + n_2 \leq n_1 \leq 2 \cdot n + 1$$

onde n é o número de entradas da rede, n_1 é a quantidade de neurônios na camada escondida e n_2 é a quantidade de neurônios em sua camada de saída (Tabela 1).

Tabela 1: Amplitude dos valores de neurônios possíveis para a camada intermediária de acordo com os métodos de Kolmogorov e Fletcher-Gloss.

Número de variáveis		Método de Fletcher-Gloss	$\leq n \leq$	Método de Kolmogorov
Entrada	Saída			
1	1	3		3
2	1	4		5
3	1	4		7
4	1	5		9
5	1	5		11
6	1	6		13
7	1	6		15
8	1	7		17
9	1	7		19
10	1	7		21
11	1	8		23
12	1	8		25
13	1	8		27
14	1	8		29
15	1	9		31
16	1	9		33
17	1	9		35
18	1	9		37
19	1	10		39
20	1	10		41
21	1	10		43
22	1	10		45
23	1	11		47
24	1	11		49
25	1	11		51
26	1	11		53
27	1	11		55
28	1	12		57
29	1	12		59
30	1	12		61
31	1	12		63

Selecionou-se 5 valores dentro da amplitude dos valores possíveis: i) para o número de variáveis de entrada cuja amplitude apresentava o número de neurônios inferior ou igual a 5, utilizou-se todos os valores da amplitude; ii) para o número de variáveis de entrada superior a 5, utilizou-se os valores das duas extremidades (dois valores), o valor médio entre os extremos (um valor), o valor médio entre o extremo inferior e o valor médio entre os extremos, e o valor entre o extremo superior e o valor médio entre os extremos.

O total de redes treinadas para cada modelo foi igual a 75 (5 configurações diferentes de neurônios x 3 iterações diferentes x 5 repetições).

Foi escolhida a rede com o menor valor do erro quadrático médio do teste para utilizar a ordenação do Método de Garson.

O processamento foi realizado no software Neuro AgroClimate (BR512016000503-3), desenvolvido para esta tese por Magalhães, *et al.* (2016).

2.6 – Construção e seleção dos modelos agrometeorológicos

Com os resultados das ordenações das variáveis de entrada por meio da Correlação de Pearson e Método de Garson, iniciou-se a construção dos modelos agrometeorológicos.

A estrutura para modelagem dos dados foi organizada de acordo com Binoti *et al.*, (2015): informações dos inventários pareadas, ou seja, o 1º IFC com o 2º IFC, o 2º IFC com o 3º IFC e, assim, sucessivamente.

Os modelos gerados (RNA's) foram estruturados sendo o “volume futuro” da madeira como variável de saída (variável independente - output) e variando o número de variáveis dependentes utilizadas como input.

i) Modelos provenientes da ordenação da Correlação de Pearson

O primeiro modelo foi composto pela variável de saída “volume futuro” e a primeira variável dependente da ordenação da Correlação de Pearson; o segundo modelo foi composto pela variável de saída “volume futuro” e as duas primeiras variáveis dependentes da ordenação da Correlação de Pearson; e assim sucessivamente até o último modelo com 21 variáveis dependentes (Tabela 2).

ii) Modelos provenientes da ordenação do Método de Garson

O primeiro modelo foi composto pela variável de saída “volume futuro” e a primeira variável dependente da ordenação do Método de Garson; o segundo modelo foi composto pela variável de saída “volume futuro” e as duas primeiras variáveis dependentes da ordenação do Método de Garson; e assim sucessivamente até o último modelo com 21 variáveis dependentes (Tabela 2).

iii) Modelos provenientes do Método Híbrido:

O Método Híbrido foi formado fundindo as variáveis dos modelos oriundos da Correlação de Pearson e Método de Garson.

O primeiro modelo híbrido foi composto pela variável de saída “volume futuro” e a primeira variável dependente da ordenação da Correlação de Pearson e do Método de Garson; o segundo modelo foi composto pela variável de saída “volume futuro” e as duas primeiras variáveis dependentes da ordenação da Correlação de Pearson e do Método de Garson; e assim sucessivamente, e assim sucessivamente sem repetição das variáveis, até o último modelo com 21 variáveis dependentes (Tabela 2).

Os modelos foram gerados por meio de redes do tipo Multilayer Perceptron (MLP) – Aproximação de Funções, com as configurações: algoritmo de treinamento - Levenberg–Marquardt; função de ativação da camada intermediária - Tangente Hiperbólica; função de ativação da camada de saída - Identidade; erro quadrático médio 10^{-4} e verificação da validação (validation checks) igual ao número de iterações; número de repetições igual a 5; taxa de aprendizado igual a 0,5; número de iterações igual a 300, 500 e 1000.

O banco de dados foi dividido em 70% para o treinamento, 15% para a validação e 15% para o teste. Os dados foram normalizados, por variável, dentro da amplitude -1 a 1.

Utilizou-se os métodos de Kolmogorov e Fletcher-Gloss (equações 1 e 2) para a escolha do número de neurônios na camada intermediária.

Foram selecionadas 21 redes (uma por modelo) para as metodologias da Correlação de Pearson e Método de Garson, e 14 redes (uma por modelo) para metodologia do Método Híbrido. A seleção ocorreu por meio do menor valor da raiz do erro quadrático médio (RMSE) do teste, descrito pela equação 3 (Mehtatalo *et al.*, 2006; Binoti *et al.*, 2015) e gráficos do volume futuro estimado versus volume futuro observado (Figuras 16 a 18 – Anexo).

$$\text{RMSE}(\%) = \frac{100}{\bar{V}} \sqrt{\frac{\sum_{i=1}^n (V_i - \bar{V}_i)^2}{n}}$$

Equação 3

em que \bar{V} é a média dos volumes totais observados e n o número de total de observações.

Para cada metodologia (Correlação de Pearson, Método de Garson e Método Híbrido), o modelo com o menor valor de RMSE foi comparado estatisticamente com os demais por meio do procedimento estatístico proposto por Leite e Oliveira (2002). O modelo com menor número de variáveis dependentes considerado estatisticamente igual ao modelo com menor valor de RMSE selecionado anteriormente, foi considerado o melhor modelo.

Posteriormente, os três melhores modelos (um por metodologia), foram comparados estatisticamente.

Cada modelo foi processado no software Neuro AgroClimate, desenvolvido como parte desse trabalho (BR512016000503-3) por Magalhães *et al.*, (2016).

Tabela 2: Descrição dos modelos trabalhados de acordo com a Correlação de Pearson, Método de Garson e Modelo Híbrido.

Variáveis de entrada			
	Correlação de Pearson	Método de Garson	Modelo Híbrido
Modelo 1	volume atual	défice de pressão de vapor (DPV)	volume atual, défice de pressão de vapor (DPV)
Modelo 2	volume atual, área basal	défice de pressão de vapor (DPV), (DPVxTmed)/Rg	volume atual, área basal, défice de pressão de vapor (DPV), (DPVxTmed)/Rg
Modelo 3	volume atual, área basal, altura dominante	défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média	volume atual, área basal, altura dominante, défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média
Modelo 4	volume atual, área basal, altura dominante, idade futura	défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média, temperatura máxima	volume atual, área basal, altura dominante, idade futura, défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média, temperatura máxima
Modelo 5	volume atual, área basal, altura dominante, idade futura, idade atual	défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média, temperatura máxima, temperatura mínima	volume atual, área basal, altura dominante, idade futura, idade atual, défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média, temperatura máxima, temperatura mínima
Modelo 6	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm	défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar
Modelo 7	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm	défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar, temperatura do ponto de orvalho	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar, temperatura do ponto de orvalho
Modelo 8	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, precipitação	défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar, temperatura do ponto de orvalho, dias com precipitação acima de 1 mm	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, precipitação, dias com precipitação acima 5 mm, défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar, temperatura do ponto de orvalho
Modelo 9	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, precipitação, amplitude térmica	défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar, temperatura do ponto de orvalho, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, precipitação, dias com precipitação acima 5 mm, amplitude térmica, défice de pressão de vapor (DPV), (DPVxTmed)/Rg, temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar, temperatura do ponto de orvalho

Modelo 15	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, precipitação, amplitude térmica, espaçamento, velocidade do vento, temperatura mínima, temperatura máxima, déficit de pressão de vapor (DPV), (DPVxTmed)/Rg	déficit de pressão de vapor (DPV), (DPVxTmed)/Rg , temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar, temperatura do ponto de orvalho, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, idade futura, idade atual, volume atual, precipitação, área basal, velocidade do vento	
Modelo 16	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, precipitação, amplitude térmica, espaçamento, velocidade do vento, temperatura mínima, temperatura máxima, déficit de pressão de vapor (DPV), (DPVxTmed)/Rg , radiação	déficit de pressão de vapor (DPV), (DPVxTmed)/Rg , temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar, temperatura do ponto de orvalho, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, idade futura, idade atual, volume atual, precipitação, área basal, velocidade do vento, altura dominante	
Modelo 17	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, precipitação, amplitude térmica, espaçamento, velocidade do vento, temperatura mínima, temperatura máxima, déficit de pressão de vapor (DPV), (DPVxTmed)/Rg , radiação, área	déficit de pressão de vapor (DPV), (DPVxTmed)/Rg , temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar, temperatura do ponto de orvalho, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, idade futura, idade atual, volume atual, precipitação, área basal, velocidade do vento, altura dominante, radiação	
Modelo 18	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, precipitação, amplitude térmica, espaçamento, velocidade do vento, temperatura mínima, temperatura máxima, déficit de pressão de vapor (DPV), (DPVxTmed)/Rg , radiação, área, temperatura média	déficit de pressão de vapor (DPV), (DPVxTmed)/Rg , temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar, temperatura do ponto de orvalho, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, idade futura, idade atual, volume atual, precipitação, área basal, velocidade do vento, altura dominante, radiação, amplitude térmica	
Modelo 19	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, precipitação, amplitude térmica, espaçamento, velocidade do vento, temperatura mínima, temperatura máxima, déficit de pressão de vapor (DPV), (DPVxTmed)/Rg , radiação, área, temperatura média, temperatura do ponto de orvalho	déficit de pressão de vapor (DPV), (DPVxTmed)/Rg , temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar, temperatura do ponto de orvalho, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, idade futura, idade atual, volume atual, precipitação, área basal, velocidade do vento, altura dominante, radiação, amplitude térmica, espaçamento	

Modelo 20	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, precipitação, amplitude térmica, espaçamento, velocidade do vento, temperatura mínima, temperatura máxima, déficit de pressão de vapor (DPV), $(DPV \times T_{med})/R_g$, radiação, área, temperatura média, temperatura do ponto de orvalho, altitude	déficit de pressão de vapor (DPV), $(DPV \times T_{med})/R_g$, temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar, temperatura do ponto de orvalho, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, idade futura, idade atual, volume atual, precipitação, área basal, velocidade do vento, altura dominante, radiação, amplitude térmica, espaçamento, área	
Modelo 21	volume atual, área basal, altura dominante, idade futura, idade atual, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, precipitação, amplitude térmica, espaçamento, velocidade do vento, temperatura mínima, temperatura máxima, déficit de pressão de vapor (DPV), $(DPV \times T_{med})/R_g$, radiação, área, temperatura média, temperatura do ponto de orvalho, altitude, umidade relativa do ar	déficit de pressão de vapor (DPV), $(DPV \times T_{med})/R_g$, temperatura média, temperatura máxima, temperatura mínima, umidade relativa do ar, temperatura do ponto de orvalho, dias com precipitação acima de 1 mm, dias com precipitação acima 5 mm, idade futura, idade atual, volume atual, precipitação, área basal, velocidade do vento, altura dominante, radiação, amplitude térmica, espaçamento, área, altitude	

3. RESULTADOS E DISCUSSÃO

3.1 – Ordenação da importância relativa das variáveis do input

Os valores da Correlação de Pearson e do Método de Garson foram obtidos por meio de processamentos distintos explicados na metodologia, sendo retirados os valores e utilizado somente o ordenamento obtido pelos dois métodos (tabela 3 e 4).

A seleção das variáveis dependentes pode otimizar o tempo de processamento de redes neurais artificiais, uma vez que já se conhece as variáveis que mais controlam a biossíntese em suas relações com as condições ambientais nos processos biofísicos.

Para o resultado da ordenação pela Correlação de Pearson (Tabela 3), já era esperado que as variáveis de inventário florestal (área basal, altura dominante e idade) apresentassem maior correlação com a variável de saída “volume futuro”. No setor florestal, os dois modelos mais utilizados para o cálculo do volume de madeira são o Modelo de Clutter (Salles *et al.*, 2012) e Modelo de Schumacher e Hall (Silva *et al.*, 2009); ambos utilizam pelo menos duas das variáveis de inventário florestal citadas e estas são diretamente proporcionais à variável de saída.

Do ponto de vista ecofisiológico, o Método de Garson (Tabela 4) apresentou maior coerência na ordenação das variáveis do input (DPV, temperatura e umidade relativa do ar), uma vez que pode ser constatado que as variáveis que apresentaram maior peso estão relacionadas com o controle estomático e conseqüentemente determinam os ganhos/perdas da produção primária bruta da floresta.

A variável que mais se destacou na seleção pelo Método de Garson foi o DPV (Tabela 4) que apresenta uma resposta inversamente proporcional ao ganho de volume de madeira. O aumento do DPV ocasiona o fechamento dos estômatos reduzindo a taxa fotossintética (Leuning, 1990; Vose e Swank, 1994; Souza Filho, 2002; Streck, 2003; Chaves *et al.*, 2004; Tatagiba *et al.*, 2007; Silva, 2007).

No Método de Garson (Tabela 4), era esperado que a variável radiação solar fosse mais representativa, uma vez que ela é uma das principais variáveis que afetam o crescimento das árvores (Souza *et al.*, 2006; Santana *et al.*,

2008). A breve redução na radiação solar incidente sobre uma árvore, provocada pela simples passagem de nuvem, pode acionar a resposta imediata dos estômatos (Rodrigues *et al.*, 2011), alterando a produtividade da planta que está relacionada principalmente à quantidade de energia interceptada e absorvida (Magalhães, 1985).

A radiação solar foi representada de forma indireta por suas variáveis derivadas, como a temperatura.

As variáveis fisiológicas na ordenação pela Correlação de Pearson (Tabela 3) não apresentaram boa colocação, DPV e $(DPV \times T_{med})/R_g$ ficaram nas posições 14° e 15°, respectivamente, no total de 21 variáveis dependentes. A umidade relativa do ar, variável que interfere diretamente na abertura dos estômatos, ficou na última colocação. A posição dessas variáveis demonstra que na metodologia da Correlação de Pearson não é dada a devida importância para as relações fisiológicas que possuem grande peso no entendimento da dinâmica de ganho de volume de madeira.

Nas duas ordenações analisadas, a variável “número de dias com precipitação acima de 1 mm” foi mais representativa do que a variável “número de dias com precipitação acima de 5 mm” (tabelas 3 e 4). Esse fato pode estar ligado ao teor de argila encontrado no solo, uma vez que solos com maior teor de argila apresentam menor espaçamento entre suas partículas e conseguem deste modo reter uma quantidade maior de água. Desta forma, mesmo o menor volume precipitado pode fazer diferença para a vegetação local devido ao tempo maior de disponibilidade de água no solo para a absorção das raízes.

