

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA DE PRODUÇÃO

**Análise comparativa entre os métodos auto-regressivo,
integrado de médias móveis e rede neural artificial para
previsão de séries temporais**

Lara Moura Silva Saúde

Itajubá, abril 2018

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO

EM ENGENHARIA DE PRODUÇÃO

**Análise comparativa entre os métodos auto-regressivo,
integrado de médias móveis e rede neural artificial para
previsão de séries temporais**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de
Produção como parte dos requisitos para obtenção de
Mestre em Engenharia de Produção.

Área de Concentração: Qualidade e Produtos

Orientador: Pedro Paulo Balestrassi

Itajubá, abril de 2018

Folha de aprovação

DEDICATÓRIA

Ao meu querido avô, Tacinho.

Agradecimentos

A Deus.

Aos meus pais, Adriana e Gilberto, que sempre me apoiaram na decisão de continuar estudando e me especializar cada vez mais como engenheira de produção.

Ao Otávio, meu namorado, que esteve ao meu lado durante todas as etapas da minha pesquisa, escutando todas as minhas dúvidas e ideias.

Aos meus amigos e colegas de mestrado que sempre me ajudaram sugerindo melhorias na pesquisa, e foi de grande importância para o resultado final.

Aos professores, em especial ao meu orientador Pedro Paulo Balestrassi, que sempre incentivou a pesquisa, confiou no meu trabalho desde o primeiro dia e exerceu papel fundamental na criação da pesquisa. Ao professor Carlos Henrique Pereira Mello, por todo auxílio que ofereceu desde o início da pesquisa, por ajudar durante o projeto *Six Sigma*, e principalmente na ausência do Pedro.

À CAPES e à UNIFEI pelo apoio financeiro e estrutural à pesquisa brasileira em engenharia de produção.

Prediction is very difficult, especially if it is about the future. Niels Bohr

RESUMO

Problemas de previsão estão presentes em diversas áreas do conhecimento e para explorá-los podem ser utilizadas diferentes metodologias. Este trabalho busca comparar a habilidade de previsão de duas destas técnicas: método auto-regressivo integrado de médias móveis (ARIMA) e redes neurais artificiais (RNA). A primeira pode ser considerada como técnica padrão e já é consagrada como ferramenta de auxílio na tomada de decisões. A segunda tem sido utilizada em profusão para problemas similares e apresenta-se como alternativa à previsão de séries temporais, pois assume menos restrições de uso, apesar de exigir uma simulação computacional mais complexa. Este estudo tem como objetivo realizar uma análise comparativa de 27 problemas sedimentados, descritos no livro *Introduction Introduction to Time Series Analysis and Forecasting* escrito por Montgomery, Jennings e Kulahci. Para tal análise, foi calculado o erro MAPE (*Mean absolute percentage error*) de cada metodologia para todos os casos, possibilitando a comparação dos modelos. Através de teste estatístico, pôde identificar que a rede neural artificial resulta em um menor erro estatístico, com 95% de confiança a rede neural apresenta um MAPE inferior ao ARIMA, solucionando o problema inicial da pesquisa.

Palavras-Chaves: Previsão, Séries temporais, Redes Neurais Artificiais, ARIMA, MAPE

ABSTRACT

Forecasting problems are present in several areas of knowledge and different methodologies can be used to exploit them. This work compares two of these techniques: autoregressive integrated moving average (ARIMA) and artificial neural networks (ANN). The first can be considered as a standard technique and is already known as an effective tool to forecasting time series. The second has been used in profusion for similar problems and is presented as an alternative to the time series forecasting, it assumes less restrictions of use, although it requires a more complex computational simulation. This study aims to perform a comparative analysis of 27 well-established problems, described in the book *Introduction to Time Series Analysis and Forecasting* (MONTGOMERY; JENNINGS; KULAHCI, 2008) by Montgomery, Jennings and Kulahci. For this analysis, MAPE error (Mean absolute percentage error) of each methodology was calculated for all cases to compare ARIMA and ANN models. A statistical test concluded that, with 95% of confidence, ANN results in a smaller error than ARIMA, solving the initial research problem.

Keywords: Forecasting, Time series, Artificial neural network, ARIMA, MAPE

LISTA DE FIGURAS

Figura 1: Publicações (a) e citações (b) na ISI Web of Knowledge para os termos artificial neural network e ARIMA _____	13
Figura 2: Publicações (a) e citações (b) na ISI Web of Knowledge para os termos ANN e ARIMA _____	13
Figura 3: Áreas do conhecimento da engenharia de produção _____	16
Figura 4: Fluxograma do modelo ARIMA de Box & Jenkins _____	24
Figura 5: Modelo não linear de um neurônio _____	34
Figura 6: Rede alimentada adiante com camada única _____	35
Figura 7: Rede alimentada adiante com uma camada oculta e uma camada de saída _____	36
Figura 8: Rede recorrente com neurônios ocultos _____	36
Figura 9: Diagrama de blocos da PNN _____	38
Figura 10: Diagrama de blocos da GRNN _____	39
Figura 11: Estrutura da Rede Neural RBF _____	40
Figura 12: Rede MLP _____	42
Figura 13: Início da criação das redes neurais _____	45
Figura 14: Critério de seleção das redes _____	46
Figura 15: Tipos de redes neurais _____	46
Figura 16: Número de unidades ocultas _____	47
Figura 17: Análise das medidas de previsão em pesquisas científicas _____	50
Figura 18: Classificação da Pesquisa _____	51
Figura 19: Etapas da metodologia Modelagem e simulação _____	53
Figura 20: Série temporal 9 - Envio de produtos para fabricantes de bebidas nos EUA _____	56
Figura 21: ACF e PACF gráficos da série temporal 9 _____	56
Figura 22: Periodograma do exercício 9 _____	57
Figura 24: Mann-Kendall Teste do exercício 9 _____	58
Figura 24: Parâmetros do modelo ARIMA do exercício 15 _____	58
Figura 25: Resultado da rede neural do exercício 15 _____	60
Figura 26: Detalhamento das 10 redes retidas do exercício 15 _____	60
Figura 27: Comparação erros MAPE _____	61
Figura 29: Pared-t MAPE _____	62

LISTA DE TABELAS

Tabela 1: Comportamento teórico de ACF e PACF para processos estacionários _____	27
Tabela 2: Medidas de precisão _____	49
Tabela 3: Resultados dos erros MAPE das séries temporais analisadas _____	55

Sumário

1. INTRODUÇÃO.....	11
1.1. CONTEXTO.....	11
1.2. RELEVÂNCIA	12
1.3. JUSTIFICATIVA.....	13
1.4. OBJETIVOS.....	16
1.4.1. Objetivo geral	16
1.4.2. Objetivos específicos	17
1.5. ORGANIZAÇÃO DO TRABALHO	17
2. FUNDAMENTAÇÃO TEÓRICA.....	18
2.1. SÉRIES TEMPORAIS E O PROCESSO DE PREVISÃO	18
2.2. ESTATÍSTICAS PARA PREVISÃO	19
2.2.1. Processos estacionários	19
2.2.3. Tendência e sazonalidade	20
2.2.3.1. Teste ADF.....	21
2.2.3.2. Teste de Mann-Kendall.....	22
2.2.3.3. Periodograma	23
2.3. MODELOS DE BOX-JENKINS.....	23
2.3.1. Visão geral.....	23
2.3.2. Modelo auto-regressivo e de médias móveis ARMA(p,q).....	25
2.3.3. Funções de autocorrelação e autocorrelação parcial para modelos ARMA(p,q) ..	26
2.3.4. Processos não estacionários: modelos ARIMA(p,d,q).....	27
2.3.1. Modelos SARIMA (p,d,q)(P,D,Q).....	28
2.3.2. Identificação dos modelos ARIMA(p,d,q).....	29
2.3.3. Estimação dos modelos ARIMA(p,d,q).....	29
2.3.4. Diagnóstico dos modelos ARIMA(p,d,q).....	30
2.3.5. Previsão dos modelos ARIMA (p,d,q).....	31
2.4. REDES NEURAIS ARTIFICIAIS (RNA)	32
2.4.1. Componentes de uma RNA	33
2.4.2. Arquiteturas de rede	34
2.4.3. Processos de aprendizagem	37
2.4.4. Redes lineares	37
2.4.5. Redes neurais probabilísticas (PNNs) e redes neurais de regressão generalizada (GRNNs)37	
2.4.6. Redes de função de base radial	40
2.4.7. Redes neurais perceptrons de múltiplas camadas.....	42
2.4.8. Software STATISTICA: Intelligent Problem Solver	44
2.5. PARÂMETROS DE AVALIAÇÃO DOS MODELOS.....	48
3. DESENVOLVIMENTO DA PESQUISA	51
3.1. CLASSIFICAÇÃO DA PESQUISA CIENTÍFICA	51
3.2. MÉTODO DE MODELAGEM E SIMULAÇÃO	52
3.2.1. Definição.....	52
3.2.2. Etapas da pesquisa	52
3.2.3. Conceitualização.....	53

3.2.4.	Modelagem.....	53
3.2.5.	Solução do modelo.....	54
3.2.6.	Implementação.....	54
4.	RESULTADOS.....	55
4.1.	APLICAÇÃO DOS DADOS EM ARIMA.....	56
4.2.	APLICAÇÃO DOS DADOS EM REDES NEURAS ARTIFICIAIS.....	59
4.3.	COMPARAÇÃO DOS MÉTODOS ARIMA E RNA.....	61
5.1.	CONSIDERAÇÕES FINAIS.....	64
5.2.	TRABALHOS FUTUROS.....	64
	ANEXO A - ARIMA.....	65
	ANEXO B - RNA.....	95
	REFERÊNCIAS.....	109

1. Introdução

1.1. Contexto

A previsão de dados é um componente comum e importante de muitos sistemas do mundo real. Alguns dos sistemas exigem a previsão de um grande portfólio de séries temporais com diferentes características, por exemplo, sistemas de previsão da demanda para empresas com inúmeros produtos e clientes espalhados por várias regiões.

Segundo Wagner *et al.* (2010), os métodos de previsão de séries temporais são, geralmente, divididos em dois grupos: métodos baseados em conceitos estatísticos e técnicas de inteligência computacional. Existem também os métodos que combinam mais de uma técnica, como utilizado por alguns autores como Cardoso e Cruz (2016), de Oliveira e Ludermir (2015), Adamowski *et al.* (2012), Zhang *et al.* (2010), Cadenas e Rivera (2010), El Desouky e Elkateb (2000).(CARDOSO; CRUZ, 2016)(CARDOSO; CRUZ, 2016)

A previsão de séries temporais baseada em conceitos estatísticos é dividida em algumas categorias (WAGNER *et al.*, 2011), entre elas:

- método de amortecimento exponencial;
- método de regressão;
- método auto-regressivo integrado de médias móveis (ARIMA);
- método *Threshold*;
- método auto-regressivo de heteroscedasticidade condicional generalizado (GARCH).

Já as técnicas que utilizam inteligência computacional apresentam duas categorias principais (WAGNER *et al.*, 2011):

- métodos baseados em Redes Neurais Artificiais (RNAs); e
- métodos baseados na computação evolutiva.

Essa pesquisa irá comparar os resultados da previsão de diversas séries através de um método baseado em conceito estatístico (ARIMA, nome considerado padrão para o método) e outro em inteligência computacional (RNA).

1.2. Relevância

A previsão de séries temporais é explorada por diversos autores que utilizam variados métodos. Entretanto, ao se tratar da comparação dos métodos de previsão de séries temporais, encontra-se uma lacuna na literatura. Uma análise bibliométrica pôde identificar a deficiência na literatura em relação a comparação dos métodos ARIMA e rede neural artificial (RNA).

Na base de dados *Scopus*, ao se pesquisar no título dos trabalhos as palavras *comparison*, *ARIMA* e *artificial neural network*, obteve-se apenas dois artigos, e ao abreviar *artificial neural network* – ANN, encontrou-se mais quatro artigos. Desta maneira, totalizaram apenas seis artigos que tem como objetivo principal comparar estes métodos. Esses artigos realizam a comparação dos métodos para séries temporais específicas, como o tráfego de dados na internet (BABU; REDDY, 2015), o preço das ações (ADEBIYI; ADEWUMI; AYO, 2014), a entrada mensal de água no reservatório de barragem (VALIPOUR *et al.*, 2013), a previsão da demanda de água em Montreal (ADAMOWSKI *et al.*, 2012), de descargas elétricas (WANG *et al.*, 2009) e concentrações diárias de ozônio máximas de Houston (PRYBUTOK; YI; MITCHELL, 2000). Entretanto, nenhum dos trabalhos encontrados realizam a comparação dos métodos de maneira generalizada, visando encontrar o melhor método independentemente do tipo de série temporal. Dessa forma, o presente trabalho irá realizar esta comparação de dois métodos amplamente usados e fundamentais na previsão de séries temporais, analisando um total de 27 séries temporais

Outra pesquisa realizada na *ISI Web of Knowledge* em 26 de abril de 2017, com os termos *ARIMA* e *artificial neural network* no título, permitiu identificar que a quantidade de publicações sobre esses dois temas é relativamente pequena (22 artigos) por se tratar de métodos de previsão consolidados. Entretanto, o número de citações em cada ano sobre esses temas vem crescendo exponencialmente, confirmando a utilização abrangente dos métodos. A Figura 1 ilustra o comportamento descrito anteriormente.

Ao modificar a pesquisa na *ISI Web of Knowledge*, com os termos *ARIMA* e *ANN* no título, encontrou-se 21 artigos, que também apresentam um crescimento exponencial em relação ao número de citações (Figura 2). Retirando algumas duplicações, obtiveram-se 41 artigos que utilizam os métodos *ARIMA* e *RNA*.

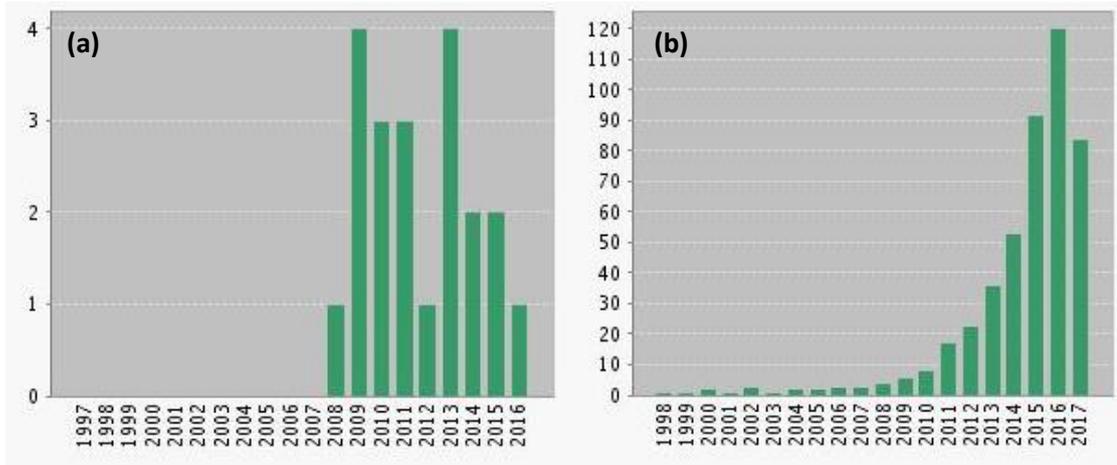


Figura 1: Publicações (a) e citações (b) na *ISI Web of Knowledge* para os termos *artificial neural network* e *ARIMA*

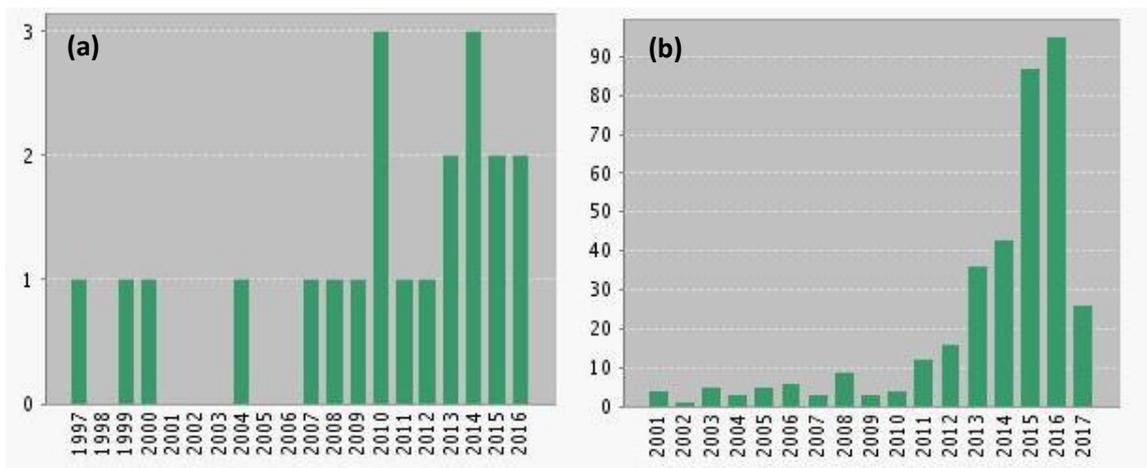


Figura 2: Publicações (a) e citações (b) na *ISI Web of Knowledge* para os termos *ANN* e *ARIMA*

1.3. Justificativa

Previsão é uma questão relevante tanto na área de pesquisa quanto na prática. Entretanto, o impacto que a previsão causa depende da finalidade para a qual a previsão é utilizada (ZOTTERI; KALCHSCHMIDT, 2007). Processos necessitam de uma previsão precisa para a melhor tomada de decisões de um planejamento da produção, lançamento de novos produtos, planejar uma promoção, entre outras decisões (DANESE; KALCHSCHMIDT, 2011). A precisão da previsão é importante pois erros grandes na previsão podem afetar empresas de maneira negativa, prejudicando o desempenho operacional, como custo e performance de entrega (KALCHSCHMIDT, M., ZOTTERI, G., VERGANTI, 2003). Portanto, a previsão

correta de processos oferece a oportunidade de conhecer melhor a dinâmica do mercado e comportamento do cliente, reduzir a incerteza sobre eventos futuros, e oferecer à empresa informação (DANESE; KALCHSCHMIDT, 2011).

Os resultados da pesquisa realizada por Danese e Kalchschmidt (2011) mostraram que quando o processo de previsão é baseado em técnicas apropriadas e usadas para tomada de decisão, atinge-se uma vantagem competitiva. Como consequência, os departamentos se motivam a alinhar os planos e decisões com as previsões fornecidas pela empresa. Deste mesmo modo, a previsão é importante em decisões no governo, universidades, departamentos de pesquisas, enfim, em diversas áreas de estudo.

A previsão de dados quantitativos é utilizada em diversas áreas e são feitas por diversos métodos. A previsão pelos métodos ARIMA e RNA são abordados por alguns autores. Huang *et al.* (2004) abordam os métodos para previsão do fluxo de um rio, Cadenas e Rivera (2010) preveem a velocidade do vento em diferentes regiões, pesquisas que realizam previsão de preços a curto prazo de mercados desregulados (ZHANG *et al.*, 2010), previsão da demanda de água (ADAMOWSKI *et al.*, 2012), previsão do consumo de gás natural (CARDOSO; CRUZ, 2016), previsão da estimativa de poluição (WONGSATHAN; SEEDADAN, 2016). Estas pesquisas e muitas outras evidenciam que os métodos de previsão são utilizados em uma diversa quantidade de áreas com o objetivo único de obter a melhor previsão possível.

ARIMA é um método estudado desde o século dezenove por Yule (1927) que iniciou a ideia de estocasticidade em séries temporais. Entretanto, Box e Jenkins (1970) integraram o conhecimento já existente criando o ciclo para identificação, estimação e verificação para as séries temporais. O livro teve um grande impacto para teoria e prática na análise e previsão de séries temporais modernas (DE GOOIJER; HYNDMAN, 2006), sendo um método de enorme valor para área de previsão. Os modelos ARIMA são muito utilizados para prever mudanças durante um processo (KARAMOUZ; ARAGHINEJAD, 2012), além de ser considerado a técnica de previsão mais eficiente em ciências sociais, sendo usado extensivamente para séries temporais (ADEBIYI; ADEWUMI; AYO, 2014).

A obra escolhida para ser utilizada como base para realização da comparação dos métodos foi o livro *Introduction to Time Series Analysis and Forecasting* (MONTGOMERY; JENNINGS; KULAHCI, 2008) por apresentar grande relevância literária na análise de séries temporais, além de possuir uma variedade de dados, contendo séries de diversas áreas do conhecimento. O livro foi escrito por pesquisadores experientes e profissionais em engenharia estatística, utilizando dados reais em suas análises. A referência no tema ARIMA é o livro de Box e Jenkins (1970). Porém, por ser um livro mais antigo, não dispunha de grande variedade

de séries temporais, restringindo o trabalho proposto. Dessa maneira, a escolha do livro foi feita, visando utilizar uma referência no tema e que oferecesse a variedade que a pesquisa requeria.

Os métodos gerais de previsão de estatística não são viáveis para a previsão de longo prazo. Entre os métodos de previsão de estatísticas, os métodos de predição não estrutural consideram apenas as mudanças de dados em vez de mudanças estruturais no sistema, e devido à complexidade dos sistemas, o método de predição estrutural não pode atingir resultados precisos em muitas situações. Portanto, o uso de modelos de predição não estrutural para prever os sistemas complexos pode ser uma escolha melhor. ARIMA sazonal é um modelo não estrutural de alta precisão para dados cíclicos, especificamente dados de séries temporais (WANG *et al.*, 2012)

O método ARIMA assume que as séries temporais são compostas por uma relação linear com os valores e erros passados, sendo que séries reais são, geralmente, não lineares (DE OLIVEIRA; LUDERMIR, 2015). Por essa razão, é interessante comparar esse método, consolidado e eficaz, com um método que é capaz de prever séries não lineares. Assim, escolheu-se o método baseado em redes neurais artificiais (RNAs).

As técnicas de RNA são mais precisas e amplamente usadas para previsão em diversas áreas, é uma técnica auto adaptativa e com necessidade de poucos pressupostos (ADEBIYI; ADEWUMI; AYO, 2014).

A parcimônia dos modelos obtidos e utilizados para previsão é considerada realmente importante (DE OLIVEIRA; LUDERMIR, 2015). Portanto, a escolha de modelos mais simples pode apresentar maior vantagem em relação à modelos mais complexos com menor erro. Então é interessante comparar o desempenho da previsão de um método linear versus modelos não-lineares, comparando-se modelos mais complexos com modelos menos complexos.

Esta questão foi considerada em bastante profundidade por Swanson e White (1997), seus resultados sugeriram que uma única camada escondida de um modelo RNA oferece uma alternativa útil e flexível à especificação de modelos lineares, particularmente em horizontes de previsão maiores do que um passo à frente.

No entanto, Osborn, Heravi Birchenhall (2004) descobriram que os modelos lineares produzem mais precisão nas previsões das séries de produção industrial mensais europeias do que modelos ANN. E essa pesquisa investigará essas questões, com a finalidade de encontrar quais dos métodos apresentam maior precisão da previsão de séries temporais.

Além da pesquisa se justificar pelo nível de importância que é realizar uma previsão de dados da melhor maneira, sabe-se que o estudo de séries temporais também possui grande valor na engenharia de produção. De acordo com a classificação da CAPES (2017), a engenharia de produção é dividida em quatro áreas do conhecimento: engenharia econômica, engenharia do produto, gerência de produção e pesquisa operacional (Figura 3). A área de Pesquisa Operacional, possui cinco subdivisões: Processos estocásticos e teoria das filas, Programação linear, não linear, mista e dinâmica, Séries temporais, Teoria dos grafos e Teoria dos jogos. A subárea de Séries Temporais é uma segmentação em função do objeto de estudo e metodologias reconhecidas. Assim, o presente trabalho se justifica novamente por estudar uma das subáreas da engenharia de produção.

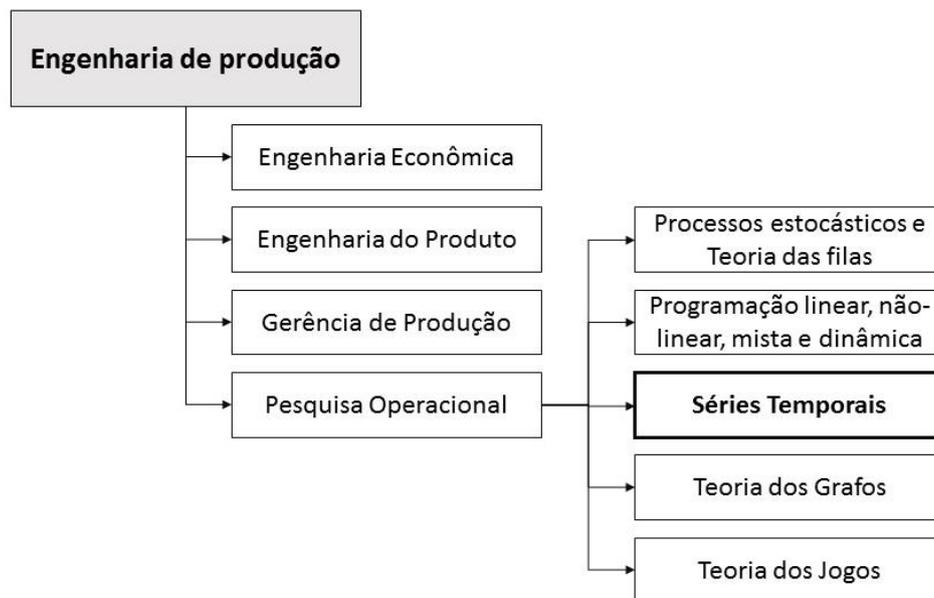


Figura 3: Áreas do conhecimento da engenharia de produção

1.4. Objetivos

1.4.1. Objetivo geral

O objetivo deste trabalho é comparar os métodos de previsão de séries temporais auto-regressivo integrado de médias móveis - ARIMA (p,d,q) e Rede Neural Artificial (RNA) a fim

de obter o melhor método, utilizando como fonte de dados os exercícios do livro *Introduction to Time Series Analysis and Forecasting* (MONTGOMERY; JENNINGS; KULAHCI, 2008)

1.4.2. Objetivos específicos

De modo a cumprir com o objetivo geral desse trabalho, surgem os seguintes objetivos específicos:

- Criar um modelo ARIMA para cada um dos casos analisados.
- Criar um modelo de rede neural artificial para cada um dos casos analisados.
- Obter o erro MAPE de cada série temporal, para cada um dos modelos ARIMA e RNA.
- Utilizar testes de hipótese para verificar se há diferença estatística nos desempenhos encontrados.

1.5. Organização do trabalho

O trabalho inicia-se com a contextualização do assunto, seguindo justificativa e relevância, itens já apresentados anteriormente.

A partir dessa seção, o trabalho apresenta a fundamentação teórica, abordando os assuntos necessários para o desenvolvimento da pesquisa. Inicialmente, explica-se alguns conceitos sobre série temporal, o processo de previsão e assuntos estatísticos necessários na pesquisa. Em seguida, são apresentados os conceitos sobre os modelos de Box-Jenkins, no qual explica-se sobre o modelo ARIMA. A teoria sobre RNA é apresentada com maior detalhamento no item 2.4. E por último, na fundamentação teórica, é evidenciado os parâmetros para avaliar modelos de previsão.

No capítulo 3 é mostrado todo desenvolvimento do trabalho, incluindo a classificação da pesquisa, o método utilizado, com todas as etapas seguidas.

No capítulo 4, a aplicação das etapas é ilustrada com os dados utilizados. A comparação entre os métodos é realizada através do teste de hipóteses, em seguida os resultados são discutidos e é determinado o método mais adequado para previsão de séries temporais.

Em seguida, as considerações finais e sugestões para trabalhos futuros são apresentados.

Nos apêndices são anexados todos os gráficos e resultados obtidos, das séries temporais analisadas.

2. Fundamentação Teórica

2.1. Séries temporais e o processo de previsão

Uma série temporal é a sequência de observações feitas no tempo (BOX; JENKINS; REINSEL, 2008). Vários tipos de dados aparecem como série temporal: observações feitas a cada hora dentro de um processo, a demanda de matéria prima requerida numa indústria por dia, a sequência mensal de produtos entregues, os dados do PIB de um país ao longo dos anos, entre outros. Esses exemplos de séries temporais variam entre diversas áreas, da economia às ciências sociais, da engenharia às ciências naturais.

As séries temporais apresentam dependência entre as observações adjacentes, que são de fundamental importância para a análise dos dados. Para isto, é necessário o desenvolvimento de modelos estocásticos e dinâmicos para dados de séries temporais (BOX; JENKINS; REINSEL, 2008).

A análise das séries temporais tem o objetivo de construir modelos que possuam propósitos determinados, podendo apresentar dois enfoques. Um enfoque é feito no domínio temporal e geram modelos paramétricos, como exemplo tem-se o modelo ARIMA. O outro enfoque é conduzido no domínio de frequências e os modelos são não-paramétricos, como ocorre na análise espectral (MORETTIN; TOLOI, 2006). Esses modelos irão proporcionar a realização de previsões, a investigação do mecanismo que originou a série, descrição do comportamento da série, assim como a identificação das periodicidades relevantes (MORETTIN; TOLOI, 2006). A série pode ser representada pelo modelo de função de transferência, conforme a equação 1 (BOX; JENKINS; REINSEL, 2008).

$$Z_t = \sum_{\tau=0}^{\infty} v(\tau) X(t - \tau) \quad (1)$$

Onde, X_t é uma série de entrada, Z_t a série de saída e $v(\tau)$ função de transferência.

Ao trabalhar com séries temporais, é comum o erro de assumir que as séries são estacionárias, ou seja, apresentam equilíbrio estatístico com as propriedades probabilísticas que não mudam ao decorrer do tempo, apresentam o nível da média e variância constantes (BOX; JENKINS; REINSEL, 2008). A maior parte das séries encontradas na prática encontram tendências, sendo o caso mais simples aquele em que a série flutua ao redor de uma reta (tendência linear) (MORETTIN; TOLOI, 2006). Portanto, nestes casos é necessário realizar a transformação da série original para que se torne estacionária. A maneira mais comum é determinar diferenças sucessivas da série original. A primeira diferença é dada por:

$$\Delta Z_t = Z_t - Z_{(t-1)} \quad (2)$$

A segunda é definida por:

$$\Delta^2 z_t = \Delta[\Delta z_t] = \Delta[z_t - z_{t-1}] = z_t - 2z_{t-1} + z_{t-2} \quad (3)$$

2.2. Estatísticas para previsão

A ideia de utilizar modelos matemáticos para descrever o comportamento de um fenômeno é utilizada com frequência. Entretanto, é pouco provável que os modelos sejam determinísticos, fatores desconhecidos podem ocorrer durante o decorrer do tempo. Então, é necessária a criação de modelos que determinem a probabilidade de ocorrência de um valor futuro, são os chamados modelos estocásticos (BOX; JENKINS; REINSEL, 2008).

2.2.1. Processos estacionários

Um processo Z é estacionário se ele se desenvolve no tempo de modo que a escolha da origem dos tempos não é importante. Existem diversos tipos de estacionariedade. Um processo estritamente estacionário contém todas as distribuições finito-dimensionais permanecendo com as mesmas translações sob o tempo. Existem ainda os processos fracamente estacionários, ou seja, os momentos de primeira e segunda ordem são constantes e a covariância entre duas variáveis depende somente de sua separação no tempo, conforme a equação 4 (MORETTIN; TOLOI, 2006).

$$E\{Z_t\} = \mu_t = \mu, \text{ constante, para todo } t \in T;$$

$$E\{Z_t^2\} < \infty, \text{ para todo } t \in T; \quad (4)$$

$$\gamma(t_1, t_2) = Cov\{Z_{t_1}, Z_{t_2}\} \text{ é uma função de } |t_1, t_2|.$$

É comum utilizar-se do *Augmented Dickey Fuller Teste* (ADF Teste) para determinar a estacionariedade de uma série.

Este trabalho tratará de processos não estacionários homogêneos, o qual o nível ou inclinação mudam ao decorrer do tempo. Processos não estacionários que apresentam comportamento evolucionário (explosivo) não serão analisados.

2.2.2. Função de autocovariância e função de autocorrelação

Lag, palavra em inglês que significa atraso, refere-se a diferença no tempo entre uma observação e a observação anterior. O coeficiente de autocovariância γ_k , no *lag* k , mede a covariância entre dois valores Z_t e Z_{t+k} a uma distância k (BOX; JENKINS; REINSEL, 2008). A função é chamada de autocovariância e plota em seu gráfico γ_k versus o *lag* k . A função de autocovariância deve satisfazer as condições:

- $\gamma_0 > 0$,
- $\gamma_{-\tau} = \gamma_{\tau}$,
- $|\gamma_{\tau}| \leq \gamma_0$,
- γ_{τ} é não definida, no sentido que

$$\sum_{j=1}^n \sum_{k=1}^n a_j a_k \gamma_{\tau_j - \tau_k} \geq 0, \quad (5)$$

Para quaisquer números reais a_1, \dots, a_n e τ_1, \dots, τ_n de Z .

A função de autocorrelação, similarmente a função de autocovariância, apresenta o coeficiente ρ_k em função do *lag* k (BOX; JENKINS; REINSEL, 2008). Ela é definida por

$$\rho_{\tau} = \frac{\gamma_{\tau}}{\gamma_0}, \tau \in Z, \quad (6)$$

e tem as propriedades de γ_{τ} , exceto que agora $\rho_0 = 1$.

Sabendo-se que $\gamma_k = \rho_k \sigma_Z^2$, pode-se afirmar que ao conhecer a função de autocorrelação ρ_k e a variância σ_Z^2 é equivalente a se conhecer a função de autocorrelação γ_k (BOX; JENKINS; REINSEL, 2008).

2.2.3. Tendência e sazonalidade

Um modelo de decomposição escreve Z_t como a soma de três componentes,

$$Z_t = T_t + S_t + a_t \quad (7)$$

onde T_t e S_t representam a tendência e sazonalidade, respectivamente, enquanto a_t é uma componente aleatória com média zero e variância constante (MORETTIN; TOLOI, 2006).

Considera-se como fenômenos sazonais aqueles que ocorrem regularmente de ano para ano. O objetivo principal de decompor Z_t dessa maneira é construir uma série livre de sazonalidade ou sazonalmente ajustada.

Segundo Pierce (1979), as componentes T_t e S_t são relacionadas e a influência de T_t sobre a componente S_t pode ser muito forte por duas razões:

- os métodos de estimação da sazonalidade podem ser afetados se não considerar a tendência;
- a especificação da sazonalidade depende dos parâmetros da tendência.

Existem vários métodos de estimar a tendência, alguns deles são (MORETTIN; TOLOI, 2006):

- ajustar a função do tempo como uma função suave de t ;
- suavizar os valores ao redor de um ponto, para estimar a tendência no próprio ponto;
- suavizar os valores da série por meio de ajustes consecutivos de retas de mínimos quadrados ponderados;
- tomar diferenças da série.

A estimativa da sazonalidade pode ocorrer através do método da regressão, ou o método de médias móveis, ou algum outro procedimento.

A determinação da presença de tendência pode ser identificada através do ADF Teste e do Mann-Kendall Teste. No caso da sazonalidade deve-se realizar o periodograma. Ambos os testes, para tendência e sazonalidade, serão explicados nos itens a seguir.

2.2.3.1. Teste ADF

O teste *Augmented Dickey Fuller* (ADF) é um teste de raiz unitária para auxiliar na determinação de uma série temporal ser ou não estacionária. O teste apresenta como hipótese nula existir apenas uma raiz unitária, o que significa que é necessário realizar diferenciação para a série ser estacionária. A hipótese alternativa é que a série não apresenta tendência.