A variável altitude não foi representativa em nenhuma das metodologias utilizadas (tabelas 3 e 4). A baixa representatividade da variável em questão pode ser explicada por sua pequena amplitude entre as áreas estudadas, com a altitude entre 527 e 852 metros.

Tabela 3: Ordenação das variáveis de entrada por meio da Correlação de Pearson.

Correlação de Pearson	
Variáveis dependentes	
1	Volume (m ³)
2	Área basal (m ²)
3	Altura dominante (m)
4	Idade futura (meses)
5	Idade (meses)
6	Dias com precipitação acima de 1 mm
7	Dias com precipitação acima de 5 mm
8	Precipitação (mm)
9	Amplitude térmica (°C)
10	Espaçamento
11	Velocidade do vento (m/s)
12	Temperatura mínima (°C)
13	Temperatura máxima (°C)
14	Défice de pressão de vapor - DPV (kPa)
15	$(DPV \times T_{med}) / R_g$
16	Radição (MJ/m ²)
17	Área (m ²)
18	Temperatura média (°C)
19	Temperatura do ponto de orvalho (°C)
20	Altitude (m)
21	Umidade relativa do ar (%)

Tabela 4: Ordenação das variáveis de entrada por meio do Método de Garson.

Método de Garson	
Variáveis dependentes	
1	Défice de pressão de vapor - DPV (kPa)
2	$(DPV \times T_{med}) / R_g$
3	Temperatura média (°C)
4	Temperatura máxima (°C)
5	Temperatura mínima (°C)
6	Umidade relativa do ar (%)
7	Temperatura do ponto de orvalho (°C)
8	Dias com precipitação acima de 1 mm
9	Dias com precipitação acima de 5 mm
10	Idade futura (meses)
11	Idade (meses)
12	Volume (m ³)
13	Precipitação (mm)
14	Área basal (m ²)
15	Velocidade do vento (m/s)
16	Altura dominante (m)
17	Radição (MJ/m ²)
18	Amplitude térmica (°C)
19	Espaçamento
20	Área (m ²)
21	Altitude (m)

3.2 – Seleção dos modelos agrometeorológicos

Ao analisar as tabelas 5, 6 e 7, observa-se que para as três metodologias analisadas, os modelos com um número reduzido de variáveis apresentaram valores maiores de RMSE do teste (%) e que a medida em que as variáveis foram acrescentadas o erro foi reduzindo até um determinado modelo, e posteriormente ocorreu aumento discreto.

Dentre os modelos estruturados com base na metodologia da ordenação da Correlação de Pearson, verificou-se que o modelo 12 com a arquitetura MLP 12-25-1 apresentou o menor valor de RMSE do teste (%) que foi igual a 6,24 (tabela 5); para a metodologia do Método de Garson, o modelo com arquitetura MLP 16-9-1 (tabela 6) apresentou o menor valor de RMSE do teste % que foi igual a 6,52; já a metodologia do Modelo Híbrido apresentou o melhor resultado do valor de RMSE do teste (%) igual a 6,61, para o modelo 9 com arquitetura MLP 16-9-1. Segundo Binoti *et al.*, (2015), valores de RMSE concentrados em $\pm 7,5\%$ no treinamento e na validação, em nível de parcela, são considerados altamente satisfatórios.

Extrapolando o valor atribuído por Binoti *et al.*, (2015) para a validação ser considerada altamente satisfatória para o resultado do teste das redes treinadas neste estudo (tabelas 5 a 7), o primeiro modelo derivado da metodologia da Correlação de Pearson a atingir o referido grau de satisfatoriedade foi o modelo 5. Já para as metodologias do Método de Garson e Modelo Híbrido foram os modelos 12 e 4, respectivamente.

Em relação à arquitetura, em 71,4 % dos modelos (tabela 5) construídos por meio da ordenação da Correlação de Pearson o número de neurônios na camada intermediária foi superior ao número de variáveis do input dos modelos analisados. Nos modelos da ordenação do Modelo Híbrido e Método de Garson foram 50% e 47,6%, respectivamente. Por meio dos valores apresentados pode-se inferir que testes com valores de neurônios da camada intermediária superiores ao número de variáveis do input do modelo devem ser considerados.

Ao analisar o número de iterações dos modelos de cada metodologia (tabelas 5 a 7), destacou-se o valor de 300 iterações com 42,8%, 42,8% e 57,1% do número total de modelos da Correlação de Pearson, Método de Garson e Modelo Híbrido.

Os gráficos das metodologias Correlação de Pearson (figura 16) e Modelo Híbrido (figura 18) apresentaram bons ajustes em todos os modelos trabalhados. No entanto, os modelos da metodologia Método de Garson (figura 17) apresentaram ajustes ruins até o modelo 11, com a inserção da variável temperatura mínima no modelo 12 (Tabela 2) o ajuste melhorou consideravelmente.

Tabela 5: Configurações e raiz do erro quadrático médio (RMSE) dos modelos gerados por meio da metodologia da Correlação de Pearson.

	Número de variáveis dependentes	Arquitetura	Critério de Parada	Número de iterações	Tempo de Treinamento (segundos)	RMSE do Treinamento (%)	RMSE do Teste (%)	RMSE do Validação (%)
Modelo 1	1	MLP 1-3-1	Número de iterações	1000	50,5	10,29	9,56	10,58
Modelo 2	2	MLP 2-5-1	Número de iterações	300	15,9	9,95	8,68	8,80
Modelo 3	3	MLP 3-5-1	Número de iterações	1000	52,9	9,16	8,03	9,72
Modelo 4	4	MLP 4-5-1	Número de iterações	1000	48,4	8,37	7,91	9,61
Modelo 5	5	MLP 5-7-1	Número de iterações	300	14,8	8,23	7,27	7,48
Modelo 6	6	MLP 6-12-1	Número de iterações	500	28,3	7,96	7,66	8,48
Modelo 7	7	MLP 7-11-1	Número de iterações	500	28,9	7,45	7,37	8,48
Modelo 8	8	MLP 8-12-1	Número de iterações	500	31,2	7,53	7,49	7,35
Modelo 9	9	MLP 9-13-1	Número de iterações	300	20,0	7,97	6,98	7,52
Modelo 10	10	MLP 10-17-1	Número de iterações	1000	77,6	7,08	7,11	8,17
Modelo 11	11	MLP 11-19-1	Número de iterações	500	41,9	7,61	7,30	7,55
Modelo 12	12	MLP 12-25-1	Número de iterações	500	53,8	7,07	6,24	7,69
Modelo 13	13	MLP 13-13-1	Número de iterações	300	22,0	7,11	6,87	7,34
Modelo 14	14	MLP 14-13-1	Número de iterações	300	22,9	7,36	7,08	7,47
Modelo 15	15	MLP 15-25-1	Número de iterações	500	62,3	6,88	6,82	8,49
Modelo 16	16	MLP 16-9-1	Número de iterações	300	20,2	6,83	6,78	9,12
Modelo 17	17	MLP 17-22-1	Número de iterações	300	40,5	7,26	7,53	7,22
Modelo 18	18	MLP 18-9-1	Número de iterações	300	21,1	6,48	9,92	7,68
Modelo 19	19	MLP 19-17-1	Número de iterações	500	50,6	8,09	7,60	8,62
Modelo 20	20	MLP 20-10-1	Número de iterações	1000	75,6	6,73	7,24	9,72
Modelo 21	21	MLP 21-18-1	Número de iterações	300	32,2	7,21	7,47	8,07

Tabela 6: Configurações e raiz do erro quadrático médio (RMSE) dos modelos gerados por meio da metodologia do Método de Garson.

	Número de variáveis dependentes	Arquitetura	Critério de Parada	Número de Iterações	Tempo de Treinamento (segundos)	RMSE do Treinamento (%)	RMSE do Teste (%)	RMSE do Validação (%)
Modelo 1	1	MLP 1-3-1	Número de iterações	1000	52,8	40,61	37,49	39,99
Modelo 2	2	MLP 2-4-1	Número de iterações	300	16,2	40,07	34,33	37,31
Modelo 3	3	MLP 3-6-1	Número de iterações	300	16,6	34,28	31,28	32,63
Modelo 4	4	MLP 4-8-1	Número de iterações	500	24,9	30,56	30,52	32,48
Modelo 5	5	MLP 5-11-1	Número de iterações	500	29,3	30,77	28,31	32,27
Modelo 6	6	MLP 6-13-1	Número de iterações	1000	60,7	28,96	27,52	30,71
Modelo 7	7	MLP 7-10-1	Número de iterações	300	18,0	29,23	26,13	27,12
Modelo 8	8	MLP 8-17-1	Número de iterações	1000	67,5	20,13	20,19	21,17
Modelo 9	9	MLP 9-7-1	Número de iterações	300	17,4	21,98	20,20	20,69
Modelo 10	10	MLP 10-11-1	Número de iterações	500	31,9	20,83	19,03	21,13
Modelo 11	11	MLP 11-11-1	Número de iterações	500	32,6	20,76	19,09	23,21
Modelo 12	12	MLP 12-12-1	Número de iterações	500	33,8	7,34	7,20	8,27
Modelo 13	13	MLP 13-18-1	Número de iterações	300	24,7	7,26	6,71	7,48
Modelo 14	14	MLP 14-8-1	Número de iterações	1000	63,4	7,37	7,20	9,70
Modelo 15	15	MLP 15-15-1	Número de iterações	300	23,5	6,83	7,21	6,98
Modelo 16	16	MLP 16-9-1	Número de iterações	1000	63,6	7,35	6,42	8,96
Modelo 17	17	MLP 17-15-1	Número de iterações	300	24,5	7,00	6,82	8,39
Modelo 18	18	MLP 18-9-1	Número de iterações	500	34,2	7,41	7,05	7,23
Modelo 19	19	MLP 19-10-1	Número de iterações	500	35,9	6,92	6,81	7,56
Modelo 20	20	MLP 20-10-1	Número de iterações	300	22,4	7,41	6,74	7,01
Modelo 21	21	MLP 21-18-1	Número de iterações	300	32,2	7,21	7,47	8,07

Tabela 7: Configurações e raiz do erro quadrático médio (RMSE) dos modelos gerados por meio por meio da metodologia do Método Híbrido.

	Número de variáveis dependentes	Arquitetura	Critério de Parada	Número de Iterações	Tempo de Treinamento (segundos)	RMSE do Treinamento (%)	RMSE do Teste (%)	RMSE do Validação (%)
Modelo 1	2	MLP 2-5-1	Número de iterações	300	15,72	10,34	9,11	9,43
Modelo 2	4	MLP 4-8-1	Número de iterações	1000	63,434	9,39	8,62	9,17
Modelo 3	6	MLP 6-13-1	Número de iterações	300	19,259	8,48	7,88	8,48
Modelo 4	8	MLP 8-15-1	Número de iterações	1000	71,058	7,71	7,09	7,85
Modelo 5	10	MLP 10-11-1	Número de iterações	1000	66,509	7,28	7,08	8,02
Modelo 6	12	MLP 12-21-1	Número de iterações	300	24,593	6,87	6,95	7,37
Modelo 7	14	MLP 14-13-1	Número de iterações	300	22,705	6,90	7,15	8,24
Modelo 8	15	MLP 15-9-1	Número de iterações	1000	68,838	7,58	7,14	7,60
Modelo 9	16	MLP 16-9-1	Número de iterações	1000	67,289	7,17	6,61	9,13
Modelo 10	17	MLP 17-9-1	Número de iterações	300	19,827	7,46	7,34	7,81
Modelo 11	18	MLP 18-9-1	Número de iterações	500	35,569	7,29	6,89	7,12
Modelo 12	19	MLP 19-32-1	Número de iterações	300	49,143	6,24	6,73	8,61
Modelo 13	20	MLP 20-10-1	Número de iterações	300	22,159	7,41	6,74	7,01
Modelo 14	21	MLP 21-18-1	Número de iterações	300	32,192	7,21	7,47	8,07

Ao analisar o resultado da análise estatística para cada metodologia, observa-se que os modelos diferem entre si (tabelas 8 a 10). Desta forma, os melhores modelos continuam sendo os 12, 16 e 9 para as metodologias da Correlação de Pearson, Método de Garson e Modelo Híbrido, respectivamente.

Tabela 8: Comparativo entre o volume futuro estimado do melhor modelo da Correlação de Pearson (modelo 12) com o volume futuro estimado dos 20 modelos restantes, utilizando o procedimento estatístico proposto por Leite e Oliveira (2002) a $\alpha=5\%$.

Correlação de Pearson	Estatística				
	F (Ho)	t (e)	$r_{y,\hat{y}} \geq 1 - \bar{e} $	Erro Médio (e)	Resultado
Rede - 1 variável	87,08*	1,27 ^{ns}	não	0,01	diferente
Rede - 2 variáveis	54,93*	0,97 ^{ns}	não	0,00	diferente
Rede - 3 variáveis	47,33*	0,57 ^{ns}	não	0,00	diferente
Rede - 4 variáveis	38,69*	3,25*	não	0,01	diferente
Rede - 5 variáveis	35,01*	0,00 ^{ns}	não	0,00	diferente
Rede - 6 variáveis	19,29*	1,12 ^{ns}	sim	-0,02	diferente
Rede - 7 variáveis	24,72*	3,79*	sim	0,01	diferente
Rede - 8 variáveis	21,37*	1,87 ^{ns}	não	0,00	diferente
Rede - 9 variáveis	12,10*	1,95 ^{ns}	sim	0,00	diferente
Rede - 10 variáveis	20,27*	2,68*	não	0,00	diferente
Rede - 11 variáveis	13,28*	0,36 ^{ns}	não	0,00	diferente
Rede - 13 variáveis	7,96*	2,78*	sim	0,01	diferente
Rede - 14 variáveis	11,85*	0,11 ^{ns}	não	0,00	diferente
Rede - 15 variáveis	20,62*	0,70 ^{ns}	sim	-0,01	diferente
Rede - 16 variáveis	39,59*	0,68 ^{ns}	não	0,00	diferente
Rede - 17 variáveis	3,41*	1,15 ^{ns}	não	0,01	diferente
Rede - 18 variáveis	30,24*	2,25*	sim	0,01	diferente
Rede - 19 variáveis	84,48*	2,24*	sim	0,01	diferente
Rede - 20 variáveis	17,92*	2,26*	sim	0,01	diferente
Rede - 21 variáveis	29,63*	5,18*	sim	0,01	diferente

Tabela 9: Comparativo entre o volume futuro estimado do melhor modelo do Método de Garson (modelo 16) com o volume futuro estimado dos 20 modelos restantes, utilizando o procedimento estatístico proposto por Leite e Oliveira (2002) a $\alpha=5\%$.

Método de Garson	Estatística				
	F (Ho)	t (e)	$r_{y,\hat{y}_1} \geq 1- e $	Erro Médio (e)	Resultado
Rede - 1 variável	25743,18*	25,14*	não	0,30	diferente
Rede - 2 variáveis	13898,66*	23,15*	não	0,28	diferente
Rede - 3 variáveis	3378,34*	18,31*	não	0,20	diferente
Rede - 4 variáveis	2247,86*	18,19*	não	0,19	diferente
Rede - 5 variáveis	2055,52*	15,79*	não	0,17	diferente
Rede - 6 variáveis	1425,78*	14,74*	não	0,15	diferente
Rede - 7 variáveis	1440,60*	12,22*	não	0,14	diferente
Rede - 8 variáveis	465,61*	4,71*	não	0,05	diferente
Rede - 9 variáveis	621,46*	5,34*	não	0,05	diferente
Rede - 10 variáveis	506,54*	4,86*	não	0,05	diferente
Rede - 11 variáveis	561,73*	4,12*	não	0,04	diferente
Rede - 12 variáveis	10,27*	0,66 ^{ns}	não	0,00	diferente
Rede - 13 variáveis	0,57 ^{ns}	0,51 ^{ns}	não	0,00	diferente
Rede - 14 variáveis	18,96*	0,81 ^{ns}	não	0,00	diferente
Rede - 15 variáveis	0,26 ^{ns}	0,73 ^{ns}	não	0,00	diferente
Rede - 17 variáveis	2,64 ^{ns}	4,22*	sim	0,00	diferente
Rede - 18 variáveis	6,68*	3,40*	não	0,00	diferente
Rede - 19 variáveis	3,73*	0,78 ^{ns}	não	0,00	diferente
Rede - 20 variáveis	0,72 ^{ns}	3,61*	não	0,00	diferente
Rede - 21 variáveis	10,10*	1,80 ^{ns}	não	0,00	diferente

Tabela 10: Comparativo entre o volume futuro estimado do melhor modelo do Método Híbrido (modelo 9) com o volume futuro estimado dos 13 modelos restantes, utilizando o procedimento estatístico proposto por Leite e Oliveira (2002) a $\alpha=5\%$.

Método Híbrido	Estatística				
	F (Ho)	t (e)	$r_{x,y} \geq 1 - \bar{\rho} $	Erro Médio (e)	Resultado
Rede - 1 variável	38,97*	0,41*	não	0,00	diferente
Rede - 2 variáveis	23,03*	0,11*	não	0,00	diferente
Rede - 3 variáveis	18,45*	0,92*	não	0,00	diferente
Rede - 4 variáveis	8,82*	3,25*	não	0,00	diferente
Rede - 5 variáveis	2,57 ^{ns}	1,64 ^{ns}	não	0,00	diferente
Rede - 6 variáveis	0,72 ^{ns}	1,47 ^{ns}	não	0,00	diferente
Rede - 7 variáveis	5,48*	0,18 ^{ns}	não	0,00	diferente
Rede - 8 variáveis	44,70*	5,32*	sim	0,00	diferente
Rede - 10 variáveis	4,90*	0,56 ^{ns}	não	0,00	diferente
Rede - 11 variáveis	6,26*	5,93*	sim	0,00	diferente
Rede - 12 variáveis	0,93 ^{ns}	1,20 ^{ns}	não	0,00	diferente
Rede - 13 variáveis	0,11 ^{ns}	2,12*	não	0,00	diferente
Rede - 14 variáveis	16,08*	3,63*	não	0,00	diferente

Os valores do RMSE do teste (%) entre as três metodologias analisadas foram muito próximos, sendo: 6,24 do modelo 12 da metodologia da Correlação de Pearson; 6,42 do modelo 16 da metodologia do Método de Garson; e 6,61 do modelo 9 da metodologia do Modelo Híbrido.

Os três modelos com os melhores desempenhos, o melhor de cada metodologia, apresentaram diferenças significativas entre eles, confirmada pelo procedimento estatístico proposto por Leite e Oliveira (2002), mesmo com valores de RMSE do teste (%) muito próximos (tabela 11). Desta forma, a rede que apresentou o menor valor do RMSE do teste (%) foi o modelo 12 da metodologia da Correlação de Pearson.

Ao analisar a ordenação das variáveis e o valor do RMSE do teste (%) das metodologias da Correlação de Pearson e Método de Garson, o modelo 16 do Método de Garson é o mais indicado quando o foco do estudo for o crescimento tendo como base as variáveis físicas e fisiológicas. Este método explica melhor quais as variáveis que mais contribuem para o ganho de volume de madeira para a área estudada e representa uma redução de 5 variáveis (23,8 %) em relação ao número total de variáveis disponíveis.

Do ponto de vista empresarial, o modelo 12 da metodologia da Correlação de Pearson atende melhor por apresentar o menor valor de RMSE do teste (%) dentre os modelos analisados e uma redução de 9 variáveis (42,8%) em relação ao número total de variáveis disponíveis.

Tabela 11: Comparativo entre os volumes estimados dos melhores modelos de cada metodologia utilizada, segundo o procedimento estatístico proposto por Leite e Oliveira (2002) a $\alpha=5\%$.

	Estatística			Erro Médio (e)	Resultado
	F (Ho)	t (e)	$r_{x,y} \geq 1 - \beta $		
Correlação de Pearson X Método de Garson	1,87*	2,34*	não	0,00	diferente
Correlação de Pearson X Método Híbrido	1,41 ^{ns}	0,38 ^{ns}	não	0,00	diferente
Método Híbrido X Método de Garson	3,69*	0,78 ^{ns}	não	0,00	diferente

4. CONSIDERAÇÕES FINAIS

A redução do número de variáveis otimizou 23,8% e 42,8% do total no número de variáveis utilizadas na construção de modelos por meio das metodologias do Método de Garson e Correlação de Pearson, respectivamente.

Os três modelos com os melhores desempenhos, o melhor de cada metodologia (Correlação de Pearson, Método de Garson e Modelo Híbrido), apresentaram diferenças significativas entre eles.

O modelo mais eficiente para a realização da prognose do inventário florestal para a região do leste de Minas Gerais foi o modelo 12 da metodologia da Correlação de Pearson com uma redução de 9 variáveis (42,8%) em relação ao número total de variáveis disponíveis.

5. REFERÊNCIAS BIBLIOGRÁFICAS

BINOTI, D.H.B.; BINOTI, M.L.M.S.; LEITE, H.G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Ciência da Madeira**, v.5, n.1, p.58-67, 2014.

BINOTI, M.L.M.S.; BINOTI, D.H.B.; LEITE, H.G.; GARCIA, S.L.R.; FERREIRA, M.Z.; RODE, R.; SILVA, A.A.L. Redes neurais artificiais para estimação do volume de árvores. **Revista Árvore**, Viçosa-MG, v.38, n.2, p.283-288, 2014.

BINOTI, M.L.M.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.

BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDERMIR, T.B. **Redes neurais artificiais: teoria e aplicações**. Editora LTC – Livros Técnicos e Científicos Editora S.A., 2.ed., Rio de Janeiro. 2007. 226p.

BRITO, L.F. **Erosão hídrica de Latossolo Vermelho distrófico típico em áreas de pós-plantio de eucalipto na região de Guanhões (MG)**. Lavras, MG: UFLA. 78p. Dissertação (Mestrado) - Universidade Federal de Lavras, Lavras. 2004.

BROWN, C. **The global outlook for future wood supply from forest plantation**. N° GFPOS/WP/03. Rome, FAO. Working Papers, 1-45, 2000.

CARNEIRO, R.L.C.; RIBEIRO, A.; HUAMAN, C.A.M.; LEITE, F.P.; SEDIYAMA, G.C.; BASTOS, N.F. Consumo de água em plantios de eucalipto: parte 1 determinação da condutância estomática em tratamentos irrigado e não-irrigado. **Revista Árvore**, v.32, n.1, p.1-10, 2008.

CARVALHO, K.H.A.; SILVA, M.L.; SOARES, N.S. Efeito da área e da produtividade na produção de celulose no Brasil. **Revista Árvore**, Viçosa-MG, v.36, n.6, p.1119-1128, 2012.

CHAVES, J.H.; REIS, G.G.; REIS, M.G.F.; NEVES, J.C.L.; PEZZOPANE, J.E.M.; POLLI, H.Q. Seleção precoce de clones de eucalipto para ambientes com disponibilidade diferenciada de água no solo: relações hídricas de plantas em tubetes. **Revista Árvore**, v. 28, n. 3, p. 333-341, 2004.

GARSON, G.D. Interpreting neural-network connection weights. **Artificial Intelligence Expert** 6 (7), 47–51. 1991.

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

HAGAN, M.T.; MENHAJ, M.B. Training feedforward networks with the Marquardt algorithm. **IEEE Transactions on Neural Network**, vol. 5, n 6, pp. 989-993. 1994.

HAYKIN, S. **Redes Neurais: Princípios e prática**. 2.ed. Porto Alegre: Editora Bookman. 900p. 2001.

KAUR, K.; KAUR, A.; MALHOTRA, R. Alternative methods to rank the impact of object oriented metrics in fault prediction modeling using neural networks. **International Journal of Engineering and Applied Sciences** 1:2. 2005.

LEITE, F.P.; BARROS, N.F.; SANS, L.M.A.; FABRES, A.S. Regimento hídrico do solo sob povoamento de eucalipto, floresta nativa e pastagem, na região de Guanhães – MG. **Revista Árvore**, v.21, n.4, p.455-462, 1997.

LEITE, H.G.; OLIVEIRA, F.H.T. Statistical procedure to test the identity of analytical methods. **Communications in Soil Science and Plant Analysis**, New York, v. 33, p. 1105-1118, 2002.

LEITE, H.G.; BINOTI, D.H.B.; NETO, R.R.O.; LOPES, P.F.; CASTRO, R.R.; PAULINO, E.J.; BINOTI, M.L.M.S.; COLODETTE, J.L. Redes Neurais Artificiais para a estimação da densidade básica da madeira. **Sci. For.**, Piracicaba, v. 44, n. 109, p. 149-154, mar. 2016.

LEUNING, R. Modeling stomatal behavior and photosynthesis of *Eucalyptus grandis*. **Australian Journal of Plant Physiology**, v.17, n.2, p.159-175. 1990.

MAGALHÃES, A.C.N. Fotossíntese. In. FERRI, M.G. **Fisiologia vegetal**. São Paulo: EDUSP, 350p. 1985.

MAGALHÃES, M.R.; FREITAS, A.R.; RIBEIRO, A.; FELIX, L.B.; BRANDAO, A.S. **Neuro AgroClimate**. Programa de Computador. BR512016000503-3. INPI - Instituto Nacional da Propriedade Industrial. Depositante: Universidade Federal de Viçosa. 02 mai. 2016.

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

MONTAGU, K. D.; KEARNEY, D. E.; SMITH, R. G. B. The biology and silviculture of pruning planted eucalypts for clear wood production: a review. **Forest Ecology and Management**, v.179, n.1, p.1-13, 2003.

RODRIGUES, H. J. B.; COSTA, R. F.; RIBEIRO, J. B. M.; SOUZA FILHO, J. D. C.; RUIVO, M. L. P.; SILVA JÚNIOR, J. A. Variabilidade sazonal da condutância estomática em um ecossistema de manguezal amazônico e suas relações com variáveis meteorológicas. **Revista Brasileira de Meteorologia**, v.26, n.2, 189 - 196, 2011.

SACRAMENTO NETO, O.B. **Balanço hídrico em plantios jovens de eucalipto na região de Belo Oriente-MG.** Viçosa-MG, 77p., Dissertação de Mestrado –Universidade Federal de Viçosa, 2001.

SANTANA, R. C; BARROS, N. F.; LEITE, H. G.; COMERFORD, N. B.; NOVAIS, R. F. Estimativa da biomassa em plantios de eucalipto no Brasil. **Revista Árvore**, v.32, n.4, p.697-706, 2008.

SANTOS, L.C.; CARVALHO, A.M.M.L.; PEREIRA, B.L.C.; OLIVEIRA, A.C.; CARNEIRO, A.C.O.; TRUGILHO, P.F. Propriedades da madeira e estimativas de massa, carbono e energia de clones de Eucalyptus plantados em diferentes locais. **Revista Árvore**, Viçosa-MG, v.36, n.5, p.971-980, 2012.

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

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

SILVA, R. DA. **Estudos das variações espectrais e texturas em florestas primárias e sucessões secundárias na flora Tapajós usando dados ALI/EO-1.** São José dos Campos, SP: INPE. Dissertação (Mestrado) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2014.

SILVA, W.C.M. **Modelagem dos balanços de radiação e de água e simulação do crescimento do eucalipto na Bacia do Rio Doce-MG.** Viçosa, MG: UFV. 122f. Tese (Doutorado em Meteorologia Agrícola) – Universidade Federal de Viçosa, Viçosa. 2007.

SOARES, N.S.; SILVA, M.L.; VALVERDE, S.R.; LIMA, J.E.; SOUZA, U.R. Análise do mercado brasileiro de celulose, 1969-2005. **Revista Árvore**, v.33, n.3, p.563-573, 2009.

SOUZA FILHO, J.D.C. **Variação sazonal dos componentes do balanço de radiação e energia sobre a floresta de Caxiuanã.** Viçosa, MG: UFV. 67f. Dissertação (Mestrado em Meteorologia Agrícola) – Universidade Federal de Viçosa, Viçosa. 2002.

SOUZA, M.J.H.; RIBEIRO, A.; LEITE, H.G.; LEITE, F.P.; MINUZZI, R.B. Disponibilidade hídrica do solo e produtividade do eucalipto em três regiões da Bacia do Rio Doce. **Revista Árvore**, v.30, p.399-410, 2006.

STRECK, N.A. Stomatal response to water vapor pressure deficit: an unsolved issue. **R. Bras. Agrociência**, v. 9, n. 4, p. 317-322, 2003.

SUDHEER, K. P.; GOSAIN, A. K.; RAMASASTRI, K. S. Estimating actual evapotranspiration from limited climatic data using neural computing technique. **Journal of Irrigation and Drainage Engineering**, v.129, n.3, p.214-218. 2003.

RYAN, M.; MÜLLER, C.; DI, H.J.; CAMERON, K.C. The use of artificial neural networks (ANNs) to simulate N₂O emissions from a temperate grassland ecosystem. **Ecological Modelling** 175. 189–194. 2004.

TATAGIBA, S.D.; PEZZOPANE, J.E.M.; REIS, E.F.; DARDENGO, M.C.J.D.; EFFGEN, T.A.M. Comportamento fisiológico de dois clones de Eucalyptus na época seca e chuvosa. **Cerne**, v.13, n.2, p.149-159, 2007.