A formulação do teste é baseada na seguinte fórmula (8):

$$\Delta Y_t = \mu + \delta T + \alpha Y_{t-1} + \sum_{i=1}^N \beta_i \Delta Y_{t-1} + v_t \quad (8)$$

onde, $\Delta Y_t = Y_t - Y_{t-1}$, μ é um termo derivado e T é a tendência do tempo com a hipótese nula $\alpha = 0$ e a hipótese alternativa $\alpha \neq 0$, N é o número de atrasos necessários para obtenção de ruído branco e v_t é o termo de erro (FULLER, 1976).

2.2.3.2. Teste de Mann-Kendall

O teste de Mann-Kendal é um teste não-paramétrico para verificar se a tendência é estatisticamente significativa em uma série (HIPEL; MCLEOD, 1994). Mann (1945) propôs que o teste apresentasse as seguintes hipóteses:

$$\left[\begin{array}{l} H_0: \text{As observações da série são independentes e identicamente distribuídas (não há} \\ \text{padrões);} \\ H_1: \text{As observações possuem tendência monotônica no tempo (há padrões).} \end{array} \right.$$

A estatística do teste é dada por:

$$S = \sum_{k=1}^{n-1} \sum_{j=k+1}^n \text{sgn}(x_j - x_k) \quad (9)$$

onde

$$\text{sgn}(x) = \begin{cases} +1 & x > 0 \\ 0 & x = 0 \\ -1 & x < 0 \end{cases} \quad (10)$$

Kendal (1970) mostra que S é normalmente distribuída, ou seja, $S \sim N(\mu; \sigma^2)$ com $\mu=0$ e

$$\sigma^2 = \frac{n(n-1)(2n+5) - \sum_{j=1}^p t_j(t_j-1)(2t_j+5)}{18} \quad (11)$$

onde p é o número de grupos possuindo valores iguais na série de dados e t_j é o número de dados com valores iguais em um grupo j .

Mesmo para um número pequeno de n , pode-se assumir que a distribuição seja normal e calculada por:

$$Z = \begin{cases} \frac{S-1}{\sigma}, & \text{se } S > 0 \\ 0, & \text{se } S = 0 \\ \frac{S+1}{\sigma}, & \text{se } S < 0 \end{cases} \quad (12)$$

A hipótese nula é rejeitada se $|Z| > Z_{crit}$, onde Z_{crit} é o valor padrão da distribuição normal com probabilidade $\alpha/2$. Caso isso ocorra, evidencia a existência significativa de padrões não aleatórios.

2.2.3.3. Periodograma

O periodograma é definido como uma medida relativa de potência da série temporal como uma função de frequência (SCHUSTER, 1998). O periodograma de um processo estacionário pode ser definido matematicamente por Priestley (1981) como:

$$I_p(f_i) = \frac{2}{n} \left[\left(\sum_{t=1}^n a_t \cos \frac{2\pi i}{n} t \right)^2 + \left(\sum_{t=1}^n a_t \sin \frac{2\pi i}{n} t \right)^2 \right] \quad (13)$$

com f_i entre 0 e 0,5 e $t=1,2,\dots, n$ em que $I(f_i)$ indica a intensidade da frequência f_i .

No gráfico do periodograma, a frequência é representada no eixo das ordenadas e a intensidade de frequência no eixo das abscissas. O pico de maior intensidade é o componente periódico. Se existir mais de um pico deve-se aplicar o teste de Fisher para verificar se o pico é um componente periódico genuíno.

2.3. Modelos de Box-Jenkins

2.3.1. Visão geral

Os modelos paramétricos podem ser analisados por diversas metodologias, destacando-se uma delas a abordagem utilizada por Box e Jenkins (1976). Esta metodologia consiste em ajustar modelos auto-regressivos integrados de médias móveis (ARIMA) a um conjunto de dados. ARIMA é uma técnica de modelagem linear, ou seja, existe uma correlação linear entre os valores da série temporal (WANG *et al.*, 2012).

De acordo com Box e Jenkins (1976), a construção do modelo ocorre através de um ciclo iterativo que apresenta as seguintes etapas:

a- Identificação: visa identificar dentre as versões existentes de modelos qual melhor descreve o comportamento da série. O comportamento das funções de autocorrelações (ACF) e das funções de autocorrelações parciais (PACF) permitem a estimativa dos parâmetros do modelo.

b- Estimação: é a etapa que estima os parâmetros e o componente auto-regressivo, os parâmetros e o componente de médias móveis e a variância.

c- Verificação: avalia se o modelo estimado é adequado para descrever o comportamento dos dados, avaliando resíduos e o erro do modelo estima-se os parâmetros do modelo identificado.

A Figura 4 mostra com maiores detalhes as etapas a serem seguidas segundo Box & Jenkins (1976).

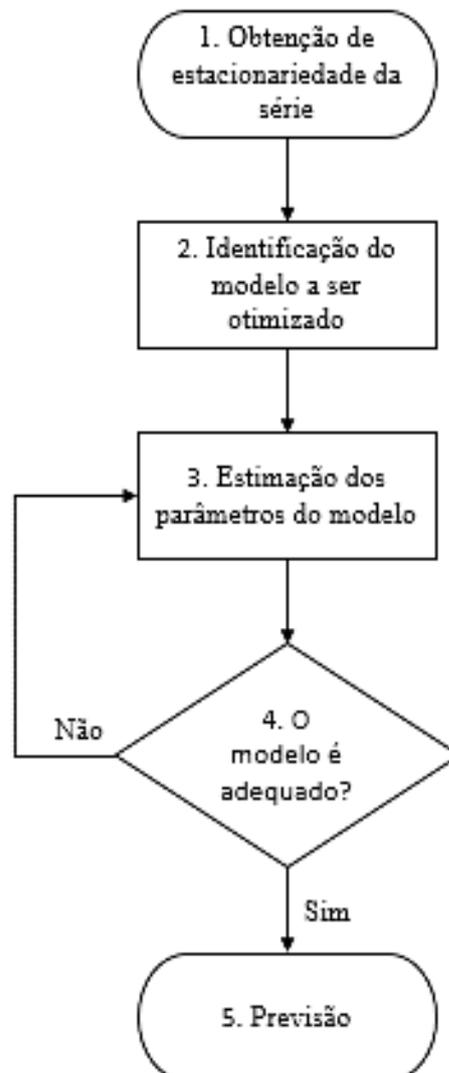


Figura 4: Fluxograma do modelo ARIMA de Box & Jenkins

Se o modelo obtido não for adequado, retorna-se a etapa de estimação e inicia-se o ciclo novamente.

Os modelos ARIMA apresentam resultados satisfatórios para pesquisadores. Ediger e Akar (2007) concluíram que este tipo de modelo demonstra ser mais confiável que o somatório de outros métodos individuais. Assim como Lúcio *et al.* (2010) que concluíram que o modelo ARIMA é apropriado para representar os dados analisados em sua pesquisa.

Para entendimento dos modelos, é necessário conhecer alguns operadores:

- operador translação para o passado B e definido por $BZ_t = Z_{t-1}$;
- operador translação para o futuro F e definido por $FZ_t = Z_{t+1}$;
- operador diferença Δ e definido por $\Delta Z_t = Z_t - Z_{t-1} \therefore \Delta = 1 - B$;
- operador soma S e definido por $SZ_t = \sum_{j=0}^{\infty} Z_{t-j} \therefore S = \Delta^{-1}$.

Os modelos lineares estacionários são divididos em processo linear geral, processos auto-regressivos, processos de médias móveis e processos auto-regressivos e de médias móveis.

2.3.2. Modelo auto-regressivo e de médias móveis ARMA(p,q)

Os modelos ARMA(p,q) são compostos da parte auto-regressiva e a de médias móveis. A parte AR (p) regressa a própria variável em seus valores passados, assim a ordem p do modelo diz quantos valores atrasados (*lags*) são incluídos. A parte MA(q) modela a série temporal por uma média móvel da série de erros que ocorre no passado (GUJARATI, 2006).

A combinação dos processos auto-regressivos de ordem p e de médias móveis de ordem q origina o modelo auto-regressivo e de média móvel, ARMA(p,q). O modelo é dado como:

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (14)$$

que também pode ser escrita através de:

$$\phi(B)\tilde{Z}_t = \theta(B)a_t \quad (15)$$

onde $\phi(B)$ é chamado operador auto-regressivo e $\theta(B)$ operador de média móvel.

A estacionariedade de um processo ARMA está relacionada com a componente AR do modelo. Se todas as raízes de $\phi(B) = 0$ forem menor que um em valor absoluto, então pode-se afirmar que o processo é estacionário (MONTGOMERY; JENNINGS; KULAHCI, 2008).

2.3.3. Funções de autocorrelação e autocorrelação parcial para modelos ARMA(p, q)

As funções de autocorrelação (ACF – *Autocorrelation Function*) e autocorrelação parcial (PACF – *Partial Autocorrelation Function*) são determinadas pelos componentes médias móveis (MA) e auto-regressivos (AR), respectivamente.

A função autocorrelação foi explicada no item 2.2.2 e é sequencial para determinação da ordem de um processo MA(q), entretanto não é muito útil para a identificação da ordem de um processo AR(p) (MONTGOMERY; JENNINGS; KULAHCI, 2008). Por esta razão, é necessário utilizar em conjunto a PACF. Sabe-se que

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kk}\rho_{j-k}, j = 1, \dots, k, \quad (16)$$

Escrevendo a equação 16 em notação matricial tem-se:

$$\begin{bmatrix} 1 & \rho_1 & \rho_2 & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \rho_{k-2} \\ \vdots & \dots & \dots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & 1 \end{bmatrix} \begin{bmatrix} \phi_{k1} \\ \phi_{k2} \\ \dots \\ \phi_{kk} \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \dots \\ \rho_k \end{bmatrix} \quad (17)$$

Resolvendo as equações para $k=1, 2, 3, \dots$ obtém-se:

$$\phi_{kk} = \frac{|P_k^*|}{|P_k|} \quad (18)$$

onde P_k é a matriz autocorrelação e P_k^* é a matriz P_k com a última coluna substituída pelo vetor de autocorrelações. O coeficiente de ϕ_{kk} é a chamada PACF do processo no lag k .

A tabela 1 mostra de forma mais concisa o comportamento dos gráficos ACF e PACF para processos estacionários.

Modelo	ACF	PACF
MA(q)	Apresenta um corte após o <i>lag</i> q	Decai de acordo com exponenciais e/ou senóides amortecidas
AR(p)	Decai de acordo com exponenciais e/ou senóides amortecidas	Apresenta um corte após o <i>lag</i> p
ARMA(p,q)	Decai de acordo com exponenciais e/ou senóides amortecidas	Decai de acordo com exponenciais e/ou senóides amortecidas

Tabela 1: Comportamento teórico de ACF e PACF para processos estacionários

Fonte: Adaptado de MONTGOMERY, JENNINGS e KULAHCI (2015)

2.3.4. Processos não estacionários: modelos ARIMA(p,d,q)

Em um processo não estacionário, é possível perceber que a análise da série ao longo do tempo apresenta comportamento similar. Chama-se a série não estacionaria homogênea se a série não é estacionaria, porém sua primeira diferença ou diferenças de maior ordem produzem uma série estacionária (MONTGOMERY; JENNINGS; KULAHCI, 2008).

O número d de diferenças necessárias para tornar a série estacionária é chamado ordem de integração. Como $W_t = \Delta^d Z_t$, é uma diferença de Z_t , então Z_t é uma integral de W_t , dessa maneira, pode-se dizer que Z_t segue um modelo auto-regressivo, integrado, de médias móveis, ou modelo ARIMA,

$$\phi(B)Z_t = \phi(B)W_t = \theta_0 + \theta(B) a_t \quad (19)$$

de ordem (p,d,q) , no qual p e q são as ordens de $\phi(B)$ e $\theta(B)$, respectivamente. Os operadores $\phi(B)$ e $\theta(B)$ são definidos por:

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (20)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (21)$$

onde $\phi(B)$ é chamado operador auto-regressivo e $\theta(B)$ operador de média móvel e $\phi(B)$ é um operador auto-regressivo não estacionário, de ordem $p+d$, com d raízes iguais a um e as restantes p fora do círculo unitário (BOX; JENKINS; REINSEL, 2008).

Portanto, a forma usual do modelo ARIMA, para o cálculo de previsão é dado por:

$$Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_{p+d} Z_{t-p-d} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (22)$$

onde $\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_{p+d} B^{p+d}$.

2.3.1. Modelos SARIMA $(p,d,q)(P,D,Q)$

As séries temporais podem apresentar padrões periódicos significativos, refere-se essa característica como comportamento sazonal (MONTGOMERY; JENNINGS; KULAHCI, 2008).

Os modelos sazonais ARIMA são conhecidos por SARIMA $(p,d,q)(P,D,Q)$, no qual p e P indicam AR não-sazonal e sazonal respectivamente, q e Q indicam MA não-sazonal e sazonal respectivamente e d significa a ordem integrada do componente não-sazonal chamado diferença regular e D significa a ordem integrada do componente sazonal chamado diferença sazonal (MAKRIDAKIS, S. WHEELWRIGHT; HYDMAN, 1998). Os modelos SARIMA podem eliminar a influência da periodicidade no processo de previsão e amplamente aplicado na previsão de séries temporais (WANG *et al.*, 2012).

SARIMA $(p,d,q)(P,D,Q)$ pode ser expresso por:

$$\phi(B)\Phi(B^s)(1 - B^s)^D(1 - B)^d Z_t = \theta(B)\Theta(B^s)\alpha_t \quad (31)$$

onde,

$$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q;$$

$$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p;$$

$\Phi(B^s) = 1 - \Phi_1 B^s - \dots - \Phi_P B^{sP}$ é o operador auto-regressivo sazonal de ordem P e estação sazonal s ;

$(1 - B^s)^D$ é o operador diferença sazonal com D indicando o número de diferenças sazonais;

$\Theta(B^s) = 1 - \Theta_1 B^s - \dots - \Theta_Q B^{sQ}$ é o operador de médias móveis sazonal de ordem Q e estação sazonal s .

As últimas três décadas foram provas do sucesso de se aplicar o modelo SARIMA tanto em pesquisa acadêmica quanto em aplicação industrial (CHEN; WANG, 2007). Entretanto, outros modelos de previsão também foram desenvolvidos ao longo do tempo, como no caso das redes neurais artificiais.

2.3.2. Identificação dos modelos ARIMA(p,d,q)

As etapas de identificação e estimação se sobrepõem, pois utiliza-se o procedimento de estimação para realizar parte da identificação. A identificação é uma etapa inexata, pois a maneira que modelos ocorrem na prática e suas circunstâncias representam um comportamento físico do mundo, portanto não pode ser decidido puramente com matemática (BOX; JENKINS; REINSEL, 2008).

O objetivo da identificação é determinar as ordens de p , d e q . A identificação possui três etapas:

- a) verificar se é necessário realizar a transformação da série original para estabilizar a variância;
- b) diferenciar Z_t o quanto for preciso para tornar a série estacionária, em caso do processo ser não estacionário. O número de diferenças d necessárias para que o processo se torne estacionário, é obtido quando a função autocorrelação amostral de $W_t = \Delta^d Z_t$ cai rapidamente para zero. Neste ponto o teste de Dickey-Fuller pode ser utilizado para verificar a existência de raízes unitárias;
- c) identificar o modelo resultante ARMA para W_t através das análises das autocorrelações e autocorrelações parciais.

A maior dificuldade desta etapa é saber o momento de parar de realizar diferenças. Pode-se verificar que um número excessivo de diferenças resulta em um valor negativo da autocorrelação de ordem 1 da série diferenciada. Além de aumentar a variância ao realizar diferenças a mais, por isso o monitoramento da variância é um guia importante na determinação de d (MCLEOD; LI, 1983).

2.3.3. Estimação dos modelos ARIMA(p,d,q)

Após a identificação do modelo, é preciso estimar os parâmetros. Para o cálculo destes parâmetros usa-se uma metodologia iterativa de estimação não-linear de mínimos quadrados e

as estimativas preliminares encontradas na etapa anterior de identificação (MORETTIN; TOLOI, 2006).

Existem vários métodos de estimação, entre eles estão os métodos dos momentos, da máxima verossimilhança e dos mínimos quadrados. Entretanto, os softwares que auxiliam o processo de construção dos modelos ARIMA como *Minitab*, *JMP* e *SAS*, realizam a estimação dos parâmetros de maneira automática (MONTGOMERY; JENNINGS; KULAHCI, 2008).

2.3.4. Diagnóstico dos modelos ARIMA(p,d,q)

Nessa etapa, verifica-se se o modelo representa adequadamente os dados. Para verificação do modelo estocástico, pode-se utilizar o *superajustamento* (*overfitting*). Esta técnica adiciona parâmetros no modelo encontrado após a estimação e verifica se estes parâmetros são significativos e se diminui a variância residual (MORETTIN; TOLOI, 2006). Os parâmetros adicionais devem ser adicionados um de cada vez em cada lado do modelo ARMA (BOX; JENKINS; REINSEL, 2008). No caso de não encontrar um modelo mais adequado que o testado, pode-se confirmar que o modelo representa os dados em análise.

O método do *superajustamento* é recomendado quando se sabe a direção que ocorre a inadequação do modelo. Entretanto, quando não se conhece essa informação é adequado realizar a análise de resíduos, que serão apresentas a seguir (BOX; JENKINS; REINSEL, 2008).

Teste de autocorrelação residual

O modelo ao se adequar aos dados resulta em

$$\hat{a}_t = \hat{\theta}^{-1}(B)\hat{\phi}(B)W_t \quad (23)$$

sendo \hat{a}_t o resíduo estimado. Então, se o modelo for adequado, os resíduos devem se comportar como ruído branco, conforme a equação 24.

$$\hat{a}_t = a_t + O\left(\frac{1}{\sqrt{n}}\right) \quad (24)$$

Para confirmar a adequação do modelo, a função de autocorrelação da amostra de resíduos não deve se diferenciar significativamente de zero para todos os *lags* maiores que um (MONTGOMERY; JENNINGS; KULAHCI, 2008). O teste Chi-Quadrado (*chi-square*) permite conhecer quais as primeiras K autocorrelações residuais devem ser consideradas para indicar adequação do modelo (MONTGOMERY; JENNINGS; KULAHCI, 2008).

Teste de Box-Pierce e de Ljung-Box

O teste de *Box-Pierce* é um teste de autocorrelação dos resíduos estimados conjuntamente para determinar se a série de resíduos é um ruído branco (MONTGOMERY; JENNINGS; KULAHCI, 2008). A estatística de Box-Pierce é dada por:

$$Q_{BP} = T \sum_{k=1}^K r_k^2 \quad (25)$$

no qual a hipótese nula é que a série é de ruído branco (BOX; PIERCE, 1970).

O teste proposto por Ljung e Box (1978) é uma modificação do teste de Box-Pierce, e funciona melhor para amostras menores. A estatística utilizada é:

$$Q_{LB} = T(T + 2) \sum_{k=1}^K \left(\frac{1}{T-k} \right) r_k^2 \quad (26)$$

Quando os valores de T forem altos, as estatísticas Q_{BP} e Q_{LB} serão muito similares.

2.3.5. Previsão dos modelos ARIMA (p, d, q)

Após encontrar o modelo adequado que representa os dados da série, eles poderão ser usados para realizar previsões de observações futuras. O tempo atual é chamado T , a previsão para $Z_{T+\tau}$ é para o período τ a frente e denotado por $\hat{Z}_{T+\tau}$. O critério padrão para obter a melhor previsão é o erro médio quadrático, no qual o erro quadrático da previsão, $E[(Z_{T+\tau} - \hat{Z}_{T+\tau}(T))^2] = E[e_T(\tau)^2]$, é minimizado (MONTGOMERY; JENNINGS; KULAHCI, 2008).

O processo ARIMA (p, d, q), pode ser representado por três formas básicas com $T + \tau$ representando o tempo.

A primeira forma é de equação de diferenças:

$$Z_{T+\tau} = \varphi_1 Z_{T+\tau-1} + \dots + \varphi_{p+d} Z_{T+\tau-p-d} - \theta_1 a_{T+\tau-1} - \dots - \theta_q a_{T+\tau-q} + a_{T+\tau} \quad (27)$$

Ou também representada pela equação 28.

$$Z_{T+\tau} = \delta + \sum_{i=1}^{p+d} \phi_i Z_{T+\tau-i} + \varepsilon_{T+\tau} - \sum_{i=1}^q \theta_i \varepsilon_{T+\tau-i} \quad (28)$$

Outra maneira de representação é em forma de choques aleatórios, mostrado a seguir.

$$Z_{T+\tau} = \sum_{j=-\infty}^{T+\tau} \psi_{T+\tau-j} a_j = \sum_{j=0}^{\infty} \psi_j a_{T+\tau-j} \quad (29)$$

onde $\psi_0 = 1$ e os demais ψ_j são pesos.

E por último, a forma invertida.

$$Z_{T+\tau} = \sum_{j=1}^{\infty} \pi_j Z_{T+\tau-j} + a_{T+\tau} \quad (30)$$

onde π_j são os pesos.

2.4. Redes neurais artificiais (RNA)

As redes neurais artificiais (RNAs) são inspiradas pelo sistema biológico, particularmente pela pesquisa sobre o cérebro humano. Originaram-se pelo trabalho de McCulloch e Pitts (1943) no qual descreveram o cálculo lógico das redes neurais que unificava o estudo de neurofisiologia e de lógica matemática.

As RNAs aprendem e generalizam através de experiência, podendo capturar relações sutis entre os dados, os quais são desconhecidos ou difíceis de descrever (ZHANG; PATUWO; HU, 1998). Generalização refere-se a RNA produzir saídas sensatas para entradas que não são encontradas durante o treinamento (HAYKIN, 1998).

O cérebro humano é complexo, não linear e possui um sistema de processamento de informação. Ele possui a capacidade de organizar os seus elementos estruturais, conhecidos como neurônios, e realizar cálculos mais rápido que o computador mais rápido existente (HAYKIN, 1998). Através desses conceitos, foi desenvolvido a RNA.

Cada neurônio ou nó recebe um sinal de entrada através de outros nós ou através de um estímulo externo, ele processa localmente a informação por meio de uma função de transferência ou ativação e produz um sinal de saída transformada por outros nós ou saídas externas (ZHANG; PATUWO; HU, 1998). A ideia não é replicar a operação do sistema biológico mas sim fazer o uso do que é conhecido sobre a funcionalidade das redes biológicas para resolver problemas complexos (BASHEER; HAJMEER, 2000).

RNAs são funções universais de aproximação, possuem funções mais generalizadas e flexíveis que outros métodos estatísticos tradicionais. Qualquer modelo de previsão assume que existe uma relação oculta entre entrada e saída, os métodos tradicionais apresentam limitações para determinar esta função devido sua complexidade. Entretanto, RNAs são uma alternativa para identificar funções desse tipo (ZHANG; PATUWO; HU, 1998).

Os modelos lineares, como o modelo ARIMA, são modelos bem estabelecidos e amplamente utilizados para previsão de séries temporais. Entretanto, esses modelos não representam elementos não lineares fundamentais que estão presentes na série original. Por exemplo, Lee *et al.* (1993) afirma que muitos economistas acreditam que o sistema econômico é não-linear e existe uma relação não-linear entre as variáveis. Portanto, os modelos lineares não poderiam representar de forma completa o sistema econômico e outros sistemas não-lineares. Além disso, RNAs não necessitam dos dados serem estacionários, são adaptativos por natureza e por essas razões tem se tornado populares em previsão de dados (BABU; REDDY, 2014).

Ao realizar comparações de modelos tradicionais e RNA, pode-se perceber maior eficiência nos modelos de RNA. Chaudhuri e Ghosh (2016) realizaram uma comparação entre RNAs e modelos econométricos e concluíram que os modelos de RNAs apresentavam melhor eficiência de previsão. Assim como Pao (2007), que afirmou que uma RNA proposta era mais robusta na previsão de vários passos à frente que os modelos auto-regressivos.

2.4.1. Componentes de uma RNA

O modelo de um neurônio (Figura 5), base para as RNAs, apresenta três elementos básicos. Um dos elementos é o conjunto de sinapses, caracterizada por um peso ou força própria, ou seja, o sinal de entrada x_j na entrada da sinapse j conectada ao neurônio k é multiplicada pelo peso sináptico ω_{kj} . Outro elemento é o somador para somar os sinais de entrada ponderados pelas respectivas sinapses do neurônio. E o elemento de função de ativação para restringir a amplitude da saída de um neurônio (HAYKIN, 1998).

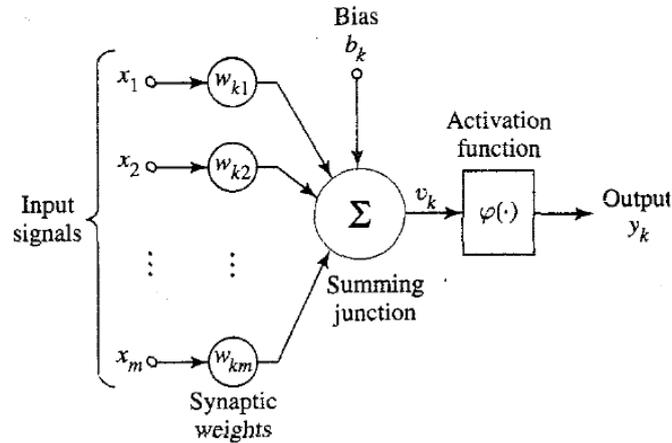


Figura 5: Modelo não linear de um neurônio

Fonte: Haykin, 2008

Pode-se descrever matematicamente um neurônio k com as equações 32 e 33 abaixo:

$$u_k = \sum_{j=0}^m \omega_{kj} x_j \quad (32)$$

$$y_k = \varphi(u_k + b_k) \quad (33)$$

onde x_1, x_2, \dots, x_m são sinais de entrada, $\omega_{k1}, \omega_{k2}, \dots, \omega_{km}$ são os pesos sinápticos (parâmetros) do neurônio k , u_k é a saída do combinador linear devido aos sinais de entrada, b_k é o bias, $\varphi(\cdot)$ é a função de ativação e y_k é a função de saída do neurônio (HAYKIN, 1998).

2.4.2. Arquiteturas de rede

A habilidade de aprender é uma característica específica a sistemas inteligentes ou biológicos. Em sistemas artificiais, aprendizagem se caracteriza por atualizar a representação interna do sistema em resposta a um estímulo externo para que possa efetuar uma tarefa específica (BASHEER; HAJMEER, 2000). O algoritmo de aprendizagem usado para treinar a rede é responsável pela maneira como a rede está estruturada. Em geral, existem três classes de rede, que são explicadas a seguir.

Redes alimentadas adiante com camada única

Neste tipo de arquitetura, os neurônios são organizados na forma de camadas. Na forma mais simples, tem-se uma camada de entrada de nós de fonte que se projeta sobre uma camada de saída de neurônios, porém não ocorre o caminho inverso.

A camada única do nome da arquitetura de rede refere-se a camada de saída, a camada com nós de fonte não realiza qualquer tipo de computação dos dados (HAYKIN, 1998).

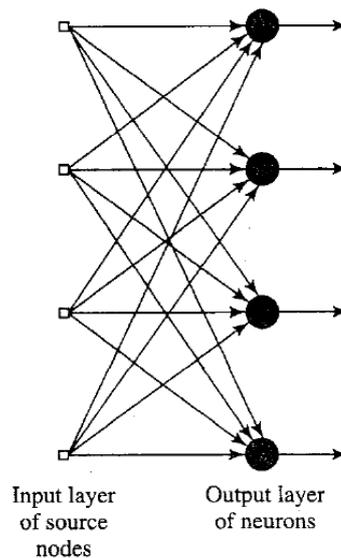


Figura 6: Rede alimentada adiante com camada única

Fonte: Haykin (2008)

Redes alimentadas adiante com múltiplas camadas

A diferença entre a primeira classe apresentada e esta é a presença de uma ou mais camadas ocultas, as quais possuem nós ocultos (Figura 7). A função dos neurônios ocultos é modificar a entrada para que a saída represente o conjunto de dados em estudo (HAYKIN, 1998). Ao aumentar a número de camadas, permite-se extrair estatísticas de ordem mais elevadas.

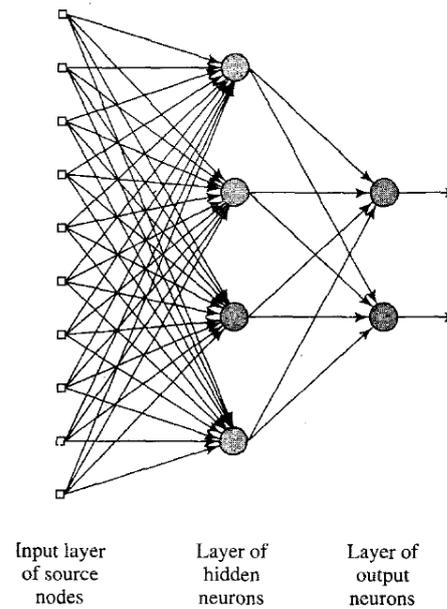


Figura 7: Rede alimentada adiante com uma camada oculta e uma camada de saída

Fonte: Haykin (2008)

Redes recorrentes

A rede neural recorrente apresenta pelo menos um laço de realimentação. A presença desses laços impacta na capacidade de aprendizagem da rede e no seu desempenho. Além de resultar em um comportamento dinâmico não-linear, permitindo a existência de elementos não-lineares (HAYKIN, 1998).

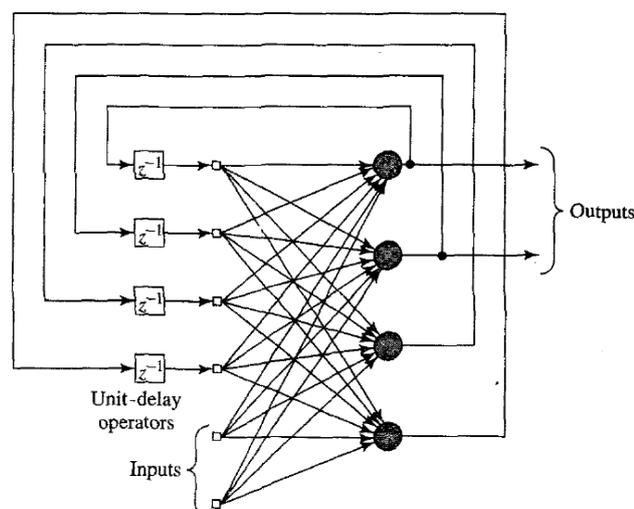


Figura 8: Rede recorrente com neurônios ocultos

Fonte: Haykin (2008)

2.4.3. Processos de aprendizagem

Como dito anteriormente, a aprendizagem de uma rede neural pode ser realizada por meio de diferentes algoritmos, no qual cada um apresenta suas próprias vantagens. Eles, basicamente, se diferem entre si pela maneira como o peso sináptico é ajustado. Entre os processos de aprendizagem conhecidos, tem a aprendizagem por correção de erro, aprendizagem baseada em memória, aprendizagem hebbiana, aprendizagem competitiva, aprendizagem de Boltzmann, aprendizagem supervisionada e aprendizagem não supervisionada.

2.4.4. Redes lineares

Um modelo parcimonioso para representar um problema real é crítico para todos os métodos estatísticos e é particularmente importante para problemas em RNAs devido ao superajustamento (ZHANG; PATUWO; HU, 1998).

Em termos de função de aproximação, o modelo mais simples é o modelo linear, no qual a função ajustada é um hiperplano. Uma rede neural com nenhuma camada oculta, uma saída com função sináptica e função de ativação identidade implementa um modelo linear. Os pesos correspondem a matriz e o limite ao vetor de bias.

Um algoritmo conhecido para utilizar-se em uma rede linear é o de decomposição em valores singulares (*singular value decomposition* - SVD), no caso do software *Statistica* (STATSOFT, 2005), utiliza-se o padrão de algoritmo de otimização pseudo-inversa (GOLUB; KAHAN, 1965).

2.4.5. Redes neurais probabilísticas (PNNs) e redes neurais de regressão generalizada (GRNNs)

Redes neurais probabilísticas

Rede neural probabilística (*Probabilistics neural network* – PNN) é a implementação do método de aproximação de densidade de probabilidade de *Parzen* em redes neurais. O método é mais adequado para problemas de classificação, é um método atrativo pois é rápido e direto para aprender as probabilidades do conjunto de treinamento (LI, 2011). A figura 9 representa a arquitetura de uma PNN.

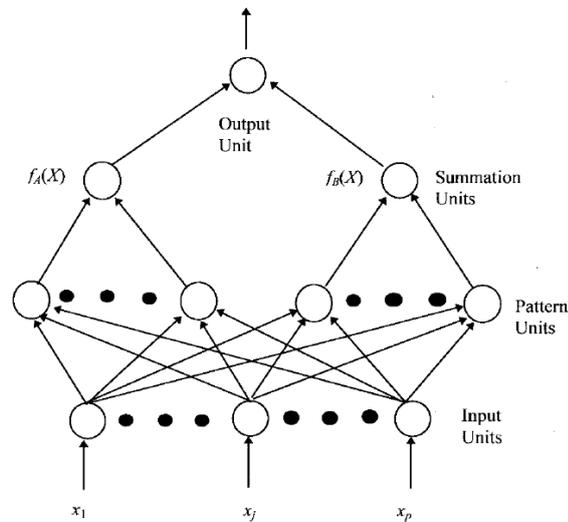


Figura 9: Diagrama de blocos da PNN
Fonte: SAAD, PROKHOROV e WUNSCH (1998)

Considera-se um vetor padrão X com m dimensões que pertencem a categorias k_1 e k_2 . Sendo $F_1(X)$ e $F_2(X)$ funções probabilidade de densidade das categorias k_1 e k_2 , respectivamente. Através da regra de decisão de Bayes, X pertence a k_1 se a equação 37 é verdadeira, ou pertence a k_2 se é falsa.

$$F_1(X)L_2P_1 > F_2(X)L_1P_2 \quad (37)$$

onde L_1 é a função custo associada à classificação errada do vetor como pertencente à categoria k_1 , enquanto pertence à categoria k_2 ; L_2 é a função custo associada à classificação errada do vetor como pertencente à categoria k_2 , enquanto pertence à categoria k_1 ; P_1 é a probabilidade de ocorrência da categoria k_1 ; P_2 é a probabilidade de ocorrência da categoria k_2 .

Sendo

$$F_1(X) = \frac{1}{(2\pi)^{m/2}\sigma^m} \sum_{j=1}^n \exp \left[-\frac{(X-X_j)^T(X-X_j)}{2\sigma^2} \right] \quad (38)$$

onde n é número total da amostra de treinamento na categoria k_1 ; m é a dimensão do vetor de entrada; j é o número da amostra de treinamento na categoria k_1 ; σ é um parâmetro ajustável de alisamento (LI, 2011).

Chen, Leung e Daouk (2003) concluíram que PNN apresenta um poder de previsão mais forte que o filtro GMM-Kalman e modelos aleatórios. Isso ocorre pois PNN apresenta melhor

capacidade de identificar erros nos dados e *outliers*, além de não requerer informação antecipada sobre a função probabilidade densidade dos dados.

Redes neurais de regressão generalizada

A rede neural de regressão generalizada (*general regression neural network* - GRNN) é um algoritmo de aprendizagem de um passo com estrutura paralela. É similar com PNNs, ambas usam função densidade probabilidade, as funções de Gaussian Kernel são localizadas em cada caso de treinamento (SPECHT, 1991). Entretanto, se diferenciam pois GRNN apresenta performance melhor em regressões, as quais trabalham com variáveis dependentes contínuas, do que em problemas de classificação (BISHOP, 1995). A saída é estimada com a média ponderada das saídas dos casos de treinamento, no qual os pesos são relacionados com a distância do ponto estimado.

No GRNN apresenta na primeira camada oculta unidades radiais e a segunda camada possui unidades para ajudar a estimar a média ponderada. Cada saída apresenta uma unidade especial designada para a camada em questão que realiza a média ponderada para a saída correspondente (BISHOP, 1995). A Figura 10 representa o diagrama de blocos de uma rede neural GRNN.

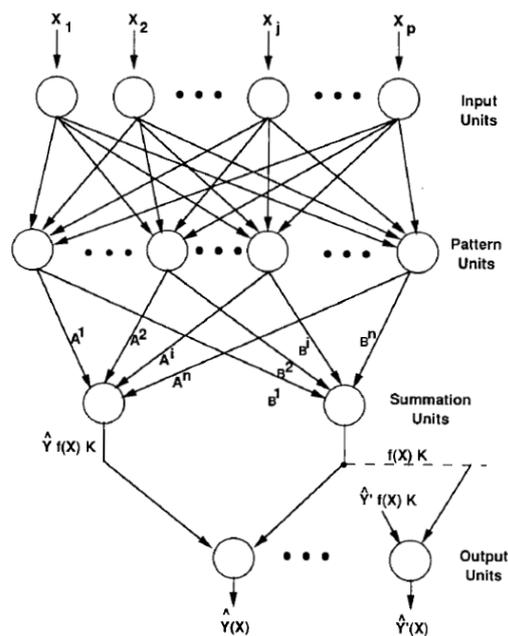


Figura 10: Diagrama de blocos da GRNN

Fonte: SPECHT (1991)

A principal vantagem de GRNN é aprender rápido e convergir a uma superfície de regressão ótima de acordo com que a o número de amostras torna-se grande. Já a desvantagem

desta técnica é a quantidade de computação requerida no sistema de treinamento para estimar a saída (SPECHT, 1991).

2.4.6. Redes de função de base radial

O método das funções de base radial aproxima-se dos trabalhos de pesquisa em interpolação estrita tradicional em um espaço multidimensional. Em redes neurais, as unidades ocultas fornecem um conjunto de funções que constituem uma base para os padrões de entrada, quando são expandidos sobre o espaço oculto, denomina-se função de base radial (HAYKIN, 1998).

A rede de função de base radial (*radial-basis function* – RBF) envolve três camadas, cada uma com seu papel único. A camada de entrada possui nós de fonte para conectar uma rede ao seu ambiente. A segunda camada é a única camada oculta da rede e aplica uma transformação não-linear do espaço de entrada para o espaço oculto. A última camada, de saída, é linear e fornece a resposta da rede ao padrão de ativação aplicado à camada de entrada (HAYKIN, 1998). A Figura 11 mostra a estrutura de uma rede RBF.

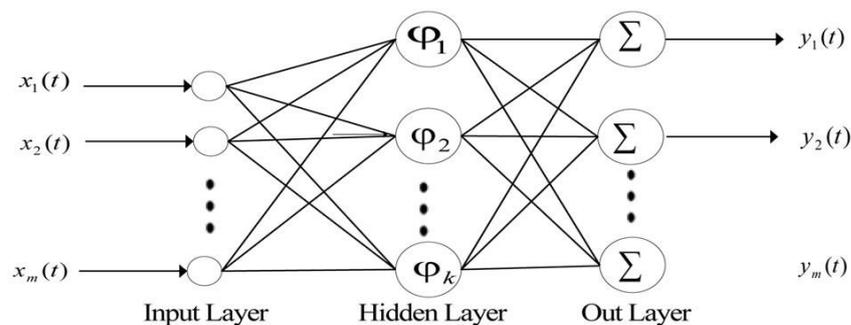


Figura 11: Estrutura da Rede Neural RBF

Fonte: BISHOP (1995)

As redes RBF apresentam várias vantagens em relação às redes perceptrons de Múltiplas Camadas. Primeiramente, eles podem modelar qualquer função não-linear usando apenas uma camada oculta. Outra vantagem, a rede pode, com uma simples transformação linear na camada de saída, otimizar totalmente usando técnicas de modelagem tradicional. Além disso, as redes

RBF podem ser treinadas rapidamente (BISHOP, 1995). Entretanto, são redes mais sensíveis a dimensionalidade e tem dificuldades se o número de unidades de entrada é grande.

Considerando um mapa de dimensão d , espaço de entrada x para um espaço alvo unidimensional t . Os dados apresentam um vetor N de vetores x , juntamente com os alvos t^n . O objetivo é encontrar a função $h(x)$, tal que:

$$h(x^n) = t^n, n = 1, \dots, N \quad (39)$$

A abordagem do RBF apresenta um conjunto de N funções de base, uma para cada ponto dos dados, representado por $\phi(\|x - x^n\|)$ onde ϕ é uma função não-linear. A saída do mapa é a combinação linear das funções de base (Equação 40).

$$h(x^n) = \sum \omega_n \phi(\|x - x^n\|) \quad (40)$$

As condições de interpolação podem ser escritas na forma de matriz como:

$$\Phi w = t \quad (41)$$

onde $t \equiv (t^n)$, $w \equiv (\omega_n)$, e a matriz quadrada Φ tem elementos .

Para uma classe grande de funções ϕ , a matriz Φ é não-singular e apresenta pontos de dados distintos. Quando os pesos na equação 40 são determinados, a função $h(x)$ representa uma superfície contínua diferenciada que passa exatamente por cada ponto dos dados. Várias formas de função de base são consideradas, entretanto, a mais conhecida é a Gaussiana, representada por:

$$\phi = \exp\left(-\frac{x^2}{2\sigma^2}\right) \quad (41)$$

onde σ é um parâmetro que controla as propriedades de alisamento da função de interpolação. A função Gaussiana é classificada como RBF devido a propriedade que $\phi \rightarrow 0$ as $|x| \rightarrow \infty$.

A função

$$\phi(x) = (x^2 + \sigma^2)^{-\beta}, 0 < \beta < 1 \quad (42)$$

na qual $\beta = \frac{1}{2}$ é conhecida como função multi-quadrática, a cúbica é conhecida por:

$$\phi(x) = x^3 \quad (43)$$

E a função linear é:

$$\phi(x) = x \quad (44)$$

E todas apresentam a propriedade de $\phi \rightarrow 0$ as $|x| \rightarrow \infty$.

A generalização para diversas variáveis é direta, cada vetor de entrada x^n deve ser conectado no vetor de saída t_n , obtendo-se os componentes t_k^n (BISHOP, 1995).

$$h_k(x^n) = t_k^n, n = 1, \dots, N \quad (45)$$

onde $h_k(x)$ é obtido pela superposição linear da mesma função base N como usado em caso de única saída.

$$h_k(x) = \sum \omega_{kn} \phi(\|x - x^n\|) \quad (46)$$

Os pesos dos parâmetros são obtidos analogamente a equação 38 (BISHOP, 1995).

$$w_{kn} = \sum (\Phi^{-1})_{nn'} t_k^{n'} \quad (47)$$

2.4.7. Redes neurais perceptrons de múltiplas camadas

Redes neurais Perceptrons de Múltiplas Camadas (*Multi-Layer Perceptron* - MLP) contêm várias camadas nas quais, tipicamente, são conectadas internamente. Este tipo de rede contém três camadas: camada de entrada, camada oculta e camada de saída, conforme mostrado na Figura 12 (AMEDI; BAGHBAN; AHMADI, 2016).

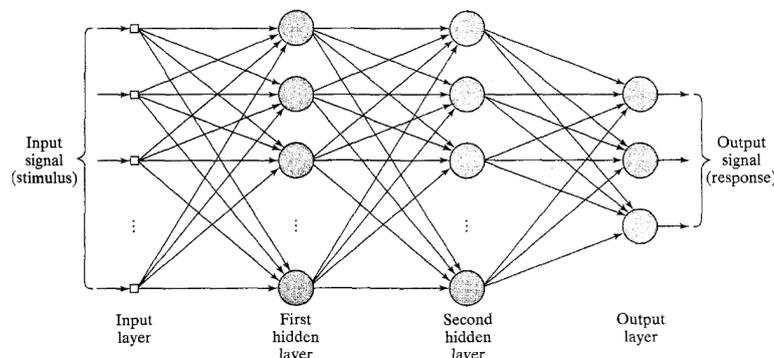


Figura 12: Rede MLP

Fonte: HAYKIN (1998)

Os neurônios de entrada possuem pesos e *bias* (viés) que são convertidos em pesos e *bias* de saídas através de uma função de ativação. Dentre as várias funções de ativação existentes, a função sigmoide é a mais usada em aplicações práticas. A função de transferência determina a saída do neurônio com base a função de ativação. As funções de transferência mais conhecidas são a linear, Log-sigmoide e sigmoide tangente hiperbólica (AMEDI; BAGHBAN; AHMADI, 2016).

O ajuste dos pesos sinápticos é obtido através dos algoritmos de aprendizagem, conforme já explicado anteriormente. Nas redes MLPs o algoritmo mais popular é o algoritmo de retropropagação do erro (*error back-propagation*) (WERBOS, 1990).

O algoritmo de retropropagação apresenta a lógica apresentada nas equações abaixo (48-51).

$$x_i = X_i, \quad 1 \leq i \leq m \quad (48)$$

$$net_i = \sum_{j=1}^{i-1} W_{ij} x_j, \quad m < i \leq N + n \quad (49)$$

$$x_i = s(net_i), \quad m < i \leq N + n \quad (50)$$

$$Y_i = x_{i+N}, \quad 1 \leq i \leq n \quad (51)$$

onde a função s em (50) é normalmente a função sigmoide (52).

$$S(Z) = \frac{1}{1+e^{-Z}} \quad (52)$$

N é uma constante inteira maior que m , o valor de $N+n$ determina a quantidade de neurônios na rede, net_i é o nível de voltagem excitando um neurônio e x_i é a intensidade do resultado (WERBOS, 1990).

O peso W_{ij} é escolhido para minimizar o erro no conjunto de treinamento (Equação 53).

$$E = \sum_{t=1}^T E(t) = \sum_{t=1}^T \sum_{i=1}^n \left(\frac{1}{2}\right) (\hat{Z}_i(t) - Z_i(t))^2 \quad (53)$$

Inicia-se com valores arbitrários os pesos W_{ij} para calcular $\hat{Z}_i(t)$ e os erros $E(t)$. Em seguida, calcula-se as derivadas de E em relação à todos os pesos. Se o erro aumenta ao aumentar os pesos, deve-se ajustar o peso para baixo. Caso o erro diminua, o ajuste deve ser para cima. Após esses ajustes de pesos, inicia-se esse processo novamente até o momento em o erro estabilize (WERBOS, 1990).

2.4.8. Software STATISTICA: *Intelligent Problem Solver*

A pesquisa experimental para obter um modelo de rede neural ótimo leva muito tempo e esforço se executado por um ser humano. Portanto, o ideal é a utilização de um software. Esta pesquisa utilizará o *Software Statistica*, módulo de redes neurais. O *Software Statistica* é utilizado neste trabalho para realização da etapa de criação das RNAs. Existem dois tipos de análises que o software oferece, o *Intelligent Problem Solver (IPS)* e o *Custom Network Designer*. Este trabalho utiliza-se do *IPS* para desenvolvimento das redes neurais das séries temporais em estudo.

Tradicionalmente, para criação de uma rede, executa-se diversas vezes os algoritmos de treinamento, selecionando as melhores redes. Para isso, é necessário selecionar os parâmetros (tipo de rede, número de unidades ocultas, algoritmo de aprendizagem, entre muitos outros) para obtenção da rede. O *IPS* segue semelhante processo. Entretanto, a heurística para seleção dos parâmetros é substituída por algoritmos de pesquisa que usam técnicas avançadas para determinar fatores chave para criação de uma RNA. Estes algoritmos são interligados, de modo que o *IPS* procura, simultaneamente, por redes ótimas de diferentes tipos (STATSOFT, 2005).

O *IPS* usa automaticamente a soma dos quadrados como função de erro, sendo erro a soma dos quadrados da diferença entre os valores de entrada e os valores de saída recebidos em cada saída do neurônio (GAJEWSKI; JONAK, 2006).

Outra vantagem da utilização da ferramenta *IPS* é que ela evita a ocorrência de ‘*over-learning*’ durante a geração da rede. O ‘*over-learning*’ da rede é caracterizado por um alto grau de uma curva hipspectral, modelando a relação do sinal de entrada, de maneira que a rede permite passar por todos os pontos de aprendizagem (DEBSKA; GUZOWSKA-ŚWIDER, 2011).

Inicialmente, é necessário determinar o tempo de otimização, tempo em que a análise deve ocorrer (Figura 13a). Pode-se utilizar a quantidade de redes a serem testadas, ou seja, as iterações que o *IPS* deve realizar ou através de horas/minutos. O *IPS* intercala buscas independentes para cada tipo de rede, não dependendo do número de iterações determinados pelo usuário. Estas buscas são estruturadas de modo que executem uma seleção básica e possibilita encontrar uma solução sensata rapidamente.

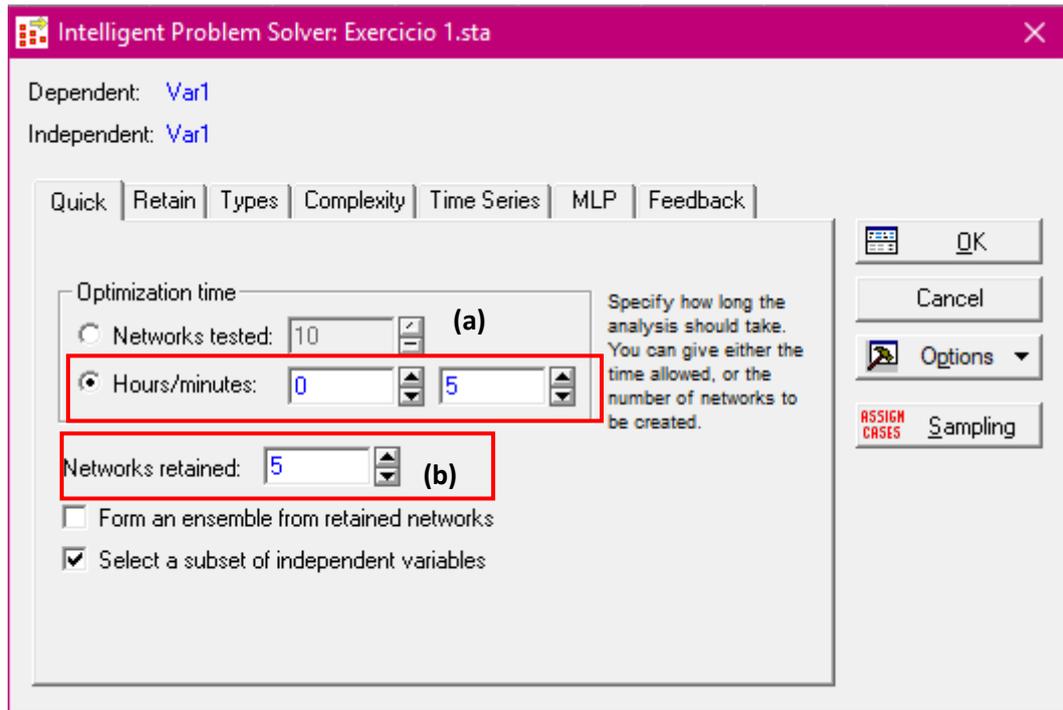


Figura 13: Início da criação das redes neurais

O usuário também pode determinar a quantidade das redes testadas que devem ser retidas (Figura 13b). Além de poder optar por formar um conjunto com as redes obtidas, gerando uma rede que representa as redes obtidas. O IPS determina ao usuário o conjunto de variáveis usadas no treinamento das redes, para isto, deve-se selecionar a opção de subconjunto de variáveis independentes.

A ferramenta do *IPS* disponibiliza duas opções de critérios de seleção das redes retidas: menor erro e balanço entre erro contra diversidade (Figura 14). Selecionar o critério de menor erro pode não ser a melhor opção, pois pode existir outro tipo de rede que tem melhor performance e não está sendo estudada. Além do mais, é importante realizar um trade-off entre performance e complexidade da rede. Já o critério de balanço entre erro contra diversidade, retém redes variadas e realiza o trade-off performance/ complexidade (STATSOFT, 2005).

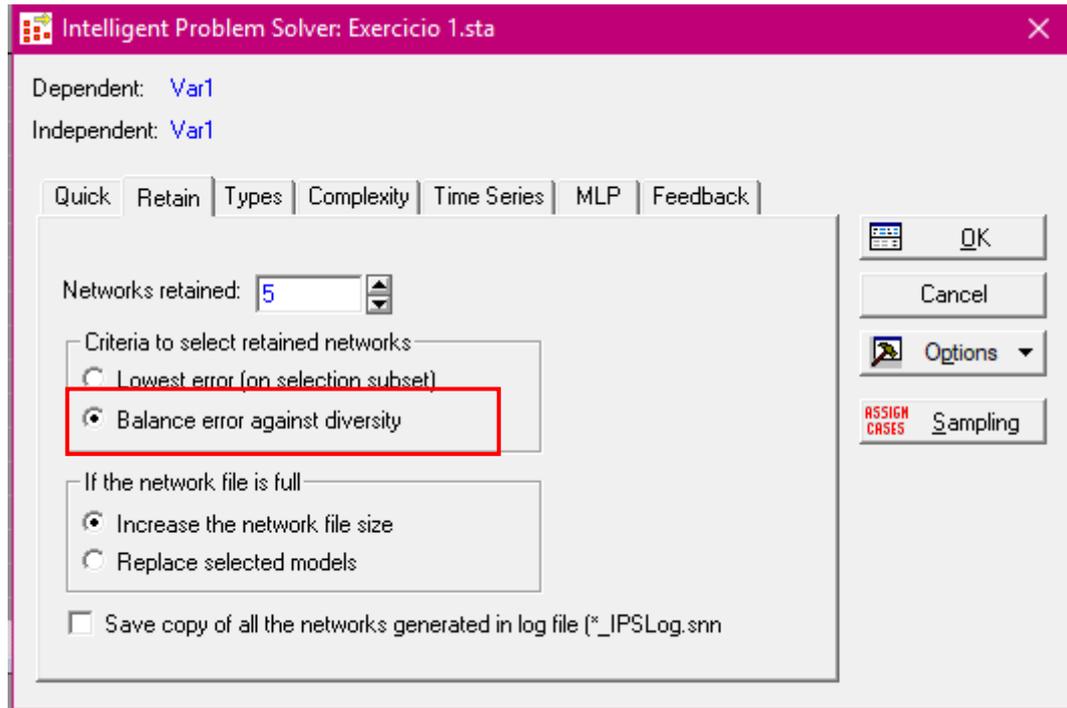


Figura 14: Critério de seleção das redes

Os tipos de redes disponíveis pelo *IPS* já foram explicados anteriormente seus respectivos funcionamentos. Existe a opção do usuário marcar redes lineares, PNN ou GRNN, RBF e MLP (*Three-layer perceptron/Four-layer perceptron*).

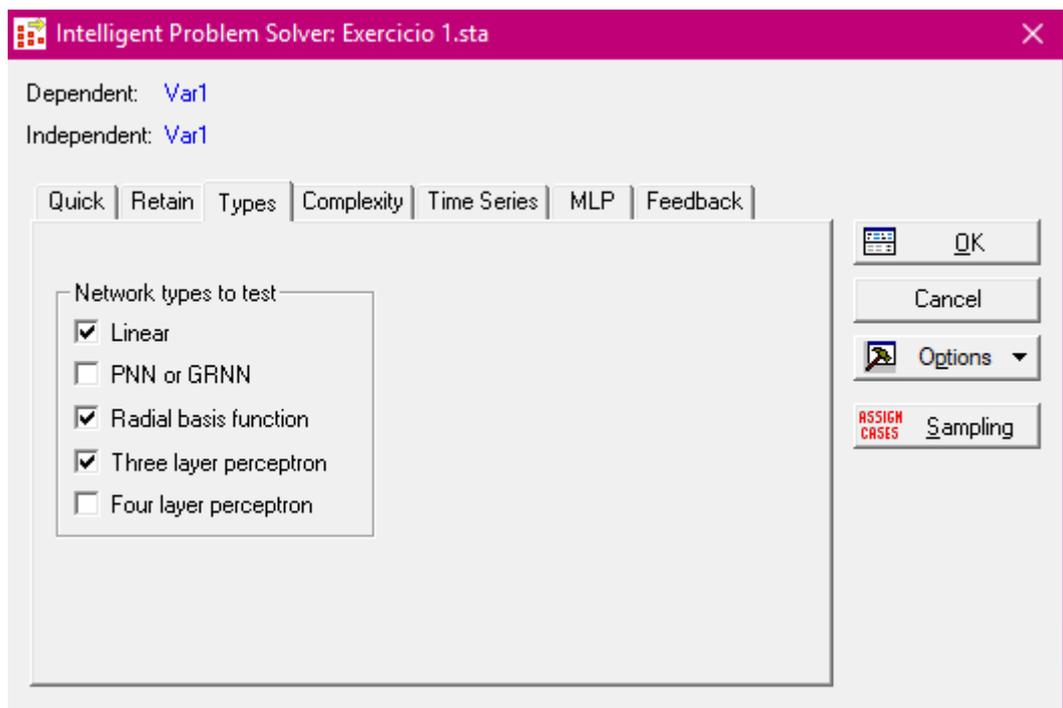


Figura 15: Tipos de redes neurais

O software *Statistica* pode determinar a complexidade das unidades ocultas, selecionando o intervalo de unidades ocultas (Figura 16). Ao aumentar o número de unidades ocultas, aumenta-se o poder da RNA, mas também se torna mais difícil de treinar, mais lenta e mais propícia para ocorrer superajustamento. No caso de funções simples, ou com muitos ruídos, ou com poucos casos, é preferível utilizar poucas unidades ocultas.

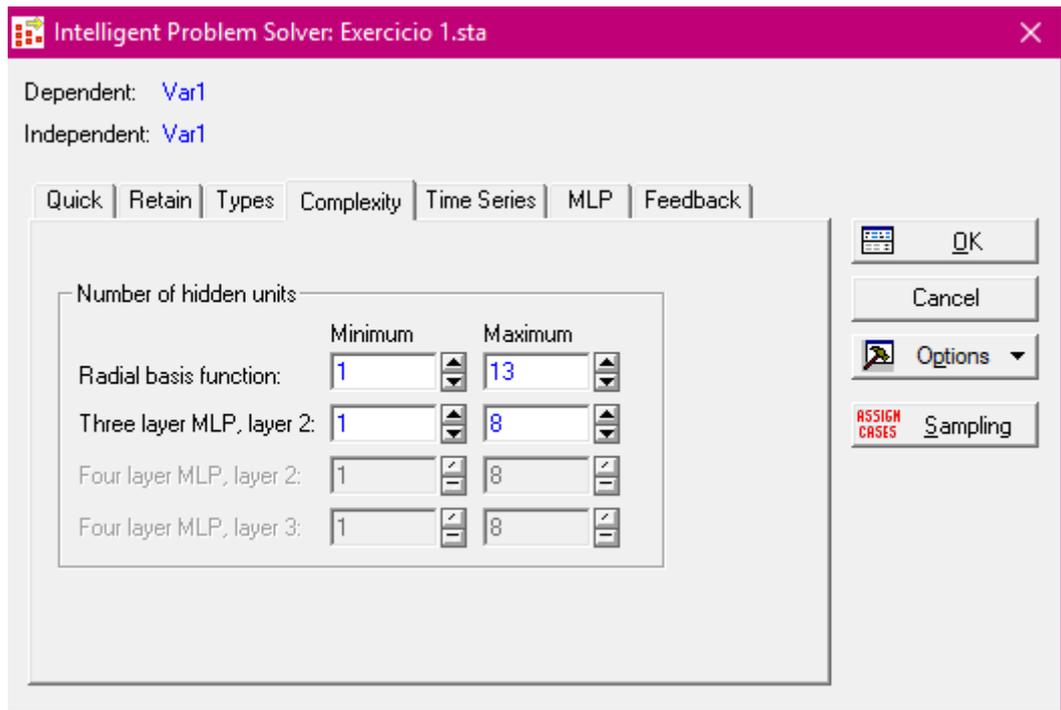


Figura 16: Número de unidades ocultas

Por se tratar de séries temporais, seleciona-se a opção de tratar o problema como séries temporais na aba de série temporal. O número de passos usados como entradas é determinado de acordo com a periodicidade do problema, caso o período não seja conhecido, deve-se deixar os valores determinados pelo *Statistica* e é recomendado rodar o *IPS* diversas vezes até encontrar um período fixo.

Existem duas abordagens para a codificação de saída: linear e logística. A linear utiliza a função de ativação identidade e a abordagem logística usa a função de ativação logística (STATSOFT, 2005).

Por último, o *IPS* tem a opção de exibir em tempo real as melhores redes, toda vez que uma melhoria na rede é encontrada em termos de erro de seleção, uma linha com a rede é adicionada a tabela de redes na caixa *IPS Progress*.

2.5. Parâmetros de avaliação dos modelos

A utilização de ARIMA e RNA permite a obtenção de diversos modelos que representam a série temporal. Portanto, é preciso escolher o melhor modelo para realizar a previsão. Existem diversos tipos de medidas que servem de comparação dos modelos, medidas dependentes de escala, medidas baseadas em porcentagem de erro, medidas baseadas em erros relativos, medidas relativas e erros escalares (HYNDMAN; KOEHLER, 2006). A tabela 2 mostra alguns tipos de medidas de precisão da previsão, sabe-se que e_t é o erro do modelo e $p_t = 100e_t/Y_t$.

As medidas mais conhecidas de comparação são as dependentes de escala, entre as quais estão MSE, RMSE, MAE e MdAE. As medidas em porcentagem de erro apresentam uma vantagem pois podem ser usadas para comparar performance entre diferentes conjuntos de dados, como é o caso do MAPE, MdAPE, sMAPE, sMdAPE, PB, PB(MAE) e PB(MSE) (HYNDMAN; KOEHLER, 2006).

Numa pesquisa feita com 31 artigos envolvendo ARIMA e/ou RNA, que utilizavam algum tipo das medidas mostradas na tabela 2, obteve-se os resultados do gráfico 17. Pode-se notar que MAPE foi o tipo de medida que apareceu na maioria dos artigos, seguido por MSE e RMSE.

MSE	<i>Mean squared error</i>	$= \text{Média}(e_t^2)$
RMSE	<i>Root mean squared error</i>	$= \sqrt{\text{MSE}}$
MAE	<i>Absolute error</i>	$= \text{Média}(e_t)$
MdAE	<i>Median absolute error</i>	$= \text{Mediana}(e_t)$
MAPE	<i>Mean absolute percentage error</i>	$= \text{Média}(p_t)$
MdAPE	<i>Median absolute percentage error</i>	$= \text{Mediana}(p_t)$
sMAPE	<i>Symmetric mean absolute percentage error</i>	$= \text{Média}(2 Y_t - F_t /(Y_t + F_t))$
sMdAPE	<i>Symmetric median absolute percentage error</i>	$= \text{Mediana}(2 Y_t - F_t /(Y_t + F_t))$
MRAE	<i>Mean relative absolute error</i>	$= \text{Média}(r_t)$
MdRAE	<i>Median relative absolute error</i>	$= \text{Mediana}(r_t)$
GMRAE	<i>Geometric mean relative absolute error</i>	$= \text{GMédia}(r_t)$
RelMAE	<i>Relative mean absolute error</i>	$= \text{MAE}/\text{MAE}_b$
RelRMSE	<i>Relative root mean squared error</i>	$= \text{RMSE}/\text{RMSE}_b$
LMR	<i>Log mean squared error ratio</i>	$= \log(\text{RelMSE})$
PB	<i>Percentage better</i>	$= 100 * \text{Média}(I\{ r_t < 1\})$
PB(MAE)	<i>Percentage better (MAE)</i>	$= 100 * \text{Média}(I\{\text{MAE} < \text{MAE}_b\})$
PB(MSE)	<i>Percentage better (MSE)</i>	$= 100 * \text{Média}(I\{\text{MSE} < \text{MSE}_b\})$

Tabela 2: Medidas de precisão

Fonte: DE GOOIJER e HYNDMAN (2006) adaptado

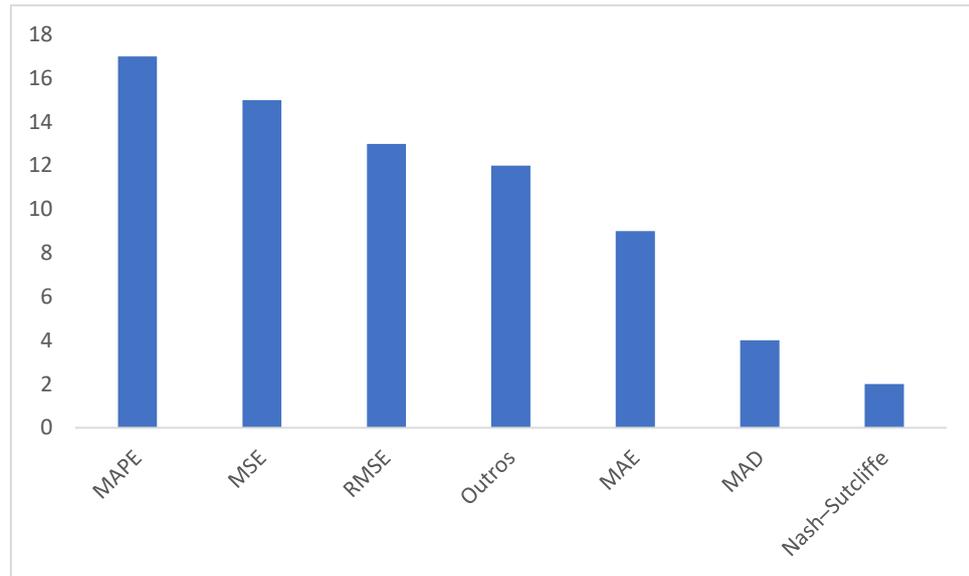


Figura 17: Análise das medidas de previsão em pesquisas científicas

Desta maneira, a escolha das medidas que avaliam a precisão da previsão dos dados deve ser escolhida de acordo com o estudo e tipo de série analisada. No caso de todos os dados serem positivos e muito maiores que zero, MAPE deve ser utilizado por razões de simplicidade (HYNDMAN; KOEHLER, 2006). Por essa razão e por ser o tipo de erro mais utilizado nas pesquisas sobre previsão de dados, escolheu-se o erro MAPE para realizar a comparação entre os modelos.

3. Desenvolvimento da Pesquisa

3.1. Classificação da pesquisa científica

É classificada quanto ao objetivo em empírica descritiva, no qual objetiva o entendimento do processo que está sendo modelado. A pesquisa empírica descritiva está interessada em criar um modelo adequado que descreve o relacionamento causal que pode existir na realidade, no qual direciona para o entendimento do processo em andamento (BERTRAND, J.WILL, FRANSOO, 2002).

No caso deste projeto, por tratar-se de séries temporais, estabelece a relação dos dados com os próprios dados com defasagem de tempo, para encontrar o modelo com o menor erro e proporcionar melhor previsibilidade dos dados. A classificação quanto a abordagem é quantitativa, pois considera os valores quantificados e se apoia de recursos e análises estatísticas. Pesquisa quantitativa inicia-se com uma descrição das características dos processos operacionais, deve conter um modelo conceitual do processo ou do problema, em seguida apresentar um modelo científico do processo, solução, prova da solução e por fim, compreender a relação da solução e modelo (BERTRAND, J.WILL, FRANSOO, 2002).

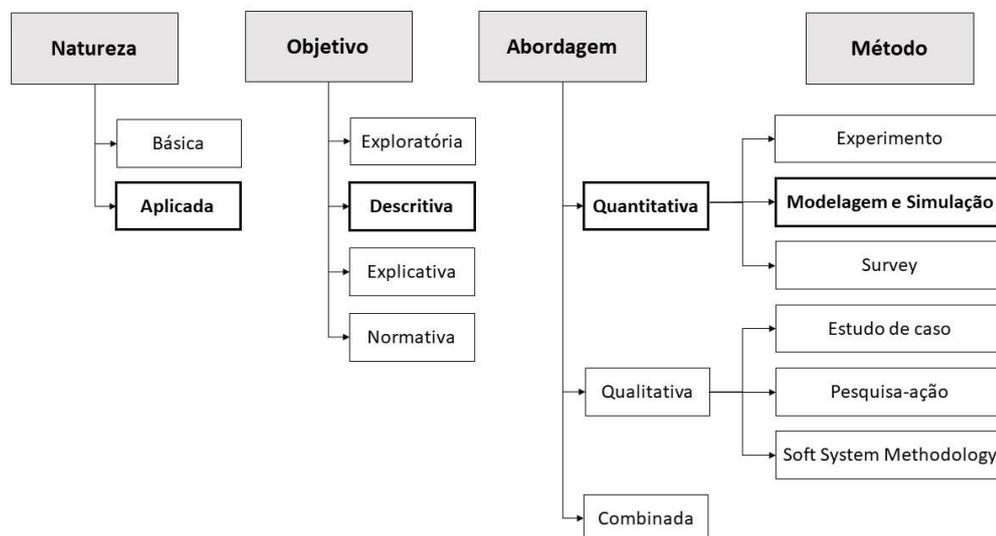


Figura 18: Classificação da Pesquisa

Quanto ao método, o projeto é classificado como modelagem e simulação, sendo explicado com maior aprofundamento no item a seguir.

3.2. Método de modelagem e simulação

3.2.1. Definição

De acordo com Chung (2004), modelagem e simulação são o processo de criar e experimentar um sistema que interage, recebe entradas e oferece resultados, através de um modelo matemático computadorizado.

As razões de se utilizar uma pesquisa de modelagem e simulação são conhecer a forma de operação do sistema, desenvolver políticas operacionais e recursos para aperfeiçoar o desempenho do sistema, testar novos conceitos e sistemas antes da implantação e obtenção de informações sem alterar o sistema atual (MARTINS; MELLO; TURRIONI, 2014).

Sistema é um conjunto de componentes ou entidades interativas, podendo ser discretos ou contínuos (SEILA, 1995). A pesquisa em questão trata-se de um sistema contínuo, pois as variáveis mudam continuamente no tempo. Já o modelo em questão é o modelo estocástico que permite a entrada de diversas variáveis que podem assumir diferentes valores dentro de uma distribuição probabilística definida pelo modelador (SEILA, 1995). Além de se caracterizar como um modelo dinâmico por representar o sistema a qualquer tempo. A classificação dessa pesquisa em relação à simulação é não terminante pois existe interesse em estudar o sistema a partir de um determinado estado estável, podendo ser prolongado indefinidamente.

Chung (2004) afirma que o método de modelagem e simulação apresenta algumas vantagens, a simulação pode ocorrer em curto período de tempo devido ao auxílio computacional, existe menor necessidade de análise dos resultados devido ao suporte que os softwares oferecem, facilidade na demonstração dos modelos e possibilidade de experimentação em níveis que não são permitidos na forma física.

3.2.2. Etapas da pesquisa

A implantação da modelagem e simulação foi inicialmente introduzida por Mitroff *et al.* (1974) através do modelo da Figura 19. O modelo possui quatro fases: conceitualização, modelagem, solução e implantação.

Na fase de conceitualização, criou-se o modelo conceitual do problema que é determinar qual dos métodos de previsão em estudo (ARIMA ou RNA) possui menor erro de previsão, obtendo melhor previsão de séries temporais. Na fase de modelagem, foi determinado os softwares e etapas necessárias para criação do modelo científico. A solução pelo modelo, a matemática desempenha um papel determinante e é quando obteve-se os resultados dos erros de previsão. E por fim, a fase de implementação é quando realiza-se a previsão dos dados.