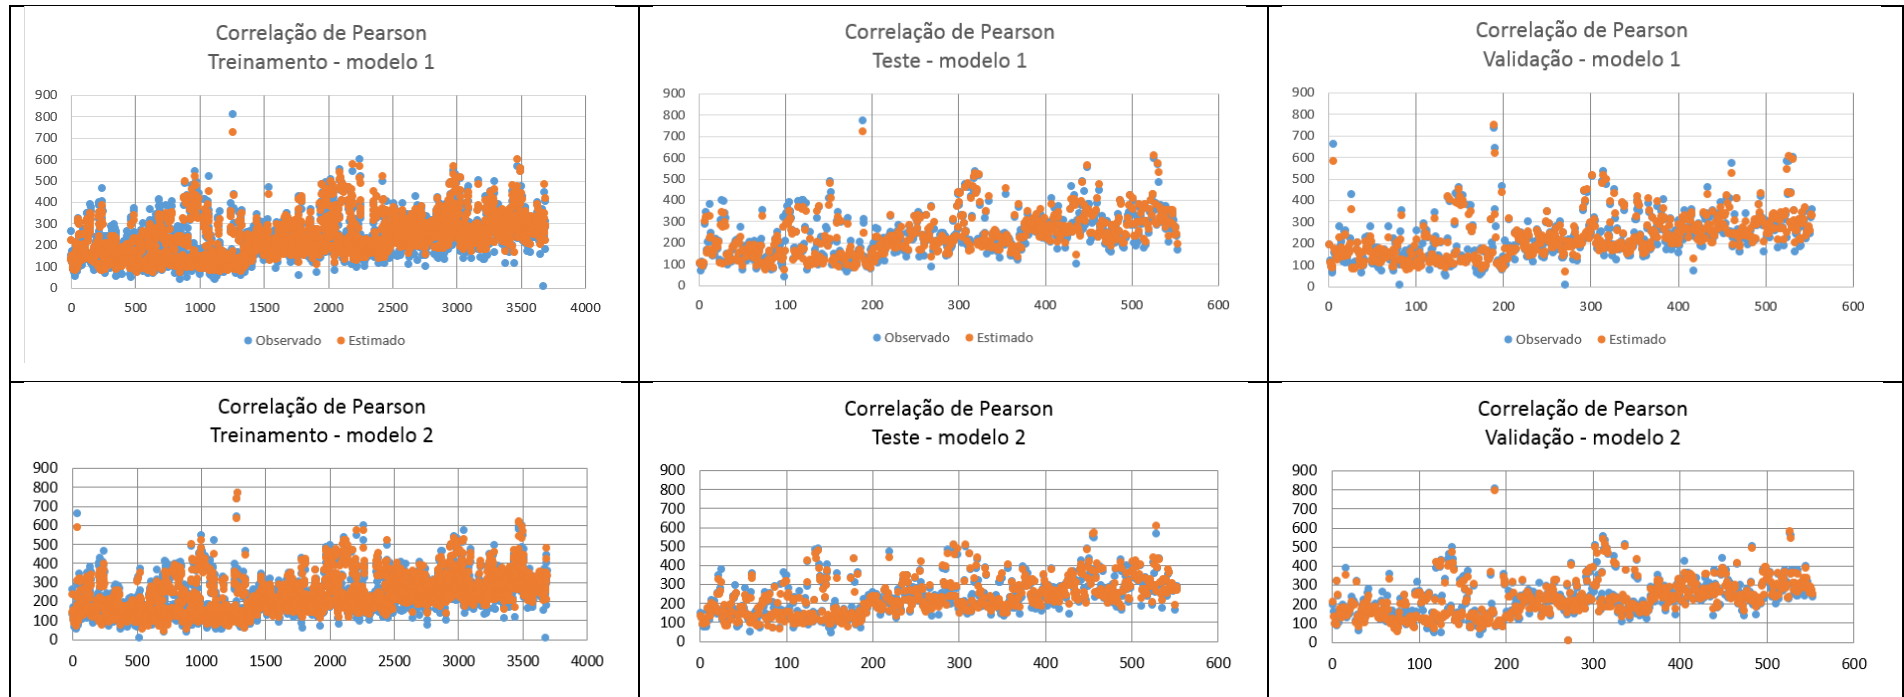
VOSE, J.M.; SWANK, W.T. Effect of long-term drought on the hydrology and growth of a white pine plantation in the southern Appalachians. **Forest Ecology and Management**, n. 64, p. 25-39, 1994.

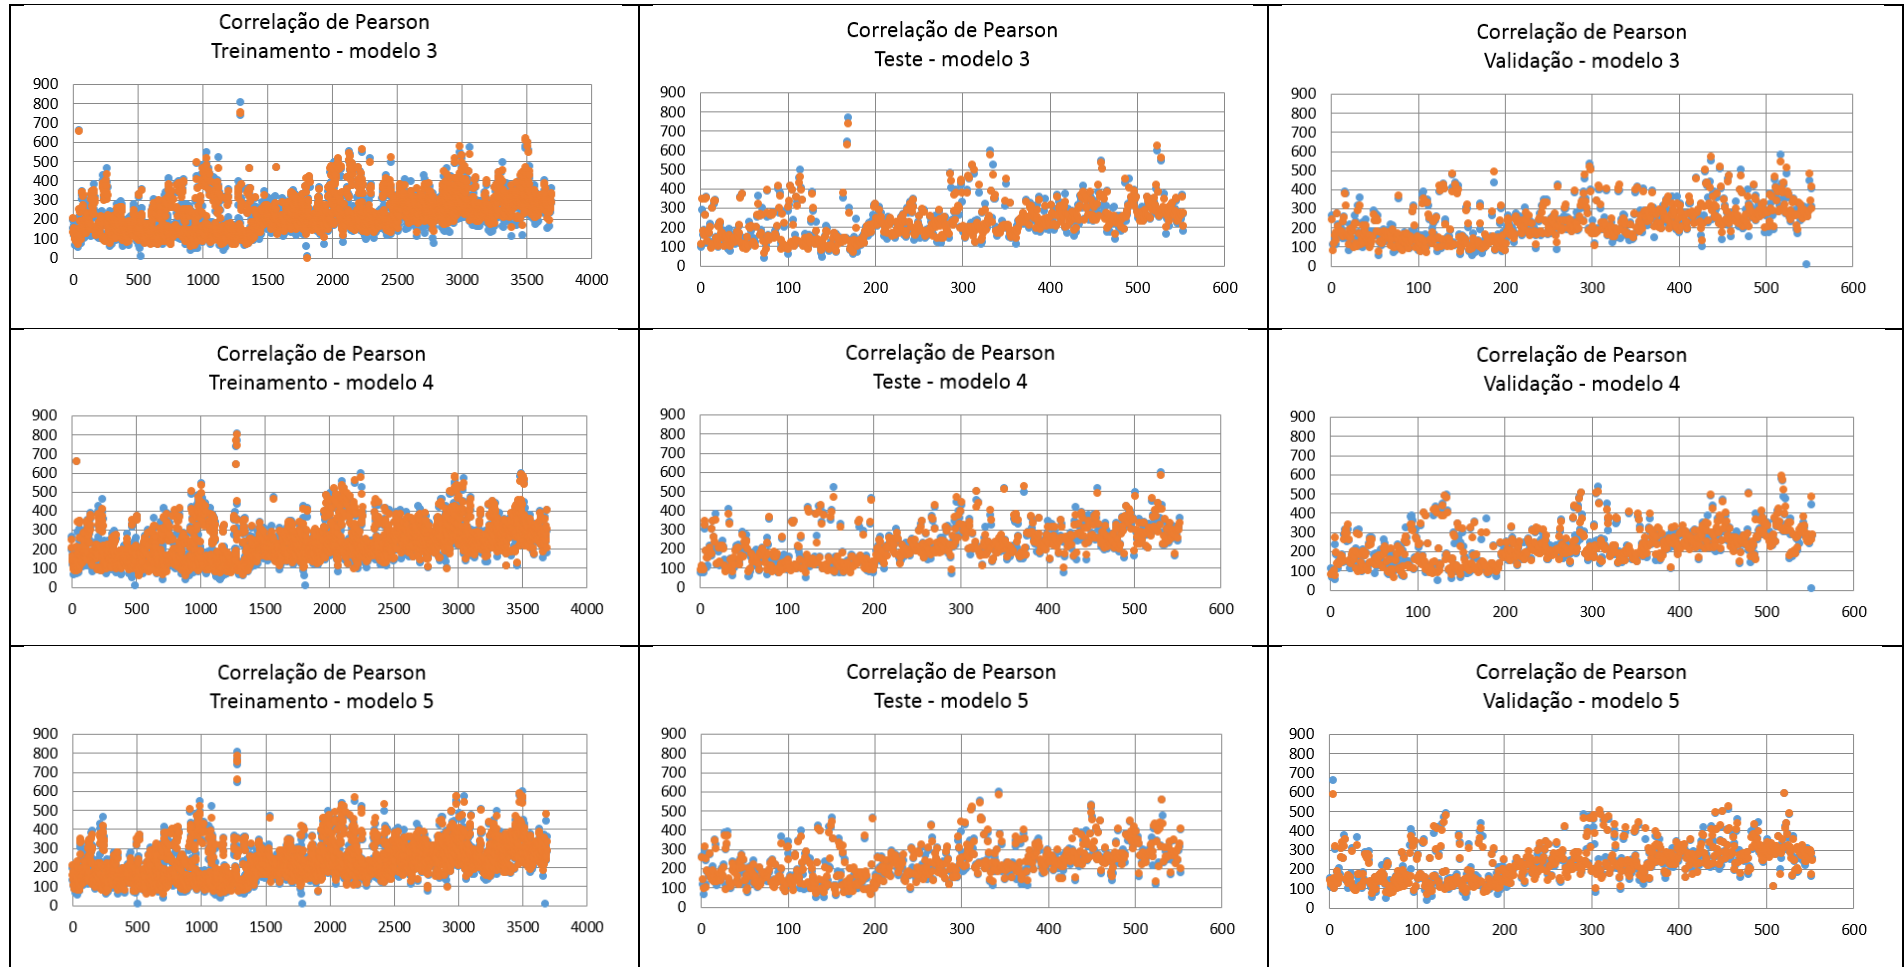
XAVIER, A.C.; KINGB, A.W.; SCANLON, B.R. Daily gridded meteorological variables in Brazil (1980–2013). **International Journal of Climatology**, 36: 2644–2659. DOI: 10.1002/joc. 2016.

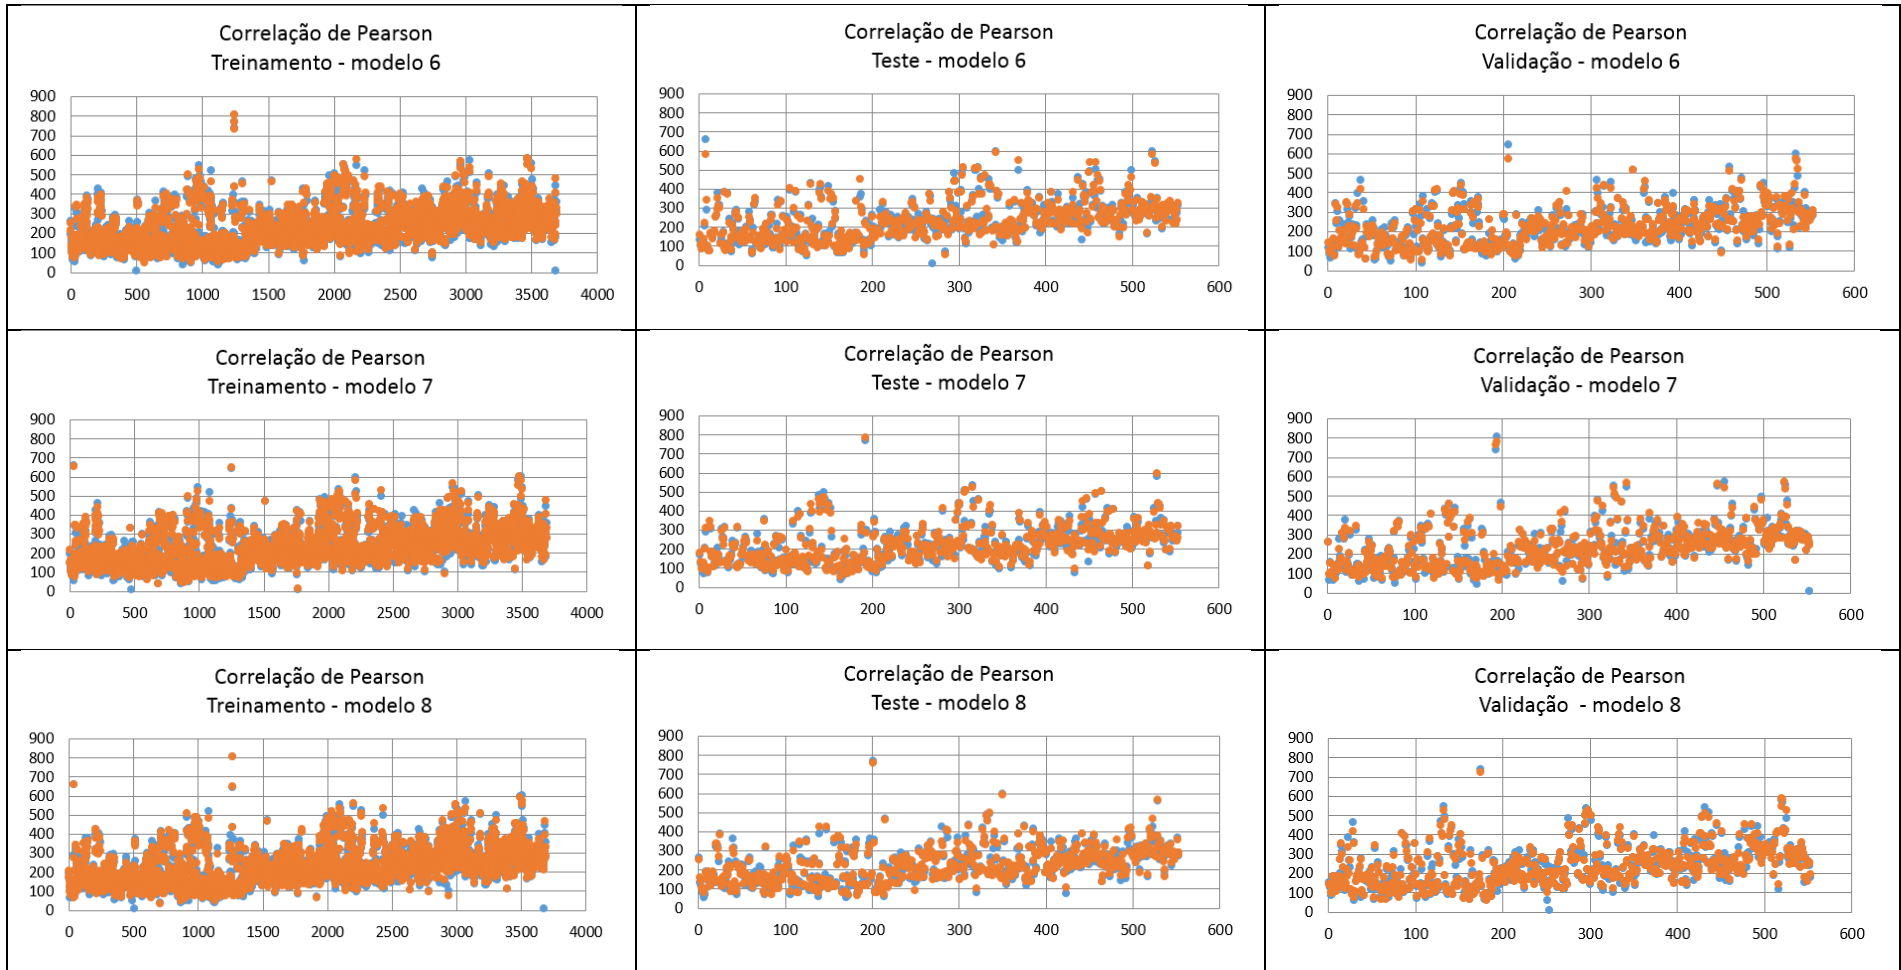
SALLES, T.T.; LEITE, H.G.; OLIVEIRA NETO, S.N.; SOARES, CARLOS P.B.; PAIVA, H.N.; SANTOS, F.L. Modelo de Clutter na modelagem de crescimento e produção de eucalipto em sistemas de integração lavoura-pecuária-floresta. **Pesq. agropec. bras.**, Brasília, v.47, n.2, p.253-260, fev. 2012.

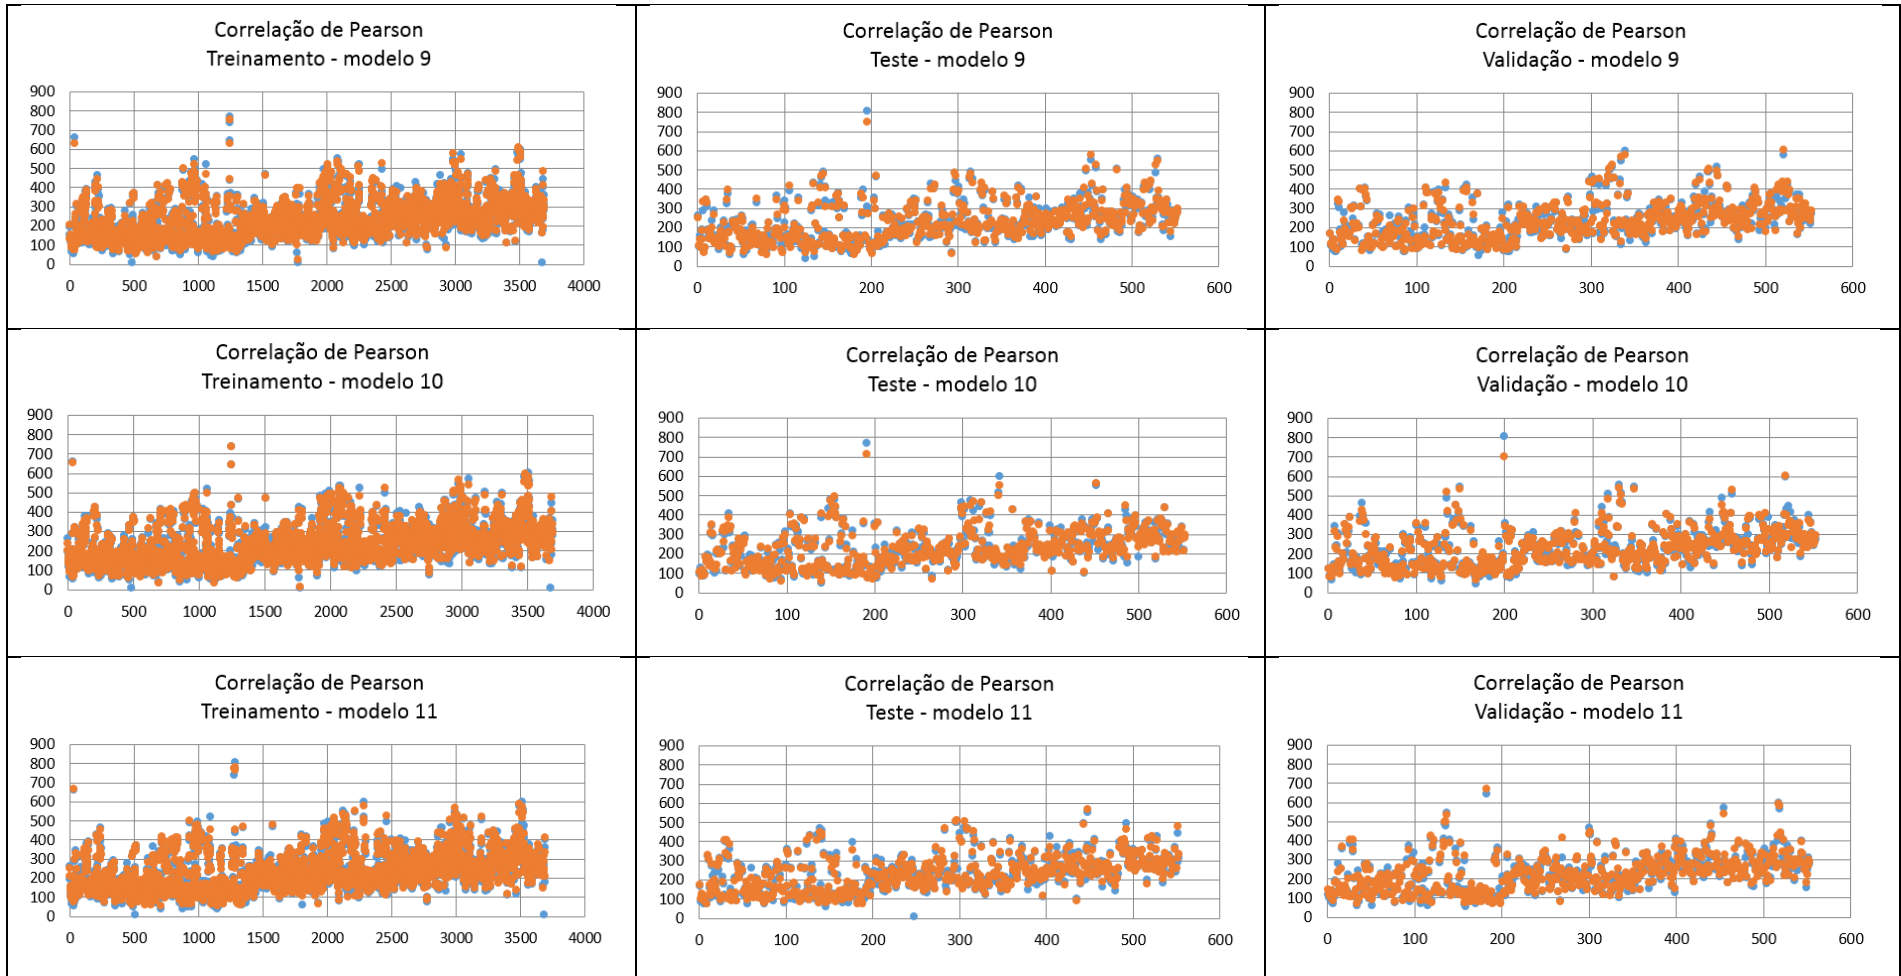
6. ANEXO

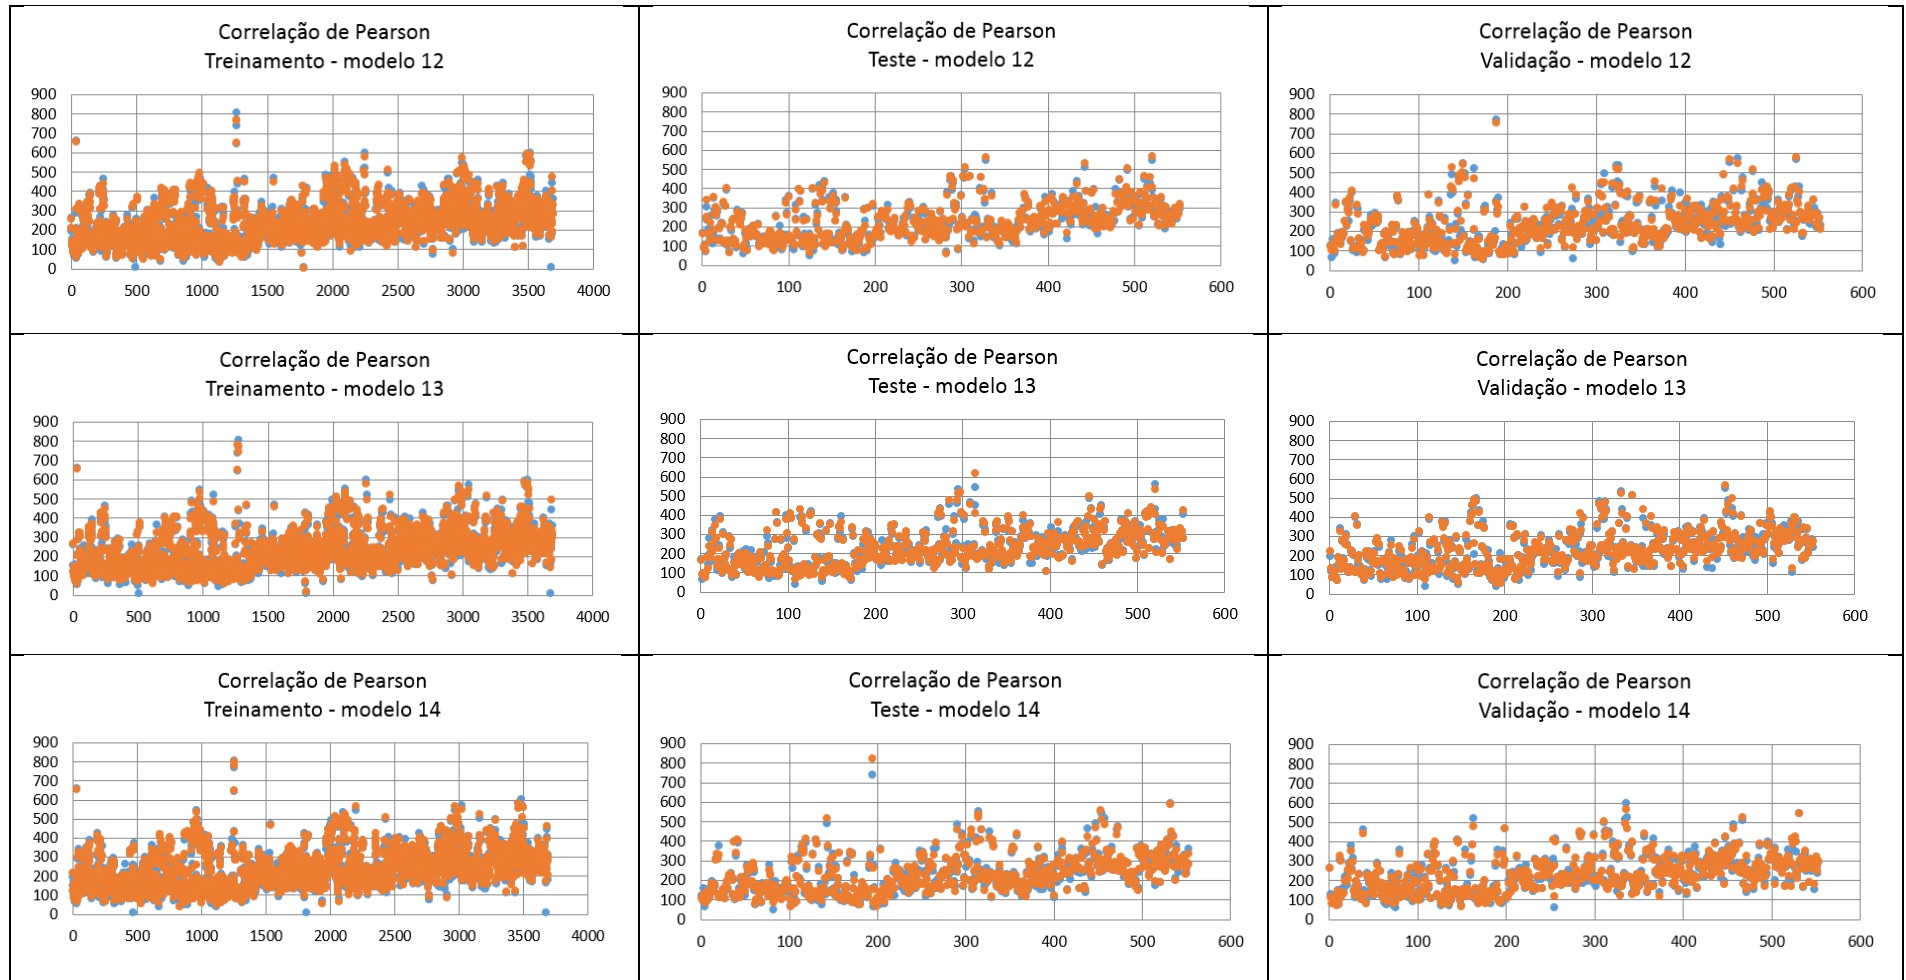
Figura 16: Gráficos do volume futuro observado X volume futuro estimado, por modelo, processados de acordo com a ordenação da Correlação de Pearson.