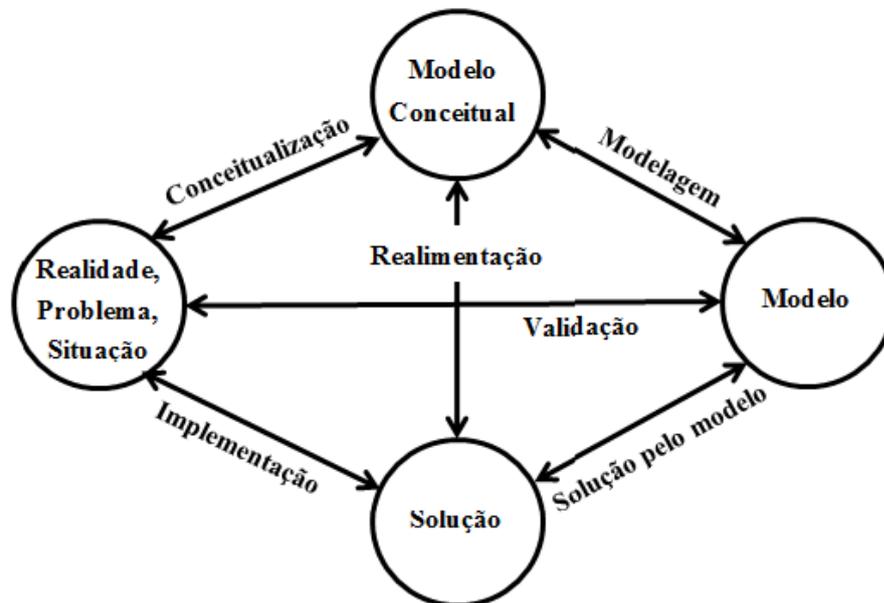


Figura 19: Etapas da metodologia Modelagem e simulação

Fonte: Mitroff *et al.* (1974)

3.2.3. Conceitualização

A primeira etapa do método é a de conceitualização, no qual o pesquisador realiza as decisões sobre as variáveis que devem ser incluídas no modelo, o escopo do problema e modelo que será utilizado.

Determinou-se como variáveis incluídas nos modelos da pesquisa, as séries temporais existentes no livro *Introduction to Time series analysis and forecasting* (MONTGOMERY; JENNINGS; KULAHCI, 2008). O escopo do problema é determinar qual método de previsão de séries temporais oferece menor erro de previsão, gerando assim melhor previsão de dados. Já os modelos utilizados são os resultantes de ARIMA e RNA. Dessa maneira, a parte inicial do método está estruturada, possibilitando a determinação da próxima etapa, modelagem.

3.2.4. Modelagem

Na etapa de modelagem, o modelo conceitual é convertido em modelo computadorizado. Os estudos e decisões de como as séries seriam tratadas na pesquisa, são concretizados nessa etapa. A modelagem foi transmitida para os softwares *Minitab* e *Statistica* todas as decisões sobre como a modelagem de todas as séries seriam realizadas.

Através dessas decisões, que foram baseadas na teoria e conceitos de previsão em séries temporais, obteve-se os modelos ARIMA e RNA, um para cada série temporal em estudo. E com esses modelos foi possível determinar a solução para o problema.

3.2.5. Solução do modelo

Com os modelos obtidos em ARIMA e RNA foi possível realizar os cálculos do erro MAPE para encontrar a solução do problema inicial, determinar qual método apresenta menor erro de previsão e conseqüentemente melhor previsão dos dados.

A solução será confirmada através de um teste de hipóteses, com o tipo de erro em análise (MAPE).

3.2.6. Implementação

A solução do modelo, qual método apresenta menor erro de previsão, será possível implementar a previsão dos dados das séries temporais com maior confiabilidade e menor erro. Dessa maneira, a implementação do modelo será a previsão das séries temporais.

4. Resultados

Os resultados obtidos com a simulação da previsão das séries temporais foram analisados através do MAPE dos métodos de previsão ARIMA e RNA. A Tabela 3 mostra os resultados obtidos, utilizando a metodologia explicada anteriormente.

	Nome	ARIMA MAPE	RNA MAPE
1	Sem informação sobre a série	9,64	0,01
2	Sem informação sobre a série	8,71	0,00
3	Sem informação sobre a série	2,40	0,76
4	Sem informação sobre a série	13,59	10,25
5	Rendimento de mercado em títulos do Tesouro dos EUA com prazo de vida constante de 10 anos	2,70	2,68
6	Vendas de produtos farmacêuticos	1,66	1,60
7	Viscosidade de um processo químico	0,95	0,99
8	Produção de queijo gorgonzola e azul nos EUA	7,51	5,33
9	Envios de produtos para fabricantes de bebidas nos EUA	1,87	1,96
10	Anomalia global da temperatura da superfície terrestre e concentração global de CO2	91,84	44,25
11	Preço de ações no mercado do Whole Foods, fechamento diário ajustado	1,79	1,61
12	Taxa de desemprego - trabalho integral, não ajustada sazonalmente	2,87	3,64
13	Números de manchas solares internacionais	80,79	133,50
14	Vôos da companhia aérea Miles do Reino Unido	4,58	5,85
15	Vendas de champanhe	12,68	9,32
16	Demanda mensal de refrigerante	15,84	10,69
17	Rendimento de processo químico, com temperatura operacional (não controlada)	1,74	1,40
18	Produção americana de sorvete e frozen yogurt	1,93	0,86
19	Concentrações atmosféricas de CO2 no Observatório Mauna Loa	0,10	0,09
20	Taxa nacional de crime dos EUA	3,13	0,23
21	Produto Interno Bruto dos EUA	4,15	3,02
22		3,36	2,37
23	Consumo total de energia nos EUA	2,43	1,65
24	Produção de carvão nos EUA	5,00	3,42
25	Taxa de afogamento no Arizona, crianças de 1-4 anos	19,77	17,59
26	Reembolso dos impostos nos EUA	8,32	3,55
27	População nacional nos EUA	0,21	0,45

Tabela 3: Resultados dos erros MAPE das séries temporais analisadas

Todas as etapas mostradas a seguir tomarão como base a série temporal 9 como exemplo, série sobre o envio de produtos para fabricantes de bebidas nos EUA. Entretanto, as mesmas etapas foram seguidas para todas as outras séries temporais e encontram-se nos anexos do trabalho, sendo anexo A para as etapas do ARIMA e o anexo B para RNA.

4.1. Aplicação dos dados em ARIMA

A realização da previsão das séries temporais de todos os exercícios, com a metodologia ARIMA, ocorreu com a utilização das premissas necessárias para obtenção dos resultados. Inicialmente, analisou-se o gráfico da série temporal em questão para conhecer um pouco sobre seu comportamento (Figura 20). Em seguida, utilizou-se os gráficos ACF e PACF (Figura 21) para identificação do modelo ARIMA que mais se adequava aos dados.

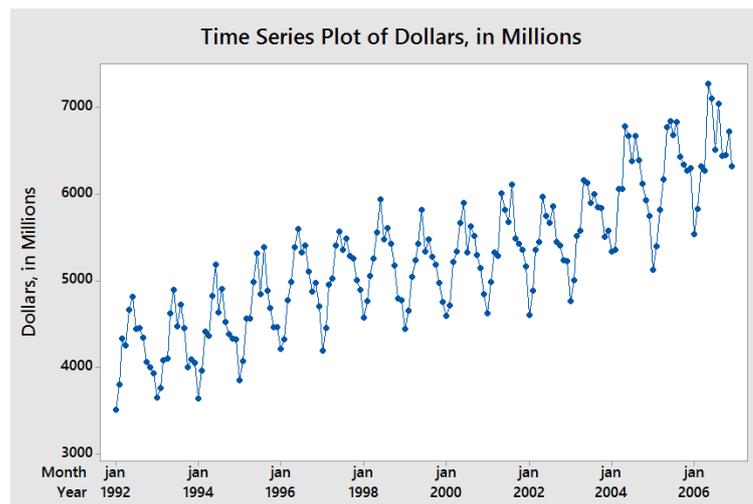


Figura 20: Série temporal 9 - Envio de produtos para fabricantes de bebidas nos EUA

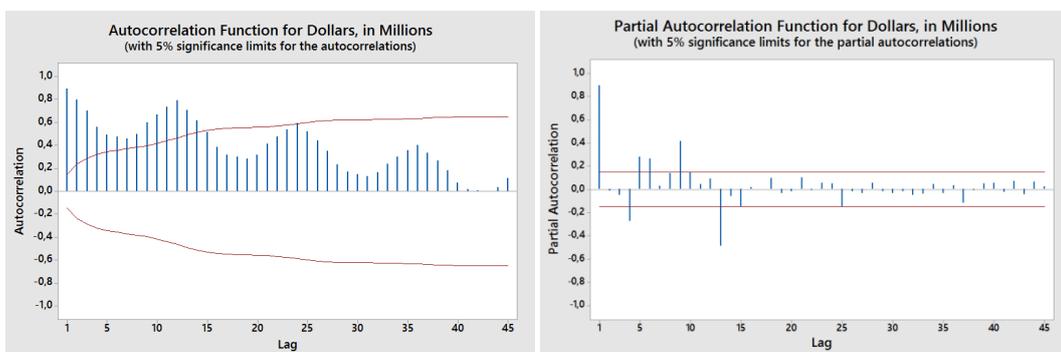


Figura 21: ACF e PACF gráficos da série temporal 9

Ao analisar o gráfico da série temporal, ACF e PACF, pode-se encontrar padrões que indicam sazonalidade ou não estacionariedade. Nas séries que ocorrerem indicações da existência de sazonalidade, foi necessário a construção do periodograma para determinar qual é a sazonalidade daquela série em estudo. A Figura 22 mostra o periodograma do exercício 9, o qual possui sazonalidade de 12, ou seja, a cada 12 meses os dados se comportam de maneira similar.

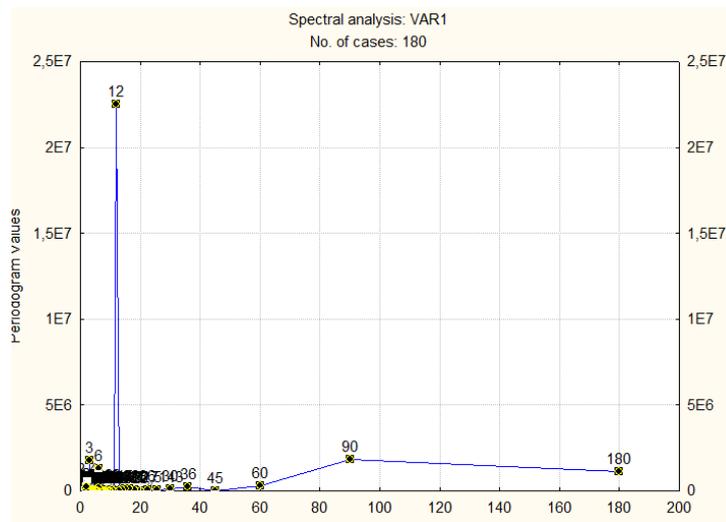


Figura 22: Periodograma do exercício 9

Já a confirmação da estacionariedade foi realizada através do ADF Teste em todas as séries, independentemente se existia indicação ou não da estacionariedade, pois dessa maneira garantiria a confirmação que o modelo ARIMA escolhido era adequado. O teste estatístico ADF foi analisado através do *p-value*, no caso de séries não estacionárias, como o exercício 9. O valor do *p-value* foi de 0,921, sendo maior que 5% de significância. O teste Mann-Kendall foi realizado em seguida através do *Minitab*, confirmando novamente a não estacionariedade da série 9, e que há evidências que a tendência é ascendente.

Mann-Kendall Trend Test by Normal Approximation

Ho: No trend in Dollars, in Millions

The calculated $z = 12,8208$

Ha: There is an upward trend, the p-value = 0
At alpha = 0,05, there is enough evidence to determine that there is an upward trend.

Ha: There is a Downward trend, the p-value = 1
At alpha = 0,05, there is not enough evidence to determine that there is a downward trend.

Figura 23: Mann-Kendall Teste do exercício 9

Finalmente, pode-se iniciar a etapa de identificação do melhor modelo ARIMA. Executou-se o software *Minitab* diversas vezes até obter um modelo que possuía a estatística de *Ljung-Box* não significativa, não correlacionado, e que os resíduos se apresentassem como ruídos brancos (normais e não correlacionados com seus ajustes). Dessa maneira, encontrou-se os parâmetros para o modelo ARIMA da série temporal (Figura 24) e calculou-se o erro MAPE.

```
Final Estimates of Parameters
Type      Coef  SE Coef   T      P
AR 1     -0,6260  0,0722  -8,67  0,000
AR 2     -0,3852  0,0738  -5,22  0,000
SMA 12     0,7748  0,0640  12,11  0,000

Differencing: 1 regular, 1 seasonal of order 12
Number of observations: Original series 180, after differencing 167
Residuals:      SS = 2888225 (backforecasts excluded)
                MS = 17611  DF = 164

Modified Box-Pierce (Ljung-Box) Chi-Square statistic
Lag         12    24    36    48
Chi-Square  9,0  26,7  35,0  45,4
DF          9    21    33    45
P-Value     0,438  0,179  0,376  0,455
```

Figura 24: Parâmetros do modelo ARIMA do exercício 9

O modelo ARIMA obtido está representado graficamente na figura 25, no qual possui a série temporal e o modelo ARIMA (*Fit*).

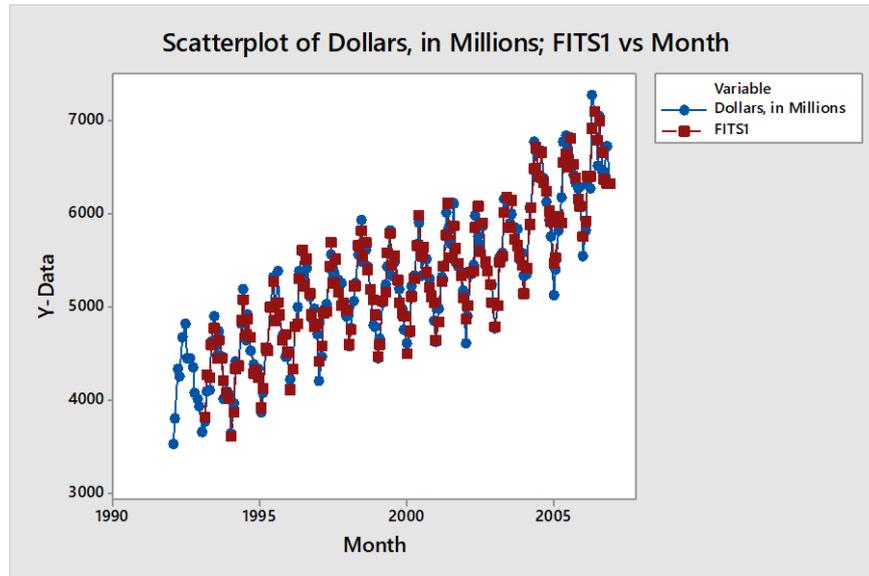


Figura 25: Modelo ARIMA do exercício 9

Algumas séries temporais não resultaram em modelos que se adequam às condições ideais para considerar um modelo que resultará em uma previsão precisa. Os modelos dos exercícios 5, 11, 12, 13, 21 e 27 não apresentaram resíduos normais. Foram testados diversos outros modelos às essas séries, e os modelos mais próximos dos ideais foram utilizados para realização dos cálculos dos erros. Entretanto, essas séries foram eliminadas na comparação entre ARIMA e RNA, pois influenciariam de forma negativa na comparação dos modelos, já que os modelos ARIMA não atendiam às premissas necessárias para realização de uma previsão adequada.

4.2. Aplicação dos dados em Redes Neurais Artificiais

Após a aplicação das séries utilizando ARIMA, iniciou-se a aplicação em ANN utilizando o software *Statistica* e sua ferramenta IPS, conforme já detalhado anteriormente.

O tempo de otimização para criação de todas as redes foi determinado de acordo com o tamanho da série temporal, de forma que não ocorresse *overfitting*. Dessa maneira, não ocorria deterioração em comparação a redes treinadas em tempos menores. Reteve-se 10 redes neurais, utilizando o critério de balanço entre erro e diversidade.

Em relação aos tipos de redes neurais, selecionou-se todos os tipos, para que pudesse ser identificado dentre todos, o que melhor representava a série.

O parâmetro da quantidade de passos mínimos e máximos como entrada está relacionado com a sazonalidade. Quando foi identificado pelo periodograma a sazonalidade, por exemplo

12 meses, colocava-se 12 como valores mínimos e máximos. Já quando não identificava sazonalidade, os valores permaneciam os padrões determinados pelo *Statistica*.

As abordagens para a codificação de saída utilizada foram lineares e logísticas.

Ao finalizar o treinamento da rede, pôde conhecer as 10 redes neurais que mais se adequavam ao conjunto de dados, assim como as previsões, resíduos e estatísticas (Figuras 25 e 26).

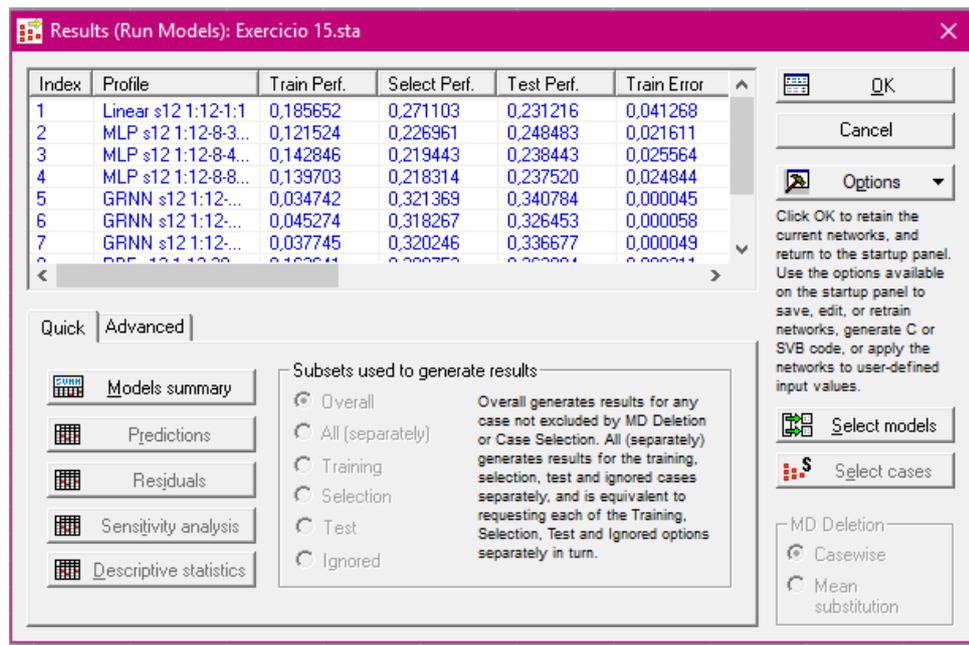


Figura 26: Resultado da rede neural do exercício 9

Model Summary Report (Spreadsheet1)												
Index	Profile	Train Perf.	Select Perf.	Test Perf.	Train Error	Select Error	Test Error	Training/Members	Note	Inputs	Hidden(1)	Hidden(2)
1	Linear s12 1:12:1:1	0,185652	0,271103	0,231216	0,041268	0,053277	0,055114	PI		1	0	0
2	MLP s12 1:12-8-3-1:1	0,121524	0,226961	0,248483	0,021611	0,034777	0,048826	BP100,CG90b		1	8	3
3	MLP s12 1:12-8-4-1:1	0,142846	0,219443	0,238443	0,025564	0,033630	0,046071	BP100,CG80b		1	8	4
4	MLP s12 1:12-8-8-1:1	0,139703	0,218314	0,237520	0,024844	0,033488	0,046587	BP100,CG100b		1	8	8
5	GRNN s12 1:12-86-2-1:1	0,034742	0,321369	0,340784	0,000045	0,000377	0,000476	SS		1	86	2
6	GRNN s12 1:12-86-2-1:1	0,045274	0,318267	0,326453	0,000058	0,000376	0,000458	SS		1	86	2
7	GRNN s12 1:12-86-2-1:1	0,037745	0,320246	0,336677	0,000049	0,000376	0,000471	SS		1	86	2
8	RBF s12 1:12-28-1:1	0,163641	0,298752	0,262904	0,000211	0,000337	0,000384	KM,KN,PI		1	28	0
9	RBF s12 1:12-43-1:1	0,128285	0,276001	0,250496	0,000166	0,000326	0,000371	KM,KN,PI		1	43	0
10	RBF s12 1:12-45-1:1	0,145430	0,275752	0,266718	0,000188	0,000316	0,000388	KM,KN,PI		1	45	0

Figura 27: Detalhamento das 10 redes retidas do exercício 9

Ao contrário dos modelos ARIMA, as redes neurais não apresentam a necessidade de análise dos resíduos. Dessa forma, calculou-se o erro MAPE para todas as 10 redes retidas. A rede com o menor erro foi escolhida para realizar a comparação com o modelo ARIMA encontrado para cada exercício.

4.3. Comparação dos métodos ARIMA e RNA

A comparação dos erros MAPE tem a finalidade de determinar quais os modelos (ARIMA ou RNA) apresentam menor erro de previsão, ou seja, qual método melhor se adequa na previsão de séries temporais de diversas características e origens. A Figura 27 indica, em uma análise inicial, que os erros dos modelos ARIMA são consideravelmente maiores que os erros dos modelos RNA.

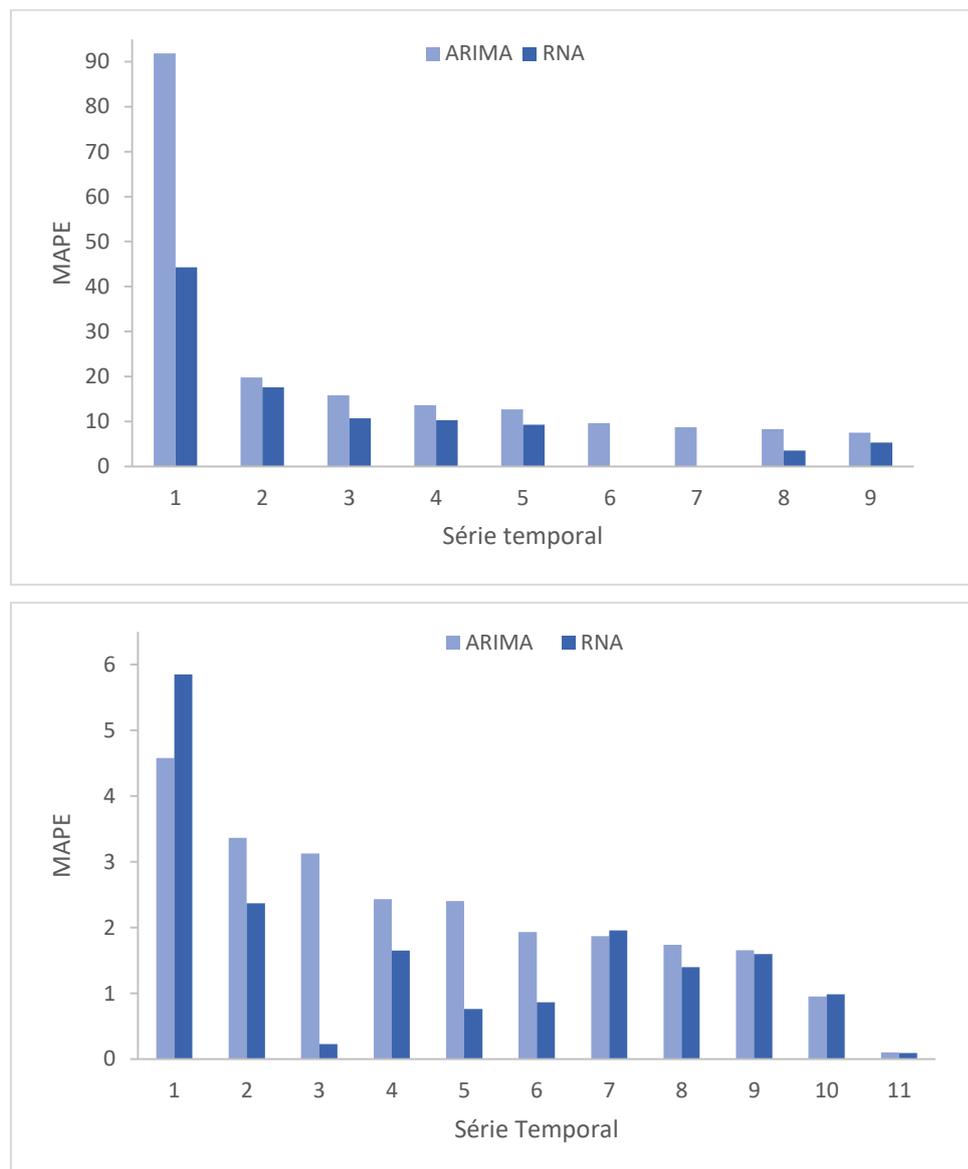


Figura 28: Comparação erros MAPE

Entretanto, é necessário a confirmação dessa informação estatisticamente. Assim, realizou-se o teste estatística chamado *Pared-t* (teste de informações emparelhadas), o qual calcula o

intervalo de confiança e realiza um teste de hipóteses entre a diferença da média de duas populações em que as observações estão emparelhadas.

Os testes de hipóteses utilizados foram:

$$\begin{cases} H_0: MAPE\ ARIMA = MAPE\ RNA \\ H_1: MAPE\ ARIMA > MAPE\ RNA \end{cases}$$

A realização do teste foi através do software *Minitab*. O teste compara o erro MAPE, resultando em um $p\text{-value}=0,029$ (Figura 29), que é menor que o nível de significância (0,05) utilizado no teste, evidenciando que deve-se aceitar a hipótese alternativa. Em outras palavras, pode-se afirmar, com 95% de confiança, que o erro MAPE dos modelos ARIMA são maiores que os erros resultantes dos modelos de RNA.

Paired T-Test and CI: MAPE ARIMA; MAPE RNA				
Paired T for MAPE ARIMA - MAPE RNA				
	N	Mean	StDev	SE Mean
MAPE ARIMA	21	10,34	19,45	4,24
MAPE RNA	21	5,82	9,92	2,17
Difference	21	4,52	10,26	2,24

95% lower bound for mean difference: 0,66
 T-Test of mean difference = 0 (vs > 0): T-Value = 2,02 P-Value = 0,029

Figura 29: *Pared-t* MAPE

O resultado obtido no teste de hipótese permite uma conclusão muito impactante para a área de previsão de série temporal. Afirma que um método de previsão utilizado e conhecido por modelos de Box e Jenkins desde 1976, não apresenta resultados tão precisos quanto aos métodos mais modernos de redes neurais. Isso não significa que o método ARIMA não tenha sido importante para o desenvolvimento estatístico e consequentemente na evolução da previsão de dados. Além disso, o método ARIMA apresenta etapas que permite conhecer a série temporal com maior profundidade, permitindo entendê-la mais que o método RNA. O método RNA resulta em uma previsão mais acessível para sua utilização, pois requer menos treinamento estatístico formal e podem ser desenvolvidas com o uso de diferentes algoritmos, quanto aos resultados obtidos.

Os outros exercícios realizados estão nos anexos da pesquisa, existindo todas as etapas mostradas com o exercício 9. Assim, com os erros MAPE de cada um dos modelos, pôde realizar a comparação dos métodos.

Além disso, em um mundo real, é comum as mudanças frequentes no portfólio de séries temporais como novas séries temporais relevantes são adicionadas ao sistema e outras séries temporais não-mais relevantes são removidas do sistema. Em sistemas como esse, não é viável que a análise de séries temporais e a seleção do modelo sejam executados manualmente, pois o número de séries temporais a serem modeladas é proibitivo. Portanto, um modelo geral que pode se atualizar, capturar e prever uma grande variedade de séries temporais de forma eficiente e sem intervenção humana devem ser empregados (WAGNER *et al.*, 2011).

5. Conclusões

5.1. Considerações finais

Os resultados obtidos com os 27 casos analisados, todos discutidos no livro de Montgomery, Jennings e Kulahci (2008), permite-se concluir que a realização da previsão de séries temporais através do método de RNA permite maior precisão na previsão. Essa conclusão é obtida nas análises dos valores absolutos dos erros dos modelos. Similarmente, ao analisar as diferenças em termos estatísticos, através da análise do *p-value* do teste para dados emparelhados, as redes neurais artificiais obtiveram um menor erro, isto é, um melhor poder de precisão quando comparadas ao ARIMA. Dessa forma, para os exemplos considerados, as redes neurais provaram ser um melhor previsor de séries temporais.

Não significa que o método ARIMA não possua seu valor e importância para o desenvolvimento de previsão de séries temporais, pois é um método consolidado e que resulta também em uma precisão adequada para realização de previsão. Ainda há a possibilidade do modelador buscar por características intrínsecas de cada metodologia ao optar por cada uma das técnicas.

Entretanto, os erros MAPE permitem concluir que apesar das vantagens e qualidades do ARIMA, RNA apresenta, em diversos tipos de séries temporais o melhor resultado, sendo mais adequado na previsão de séries temporais.

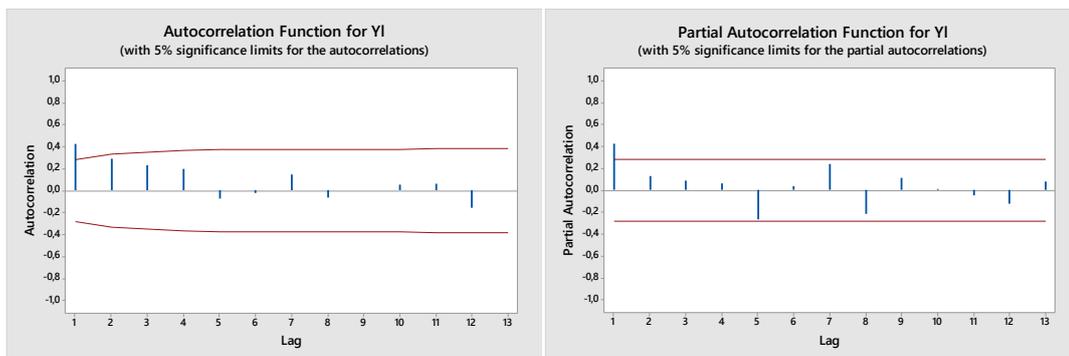
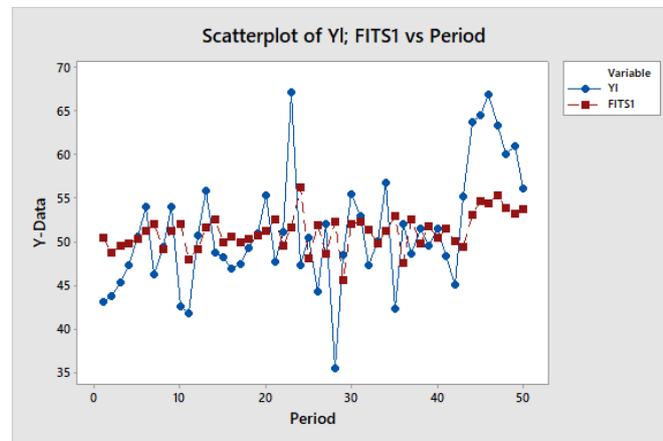
5.2. Trabalhos futuros

Em trabalhos futuros, pode-se desenvolver essa mesma comparação de pesquisa utilizando o desenho do experimento (*Design of Experiments* – DOE) para garantia dos parâmetros nos modelos ARIMA e RNA da melhor maneira. Assim, utilizando os modelos RNA sem a ferramenta IPS e determinando todos os parâmetros através do DOE para criar um modelo RNA, oferece um aprofundamento maior para confirmar que os modelos RNA apresentam maior precisão.

A pesquisa também permite a possibilidade, de em trabalhos futuros comparar RNA, que foi o modelo de maior precisão, com outros métodos lineares e não-lineares. Do mesmo modo, que o ARIMA pode ser comparado com outros métodos. Dessa maneira, pode-se encontrar outros métodos com maior precisão e sendo mais adequados na previsão de séries temporais.