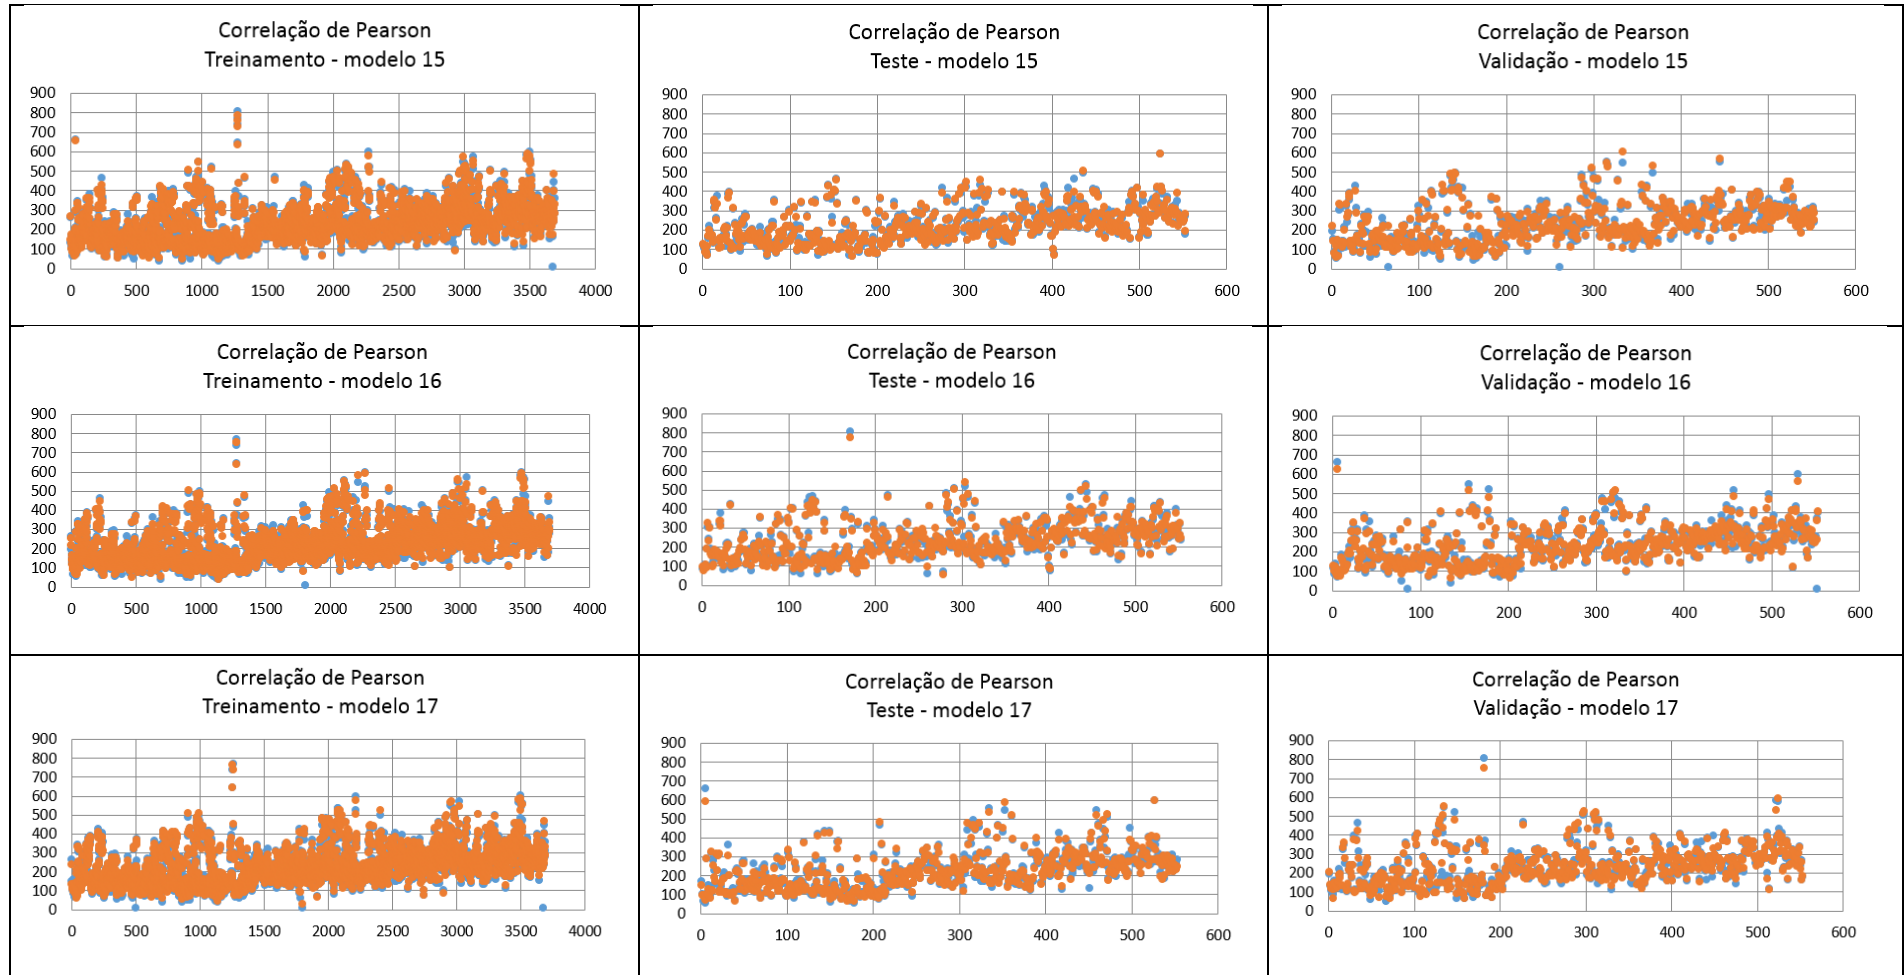


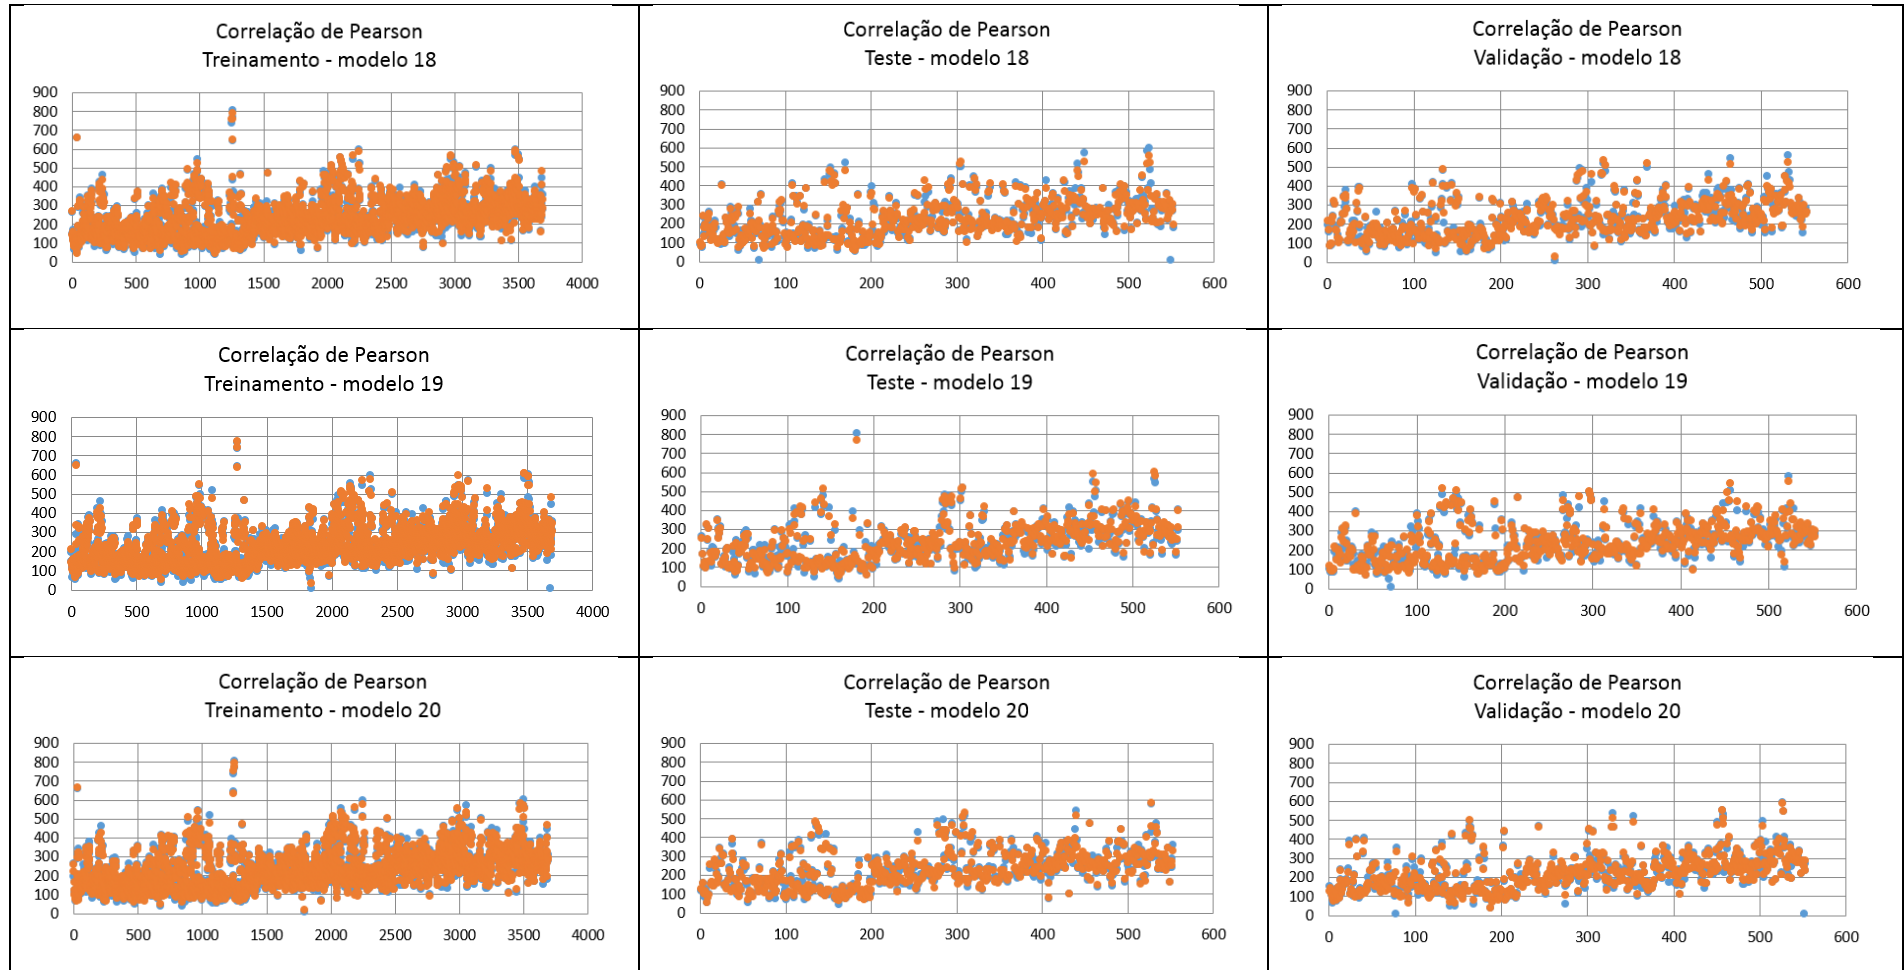














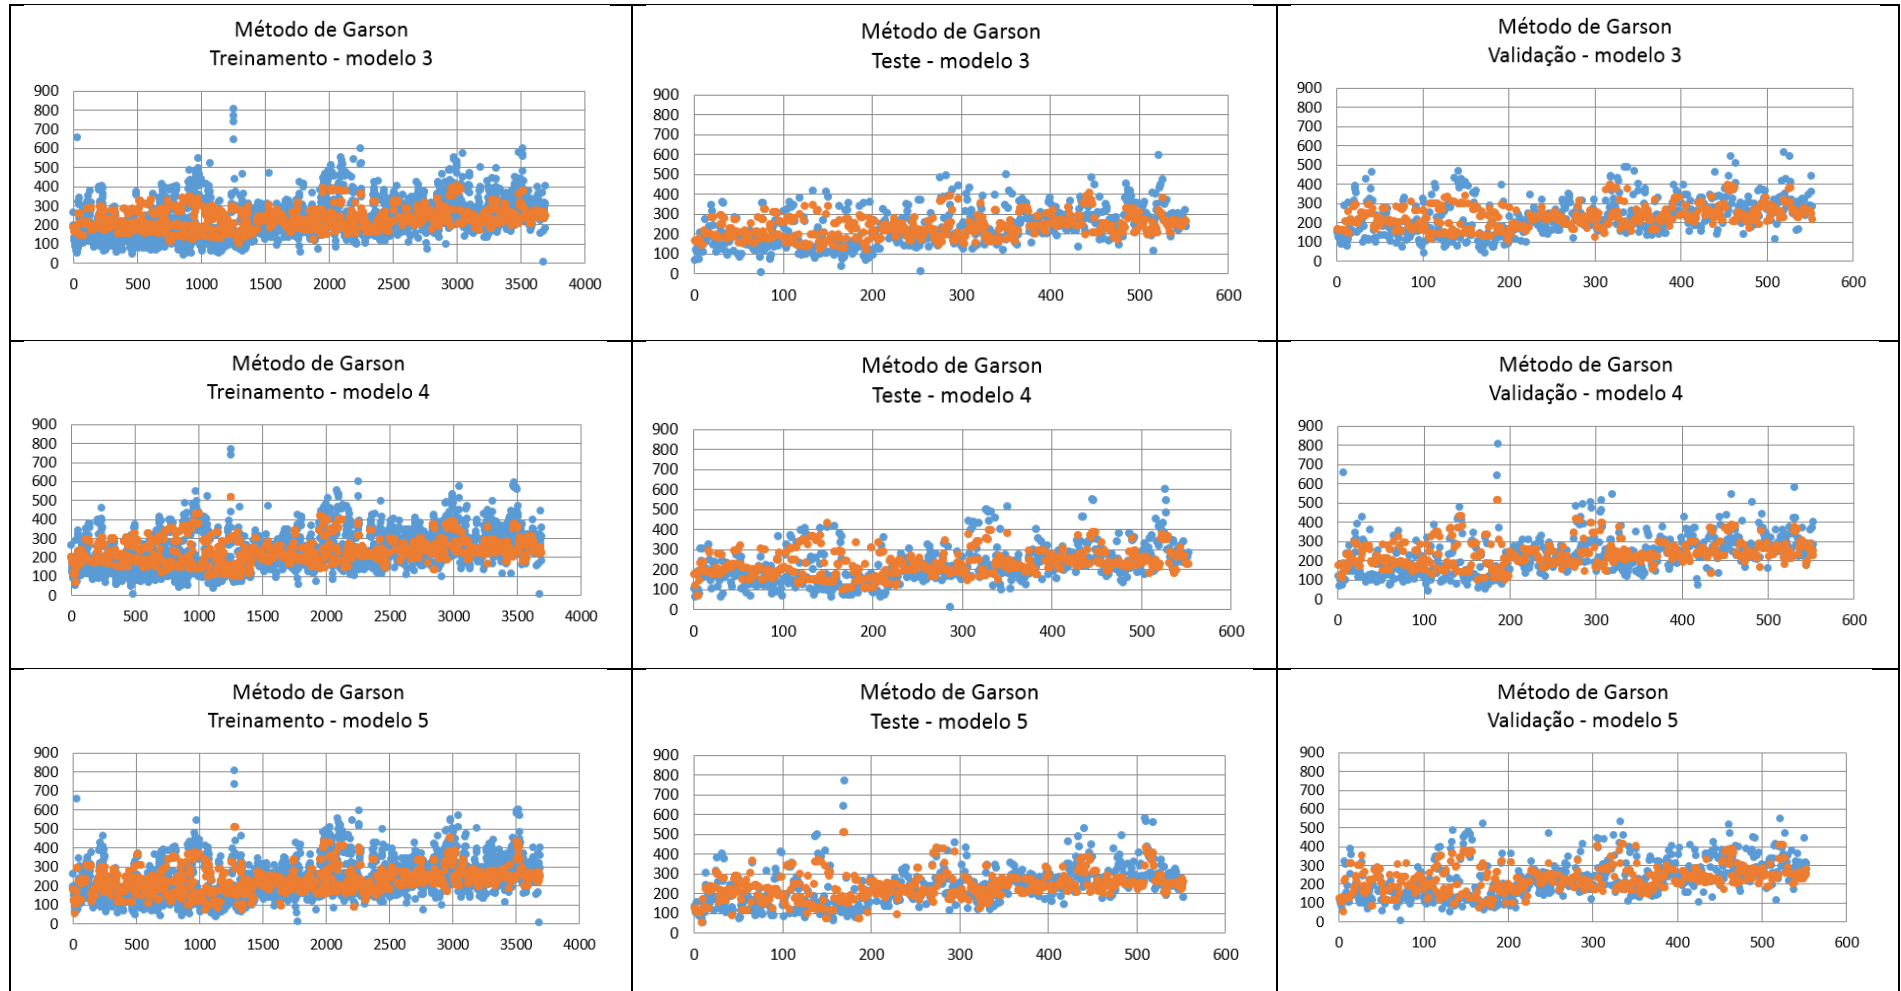
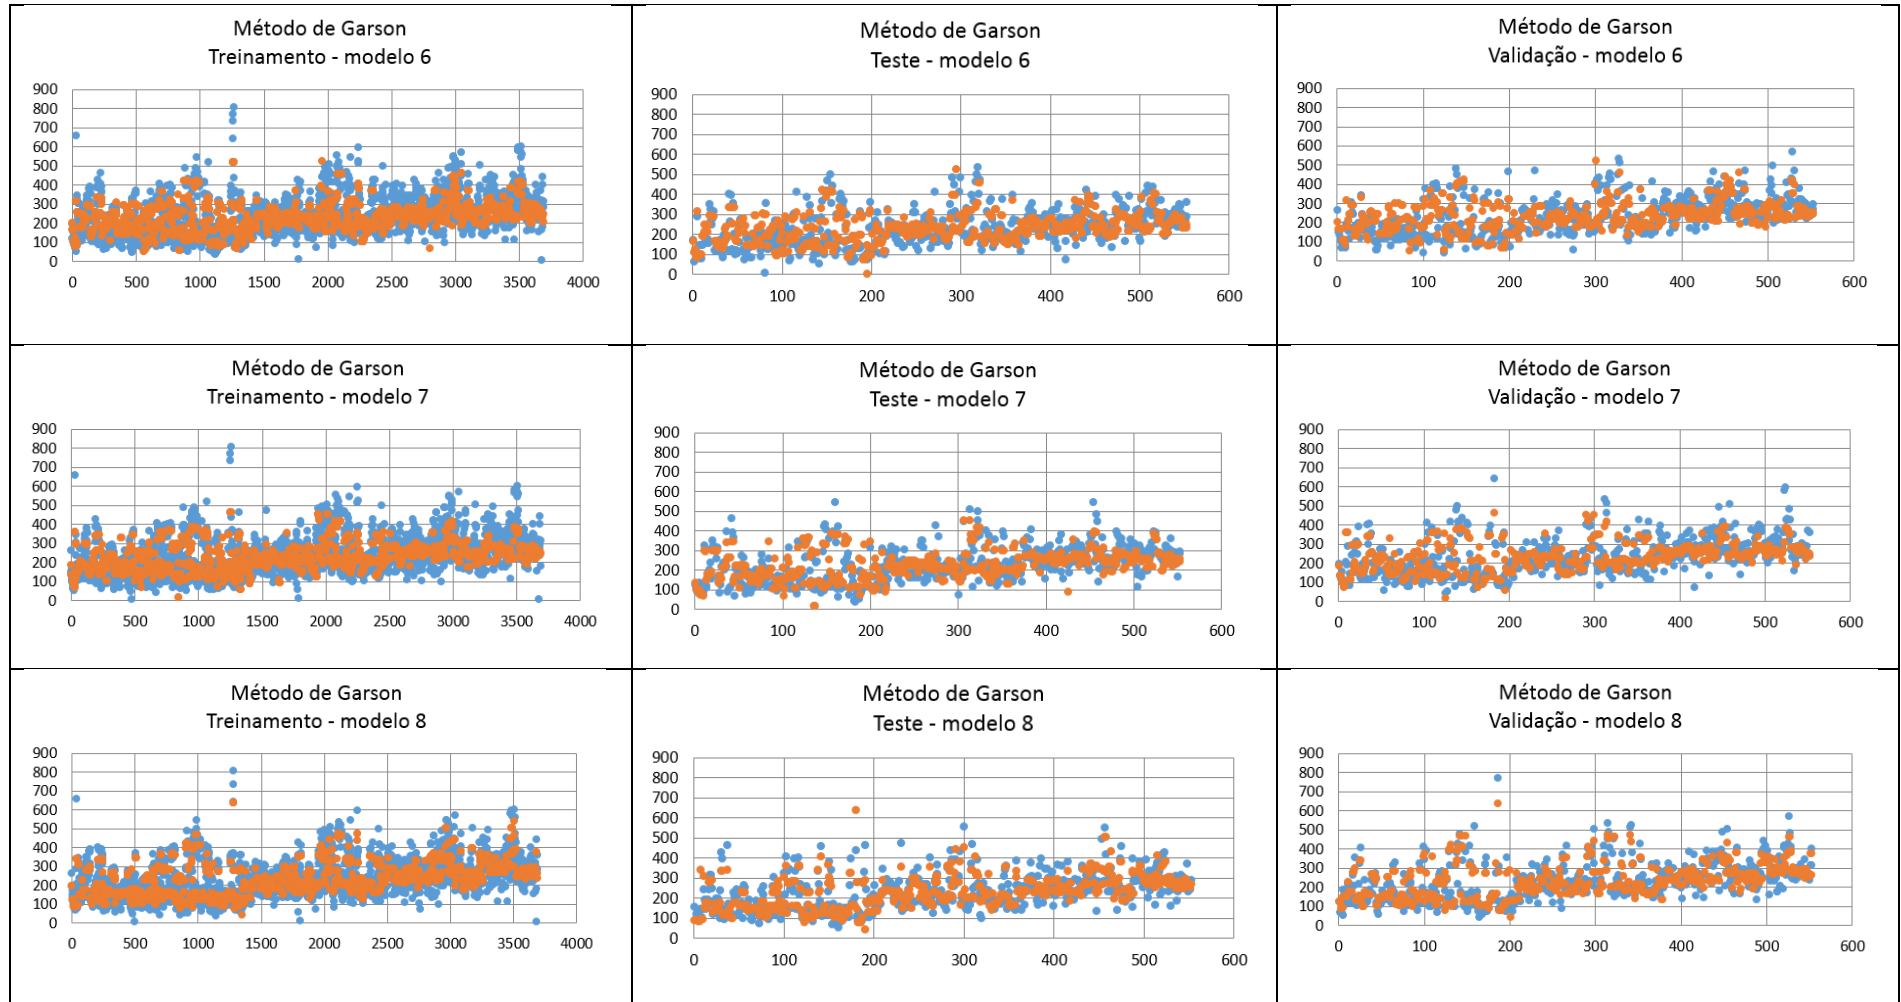
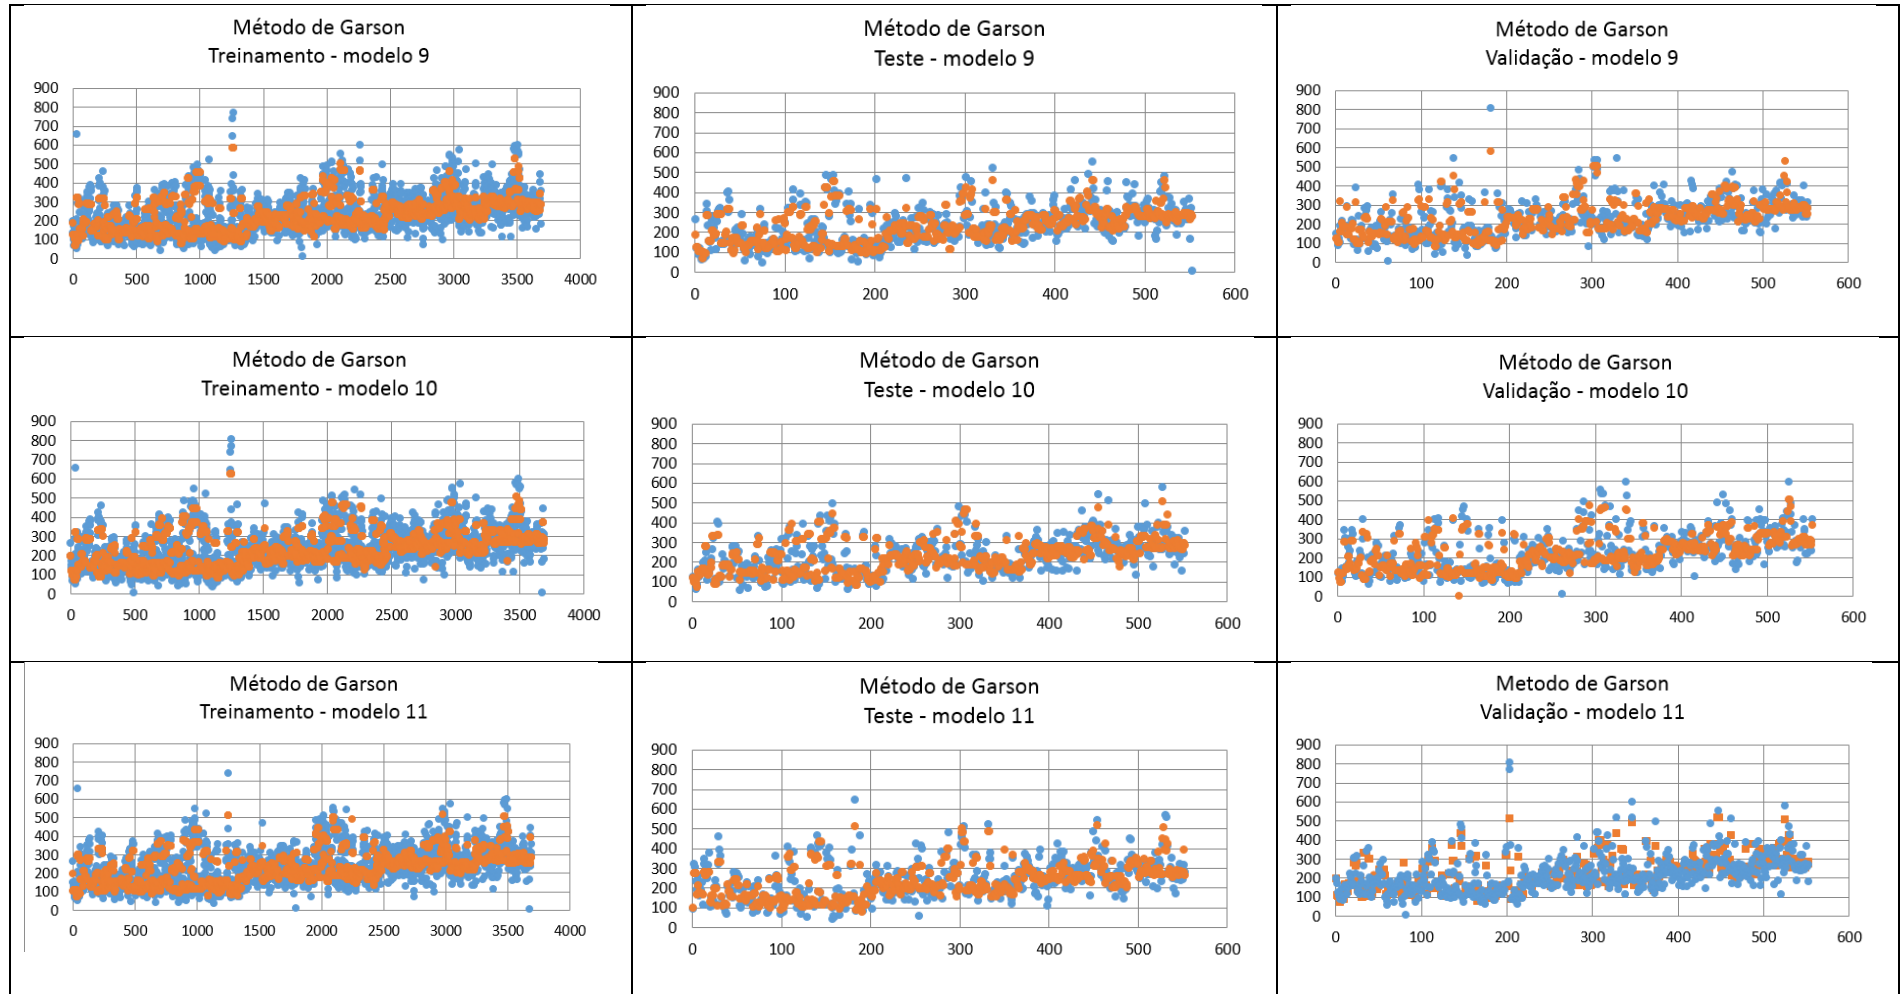