ANEXO A - ARIMA

Exercício 1



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
MA 1	-0,3311	0,1360	-2,43	0,019
Constant	51,090	1,179	43,35	0,000
Mean	51,090	1,179		

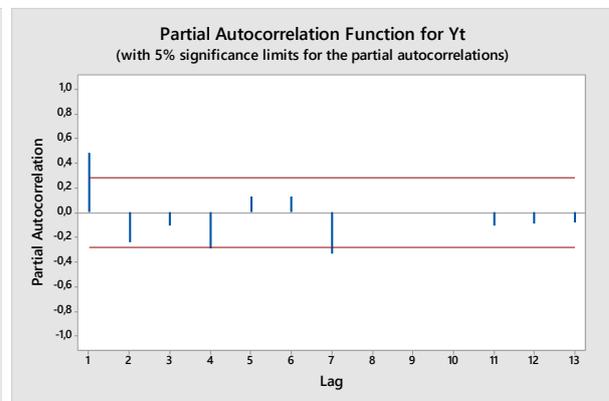
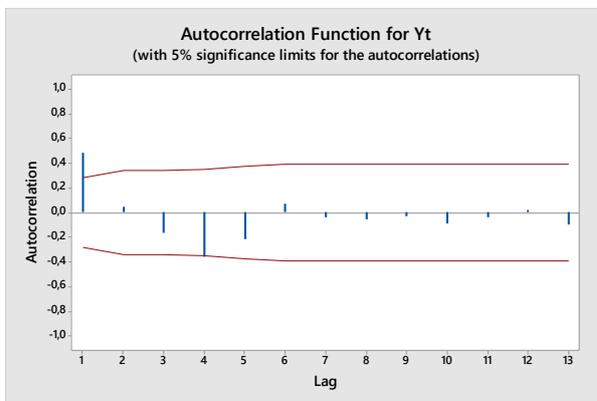
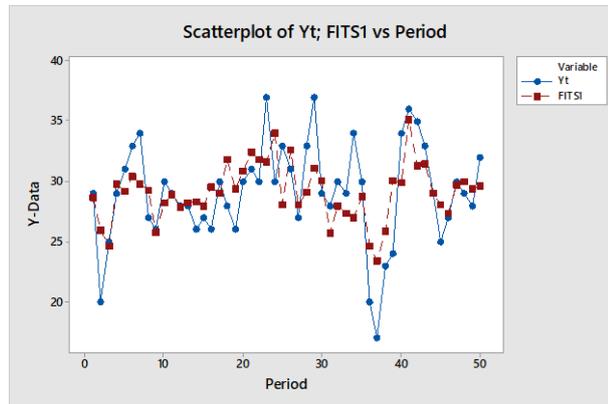
Number of observations: 50

Residuals: SS = 1883,45 (backforecasts excluded)
MS = 39,24 DF = 48

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	16,2	24,3	31,1	55,3
DF	10	22	34	46
P-Value	0,094	0,334	0,612	0,164

Exercício 2



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	0,7652	0,1112	6,88	0,000
MA 1	0,4448	0,1673	2,66	0,011
MA 2	0,6656	0,1025	6,49	0,000
Constant	6,89916	0,01345	513,10	0,000
Mean	29,3846	0,0573		

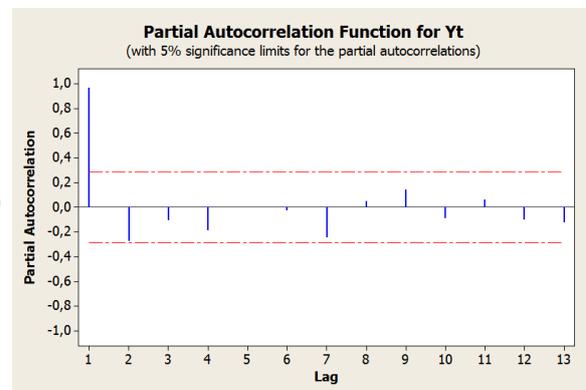
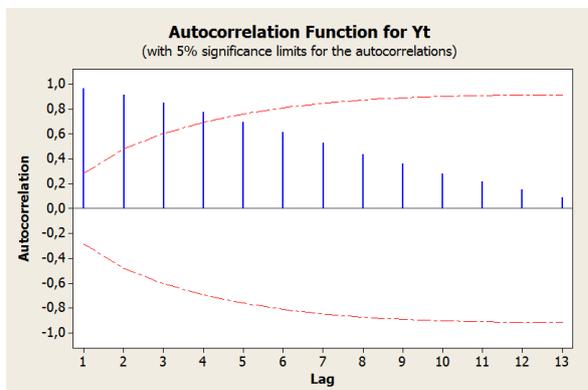
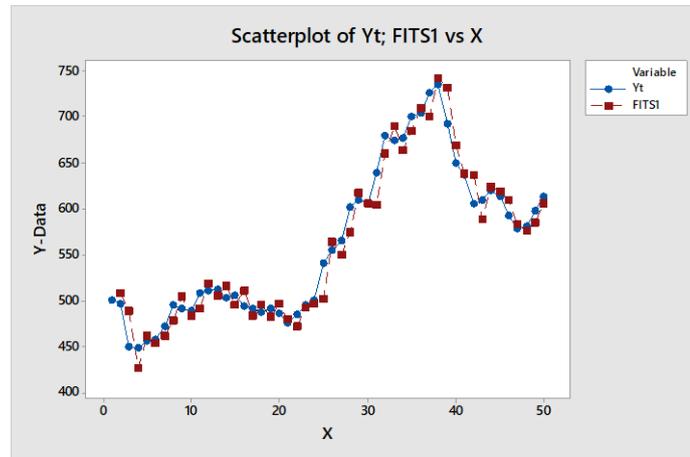
Number of observations: 50

Residuals: SS = 470,610 (backforecasts excluded)
MS = 10,231 DF = 46

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	11,9	20,0	31,7	39,5
DF	8	20	32	44
P-Value	0,154	0,460	0,482	0,666

Exercício 3



ARIMA Model: Yt

Estimates at each iteration

Iteration	SSE	Parameters
0	18971,7	0,100
1	16837,4	-0,050
2	15468,2	-0,200
3	14576,0	-0,350
4	14043,3	-0,496
5	13930,3	-0,558
6	13912,2	-0,582
7	13909,7	-0,591
8	13909,4	-0,594
9	13909,3	-0,595
10	13909,3	-0,595

Relative change in each estimate less than 0,0010

Final Estimates of Parameters

Type	Coef	SE Coef	T	P
MA 1	-0,5951	0,1153	-5,16	0,000

Differencing: 1 regular difference

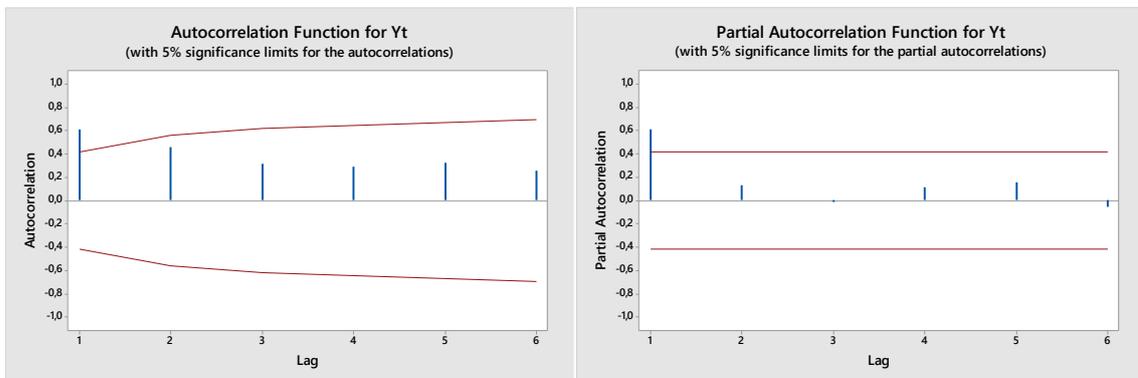
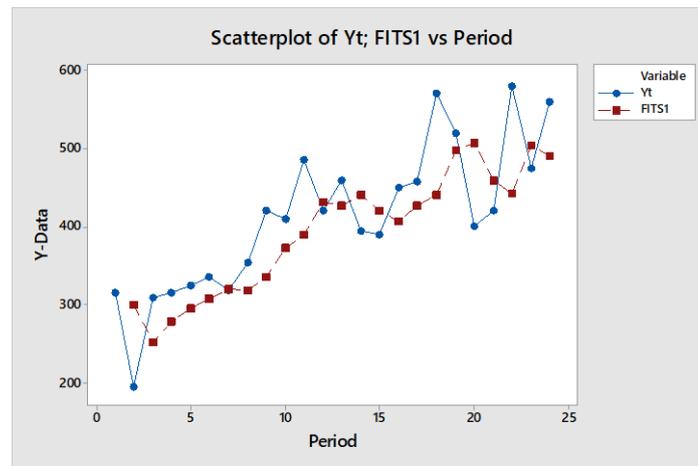
Number of observations: Original series 50, after differencing 49

Residuals: SS = 13752,3 (backforecasts excluded)
MS = 286,5 DF = 48

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	19,6	30,2	46,4	57,7
DF	11	23	35	47
P-Value	0,051	0,143	0,095	0,135

Exercício 4



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
MA 1	0,5542	0,1833	3,02	0,006

Differencing: 1 regular difference

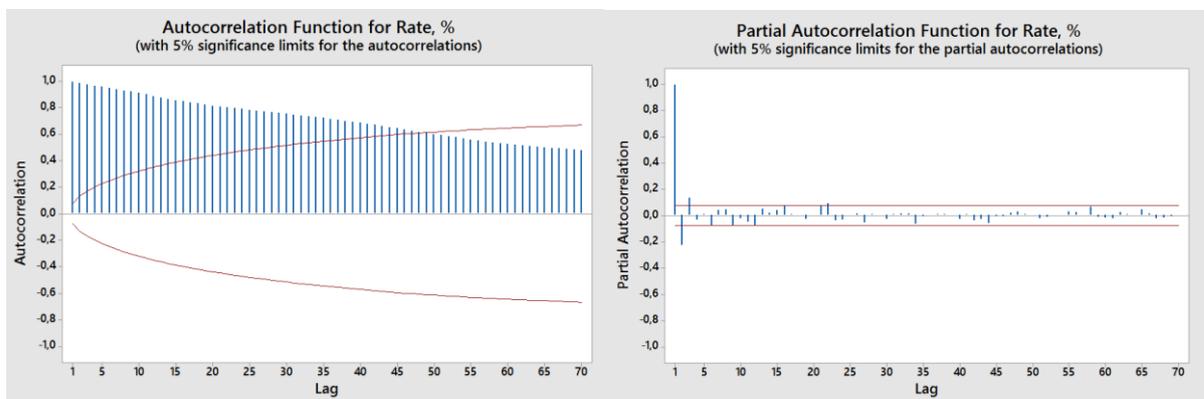
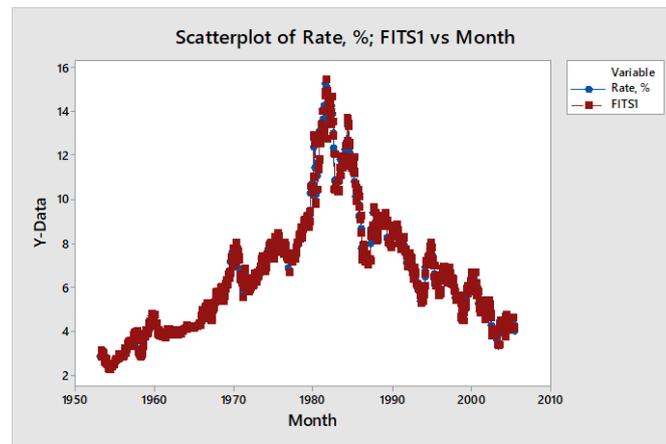
Number of observations: Original series 24, after differencing 23

Residuals: SS = 98508,6 (backforecasts excluded)
MS = 4477,7 DF = 22

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	4,9	*	*	*
DF	11	*	*	*
P-Value	0,937	*	*	*

Exercício 5



Estimates at each iteration

Iteration	SSE	Parameters	
0	49,3591	0,100	0,100
1	44,4166	0,234	-0,034
2	43,5930	0,106	-0,184
3	42,8061	-0,018	-0,334
4	42,0725	-0,135	-0,484
5	41,5749	-0,233	-0,634
6	41,5520	-0,208	-0,631
7	41,5519	-0,207	-0,631
8	41,5519	-0,207	-0,631

Relative change in each estimate less than 0,0010

Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	-0,2069	0,0801	-2,58	0,010
MA 1	-0,6312	0,0635	-9,94	0,000

Differencing: 1 regular difference

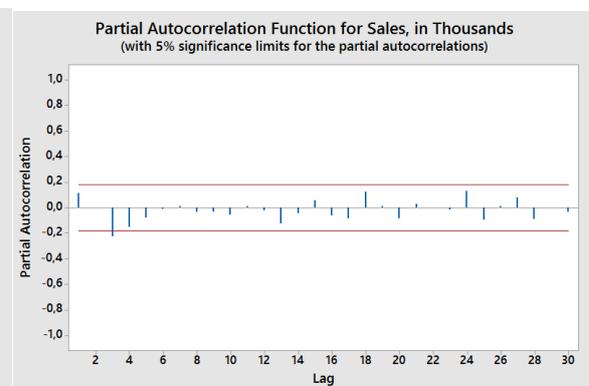
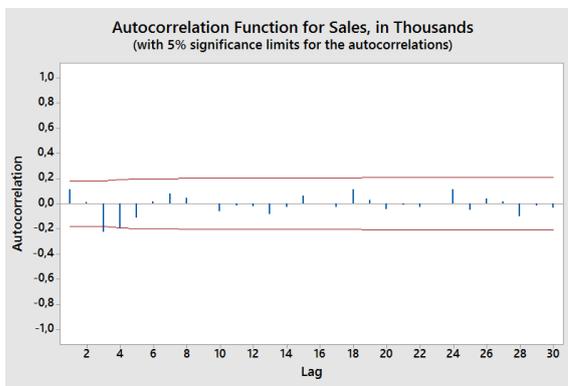
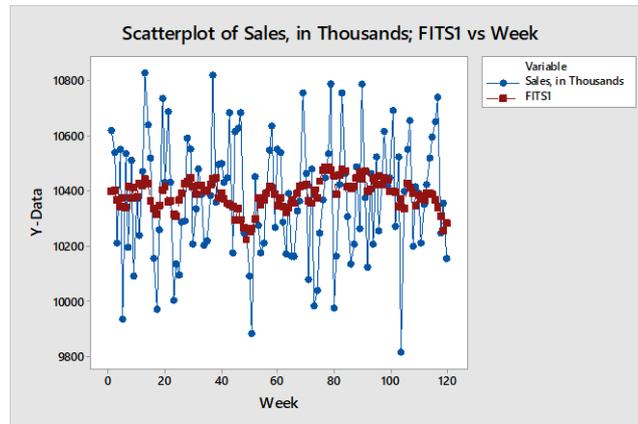
Number of observations: Original series 627, after differencing 626

Residuals: SS = 41,5489 (backforecasts excluded)
MS = 0,0666 DF = 624

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	24,5	57,6	69,4	78,0
DF	10	22	34	46
P-Value	0,006	0,000	0,000	0,002

Exercício 6



Final Estimates of Parameters

Type		Coef	SE Coef	T	P
AR	1	0,8413	0,0607	13,87	0,000
MA	1	0,8271	0,0310	26,70	0,000
MA	2	0,1565	0,0647	2,42	0,017
Constant		1646,45	0,63	2601,71	0,000
Mean		10374,4	4,0		

Number of observations: 120

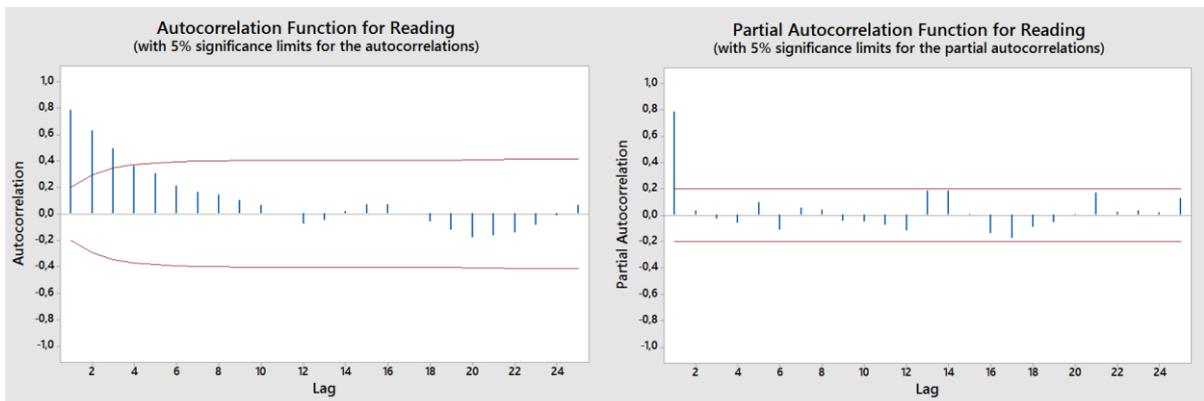
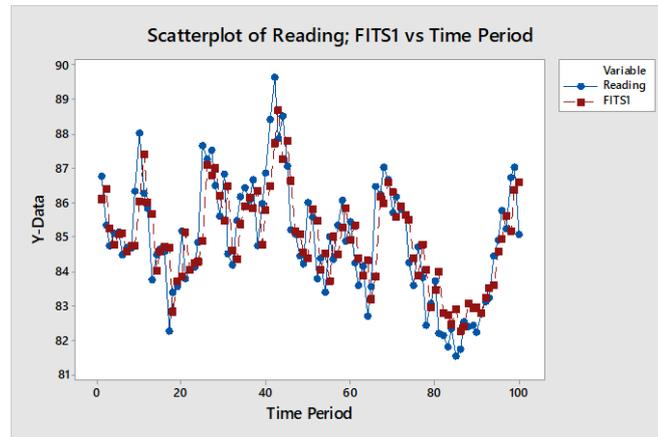
Residuals: SS = 5210399 (backforecasts excluded)

MS = 44917 DF = 116

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	7,3	12,7	24,7	30,2
DF	8	20	32	44
P-Value	0,500	0,890	0,818	0,944

Exercício 7



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	0,7938	0,0616	12,88	0,000
Constant	17,5251	0,1037	168,95	0,000
Mean	84,9856	0,5030		

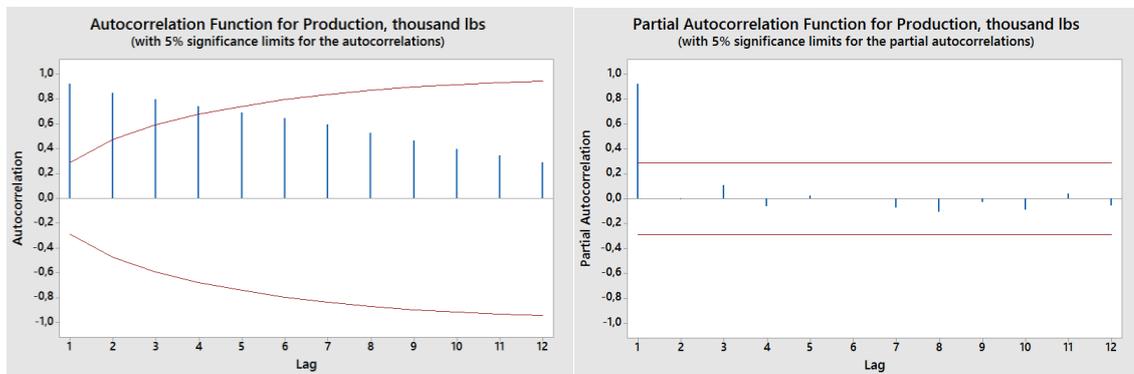
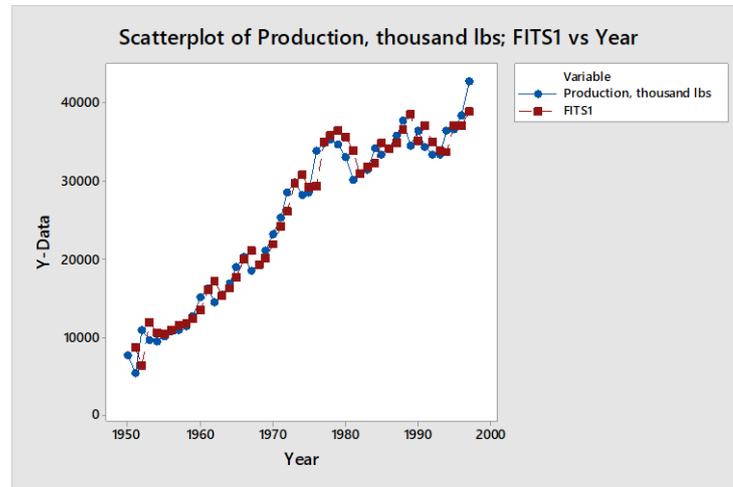
Number of observations: 100

Residuals: SS = 105,328 (backforecasts excluded)
 MS = 1,075 DF = 98

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	10,5	23,7	37,6	51,9
DF	10	22	34	46
P-Value	0,399	0,365	0,307	0,255

Exercício 8



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	0,9978	0,0212	47,08	0,000
MA 1	0,9535	0,1178	8,10	0,000

Differencing: 1 regular difference

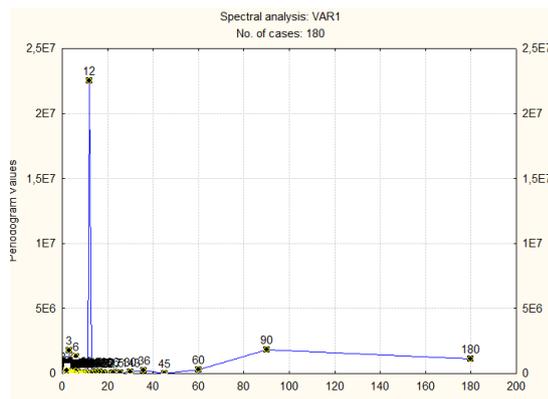
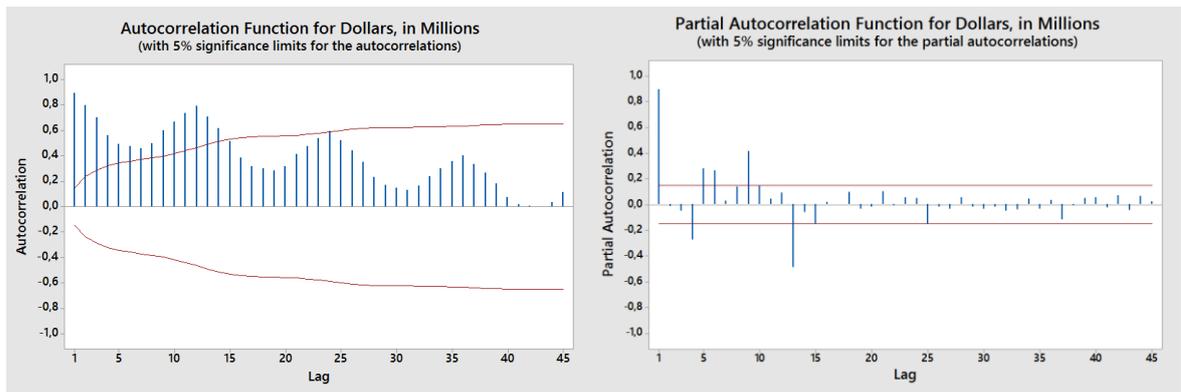
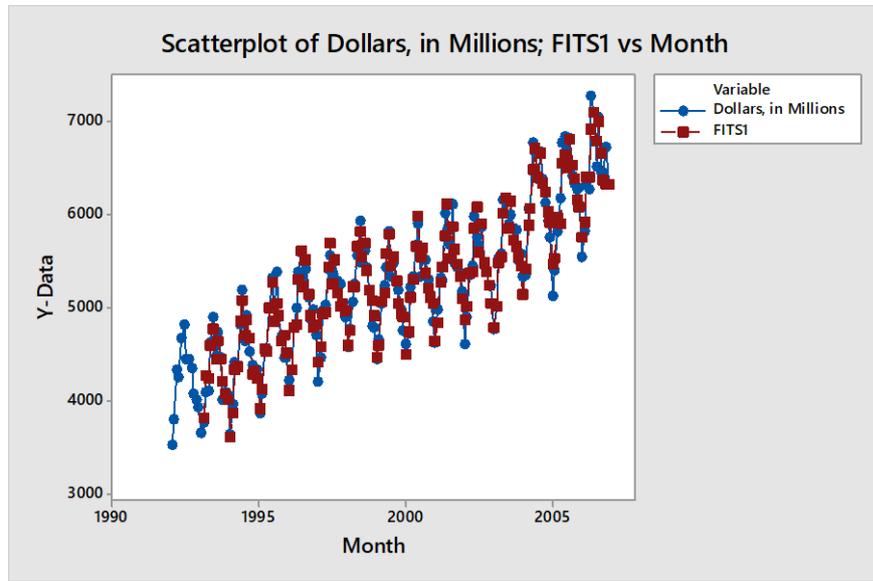
Number of observations: Original series 48, after differencing 47

Residuals: SS = 177730318 (backforecasts excluded)
MS = 3949563 DF = 45

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	9,0	20,0	23,7	*
DF	10	22	34	*
P-Value	0,528	0,581	0,907	*

Exercício 9



Final Estimates of Parameters

Type		Coef	SE Coef	T	P
AR	1	-0,6260	0,0722	-8,67	0,000
AR	2	-0,3852	0,0738	-5,22	0,000
SMA	12	0,7748	0,0640	12,11	0,000

Differencing: 1 regular, 1 seasonal of order 12

Number of observations: Original series 180, after differencing 167

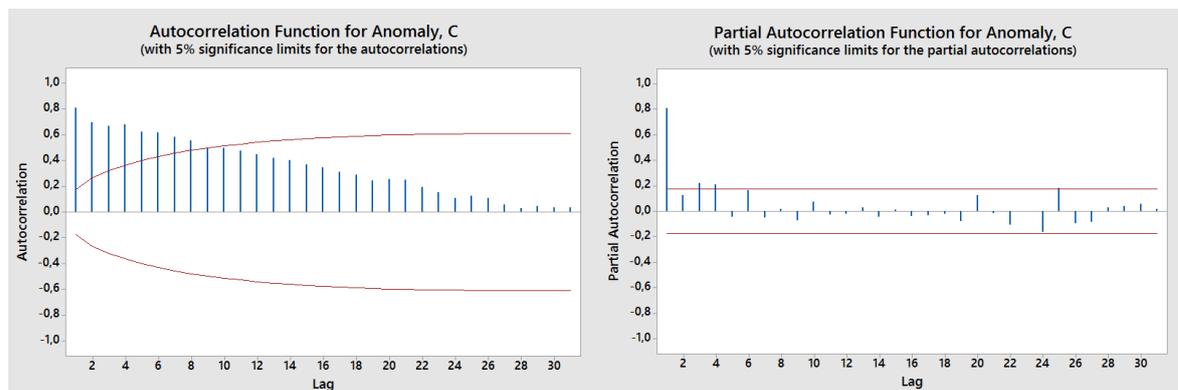
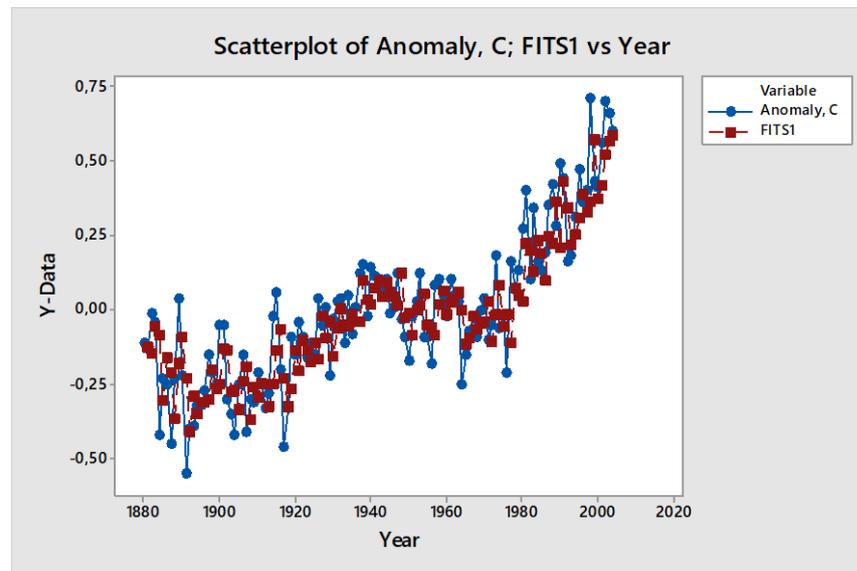
Residuals: SS = 2888225 (backforecasts excluded)

MS = 17611 DF = 164

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	9,0	26,7	35,0	45,4
DF	9	21	33	45
P-Value	0,438	0,179	0,376	0,455

Exercício 10



Final Estimates of Parameters

Type		Coef	SE Coef	T	P
AR	1	-0,9101	0,1054	-8,63	0,000
MA	1	-0,5248	0,1267	-4,14	0,000
MA	2	0,6159	0,0982	6,27	0,000
MA	3	0,3430	0,0883	3,88	0,000

Differencing: 1 regular difference

Number of observations: Original series 125, after differencing 124

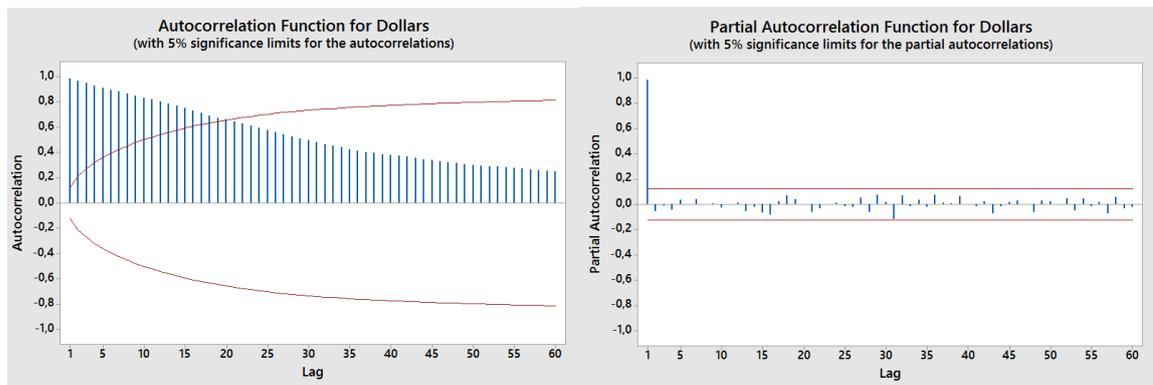
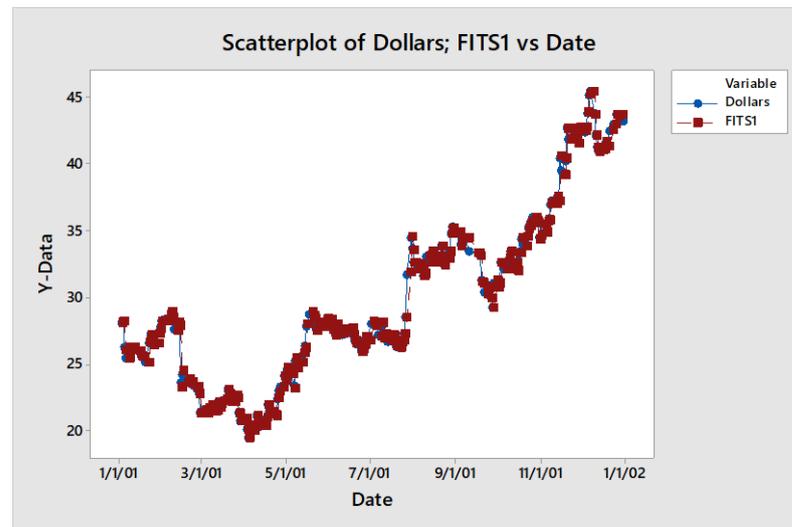
Residuals: SS = 2,02799 (backforecasts excluded)

MS = 0,01690 DF = 120

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	8,1	20,3	33,6	39,7
DF	8	20	32	44
P-Value	0,426	0,441	0,391	0,658

Exercício 11



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	-0,6842	0,2669	-2,56	0,011
MA 1	-0,7626	0,2356	-3,24	0,001

Differencing: 1 regular difference

Number of observations: Original series 248, after differencing 247

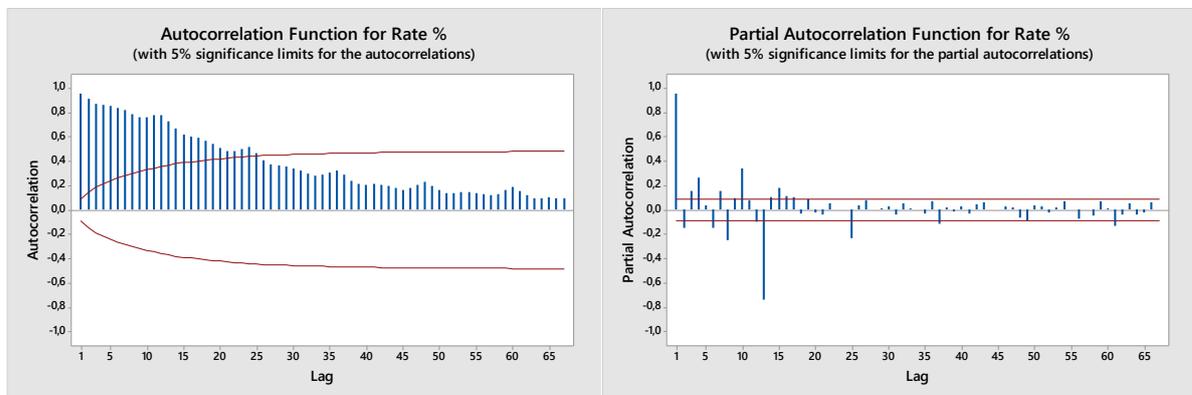
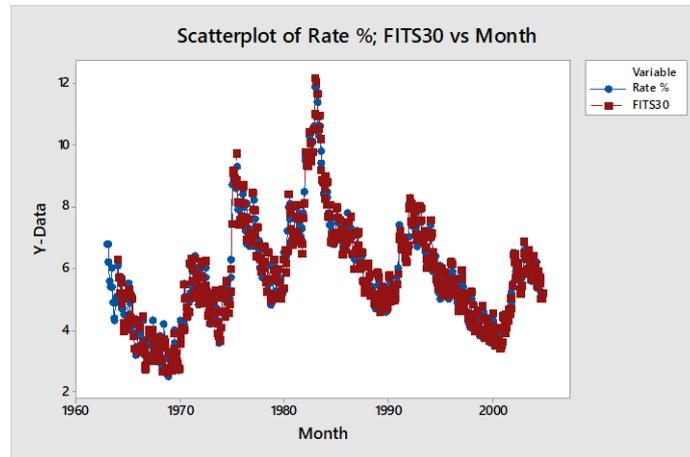
Residuals: SS = 144,431 (backforecasts excluded)

MS = 0,590 DF = 245

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	4,6	12,0	24,3	39,3
DF	10	22	34	46
P-Value	0,918	0,957	0,889	0,746

Exercício 12



Iteration	SSE	Parameters		
0	32,8216	0,100	0,100	0,100
1	29,0369	0,140	0,060	0,250
2	28,5338	0,290	0,207	0,265
3	27,9612	0,440	0,356	0,281
4	27,2153	0,590	0,504	0,306
5	26,0720	0,740	0,644	0,359
6	23,7133	0,843	0,706	0,509
7	22,3591	0,823	0,642	0,659
8	21,9901	0,831	0,645	0,745
9	21,9579	0,826	0,645	0,767
10	21,9560	0,824	0,646	0,771
11	21,9558	0,824	0,646	0,773
12	21,9558	0,824	0,646	0,773

Relative change in each estimate less than 0,0010

Final Estimates of Parameters

Type	Coef	SE Coef	T	P	
AR	1	0,8239	0,0684	12,05	0,000
MA	1	0,6462	0,0921	7,02	0,000
SMA	12	0,7732	0,0287	26,95	0,000

Differencing: 1 regular, 1 seasonal of order 12

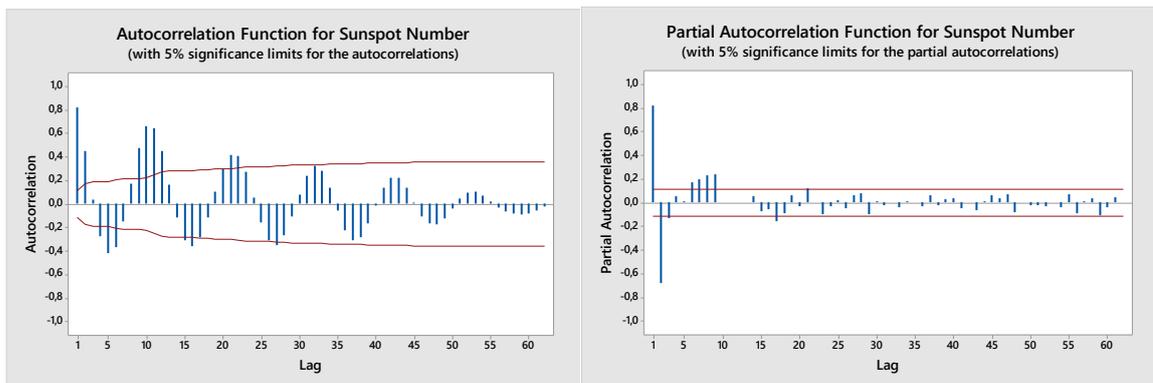
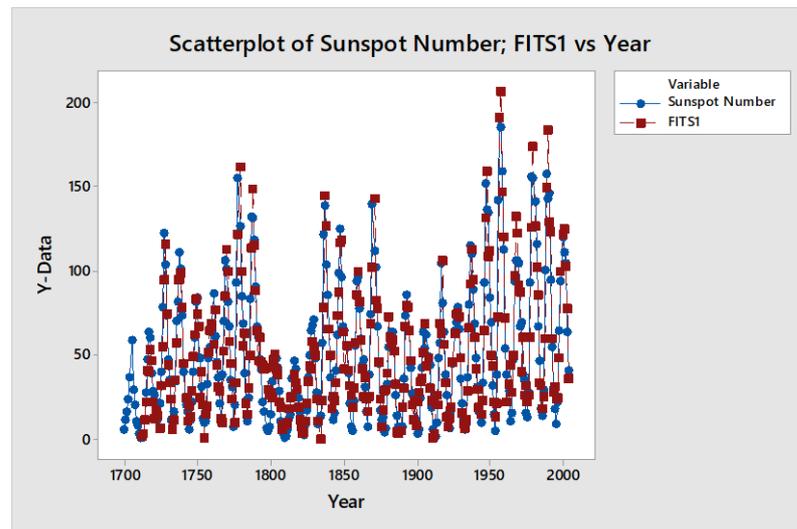
Number of observations: Original series 504, after differencing 491

Residuals: SS = 21,5533 (backforecasts excluded)
MS = 0,0442 DF = 488

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	19,5	27,3	43,9	55,1
DF	9	21	33	45
P-Value	0,021	0,161	0,097	0,144

Exercício 13



Final Estimates of Parameters

Type		Coef	SE Coef	T	P
AR	1	1,5778	0,0381	41,43	0,000
AR	2	-0,9228	0,0346	-26,71	0,000
MA	1	1,4110	0,0648	21,78	0,000
MA	2	-0,4817	0,0995	-4,84	0,000
MA	3	0,0001	0,1068	0,00	0,999
MA	4	-0,1926	0,1054	-1,83	0,069
MA	5	0,1376	0,0655	2,10	0,037
SMA	11	0,8979	0,0454	19,79	0,000