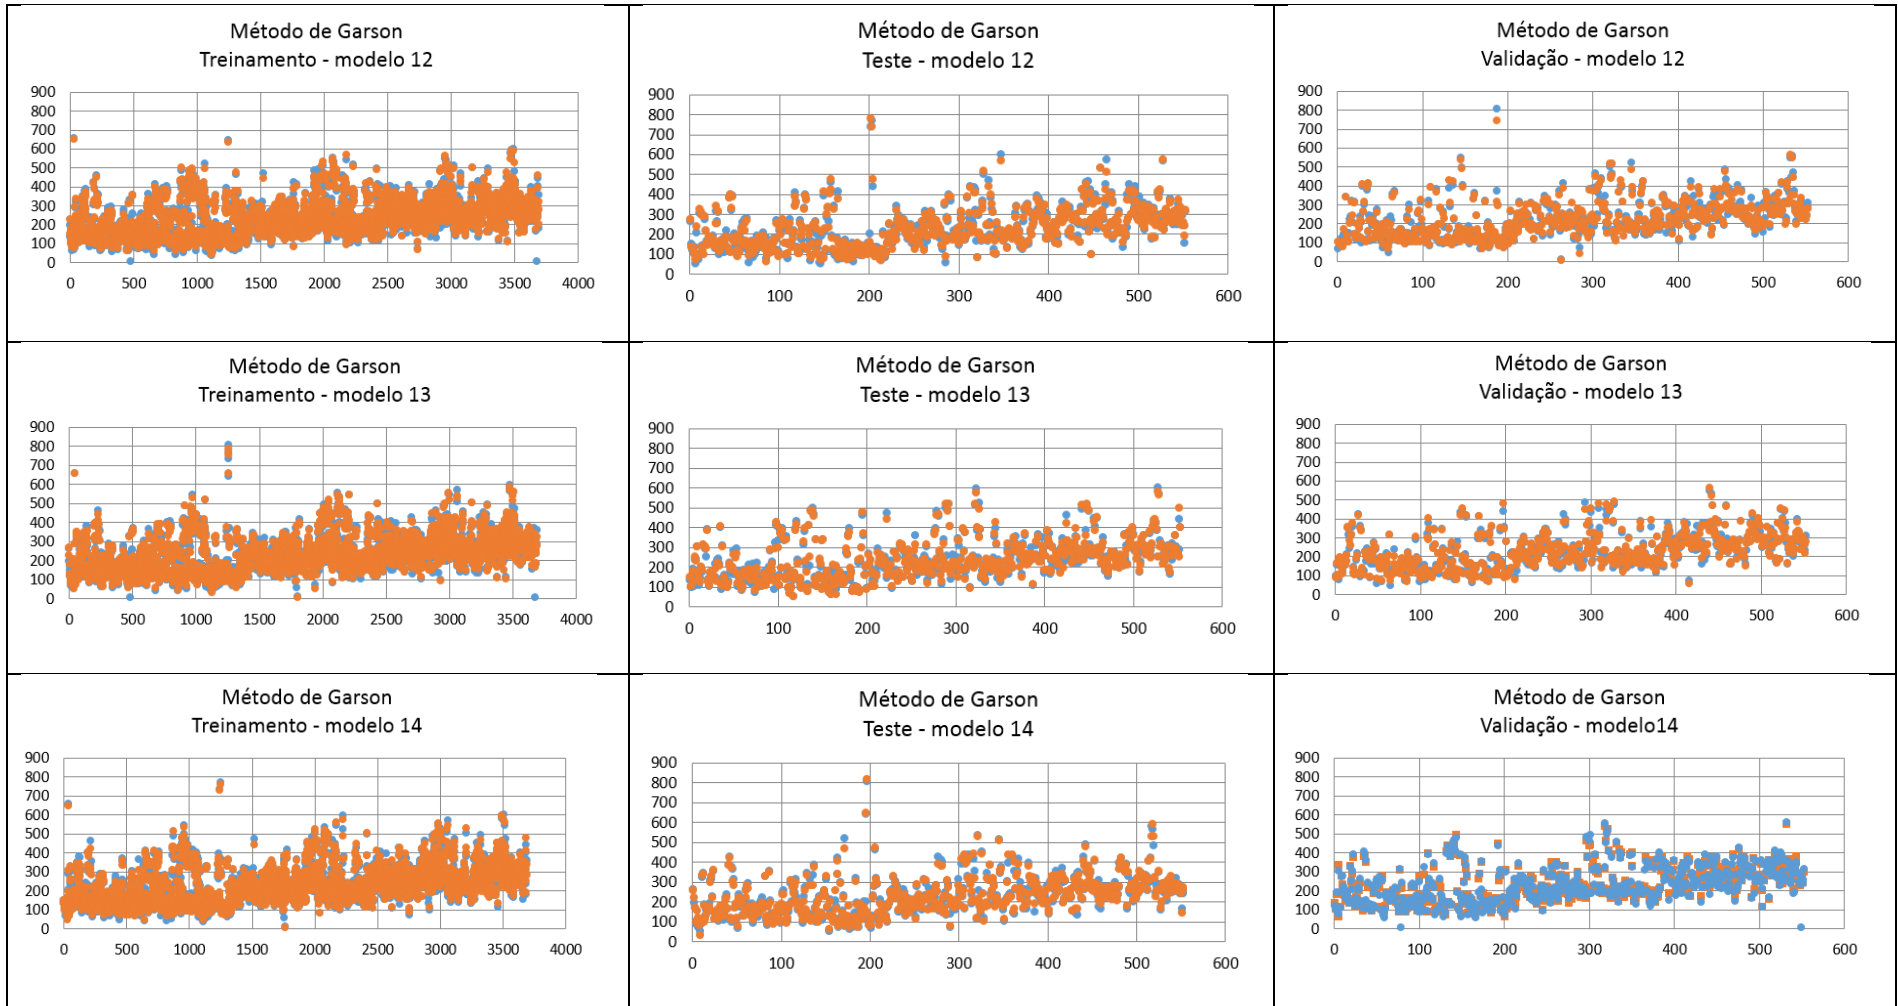
Figura 17: Gráficos do volume futuro observado X volume futuro estimado, por modelo, processados de acordo com a ordenação do Método de Garson.