Differencing: 1 regular, 1 seasonal of order 11

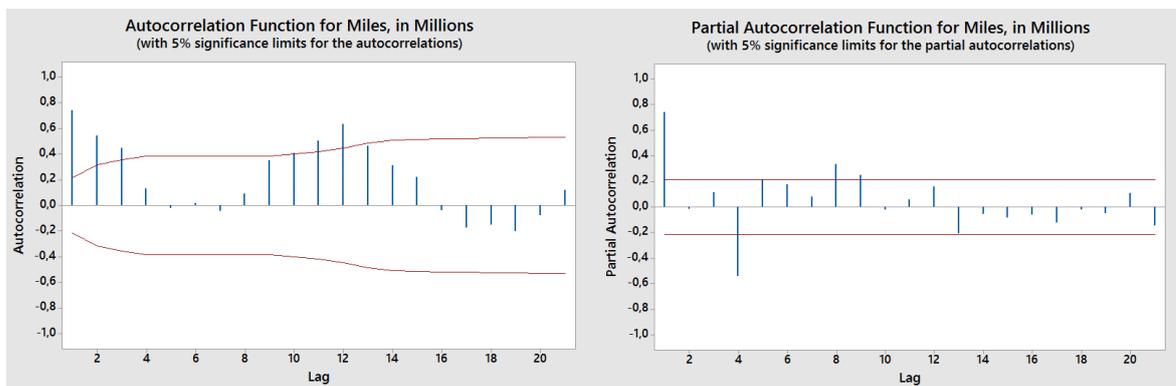
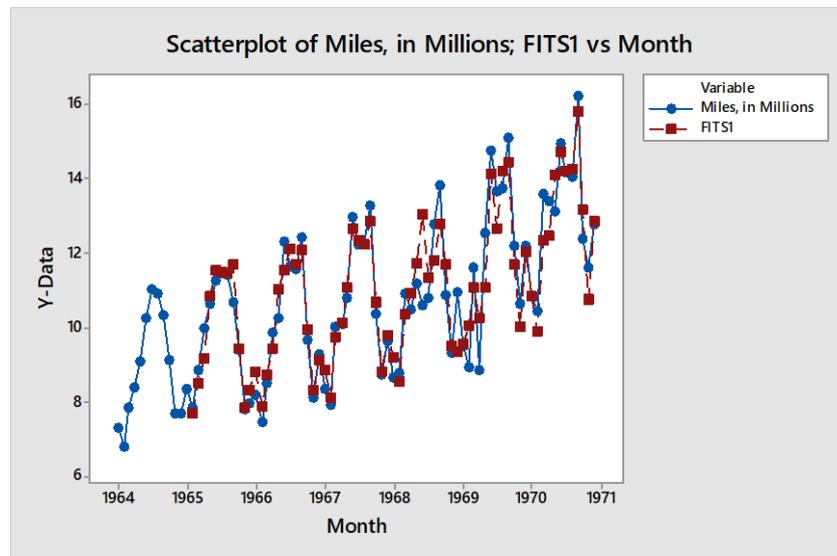
Number of observations: Original series 305, after differencing 293

Residuals: SS = 68981,9 (backforecasts excluded)
MS = 242,0 DF = 285

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	9,3	23,0	40,3	49,7
DF	4	16	28	40
P-Value	0,055	0,115	0,062	0,141

Exercício 14



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	-0,4629	0,1383	-3,35	0,001
AR 2	-0,6705	0,1267	-5,29	0,000
MA 1	0,0989	0,1355	0,73	0,468
MA 2	-0,3005	0,1363	-2,20	0,031
MA 3	0,3276	0,1208	2,71	0,009
MA 4	0,5737	0,1180	4,86	0,000
SMA 12	0,7387	0,1328	5,56	0,000

Differencing: 1 regular, 1 seasonal of order 12

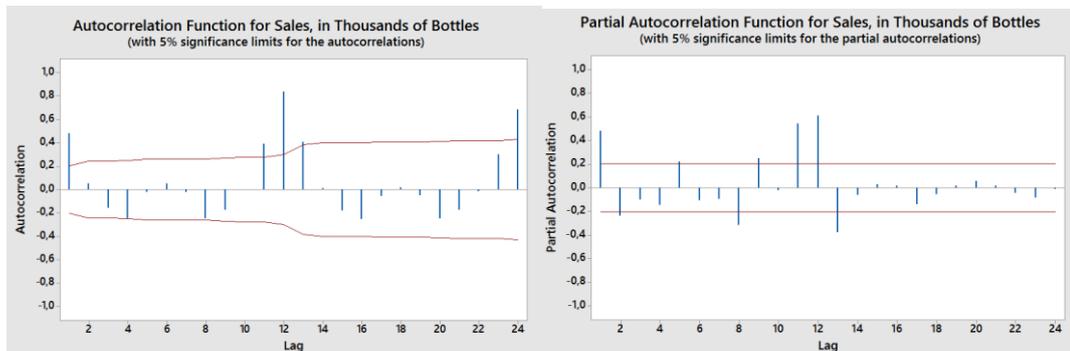
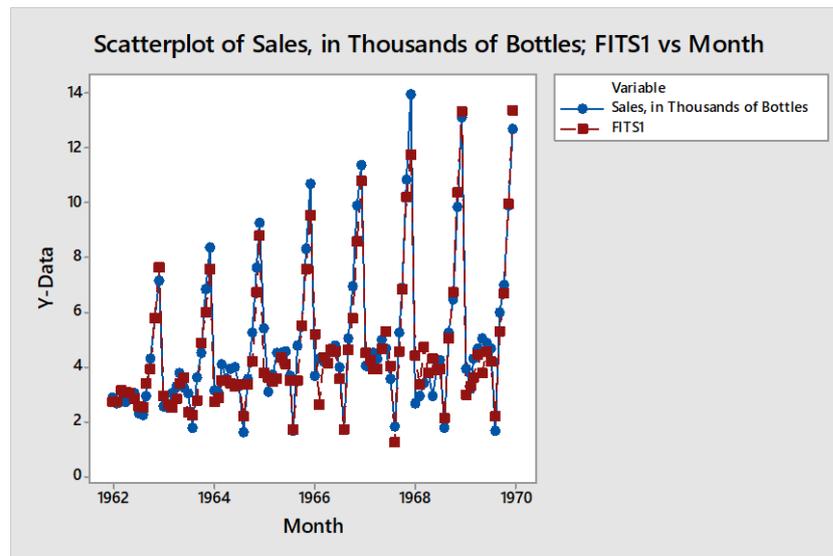
Number of observations: Original series 84, after differencing 71

Residuals: SS = 31,7611 (backforecasts excluded)
MS = 0,4963 DF = 64

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	10,3	22,3	27,5	34,3
DF	5	17	29	41
P-Value	0,067	0,174	0,543	0,761

Exercício 15



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	0,3907	0,0606	6,45	0,000
AR 2	-0,8571	0,0688	-12,45	0,000
SAR 12	1,0067	0,0060	168,78	0,000
MA 1	0,0575	0,0240	2,40	0,019
MA 2	-0,8416	0,0021	-396,00	0,000
MA 3	-0,4441	0,0118	-37,72	0,000
SMA 12	0,2530	0,1152	2,20	0,031

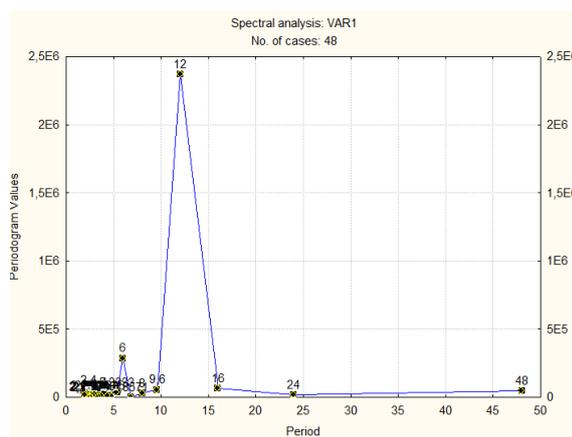
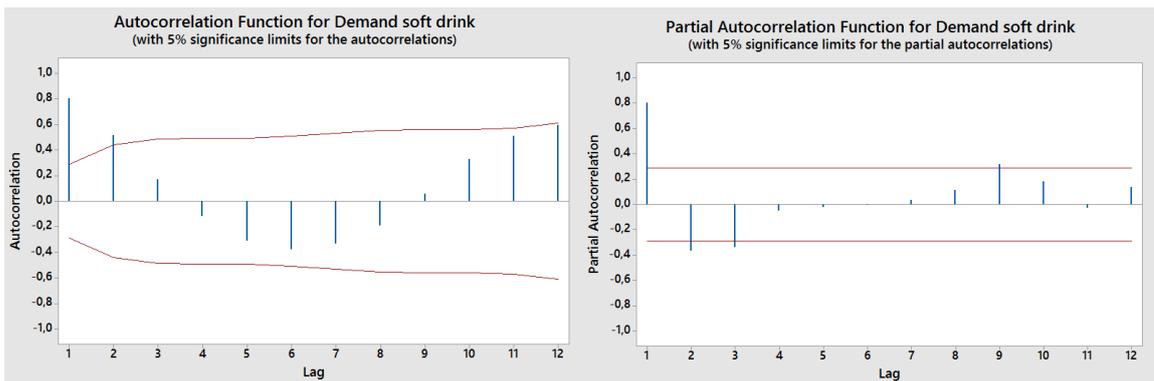
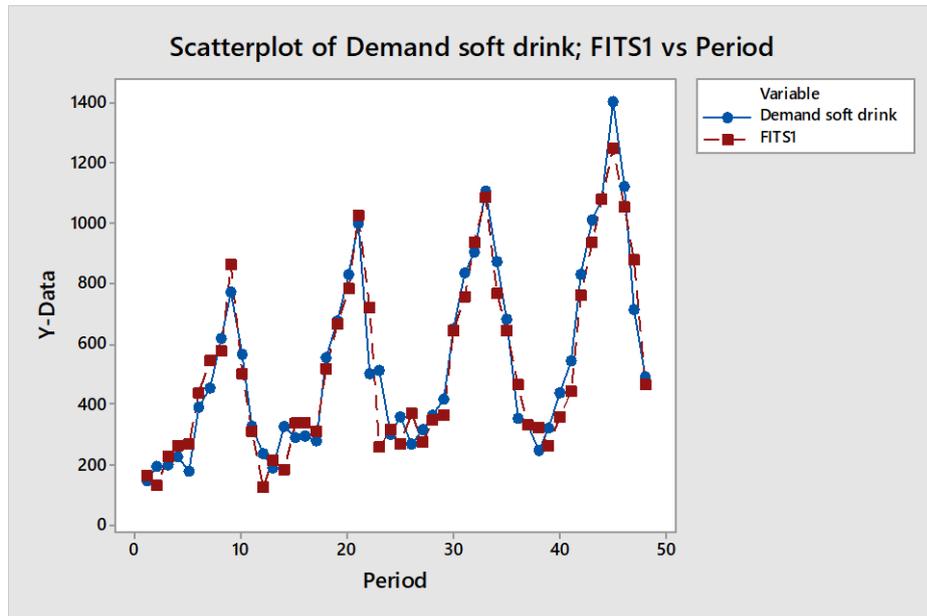
Number of observations: 96

Residuals: SS = 45,3552 (backforecasts excluded)
MS = 0,5096 DF = 89

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	5,1	18,9	36,5	46,6
DF	5	17	29	41
P-Value	0,403	0,332	0,160	0,252

Exercício 16



Final Estimates of Parameters

Type		Coef	SE Coef	T	P
AR	1	0,8873	0,0781	11,36	0,000
SAR	12	0,9973	0,0191	52,14	0,000
SMA	12	0,7727	0,1682	4,59	0,000

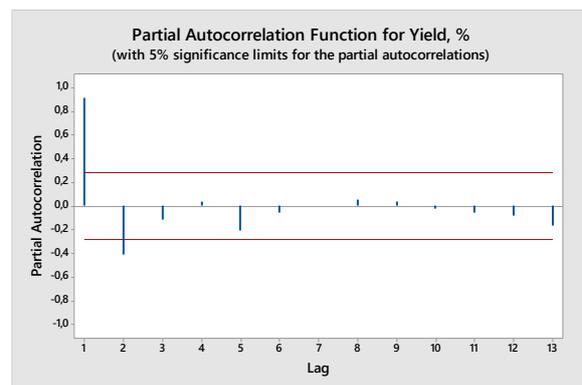
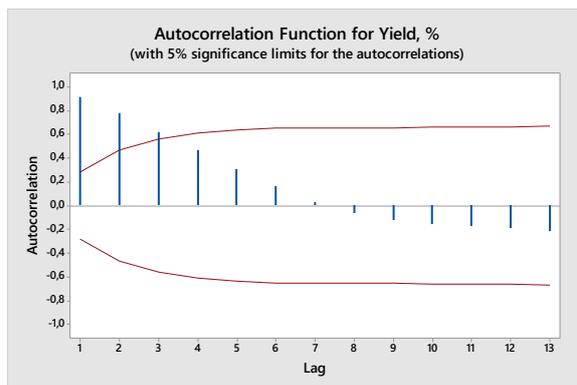
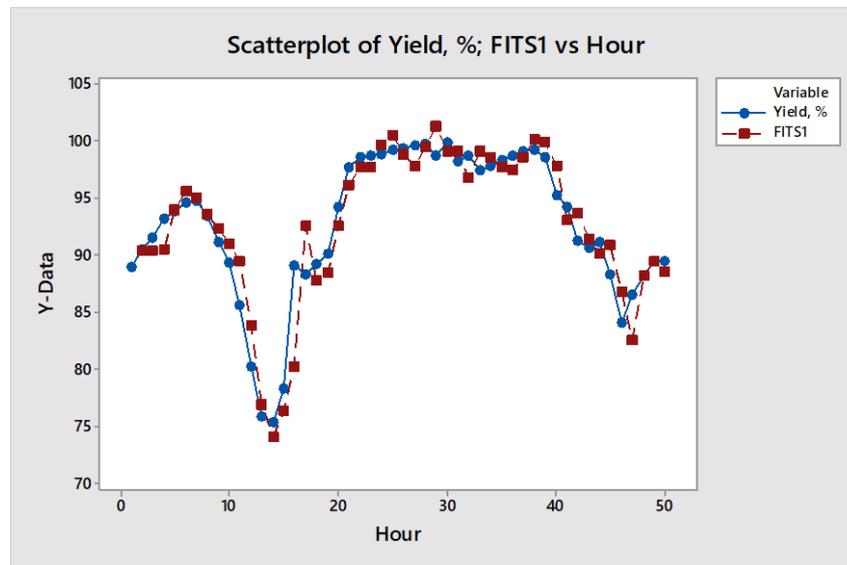
Number of observations: 48

Residuals: SS = 345345 (backforecasts excluded)
MS = 7674 DF = 45

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	15,2	32,4	42,3	*
DF	9	21	33	*
P-Value	0,084	0,053	0,128	*

Exercício 17



Final Estimates of Parameters

Type		Coef	SE Coef	T	P
AR	1	0,7658	0,1807	4,24	0,000
AR	2	-0,9677	0,2093	-4,62	0,000
AR	3	0,1418	0,2461	0,58	0,567
AR	4	0,2171	0,2066	1,05	0,299
AR	5	-0,1134	0,1735	-0,65	0,517
MA	1	0,3712	0,1421	2,61	0,012
MA	2	-0,9220	0,1207	-7,64	0,000

Differencing: 1 regular difference

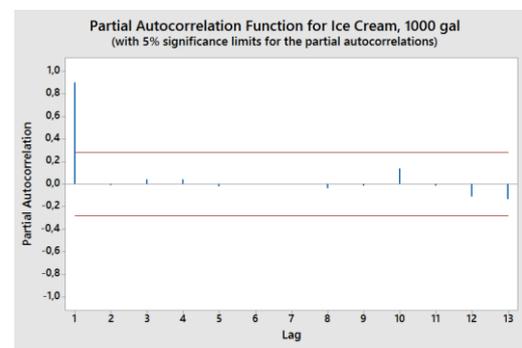
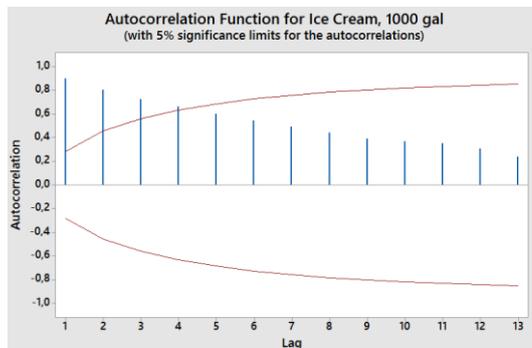
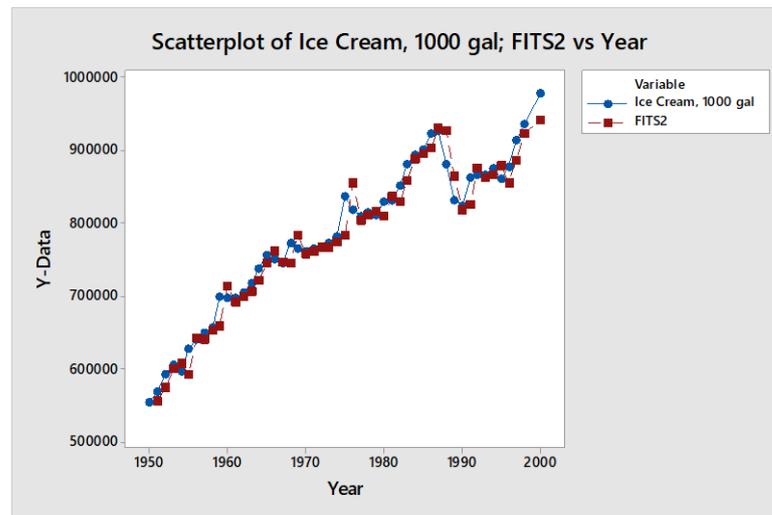
Number of observations: Original series 50, after differencing 49

Residuals: SS = 226,934 (backforecasts excluded)
MS = 5,403 DF = 42

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	8,2	13,6	30,2	33,2
DF	5	17	29	41
P-Value	0,143	0,693	0,403	0,801

Exercício 18



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	-0,5139	0,2566	-2,00	0,052
AR 2	0,9497	0,2200	4,32	0,000
AR 3	0,5467	0,2933	1,86	0,070
AR 4	-0,1222	0,1927	-0,63	0,529
AR 5	0,1370	0,1835	0,75	0,460
MA 1	-0,8143	0,2415	-3,37	0,002
MA 2	0,9437	0,1756	5,37	0,000
MA 3	0,8841	0,2732	3,24	0,002

Differencing: 1 regular difference

Number of observations: Original series 50, after differencing 49

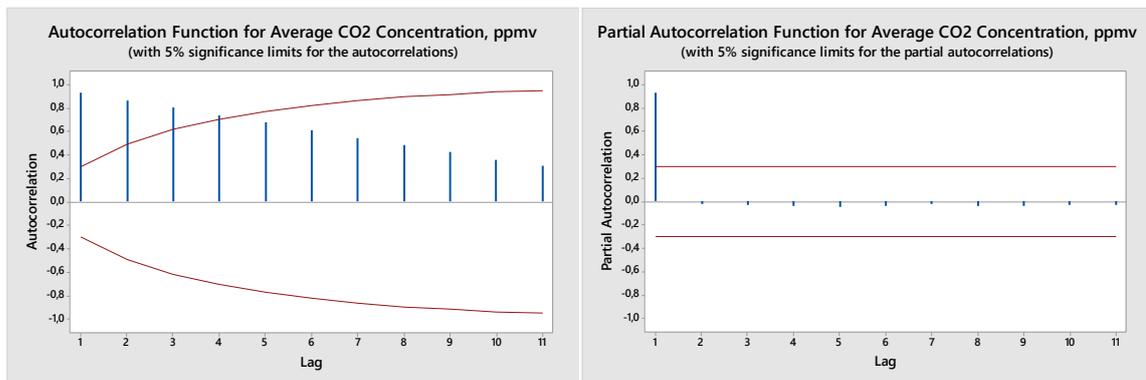
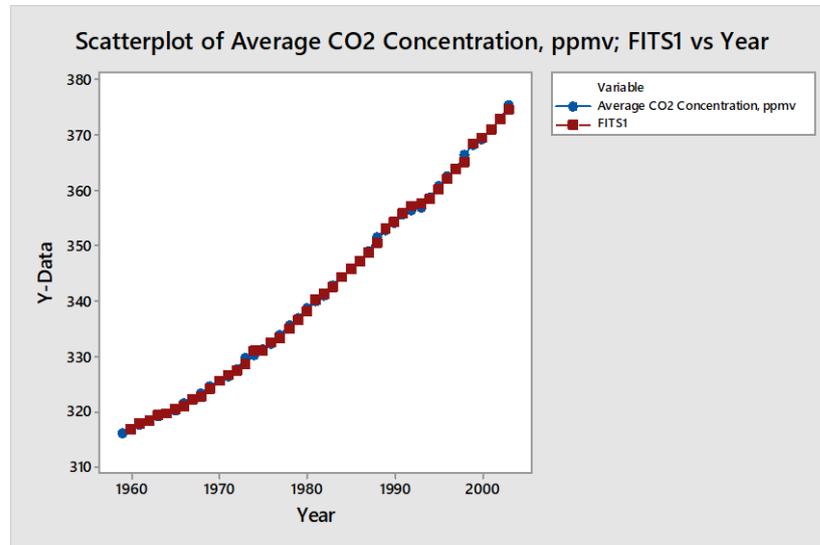
Residuals: SS = 15727729782 (backforecasts excluded)

MS = 383603165 DF = 41

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	4,1	18,1	26,2	32,6
DF	4	16	28	40
P-Value	0,393	0,316	0,562	0,791

Exercício 19



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	1,0027	0,2012	4,98	0,000
AR 2	-0,3539	0,2194	-1,61	0,115
AR 3	0,3549	0,1776	2,00	0,053
MA 1	0,6805	0,1996	3,41	0,001

Differencing: 1 regular difference

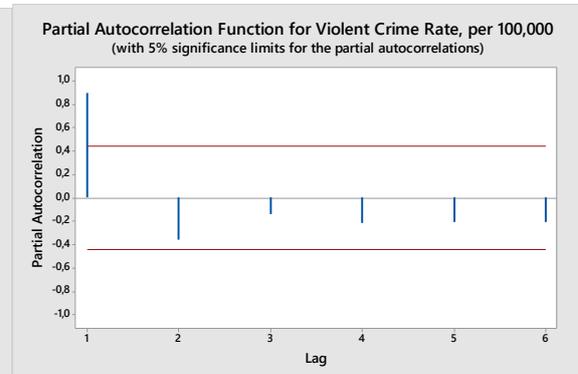
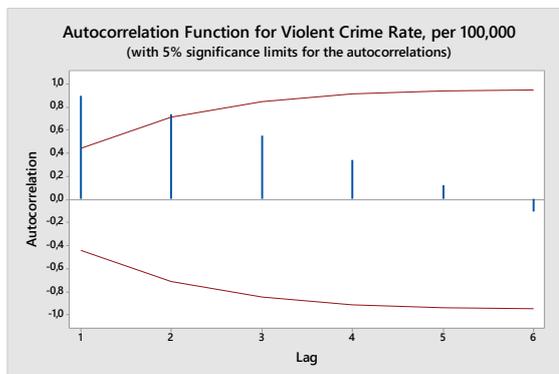
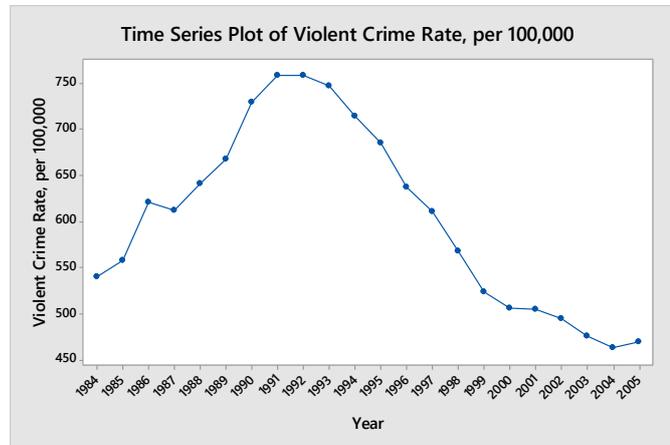
Number of observations: Original series 45, after differencing 44

Residuals: SS = 8,53488 (backforecasts excluded)
MS = 0,21337 DF = 40

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	12,9	27,4	38,6	*
DF	8	20	32	*
P-Value	0,115	0,124	0,196	*

Exercício 20



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	0,6400	0,1719	3,72	0,001

Differencing: 1 regular difference

Number of observations: Original series 22, after differencing 21

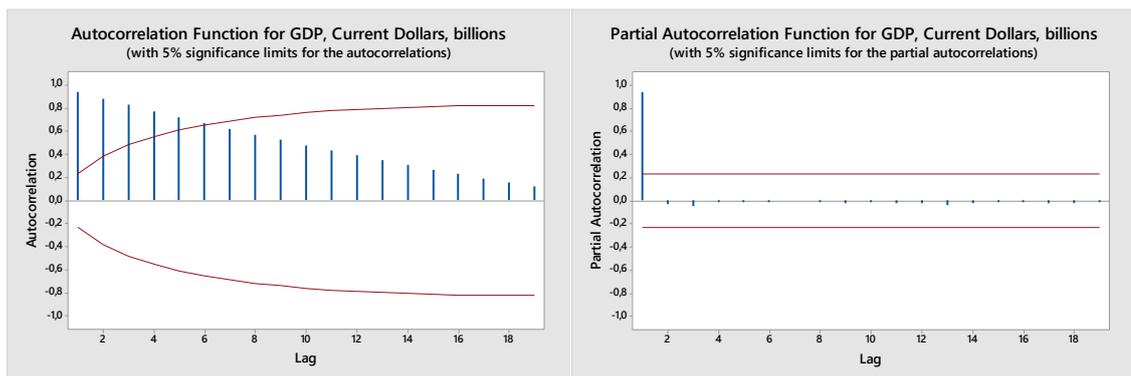
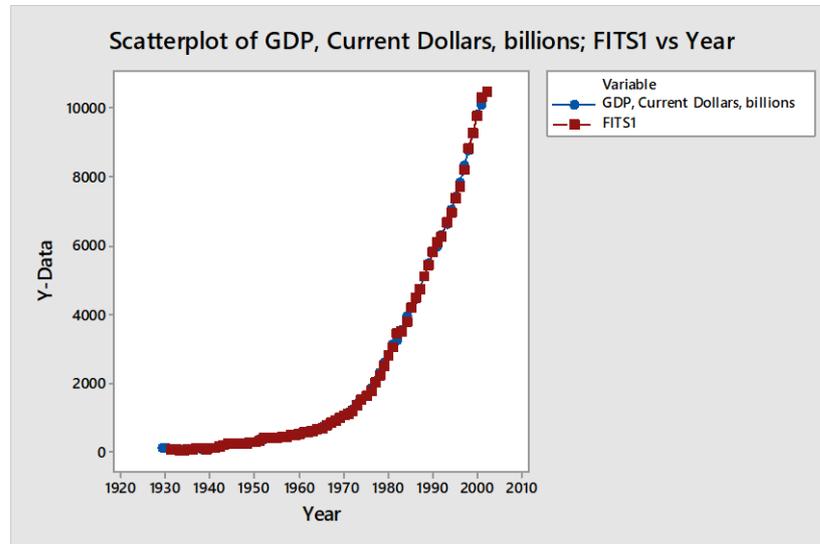
Residuals: SS = 12047,7 (backforecasts excluded)

MS = 602,4 DF = 20

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	10,0	*	*	*
DF	11	*	*	*
P-Value	0,529	*	*	*

Exercício 21



Final Estimates of Parameters

Type		Coef	SE Coef	T	P
AR	1	0,6539	0,1676	3,90	0,000
AR	2	-0,9028	0,1267	-7,13	0,000
MA	1	1,2305	0,2310	5,33	0,000
MA	2	-1,2077	0,2170	-5,57	0,000
MA	3	0,3178	0,1508	2,11	0,039

Differencing: 2 regular differences

Number of observations: Original series 74, after differencing 72

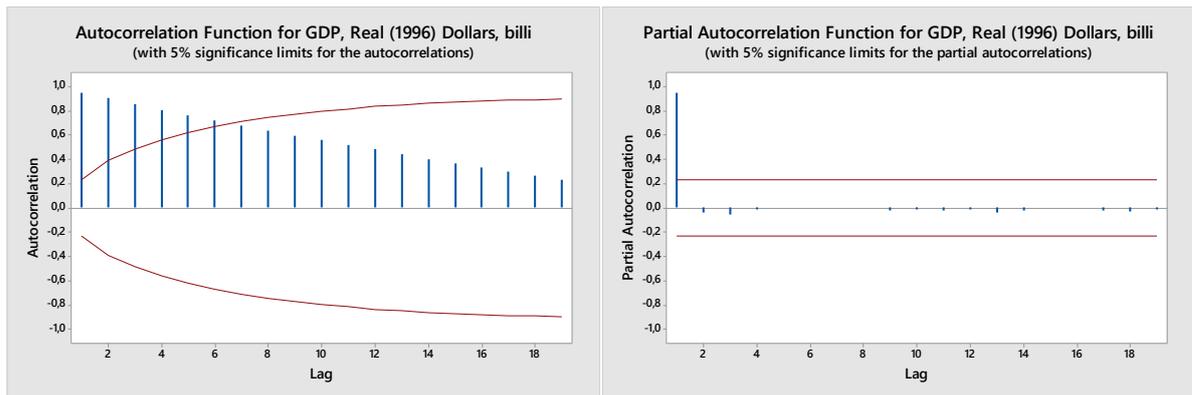
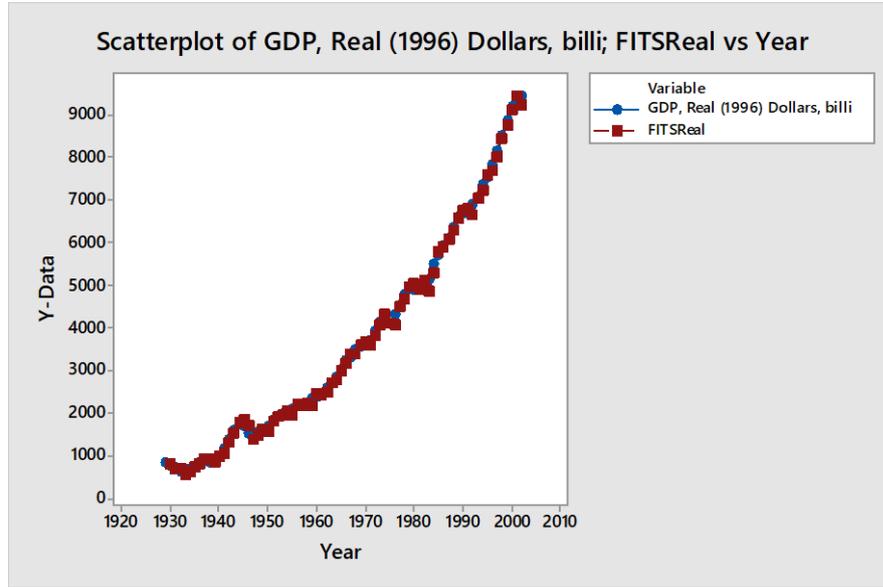
Residuals: SS = 209844 (backforecasts excluded)

MS = 3132 DF = 67

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	7,8	25,9	27,4	28,8
DF	7	19	31	43
P-Value	0,348	0,133	0,651	0,952

Exercício 22



Final Estimates of Parameters

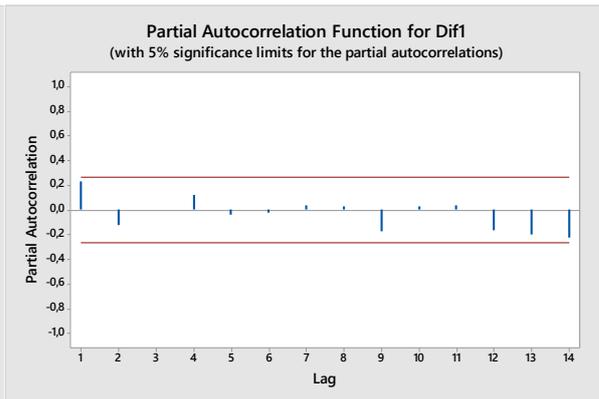
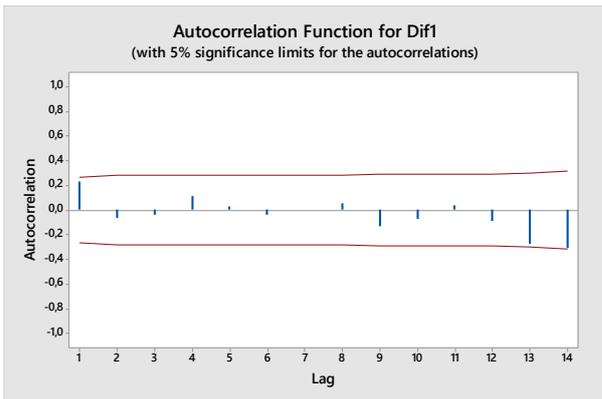
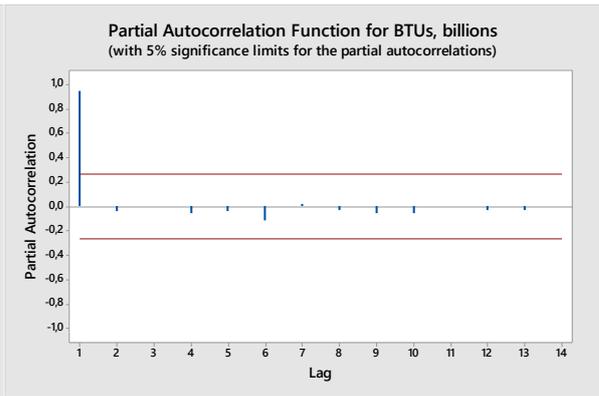
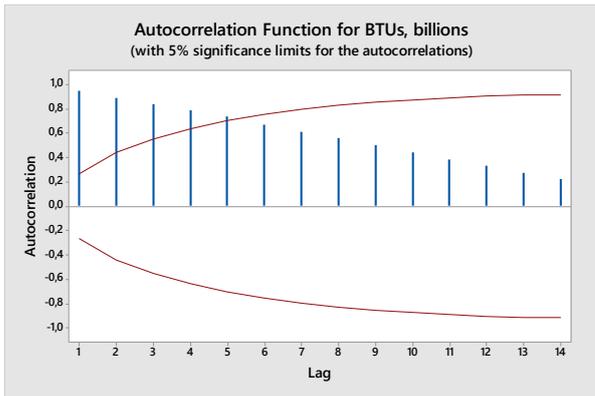
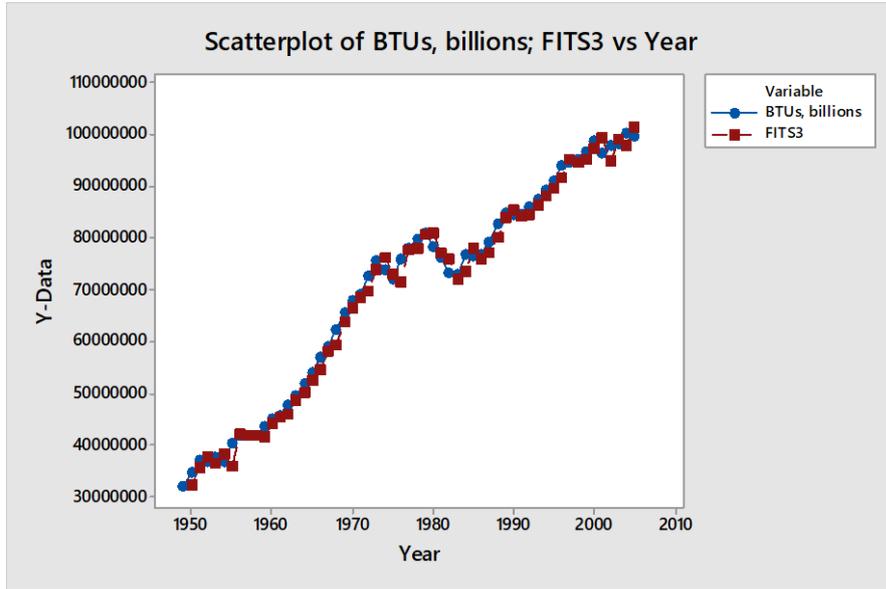
Type	Coef	SE Coef	T	P
AR 1	1,0112	0,0047	215,53	0,000
MA 1	-0,5224	0,1093	-4,78	0,000

Number of observations: 74
 Residuals: SS = 903833 (backforecasts excluded)
 MS = 12553 DF = 72

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	6,6	17,2	24,0	37,5
DF	10	22	34	46
P-Value	0,760	0,754	0,899	0,809

Exercício 23



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
MA 1	-0,4247	0,1251	-3,39	0,001

Differencing: 1 regular difference

Number of observations: Original series 57, after differencing 56

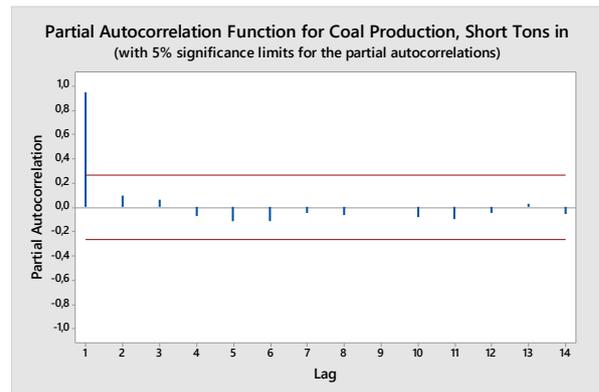
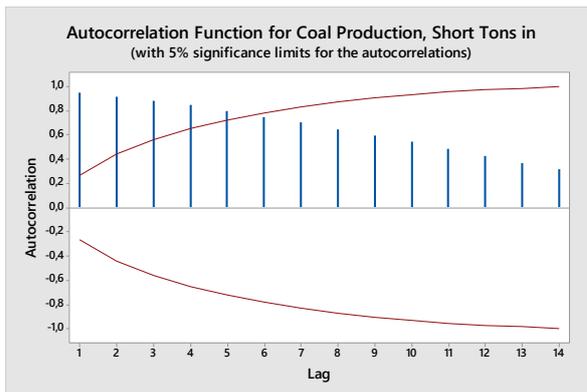
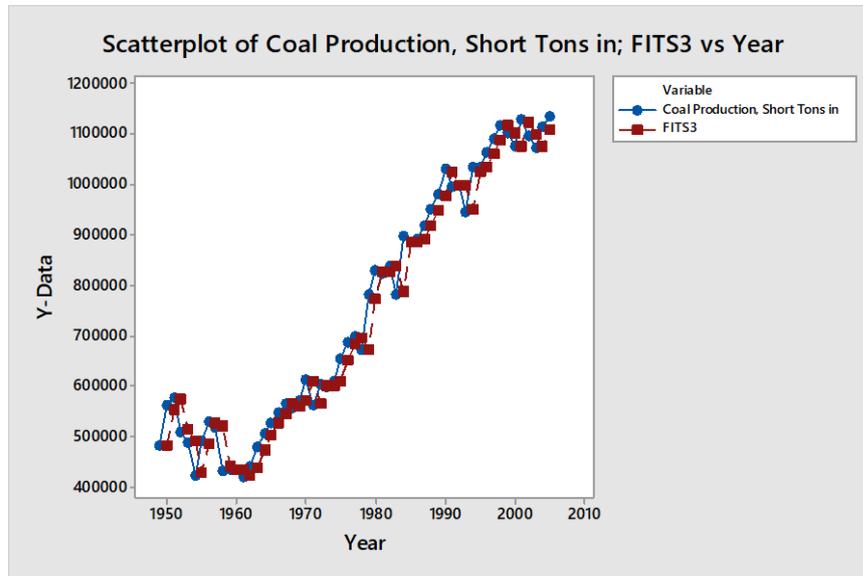
Residuals: SS = 196778800374223 (backforecasts excluded)

MS = 3577796370440 DF = 55

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	5,9	15,6	25,5	40,5
DF	11	23	35	47
P-Value	0,882	0,871	0,881	0,737

Exercício 24



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	-0,0909	0,1345	-0,68	0,502

Differencing: 1 regular difference

Number of observations: Original series 57, after differencing 56

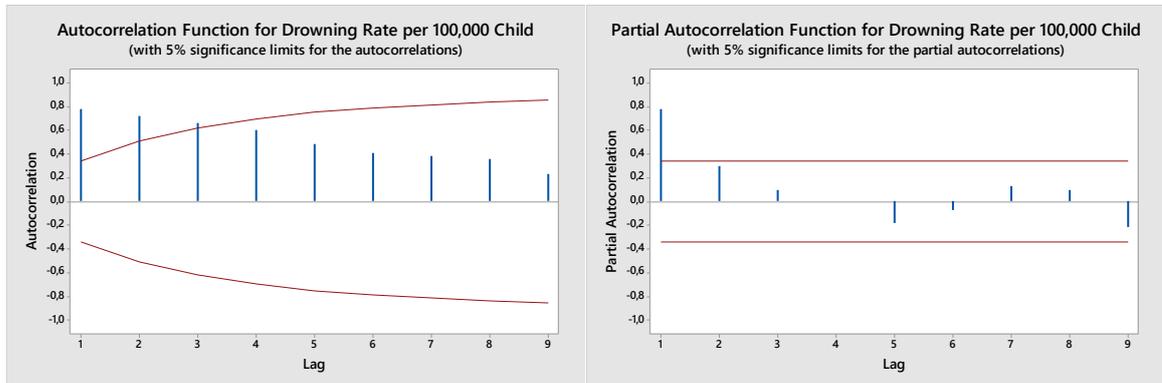
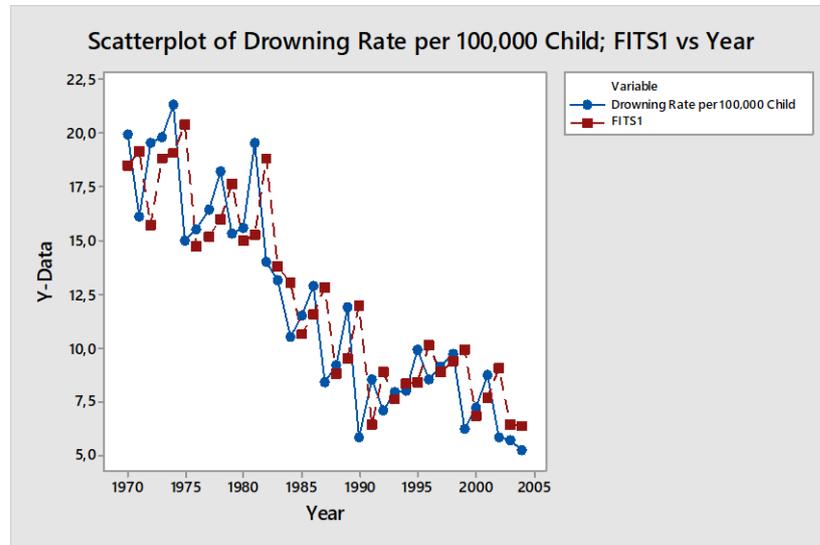
Residuals: SS = 101669879353 (backforecasts excluded)

MS = 1848543261 DF = 55

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	8,8	21,9	42,2	51,1
DF	11	23	35	47
P-Value	0,637	0,524	0,187	0,314

Exercício 25



Final Estimates of Parameters

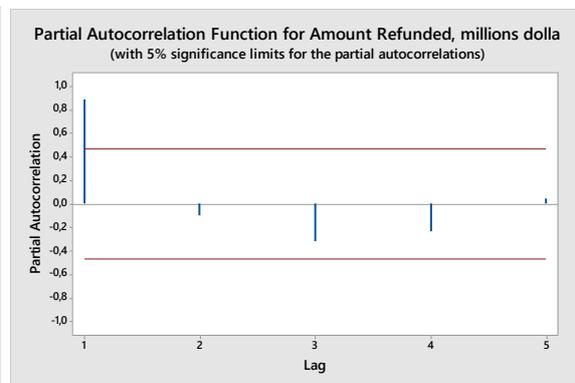
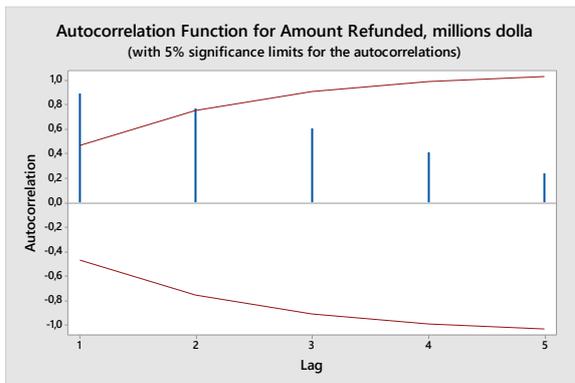
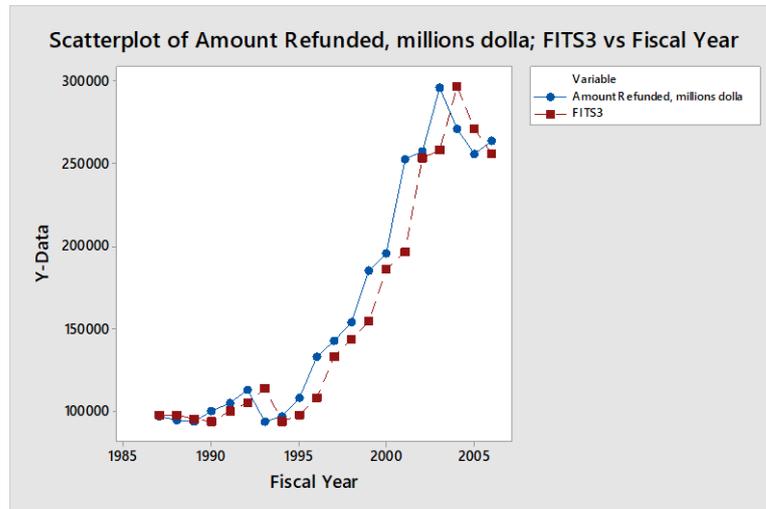
Type	Coef	SE Coef	T	P
AR 1	0,9034	0,0926	9,76	0,000
Constant	1,1714	0,4437	2,64	0,013
Mean	12,124	4,592		

Number of observations: 35
 Residuals: SS = 227,010 (backforecasts excluded)
 MS = 6,879 DF = 33

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	13,5	23,1	*	*
DF	10	22	*	*
P-Value	0,199	0,395	*	*

Exercício 26



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	1,0021	0,0270	37,14	0,000

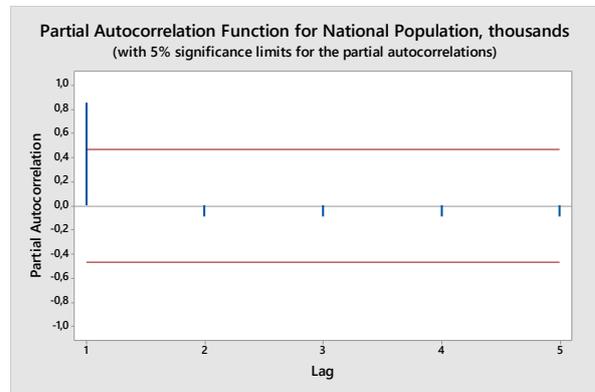
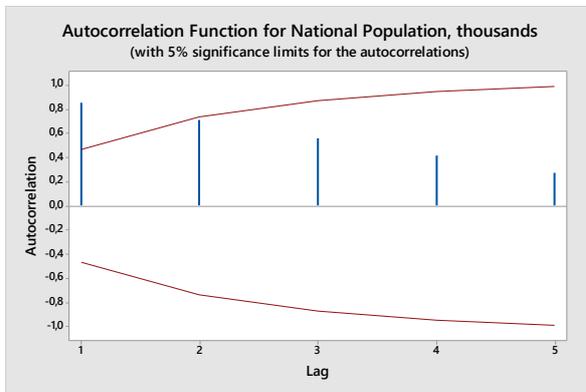
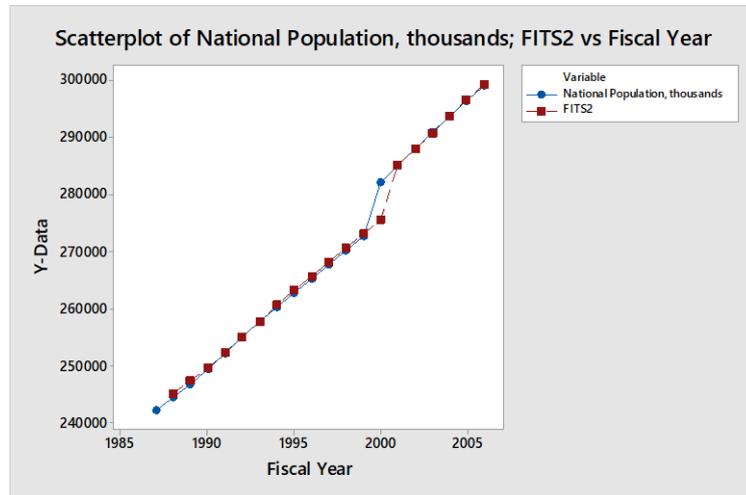
Number of observations: 20

Residuals: SS = 8172552373 (backforecasts excluded)
MS = 430134335 DF = 19

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	9,9	*	*	*
DF	11	*	*	*
P-Value	0,542	*	*	*

Exercício 27



Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	1,0002	0,0020	497,95	0,000
MA 1	1,0176	0,0079	128,51	0,000

Differencing: 1 regular difference

Number of observations: Original series 20, after differencing 19

Residuals: SS = 45157539 (backforecasts excluded)

MS = 2656326 DF = 17

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	1,5	*	*	*
DF	10	*	*	*
P-Value	0,999	*	*	*

ANEXO B - RNA

Exercício 1

	Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1	Linear s2 1:2-1:1	0,865049	1,411686	1,016709	0,217596	0,145011	0,211302	PI	1	0	0
2	Linear 1:1-1:1	0,921318	0,974382	0,796700	0,231750	0,099943	0,168976	PI	1	0	0
3	MLP s3 1:3-5-1:1	0,737621	0,649311	1,415695	0,148627	0,053300	0,235042	BP100,CG55b	1	5	0
4	MLP s3 1:3-8-1:1	0,737811	0,638599	1,406628	0,148475	0,052766	0,234252	BP100,CG64b	1	8	0
5	GRNN s4 1:4-22-2-1:1	0,897395	0,929837	0,868239	0,108015	0,045586	0,086857	SS	1	22	2
6	GRNN s4 1:4-22-2-1:1	0,898883	0,929821	0,869985	0,108195	0,045583	0,087024	SS	1	22	2
7	GRNN s4 1:4-22-2-1:1	0,899919	0,929849	0,871208	0,108321	0,045583	0,087141	SS	1	22	2
8	RBF s5 1:5-1-1:1	0,968540	0,786829	0,975705	0,116310	0,038733	0,096666	KM,KN,PI	1	1	0
9	RBF s5 1:5-2-1:1	0,975529	0,772219	0,986928	0,117149	0,037918	0,097766	KM,KN,PI	1	2	0
10	RBF s5 1:5-2-1:1	0,975529	0,772219	0,986928	0,117149	0,037918	0,097766	KM,KN,PI	1	2	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	51,68222	51,68222	51,68222	51,68222	51,68222	51,68222	51,68222	51,68222	51,68222	51,68222
Data S.D	6,68199	6,68199	6,68199	6,68199	6,68199	6,68199	6,68199	6,68199	6,68199	6,68199
Error Mean	0,22008	0,03041	0,00495	0,17759	-0,25145	-0,24993	-0,24878	0,20804	0,22623	0,22623
Error S.D.	6,31023	6,12883	6,07491	6,03998	6,00429	6,01366	6,02021	6,37385	6,41744	6,41744
Abs. E. Mean	4,90589	4,76240	4,15761	4,09811	4,47545	4,48600	4,49330	4,73614	4,78940	4,78940
S.D. Ratio	0,94436	0,91722	0,90915	0,90392	0,89858	0,89998	0,90096	0,95388	0,96041	0,96041
Correlation	0,37746	0,39901	0,48640	0,48133	0,50615	0,50534	0,50477	0,30025	0,27881	0,27881

Exercício 2

	Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1	Linear s2 1:2-1:1	0,888210	0,970243	0,666445	0,198938	0,136577	0,132571	PI	1	0	0
2	Linear 1:1-1:1	0,904842	0,836164	0,766302	0,202663	0,128583	0,155067	PI	1	0	0
3	RBF s2 1:2-2-1:1	0,967296	0,635386	1,073368	0,206122	0,104625	0,225751	KM,KN,PI	1	2	0
4	RBF s2 1:2-1-1:1	0,977945	0,636846	1,088799	0,208391	0,098596	0,229813	KM,KN,PI	1	1	0
5	GRNN s4 1:4-22-2-1:1	0,619141	0,607890	0,979279	0,131940	0,094995	0,195105	SS	1	22	2
6	GRNN s4 1:4-22-2-1:1	0,598080	0,601697	0,981032	0,127447	0,094977	0,195322	SS	1	22	2
7	GRNN s4 1:4-22-2-1:1	0,604452	0,603446	0,980531	0,128806	0,094959	0,195259	SS	1	22	2
8	MLP s5 1:5-1-3-1:1	1,036776	0,560302	0,997753	0,186464	0,067058	0,166568	BP100,CG20b	1	1	3
9	MLP s3 1:3-8-1:1	1,030082	0,525591	1,097147	0,209203	0,059267	0,177050	BP2b	1	8	0
10	MLP s5 1:5-8-8-1:1	0,991913	0,525968	1,283344	0,202271	0,057976	0,202483	BP0b	1	8	8

	1	2	3	4	5	6	7	8	9	10
Data Mean	29,31111	29,31111	29,31111	29,31111	29,31111	29,31111	29,31111	29,31111	29,31111	29,31111
Data S.D	4,03222	4,03222	4,03222	4,03222	4,03222	4,03222	4,03222	4,03222	4,03222	4,03222
Error Mean	-0,25479	-0,43924	-0,81199	-0,79933	-0,56323	-0,57163	-0,56915	-0,25653	1,64625	1,35214
Error S.D.	3,39417	3,49423	3,89275	3,93032	2,94064	2,89721	2,91016	3,99058	4,10745	4,23915
Abs. E. Mean	2,68991	2,70291	3,00677	3,01470	2,18279	2,14142	2,15384	2,92829	3,28608	3,26905
S.D. Ratio	0,84176	0,86658	0,96541	0,97473	0,72929	0,71851	0,72173	0,98967	1,01866	1,05132
Correlation	0,54372	0,50032	0,26074	0,22426	0,70363	0,71168	0,70925	0,25081	0,21478	0,15639

Exercício 3

	Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1	Linear s5 1:5-1:1	0,276268	0,348534	0,311374	0,072406	0,118692	0,154839	PI	1	0	0
2	Linear s6 1:6-1:1	0,257980	0,343706	0,311021	0,067613	0,115726	0,127038	PI	1	0	0
3	MLP s12 1:12-2-1:1	0,165778	0,100831	0,267039	0,043716	0,034346	0,150806	BP100,CG42b	1	2	0
4	MLP s12 1:12-3-1:1	0,083763	0,036218	0,553051	0,022293	0,012308	0,164065	BP100,CG28b	1	3	0
5	MLP s14 1:14-8-3-1:1	0,053112	0,033204	0,287555	0,013920	0,011284	0,121894	BP100,CG34b	1	8	3
6	GRNN s25 1:25-15-2-1:1	0,096585	0,274421	0,397358	0,002012	0,007330	0,011800	SS	1	15	2
7	GRNN s25 1:25-15-2-1:1	0,094299	0,274424	0,398504	0,001964	0,007330	0,011793	SS	1	15	2
8	RBF s13 1:13-4-1:1	0,376784	0,260884	0,126229	0,007847	0,007036	0,005081	KM,KN,PI	1	4	0
9	RBF s13 1:13-8-1:1	0,166507	0,229325	0,281043	0,003468	0,006682	0,008117	KM,KN,PI	1	8	0
10	RBF s13 1:13-10-1:1	0,104337	0,160417	0,136197	0,002173	0,004299	0,007870	KM,KN,PI	1	10	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	634,5600	634,5600	634,5600	634,5600	634,5600	634,5600	634,5600	634,5600	634,5600	634,5600
Data S.D	49,9657	49,9657	49,9657	49,9657	49,9657	49,9657	49,9657	49,9657	49,9657	49,9657
Error Mean	-5,0590	-3,4327	-4,1968	-1,6298	-3,2308	-3,4533	-3,4430	-2,2533	-1,1319	-3,2865
Error S.D.	16,9996	15,5282	12,4827	12,8205	8,9777	13,3442	13,3211	15,3551	11,5979	8,7638
Abs. E. Mean	13,7331	12,5195	9,4595	6,9007	4,9734	8,4252	8,3738	13,1796	9,3788	6,7293
S.D. Ratio	0,3402	0,3108	0,2498	0,2566	0,1797	0,2671	0,2666	0,3073	0,2321	0,1754
Correlation	0,9437	0,9535	0,9683	0,9667	0,9839	0,9642	0,9643	0,9535	0,9755	0,9845

Exercício 4

	Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1	Linear s4 1:4-1:1	0,755758	1,199605	1,010485	0,226313	0,671894	0,930598	PI	1	0	0
2	Linear s5 1:5-1:1	0,694730	0,895632	1,765713	0,208037	0,501845	0,886619	PI	1	0	0
3	RBF s4 1:4-1-1:1	0,997719	1,003023	1,001304	0,022426	0,047408	0,066057	KM,KN,PI	1	1	0
4	RBF s4 1:4-2-1:1	0,958232	0,992970	1,265884	0,021538	0,046205	0,060316	KM,KN,PI	1	2	0
5	RBF s4 1:4-3-1:1	0,796509	0,980430	1,406575	0,017903	0,043485	0,070887	KM,KN,PI	1	3	0
6	MLP s5 1:5-5-1:1	0,391989	0,077177	2,902366	0,156635	0,042540	1,286554	BP100,CG21b	1	5	0
7	GRNN s5 1:5-8-2-1:1	0,000000	0,959985	1,302828	0,000000	0,042083	0,085588	SS	1	8	2
8	GRNN s5 1:5-8-2-1:1	0,000000	0,959671	1,302862	0,000000	0,042075	0,085590	SS	1	8	2
9	MLP s5 1:5-8-1:1	1,196301	0,035729	4,449928	0,360382	0,022457	1,423091	BP0b	1	8	0
10	MLP s5 1:5-8-4-1:1	0,162706	0,025754	3,706442	0,048775	0,017400	1,269705	BP100,CG21b	1	8	4

	1	2	3	4	5	6	7	8	9	10
Data Mean	443,2105	443,2105	443,2105	443,2105	443,2105	443,2105	443,2105	443,2105	443,2105	443,2105
Data S.D	73,4622	73,4622	73,4622	73,4622	73,4622	73,4622	73,4622	73,4622	73,4622	73,4622
Error Mean	-3,8359	8,2366	-7,4466	8,6290	-1,7144	-7,7791	-9,8304	-9,8336	59,7160	38,3578
Error S.D.	72,2286	71,6486	71,0758	82,6186	74,2038	79,2100	76,1372	76,1351	139,8186	112,1709
Abs. E. Mean	56,1370	55,0371	57,1227	65,4801	58,5575	44,6827	47,4313	47,4285	104,8852	70,5032
S.D. Ratio	0,9832	0,9753	0,9675	1,1246	1,0101	1,0782	1,0364	1,0364	1,9033	1,5269
Correlation	0,2168	0,3071	0,4289	-0,3885	0,0807	0,2678	0,1189	0,1190	-0,2667	-0,0898

Exercício 5

Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 GRNN s10 1:10-311-2-1:1	0,063378	0,158456	0,150839	0,022753	0,056540	0,048142	SS	1	311	2
2 GRNN s10 1:10-311-2-1:1	0,076402	0,158023	0,153620	0,027429	0,056525	0,048966	SS	1	311	2
3 RBF s5 1:5-52-1:1	0,115254	0,108087	0,106967	0,041374	0,037564	0,034010	SS,KN,PI	1	52	0
4 RBF s5 1:5-52-1:1	0,122956	0,106935	0,100079	0,044139	0,037084	0,031703	SS,KN,PI	1	52	0
5 Linear s9 1:9-1:1	0,094073	0,101146	0,098818	0,020155	0,020946	0,018676	PI	1	0	0
6 Linear s7 1:7-1:1	0,094132	0,101043	0,099070	0,020168	0,020922	0,018723	PI	1	0	0
7 Linear s6 1:6-1:1	0,094140	0,100672	0,098802	0,020169	0,020845	0,018674	PI	1	0	0
8 MLP s6 1:6-8-3-1:1	0,105691	0,093778	0,102475	0,018118	0,015525	0,015478	BP100,CG37b	1	8	3
9 MLP s6 1:6-6-6-1:1	0,101379	0,093740	0,096218	0,017389	0,015522	0,014533	BP100,CG102b	1	6	6
10 MLP s6 1:6-8-5-1:1	0,108523	0,092255	0,101573	0,018604	0,015315	0,015341	BP100,CG38b	1	8	5

	1	2	3	4	5	6	7	8	9	10
Data Mean	6,609984	6,609984	6,609984	6,609984	6,609984	6,609984	6,609984	6,609984	6,609984	6,609984
Data S.D	2,689948	2,689948	2,689948	2,689948	2,689948	2,689948	2,689948	2,689948	2,689948	2,689948
Error Mean	-0,036950	-0,037201	-0,011656	-0,004854	0,000530	0,000748	0,000908	0,004295	0,005553	-0,003108
Error S.D.	0,309932	0,322919	0,299299	0,306662	0,259216	0,259360	0,258963	0,273276	0,263424	0,276328
Abs. E. Mean	0,193455	0,213310	0,202993	0,208026	0,181098	0,181020	0,181004	0,196645	0,190165	0,196862
S.D. Ratio	0,115219	0,120047	0,111266	0,114003	0,096365	0,096418	0,096271	0,101591	0,097929	0,102726
Correlation	0,993460	0,992929	0,993807	0,993498	0,995349	0,995343	0,995358	0,994836	0,995208	0,994723

Exercício 6

Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 Linear s5 1:5-1:1	0,928279	1,015671	1,018798	0,215976	0,199487	0,230648	PI	1	0	0
2 Linear s6 1:6-1:1	0,928269	1,015229	1,019086	0,215974	0,199371	0,230712	PI	1	0	0
3 MLP s5 1:5-8-1:1	1,051777	0,868890	1,022157	0,197400	0,135293	0,182199	BP1b	1	8	0
4 MLP s5 1:5-8-1:1	0,989098	0,870408	0,997564	0,186941	0,135015	0,187770	BP1b	1	8	0
5 RBF s4 1:4-1-1:1	0,977503	0,981938	0,992859	0,004246	0,003705	0,004035	KM,KN,PI	1	1	0
6 GRNN s5 1:5-56-2-1:1	0,941393	0,975058	0,988171	0,004093	0,003701	0,003989	SS	1	56	2
7 GRNN s5 1:5-56-2-1:1	0,938277	0,974843	0,988078	0,004080	0,003701	0,003986	SS	1	56	2
8 GRNN s5 1:5-56-2-1:1	0,939216	0,974900	0,988103	0,004084	0,003701	0,003987	SS	1	56	2
9 RBF s5 1:5-2-1:1	0,948486	0,940789	0,921723	0,004120	0,003475	0,003813	KM,KN,PI	1	2	0
10 RBF s4 1:4-3-1:1	0,929667	0,906795	0,984478	0,004038	0,003389	0,004006	KM,KN,PI	1	3	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	10378,14	10378,14	10378,14	10378,14	10378,14	10378,14	10378,14	10378,14	10378,14	10378,14
Data S.D	214,85	214,85	214,85	214,85	214,85	214,85	214,85	214,85	214,85	214,85
Error Mean	-10,76	-10,82	-27,00	-42,22	-0,41	7,82	8,08	8,00	-5,85	-2,67
Error S.D.	207,75	207,74	223,77	211,24	210,23	205,86	205,44	205,57	201,78	202,30
Abs. E. Mean	172,86	172,83	188,80	178,42	170,47	170,00	169,77	169,84	165,83	168,22
S.D. Ratio	0,97	0,97	1,04	0,98	0,98	0,96	0,96	0,96	0,94	0,94
Correlation	0,27	0,28	0,18	0,23	0,21	0,39	0,40	0,39	0,34	0,34

Exercício 7

Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 RBF s5 1:5-4-1:1	0,626576	0,632616	0,642836	0,337709	0,286083	0,335054	KM,KN,PI	1	4	0
2 RBF s5 1:5-5-1:1	0,624126	0,641559	0,670748	0,336388	0,282712	0,347729	KM,KN,PI	1	5	0
3 GRNN s8 1:8-46-2-1:1	0,592742	0,597636	0,653517	0,319748	0,258819	0,335015	SS	1	46	2
4 GRNN s8 1:8-46-2-1:1	0,601314	0,597575	0,656915	0,324365	0,258786	0,336779	SS	1	46	2
5 Linear s5 1:5-1:1	0,583981	0,655492	0,607924	0,130592	0,120547	0,129171	PI	1	0	0
6 Linear s6 1:6-1:1	0,582157	0,645132	0,600560	0,130184	0,118934	0,127577	PI	1	0	0
7 Linear s7 1:7-1:1	0,581223	0,641665	0,604488	0,129975	0,117820	0,128397	PI	1	0	0
8 MLP s5 1:5-2-4-1:1	0,640445	0,568379	0,676945	0,115624	0,081634	0,115473	BP100,CG22b	1	2	4
9 MLP s5 1:5-8-1:1	0,613175	0,550411	0,652937	0,109758	0,079493	0,111377	BP100,CG7b	1	8	0
10 MLP s5 1:5-8-8-1:1	0,634984	0,547810	0,677594	0,114191	0,079392	0,115597	BP29b	1	8	8

	1	2	3	4	5	6	7	8	9	10
Data Mean	84,89827	84,89827	84,89827	84,89827	84,89827	84,89827	84,89827	84,89827	84,89827	84,89827
Data S.D	1,73512	1,73512	1,73512	1,73512	1,73512	1,73512	1,73512	1,73512	1,73512	1,73512
Error Mean	0,08069	0,05127	-0,06379	-0,06322	0,02083	0,02072	0,01499	-0,10048	-0,01522	-0,05271
Error S.D.	1,10959	1,11576	1,08189	1,09102	1,05752	1,04917	1,04780	1,12442	1,07709	1,11755
Abs. E. Mean	0,88065	0,88539	0,87758	0,88539	0,84586	0,83049	0,82982	0,89589	0,83939	0,88772
S.D. Ratio	0,63949	0,64304	0,62353	0,62879	0,60948	0,60467	0,60388	0,64804	0,62076	0,64407
Correlation	0,77003	0,76661	0,81295	0,81030	0,79483	0,79842	0,79897	0,77626	0,78867	0,77347

Exercício 8

Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 Linear s4 1:4-1:1	0,196981	0,280916	0,299470	0,059772	0,076372	0,075564	PI	1	0	0
2 Linear s5 1:5-1:1	0,196980	0,280533	0,299630	0,059772	0,076312	0,075591	PI	1	0	0
3 MLP s6 1:6-8-1:1	0,236333	0,128227	0,174701	0,077232	0,028589	0,063014	BP95b	1	8	0
4 MLP s6 1:6-8-1:1	0,276183	0,105622	0,268008	0,085724	0,023504	0,100942	BP41b	1	8	0
5 RBF s6 1:6-1:1	0,920825	1,050231	0,772868	0,000102	0,000085	0,000071	KM,KN,PI	1	1	0
6 GRNN s4 1:4-20-2-1:1	0,319327	0,347116	0,284882	0,000035	0,000030	0,000031	SS	1	20	2
7 GRNN s4 1:4-20-2-1:1	0,316118	0,347353	0,281382	0,000035	0,000030	0,000031	SS	1	20	2
8 GRNN s4 1:4-20-2-1:1	0,317021	0,347225	0,282376	0,000035	0,000030	0,000031	SS	1	20	2
9 RBF s6 1:6-2-1:1	0,253062	0,317417	0,333669	0,000028	0,000028	0,000038	KM,KN,PI	1	2	0
10 RBF s6 1:6-2-1:1	0,253062	0,317417	0,333669	0,000028	0,000028	0,000038	KM,KN,PI	1	2	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	27415,40	27415,40	27415,40	27415,40	27415,40	27415,40	27415,40	27415,40	27415,40	27415,40
Data S.D	9024,16	9024,16	9024,16	9024,16	9024,16	9024,16	9024,16	9024,16	9024,16	9024,16
Error Mean	-86,04	-86,45	829,46	853,19	258,12	843,31	841,47	842,03	474,06	474,06
Error S.D.	1835,10	1834,85	1719,06	2100,56	7065,75	3115,06	3090,58	3097,49	2376,05	2376,05
Abs. E. Mean	1466,47	1466,72	1460,96	1727,51	6393,43	2558,37	2538,13	2543,98	1913,89	1913,89
S.D. Ratio	0,20	0,20	0,19	0,23	0,78	0,35	0,34	0,34	0,26	0,26
Correlation	0,98	0,98	0,98	0,97	0,63	0,96	0,96	0,96	0,96	0,96

Exercício 9

	Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1	Linear s12 1:12-1:1	0,185652	0,271103	0,231216	0,041268	0,053277	0,055114	PI	1	0	0
2	MLP s12 1:12-8-3-1:1	0,121524	0,226961	0,248483	0,021611	0,034777	0,048826	BP100,CG90b	1	8	3
3	MLP s12 1:12-8-4-1:1	0,142846	0,219443	0,238443	0,025564	0,033630	0,046071	BP100,CG80b	1	8	4
4	MLP s12 1:12-8-8-1:1	0,139703	0,218314	0,237520	0,024844	0,033488	0,046587	BP100,CG100b	1	8	8
5	GRNN s12 1:12-86-2-1:1	0,034742	0,321369	0,340784	0,000045	0,000377	0,000476	SS	1	86	2
6	GRNN s12 1:12-86-2-1:1	0,045274	0,318267	0,326453	0,000058	0,000376	0,000458	SS	1	86	2
7	GRNN s12 1:12-86-2-1:1	0,037745	0,320246	0,336677	0,000049	0,000376	0,000471	SS	1	86	2
8	RBF s12 1:12-28-1:1	0,163641	0,298752	0,262904	0,000211	0,000337	0,000384	KM,KN,PI	1	28	0
9	RBF s12 1:12-43-1:1	0,128285	0,276001	0,250496	0,000166	0,000326	0,000371	KM,KN,PI	1	43	0
10	RBF s12 1:12-45-1:1	0,145430	0,275752	0,266718	0,000188	0,000316	0,000388	KM,KN,PI	1	45	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	5311,536	5311,536	5311,536	5311,536	5311,536	5311,536	5311,536	5311,536	5311,536	5311,536
Data S.D	753,223	753,223	753,223	753,223	753,223	753,223	753,223	753,223	753,223	753,223
Error Mean	3,613	-15,898	-15,252	-11,538	-30,366	-32,494	-30,974	-27,533	-36,297	-29,874
Error S.D.	165,338	142,937	143,816	143,565	176,173	172,318	174,990	172,257	156,695	164,106
Abs. E. Mean	130,635	107,518	112,107	111,425	104,904	105,164	104,907	130,611	118,089	121,145
S.D. Ratio	0,220	0,190	0,191	0,191	0,234	0,229	0,232	0,229	0,208	0,218
Correlation	0,976	0,982	0,982	0,982	0,972	0,974	0,973	0,974	0,978	0,976