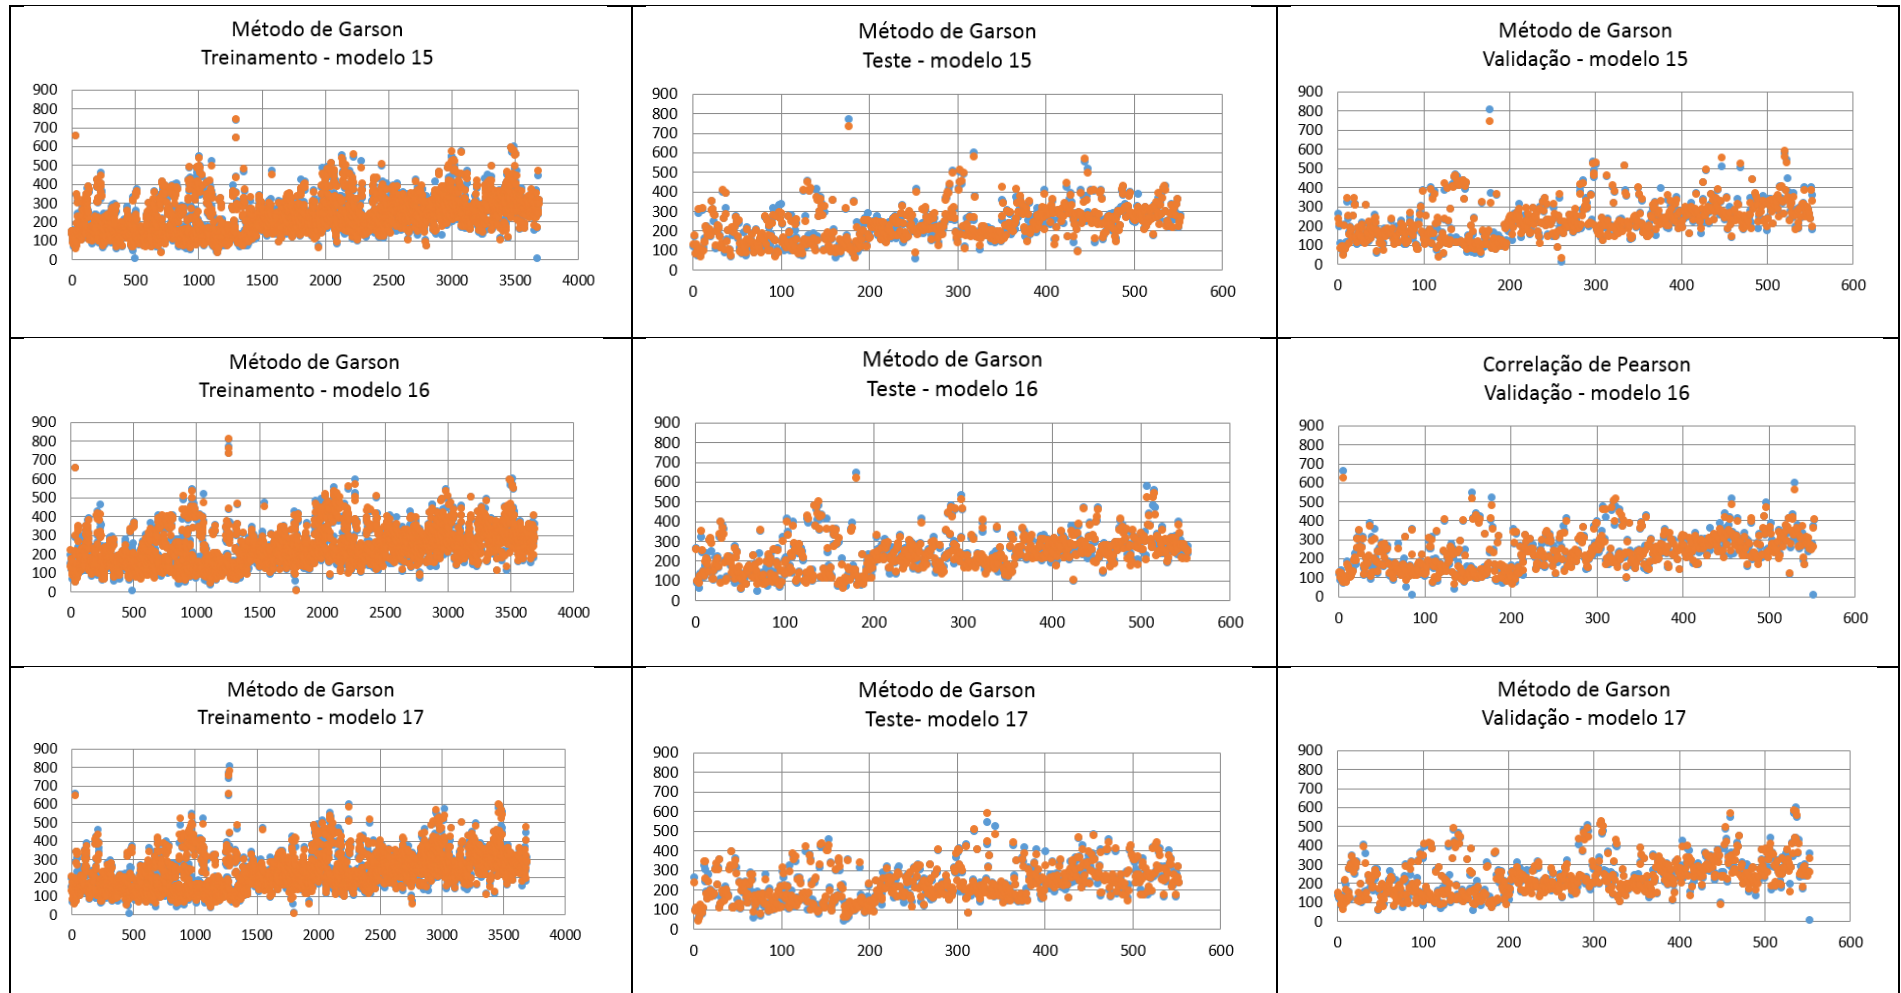


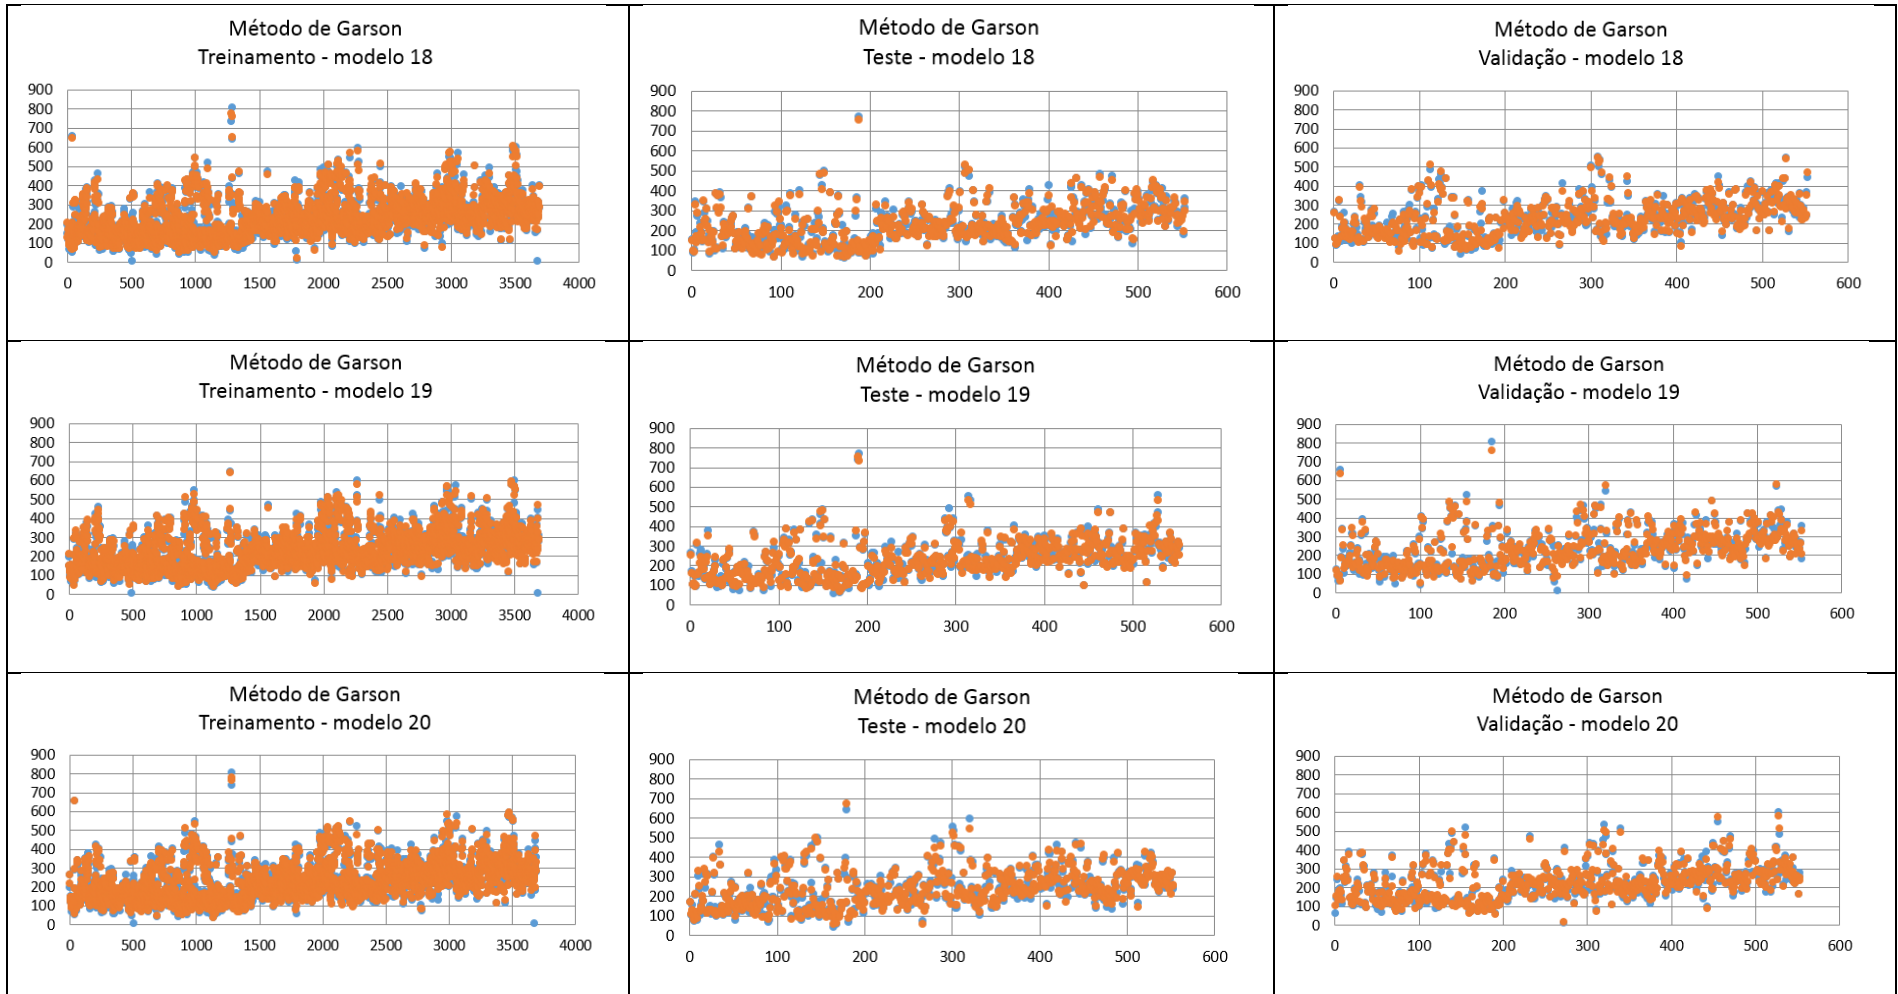















Figura 18: Gráficos do volume futuro observado X volume futuro estimado, por modelo, processados de acordo com o Modelo Híbrido.