Exercício 10

	Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1	GRNN s10 1:10-59-2-1:1	0,207497	0,588980	0,558255	0,807131	2,212744	2,329112	SS	1	59	2
2	GRNN s10 1:10-59-2-1:1	0,222975	0,589199	0,554040	0,867372	2,212690	2,311301	SS	1	59	2
3	RBF s5 1:5-2-1:1	0,521398	0,551922	0,538591	2,027560	2,072342	2,258599	KM,KN,PI	1	2	0
4	RBF s5 1:5-2-1:1	0,521398	0,551922	0,538591	2,027560	2,072342	2,258599	KM,KN,PI	1	2	0
5	Linear s5 1:5-1:1	0,400842	0,620757	0,601929	0,081065	0,122279	0,132258	PI	1	0	0
6	Linear s4 1:4-1:1	0,401786	0,620160	0,604688	0,081256	0,122052	0,132557	PI	1	0	0
7	Linear s3 1:3-1:1	0,486862	0,611078	0,554500	0,098462	0,119301	0,120362	PI	1	0	0
8	MLP s5 1:5-2-1:1	0,480015	0,500114	0,501051	0,077761	0,078249	0,086878	BP100,CG25b	1	2	0
9	MLP s5 1:5-3-1:1	0,493091	0,500309	0,495277	0,080083	0,078137	0,085918	BP100,CG23b	1	3	0
10	MLP s6 1:6-2-4-1:1	0,506047	0,496403	0,477955	0,081896	0,077622	0,082868	BP100,CG26b	1	2	4

	1	2	3	4	5	6	7	8	9	10
Data Mean	0,009043	0,009043	0,009043	0,009043	0,009043	0,009043	0,009043	0,009043	0,009043	0,009043
Data S.D	0,256752	0,256752	0,256752	0,256752	0,256752	0,256752	0,256752	0,256752	0,256752	0,256752
Error Mean	-0,003863	-0,003472	0,004746	0,004746	-0,011595	-0,010772	-0,002416	0,000958	0,006748	-0,000024
Error S.D.	0,109624	0,110243	0,136230	0,136230	0,132198	0,132396	0,136718	0,125297	0,126510	0,126745
Abs. E. Mean	0,076773	0,078347	0,110412	0,110412	0,104604	0,104518	0,110526	0,100788	0,102472	0,102051
S.D. Ratio	0,426962	0,429377	0,530589	0,530589	0,514887	0,515657	0,532490	0,488007	0,492731	0,493648
Correlation	0,912029	0,911672	0,850642	0,850642	0,857417	0,856871	0,846565	0,874557	0,871478	0,871915

Exercício 11

	Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1	Linear s2 1:2-1:1	0,140106	0,102472	0,082481	0,035069	0,027316	0,022674	PI	1	0	0
2	Linear s3 1:3-1:1	0,140082	0,102362	0,083036	0,035063	0,027276	0,022836	PI	1	0	0
3	MLP s5 1:5-3-1:1	0,148318	0,101003	0,089225	0,029717	0,021418	0,019610	BP100,CG35b	1	3	0
4	MLP s5 1:5-5-5-1:1	0,146929	0,099359	0,093528	0,029422	0,021092	0,020724	BP100,CG43b	1	5	5
5	MLP s5 1:5-8-6-1:1	0,144425	0,098508	0,080028	0,028920	0,020957	0,017779	BP100,CG22b	1	8	6
6	GRNN s10 1:10-120-2-1:1	0,088701	0,118926	0,117365	0,014001	0,020925	0,020943	SS	1	120	2
7	GRNN s10 1:10-120-2-1:1	0,083542	0,118831	0,115822	0,013187	0,020900	0,020682	SS	1	120	2
8	RBF s4 1:4-21-1:1	0,132382	0,116418	0,110325	0,020896	0,019784	0,019227	KM,KN,PI	1	21	0
9	RBF s4 1:4-24-1:1	0,125904	0,116424	0,106746	0,019873	0,019587	0,018698	KM,KN,PI	1	24	0
10	RBF s4 1:4-26-1:1	0,124792	0,110236	0,108434	0,019698	0,018455	0,018750	KM,KN,PI	1	26	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	29,89903	29,89903	29,89903	29,89903	29,89903	29,89903	29,89903	29,89903	29,89903	29,89903
Data S.D	6,54539	6,54539	6,54539	6,54539	6,54539	6,54539	6,54539	6,54539	6,54539	6,54539
Error Mean	0,02816	0,02843	0,02751	0,01209	0,03709	0,11320	0,11259	0,05891	0,05153	0,01076
Error S.D.	0,76596	0,76639	0,80208	0,80179	0,77334	0,69857	0,68247	0,80262	0,77511	0,76265
Abs. E. Mean	0,53047	0,53061	0,57106	0,55883	0,54246	0,48559	0,47056	0,58872	0,59312	0,56087
S.D. Ratio	0,11702	0,11709	0,12254	0,12250	0,11815	0,10673	0,10427	0,12262	0,11842	0,11652
Correlation	0,99318	0,99317	0,99269	0,99251	0,99303	0,99447	0,99474	0,99261	0,99306	0,99325

Exercício 12

	Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1	RBF s3 1:3-7-1:1	0,306580	0,303120	0,336507	0,176377	0,167262	0,186443	KM,KN,PI	1	7	0
2	GRNN s10 1:10-248-2-1:1	0,018453	0,301226	0,322911	0,010616	0,165968	0,178872	SS	1	248	2
3	GRNN s10 1:10-248-2-1:1	0,035300	0,300619	0,314330	0,020309	0,165630	0,174116	SS	1	248	2
4	RBF s5 1:5-7-1:1	0,290806	0,292458	0,332460	0,167302	0,162779	0,184670	KM,KN,PI	1	7	0
5	Linear s6 1:6-1:1	0,244513	0,236306	0,279559	0,045516	0,043439	0,050112	PI	1	0	0
6	Linear s9 1:9-1:1	0,236899	0,235663	0,248793	0,044099	0,043302	0,044660	PI	1	0	0
7	Linear s10 1:10-1:1	0,218552	0,229406	0,233230	0,040684	0,042246	0,042046	PI	1	0	0
8	MLP s10 1:10-1-1:1	0,250816	0,239475	0,271441	0,037387	0,034547	0,038964	BP100,CG58b	1	1	0
9	MLP s10 1:10-2-1:1	0,238537	0,226670	0,270045	0,035528	0,033086	0,038849	BP100,CG36b	1	2	0
10	MLP s10 1:10-5-1:1	0,212976	0,218907	0,230048	0,031753	0,032050	0,033033	BP100,CG65b	1	5	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	5,762955	5,762955	5,762955	5,762955	5,762955	5,762955	5,762955	5,762955	5,762955	5,762955
Data S.D	1,697338	1,697338	1,697338	1,697338	1,697338	1,697338	1,697338	1,697338	1,697338	1,697338
Error Mean	-0,003928	-0,000408	0,000137	0,027613	0,026234	0,030009	0,035002	0,010943	0,033013	0,017197
Error S.D.	0,531841	0,367089	0,363428	0,512942	0,428928	0,408497	0,383597	0,431225	0,414927	0,373351
Abs. E. Mean	0,421385	0,191899	0,197876	0,386457	0,313172	0,306504	0,296646	0,327629	0,315775	0,284667
S.D. Ratio	0,313338	0,216273	0,214116	0,302204	0,252706	0,240669	0,225999	0,254059	0,244458	0,219963
Correlation	0,949696	0,976338	0,976833	0,953620	0,967591	0,970617	0,974165	0,967189	0,969709	0,975510

Exercício 13

Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 Linear s8 1:8-1:1	0,420748	0,306848	0,427368	0,101342	0,087554	0,114350	PI	1	0	0
2 Linear s9 1:9-1:1	0,408834	0,301169	0,404611	0,098472	0,086073	0,107779	PI	1	0	0
3 MLP s9 1:9-3-1:1	0,329462	0,246626	0,408321	0,063520	0,056294	0,086759	BP100,CG56b	1	3	0
4 MLP s9 1:9-4-1:1	0,347219	0,233449	0,383291	0,066922	0,053415	0,082037	BP100,CG63b	1	4	0
5 MLP s9 1:9-5-1:1	0,316145	0,226650	0,385265	0,060918	0,051788	0,081419	BP100,CG45b	1	5	0
6 GRNN s11 1:11-150-2-1:1	0,260654	0,447113	0,665333	0,006822	0,013936	0,018946	SS	1	150	2
7 GRNN s11 1:11-150-2-1:1	0,249407	0,447167	0,668754	0,006527	0,013933	0,019035	SS	1	150	2
8 RBF s10 1:10-19-1:1	0,404107	0,383269	0,515022	0,010575	0,011892	0,014771	KM,KN,PI	1	19	0
9 RBF s10 1:10-20-1:1	0,427660	0,367456	0,526415	0,011191	0,011395	0,015038	KM,KN,PI	1	20	0
10 RBF s10 1:10-21-1:1	0,390379	0,329138	0,440020	0,010215	0,010202	0,012764	KM,KN,PI	1	21	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	51,45612	51,45612	51,45612	51,45612	51,45612	51,45612	51,45612	51,45612	51,45612	51,45612
Data S.D	40,62706	40,62706	40,62706	40,62706	40,62706	40,62706	40,62706	40,62706	40,62706	40,62706
Error Mean	-0,90160	-0,61862	-1,00714	-0,82650	-0,47593	-1,15339	-1,09291	-0,94986	-0,48773	-0,96412
Error S.D.	15,98432	15,43440	13,43635	13,38197	12,71796	18,26702	18,20191	17,44908	17,82303	15,77031
Abs. E. Mean	12,08280	11,67358	9,95236	10,11482	9,56205	11,65905	11,51911	12,39802	12,56953	11,59372
S.D. Ratio	0,39344	0,37990	0,33072	0,32939	0,31304	0,44963	0,44802	0,42949	0,43870	0,38817
Correlation	0,91987	0,92568	0,94447	0,94540	0,94984	0,89652	0,89685	0,90548	0,89994	0,92351

Exercício 14

Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 GRNN s12 1:12-38-2-1:1	0,323678	0,521067	0,412323	0,153306	0,271905	0,190317	SS	1	38	2
2 GRNN s12 1:12-38-2-1:1	0,337345	0,523957	0,416742	0,159798	0,271902	0,192523	SS	1	38	2
3 GRNN s12 1:12-38-2-1:1	0,327678	0,521874	0,413577	0,155206	0,271882	0,190945	SS	1	38	2
4 RBF s12 1:12-7-1:1	0,380524	0,485996	0,481567	0,179819	0,238920	0,216619	KM,KN,PI	1	7	0
5 RBF s12 1:12-5-1:1	0,460303	0,465328	0,471163	0,217519	0,226802	0,214509	KM,KN,PI	1	5	0
6 RBF s12 1:12-8-1:1	0,410477	0,353230	0,308105	0,193974	0,186498	0,140649	KM,KN,PI	1	8	0
7 Linear s12 1:12-1:1	0,317769	0,610813	0,555739	0,078554	0,167393	0,131243	PI	1	0	0
8 MLP s12 1:12-1-1-1:1	0,450197	0,304438	0,481027	0,089496	0,060183	0,091810	BP100,CG29b	1	1	1
9 MLP s12 1:12-8-1:1	0,612083	0,252697	0,410404	0,121066	0,049713	0,081706	BP17b	1	8	0
10 MLP s12 1:12-8-8-1:1	0,570197	0,218747	0,396754	0,112838	0,043918	0,076804	BP21b	1	8	8

	1	2	3	4	5	6	7	8	9	10
Data Mean	10,98942	10,98942	10,98942	10,98942	10,98942	10,98942	10,98942	10,98942	10,98942	10,98942
Data S.D	2,05057	2,05057	2,05057	2,05057	2,05057	2,05057	2,05057	2,05057	2,05057	2,05057
Error Mean	-0,10080	-0,09826	-0,10006	-0,06250	-0,02656	-0,06207	-0,12102	0,07348	0,07419	0,04413
Error S.D.	0,84861	0,86303	0,85275	0,88736	0,95473	0,78652	0,97662	0,87312	1,03375	0,96339
Abs. E. Mean	0,63583	0,65139	0,64040	0,65310	0,76338	0,57975	0,67666	0,66453	0,79595	0,73001
S.D. Ratio	0,41384	0,42087	0,41586	0,43274	0,46559	0,38356	0,47627	0,42579	0,50413	0,46982
Correlation	0,92527	0,92449	0,92504	0,90167	0,88542	0,92354	0,88058	0,90677	0,87089	0,88595

Exercício 15

	Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1	GRNN s12 1:12-44-2-1:1	0,108799	0,347742	0,226972	0,045232	0,191551	0,120720	SS	1	44	2
2	GRNN s12 1:12-44-2-1:1	0,111333	0,347606	0,226995	0,046285	0,191504	0,120736	SS	1	44	2
3	GRNN s12 1:12-44-2-1:1	0,117264	0,347506	0,227164	0,048751	0,191504	0,120836	SS	1	44	2
4	RBF s12 1:12-18-1:1	0,196624	0,238967	0,255796	0,081732	0,129482	0,135986	KM,KN,PI	1	18	0
5	RBF s12 1:12-21-1:1	0,195182	0,207181	0,258386	0,081133	0,112293	0,137343	KM,KN,PI	1	21	0
6	RBF s12 1:12-24-1:1	0,187578	0,182360	0,270192	0,077972	0,098810	0,143817	KM,KN,PI	1	24	0
7	Linear s12 1:12-1:1	0,281438	0,336728	0,315300	0,057955	0,091785	0,083022	PI	1	0	0
8	MLP s12 1:12-1-1-1:1	0,292443	0,273215	0,308170	0,048222	0,059014	0,065043	BP100,CG23b	1	1	1
9	MLP s12 1:12-3-1:1	0,142974	0,195882	0,296223	0,023553	0,042354	0,063599	BP100,CG50b	1	3	0
10	MLP s12 1:12-5-1:1	0,146596	0,159394	0,254489	0,024159	0,034266	0,054714	BP100,CG70b	1	5	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	4,992726	4,992726	4,992726	4,992726	4,992726	4,992726	4,992726	4,992726	4,992726	4,992726
Data S.D	2,700585	2,700585	2,700585	2,700585	2,700585	2,700585	2,700585	2,700585	2,700585	2,700585
Error Mean	-0,038180	-0,038141	-0,038048	0,004527	-0,001716	0,011007	-0,044943	-0,023291	0,059016	0,036645
Error S.D.	0,650599	0,651762	0,654911	0,616808	0,591613	0,577621	0,838258	0,788391	0,582096	0,512863
Abs. E. Mean	0,410844	0,413836	0,421225	0,445005	0,420782	0,400818	0,626212	0,584482	0,441709	0,377480
S.D. Ratio	0,240910	0,241341	0,242507	0,228398	0,219068	0,213887	0,310399	0,291933	0,215544	0,189908
Correlation	0,973010	0,972974	0,972878	0,975022	0,976292	0,977278	0,952642	0,956864	0,976514	0,981806

Exercício 16

	Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1	Linear s12 1:12-1:1	0,137327	0,610017	1,468414	0,039348	0,094178	0,140639	PI	1	0	0
2	MLP s12 1:12-5-1:1	0,151622	0,192832	1,425734	0,043461	0,029160	0,138866	BP100,CG28b	1	5	0
3	MLP s12 1:12-6-1:1	0,334450	0,092690	1,164604	0,096020	0,020516	0,116353	BP100,CG22b	1	6	0
4	MLP s12 1:12-8-5-1:1	0,181500	0,117563	1,460624	0,052161	0,018090	0,140991	BP100,CG23b	1	8	5
5	RBF s12 1:12-1-1:1	0,980945	1,107432	0,829682	0,002699	0,002192	0,001815	KM,KN,PI	1	1	0
6	GRNN s12 1:12-22-2-1:1	0,137214	0,353935	1,490657	0,000377	0,000599	0,001386	SS	1	22	2
7	GRNN s12 1:12-22-2-1:1	0,128264	0,355827	1,503136	0,000353	0,000599	0,001395	SS	1	22	2
8	GRNN s12 1:12-22-2-1:1	0,133533	0,354637	1,495991	0,000367	0,000599	0,001390	SS	1	22	2
9	RBF s12 1:12-2-1:1	0,288283	0,395129	1,364134	0,000793	0,000572	0,001260	KM,KN,PI	1	2	0
10	RBF s12 1:12-4-1:1	0,241497	0,338238	0,999203	0,000664	0,000525	0,000921	KM,KN,PI	1	4	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	593,7778	593,7778	593,7778	593,7778	593,7778	593,7778	593,7778	593,7778	593,7778	593,7778
Data S.D	309,6422	309,6422	309,6422	309,6422	309,6422	309,6422	309,6422	309,6422	309,6422	309,6422
Error Mean	-7,5713	-6,4238	7,0480	8,5713	77,4850	12,9791	12,3627	12,7205	5,3028	6,8395
Error S.D.	97,4663	85,9823	110,4250	90,1482	299,7644	90,9605	90,4704	90,7555	109,5874	87,8532
Abs. E. Mean	67,5485	59,2595	78,2609	57,1418	266,4232	52,7162	51,6650	52,2466	88,6012	66,8843
S.D. Ratio	0,3148	0,2777	0,3566	0,2911	0,9681	0,2938	0,2922	0,2931	0,3539	0,2837
Correlation	0,9574	0,9648	0,9374	0,9574	0,2520	0,9561	0,9568	0,9564	0,9386	0,9596

Exercício 17

Profile	Train. Perf.	Selesct Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 Linear s2 1:2-1:1	0,297182	0,495028	0,285679	0,085637	0,146668	0,074235	PI	1	0	0
2 Linear s3 1:3-1:1	0,296124	0,491838	0,289051	0,085332	0,146104	0,074964	PI	1	0	0
3 RBF s6 1:6-3-1:1	0,381118	0,533281	0,255186	0,051529	0,073375	0,035003	KM,KN,PI	1	3	0
4 GRNN s10 1:10-22-2-1:1	0,211028	0,522347	0,208957	0,028608	0,072381	0,025938	SS	1	22	2
5 GRNN s10 1:10-22-2-1:1	0,217701	0,522573	0,210553	0,029510	0,072374	0,026752	SS	1	22	2
6 RBF s5 1:5-4-1:1	0,291561	0,497553	0,381252	0,039420	0,068481	0,040841	KM,KN,PI	1	4	0
7 RBF s6 1:6-5-1:1	0,307680	0,318539	0,449478	0,041600	0,044105	0,037028	KM,KN,PI	1	5	0
8 MLP s5 1:5-8-1:1	0,260010	0,138658	0,421213	0,075253	0,042184	0,080090	BP100,CG13b	1	8	0
9 MLP s5 1:5-8-7-1:1	0,224446	0,172676	0,479701	0,053315	0,040736	0,073987	BP100,CG20b	1	8	7
10 MLP s5 1:5-8-8-1:1	0,269065	0,075331	0,487566	0,077977	0,028919	0,082012	BP100,CG11b	1	8	8

	1	2	3	4	5	6	7	8	9	10
Data Mean	92,80000	92,80000	92,80000	92,80000	92,80000	92,80000	92,80000	92,80000	92,80000	92,80000
Data S.D	6,98484	6,98484	6,98484	6,98484	6,98484	6,98484	6,98484	6,98484	6,98484	6,98484
Error Mean	-0,44611	-0,46133	-0,38920	-0,29349	-0,29980	-0,39033	-0,24839	-0,27377	-0,53786	-0,15660
Error S.D.	2,42315	2,41517	2,80804	2,18358	2,20649	2,46545	2,13729	1,70330	1,63778	1,73326
Abs. E. Mean	1,76586	1,75433	2,22726	1,42974	1,47455	1,83164	1,62940	1,42680	1,37962	1,27121
S.D. Ratio	0,34691	0,34577	0,40202	0,31262	0,31590	0,35297	0,30599	0,24386	0,23448	0,24815
Correlation	0,93879	0,93915	0,91578	0,95010	0,94919	0,93641	0,95267	0,96983	0,97218	0,96951

Exercício 18

Profile	Train. Perf.	Selesct Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 Linear s2 1:2-1:1	0,291551	0,377601	0,230584	0,072055	0,074885	0,072929	PI	1	0	0
2 Linear 1:1-1:1	0,302355	0,299096	0,280822	0,074725	0,057857	0,083894	PI	1	0	0
3 MLP s4 1:4-8-8-1:1	0,464256	0,165581	0,436705	0,110588	0,025507	0,153142	BP1b	1	8	8
4 MLP s5 1:5-8-1:1	0,540208	0,157596	0,569849	0,123615	0,024293	0,144837	BP0b	1	8	0
5 RBF s5 1:5-1-1:1	0,991756	0,996818	0,864889	0,000014	0,000012	0,000015	KM,KN,PI	1	1	0
6 RBF s5 1:5-2-1:1	0,431892	0,336707	0,371859	0,000006	0,000004	0,000006	KM,KN,PI	1	2	0
7 RBF s10 1:10-3-1:1	0,365754	0,149202	0,454691	0,000005	0,000002	0,000007	KM,KN,PI	1	3	0
8 GRNN s9 1:9-22-2-1:1	0,127213	0,186536	0,230510	0,000002	0,000002	0,000004	SS	1	22	2
9 GRNN s9 1:9-22-2-1:1	0,111522	0,190914	0,227587	0,000002	0,000002	0,000004	SS	1	22	2
10 GRNN s9 1:9-22-2-1:1	0,116250	0,189155	0,228115	0,000002	0,000002	0,000004	SS	1	22	2

	1	2	3	4	5	6	7	8	9	10
Data Mean	822829,4	822829,4	822829,4	822829,4	822829,4	822829,4	822829,4	822829,4	822829,4	822829,4
Data S.D	70535,8	70535,8	70535,8	70535,8	70535,8	70535,8	70535,8	70535,8	70535,8	70535,8
Error Mean	3367,5	1632,1	20790,3	17261,5	2944,5	-427,8	-1954,4	330,9	457,6	417,4
Error S.D.	19777,8	20173,1	31712,3	35651,5	66362,9	27813,8	25114,4	12005,8	11493,9	11629,6
Abs. E. Mean	15134,4	15031,7	26743,6	26170,2	56774,3	20619,6	15940,6	7590,9	7141,6	7268,1
S.D. Ratio	0,3	0,3	0,4	0,5	0,9	0,4	0,4	0,2	0,2	0,2
Correlation	1,0	1,0	0,9	0,9	0,5	0,9	0,9	1,0	1,0	1,0

Exercício 19

Profile	Train. Perf.	Selesct Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 Linear s4 1:4-1:1	0,023888	0,049554	0,031013	0,007626	0,011654	0,005671	PI	1	0	0
2 Linear s3 1:3-1:1	0,023949	0,049529	0,031682	0,007645	0,011599	0,005754	PI	1	0	0
3 MLP s5 1:5-8-1:1	0,053085	0,035697	0,057522	0,013841	0,007002	0,010658	BP100,CG8b	1	8	0
4 MLP s3 1:3-5-5-1:1	0,061262	0,030312	0,079282	0,016440	0,005764	0,012188	BP100,CG34b	1	5	5
5 MLP s3 1:3-8-7-1:1	0,054162	0,026265	0,066911	0,013924	0,004862	0,010419	BP100,CG26b	1	8	7
6 GRNN s10 1:10-19-2-1:1	0,097399	0,069807	0,139213	0,005668	0,003808	0,004637	SS	1	19	2
7 GRNN s10 1:10-19-2-1:1	0,095842	0,071015	0,138078	0,005577	0,003806	0,004602	SS	1	19	2
8 RBF s3 1:3-7-1:1	0,022425	0,055572	0,064400	0,001305	0,002321	0,002339	KM,KN,PI	1	7	0
9 RBF s3 1:3-8-1:1	0,021600	0,051226	0,057571	0,001257	0,002149	0,002053	KM,KN,PI	1	8	0
10 RBF s3 1:3-10-1:1	0,017759	0,043562	0,071570	0,001033	0,001876	0,002895	KM,KN,PI	1	10	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	348,0114	348,0114	348,0114	348,0114	348,0114	348,0114	348,0114	348,0114	348,0114	348,0114
Data S.D	15,1370	15,1370	15,1370	15,1370	15,1370	15,1370	15,1370	15,1370	15,1370	15,1370
Error Mean	0,0222	0,0232	-0,2304	0,2579	-0,1225	-0,1359	-0,1292	0,0731	0,0663	0,0770
Error S.D.	0,4261	0,4263	0,7217	0,8360	0,7320	1,4116	1,3946	0,5113	0,4701	0,5025
Abs. E. Mean	0,3271	0,3247	0,5843	0,6619	0,5531	1,1104	1,1080	0,4039	0,3760	0,3931
S.D. Ratio	0,0281	0,0282	0,0477	0,0552	0,0484	0,0933	0,0921	0,0338	0,0311	0,0332
Correlation	0,9996	0,9996	0,9989	0,9987	0,9989	0,9961	0,9962	0,9994	0,9995	0,9995

Exercício 20

Profile	Train. Perf.	Selesct Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 Linear s2 1:2-1:1	0,114044	0,009388	3,283219	0,035963	0,085587	0,043276	PI	1	0	0
2 Linear 1:1-1:1	0,148777	0,093304	3,091374	0,046916	0,050240	0,048848	PI	1	0	0
3 MLP s5 1:5-1-1:1	0,169701	0,008759	0,319498	0,043378	0,001417	0,024809	BP100,CG23b	1	1	0
4 RBF s3 1:3-2-1:1	0,194049	0,053393	2,219655	0,002150	0,000311	0,002846	KM,KN,PI	1	2	0
5 GRNN s10 1:10-8-2-1:1	0,000004	0,010996	1,651219	0,000000	0,000171	0,000769	SS	1	8	2
6 RBF s3 1:3-3-1:1	0,168242	0,025167	1,608594	0,001864	0,000169	0,000954	KM,KN,PI	1	3	0
7 GRNN s10 1:10-8-2-1:1	0,000024	0,010567	1,599601	0,000000	0,000105	0,000748	SS	1	8	2
8 MLP s5 1:5-2-1:1	0,156786	0,000172	0,073308	0,039838	0,000073	0,024690	BP100,CG21b	1	2	0
9 GRNN s10 1:10-8-2-1:1	0,000015	0,010699	1,613190	0,000000	0,000060	0,000753	SS	1	8	2
10 MLP s5 1:5-8-1:1	0,196641	0,000335	2,911188	0,063823	0,000049	0,046519	BP10b	1	8	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	554,1583	554,1583	554,1583	554,1583	554,1583	554,1583	554,1583	554,1583	554,1583	554,1583
Data S.D	83,4313	83,4313	83,4313	83,4313	83,4313	83,4313	83,4313	83,4313	83,4313	83,4313
Error Mean	-3,5401	-3,1420	-0,1254	2,9804	0,0997	0,8364	-0,2263	2,2755	-0,1398	3,6192
Error S.D.	11,7324	11,5519	11,5310	14,7313	2,2884	11,1757	2,1845	10,4130	2,1932	13,4082
Abs. E. Mean	10,9068	10,2771	9,6581	12,2935	1,0998	8,1003	0,9867	8,4961	0,9533	10,0937
S.D. Ratio	0,1406	0,1385	0,1382	0,1766	0,0274	0,1340	0,0262	0,1248	0,0263	0,1607
Correlation	0,9908	0,9904	0,9904	0,9849	0,9996	0,9910	0,9997	0,9922	0,9997	0,9871

Exercício 21

Current

Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 Linear s7 1:7-1:1	0,010034	0,017420	0,031156	0,002836	0,006490	0,012609	PI	1	0	0
2 Linear s6 1:6-1:1	0,010167	0,016847	0,030897	0,002874	0,006405	0,012811	PI	1	0	0
3 MLP s3 1:3-8-5-1:1	0,022772	0,008442	0,033676	0,005158	0,002291	0,009777	BP100,CG33b	1	8	5
4 MLP s3 1:3-8-6-1:1	0,024145	0,008057	0,034466	0,005483	0,002155	0,009857	BP100,CG28b	1	8	6
5 MLP s3 1:3-8-8-1:1	0,023832	0,007136	0,037267	0,005401	0,001927	0,010766	BP100,CG17b	1	8	8
6 GRNN s10 1:10-34-2-1:1	0,080827	0,065873	0,090163	0,000029	0,000029	0,000041	SS	1	34	2
7 GRNN s10 1:10-34-2-1:1	0,079068	0,065826	0,089482	0,000028	0,000028	0,000041	SS	1	34	2
8 RBF s5 1:5-4-1:1	0,014689	0,011903	0,039731	0,000005	0,000005	0,000019	KM,KN,PI	1	4	0
9 RBF s5 1:5-12-1:1	0,008583	0,010637	0,028750	0,000003	0,000004	0,000013	KM,KN,PI	1	12	0
10 RBF s5 1:5-10-1:1	0,010163	0,010188	0,024862	0,000004	0,000004	0,000011	KM,KN,PI	1	10	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	2725,103	2725,103	2725,103	2725,103	2725,103	2725,103	2725,103	2725,103	2725,103	2725,103
Data S.D	3045,330	3045,330	3045,330	3045,330	3045,330	3045,330	3045,330	3045,330	3045,330	3045,330
Error Mean	21,077	22,711	-7,946	-8,162	-8,828	-29,024	-28,582	15,513	6,725	1,651
Error S.D.	66,452	66,668	74,271	76,271	79,708	248,760	245,703	78,272	54,426	48,790
Abs. E. Mean	38,492	39,223	41,379	47,535	44,517	206,276	203,233	42,961	31,101	28,717
S.D. Ratio	0,022	0,022	0,024	0,025	0,026	0,082	0,081	0,026	0,018	0,016
Correlation	1,000	1,000	1,000	1,000	1,000	0,997	0,997	1,000	1,000	1,000

Exercício 22

Real

Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 Linear s5 1:5-1:1	0,043339	0,029695	0,033334	0,012291	0,009905	0,009262	PI	1	0	0
2 Linear s3 1:3-1:1	0,047438	0,028404	0,024146	0,013454	0,009628	0,007304	PI	1	0	0
3 MLP s5 1:5-3-1:1	0,051476	0,025696	0,034004	0,014647	0,008148	0,009197	BP100,CG44b	1	3	0
4 MLP s5 1:5-6-1:1	0,051032	0,022065	0,041680	0,014474	0,006507	0,011519	BP100,CG22b	1	6	0
5 MLP s4 1:4-8-5-1:1	0,052792	0,021902	0,039819	0,014973	0,006437	0,010523	BP100,CG23b	1	8	5
6 GRNN s10 1:10-34-2-1:1	0,055344	0,080966	0,081740	0,000022	0,000034	0,000031	SS	1	34	2
7 GRNN s10 1:10-34-2-1:1	0,058226	0,080563	0,084363	0,000023	0,000034	0,000032	SS	1	34	2
8 RBF s5 1:5-5-1:1	0,061570	0,044725	0,055560	0,000025	0,000020	0,000021	KM,KN,PI	1	5	0
9 RBF s5 1:5-7-1:1	0,042825	0,028433	0,035849	0,000017	0,000013	0,000014	KM,KN,PI	1	7	0
10 RBF s5 1:5-8-1:1	0,043377	0,027463	0,035120	0,000017	0,000013	0,000014	KM,KN,PI	1	8	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	4168,988	4168,988	4168,988	4168,988	4168,988	4168,988	4168,988	4168,988	4168,988	4168,988
Data S.D	2411,090	2411,090	2411,090	2411,090	2411,090	2411,090	2411,090	2411,090	2411,090	2411,090
Error Mean	-15,792	-17,228	-5,505	-9,071	-3,316	-5,438	-6,111	-9,254	-14,912	-15,313
Error S.D.	93,486	95,941	104,181	104,959	106,147	165,714	170,198	136,792	93,000	93,124
Abs. E. Mean	78,547	80,261	83,879	82,725	84,734	130,565	134,934	113,174	74,667	77,472
S.D. Ratio	0,039	0,040	0,043	0,044	0,044	0,069	0,071	0,057	0,039	0,039
Correlation	0,999	0,999	0,999	0,999	0,999	0,998	0,998	0,998	0,999	0,999

Exercício 23

Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 Linear s4 1:4-1:1	0,088333	0,133572	0,106655	0,025053	0,036947	0,039801	PI	1	0	0
2 Linear s3 1:3-1:1	0,089426	0,131456	0,103093	0,025363	0,036139	0,038584	PI	1	0	0
3 MLP s5 1:5-1:1:1	0,113861	0,121163	0,094277	0,032319	0,032674	0,037683	BP100,CG55b	1	1	0
4 MLP s5 1:5-8-5-1:1	0,098758	0,095917	0,105738	0,022439	0,022601	0,031770	BP100,CG37b	1	8	5
5 RBF s6 1:6-2-1:1	0,255784	0,289194	0,284844	0,000000	0,000000	0,000000	KM,KN,PI	1	2	0
6 RBF s5 1:5-3-1:1	0,131958	0,170695	0,149674	0,000000	0,000000	0,000000	KM,KN,PI	1	3	0
7 GRNN s10 1:10-25-2-1:1	0,050405	0,165957	0,120254	0,000000	0,000000	0,000000	SS	1	25	2
8 GRNN s10 1:10-25-2-1:1	0,041678	0,165731	0,111805	0,000000	0,000000	0,000000	SS	1	25	2
9 GRNN s10 1:10-25-2-1:1	0,046674	0,165768	0,116863	0,000000	0,000000	0,000000	SS	1	25	2
10 RBF s6 1:6-4-1:1	0,149031	0,143510	0,123050	0,000000	0,000000	0,000000	KM,KN,PI	1	4	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	76659355	76659355	76659355	76659355	76659355	76659355	76659355	76659355	76659355	76659355
Data S.D	16068410	16068410	16068410	16068410	16068410	16068410	16068410	16068410	16068410	16068410
Error Mean	-131144	-138334	-171585	-160869	490910	-16947	295871	288332	293991	56413
Error S.D.	1677729	1654052	1765501	1633596	4398412	2331313	1737786	1651185	1701359	2232243
Abs. E. Mean	1371210	1355443	1351511	1275762	3363305	1742406	1175611	1096543	1143003	1647935
S.D. Ratio	0	0	0	0	0	0	0	0	0	0
Correlation	1	1	1	1	1	1	1	1	1	1

Exercício 24

Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 Linear s3 1:3-1:1	0,137826	0,238720	0,133476	0,044592	0,070417	0,043329	PI	1	0	0
2 Linear s4 1:4-1:1	0,137587	0,237568	0,135660	0,044514	0,070416	0,043800	PI	1	0	0
3 MLP s4 1:4-8-1:1	0,197861	0,080133	0,253126	0,056262	0,019544	0,066459	BP100b	1	8	0
4 MLP s4 1:4-8-8-1:1	0,186077	0,078075	0,213242	0,048698	0,018898	0,054995	BP100,CG6b	1	8	8
5 RBF s5 1:5-1-1:1	0,871931	0,823407	0,773775	0,000004	0,000004	0,000003	KM,KN,PI	1	1	0
6 GRNN s9 1:9-25-2-1:1	0,106755	0,193722	0,183108	0,000000	0,000001	0,000001	SS	1	25	2
7 GRNN s9 1:9-25-2-1:1	0,099262	0,193841	0,181571	0,000000	0,000001	0,000001	SS	1	25	2
8 GRNN s9 1:9-25-2-1:1	0,101486	0,193741	0,182017	0,000000	0,000001	0,000001	SS	1	25	2
9 RBF s3 1:3-2-1:1	0,185142	0,109212	0,216186	0,000001	0,000000	0,000001	KM,KN,PI	1	2	0
10 RBF s3 1:3-2-1:1	0,185142	0,109212	0,216186	0,000001	0,000000	0,000001	KM,KN,PI	1	2	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	795641,3	795641,3	795641,3	795641,3	795641,3	795641,3	795641,3	795641,3	795641,3	795641,3
Data S.D	237077,8	237077,8	237077,8	237077,8	237077,8	237077,8	237077,8	237077,8	237077,8	237077,8
Error Mean	5518,4	5645,3	-12629,0	-3004,4	-35213,0	2744,1	2541,8	2603,0	6187,4	6187,4
Error S.D.	38506,7	38324,5	44979,4	41449,9	197509,2	34416,9	33571,4	33815,9	42132,6	42132,6
Abs. E. Mean	28911,4	29189,4	38830,3	32602,3	180764,3	25311,7	24325,5	24622,7	33143,6	33143,6
S.D. Ratio	0,2	0,2	0,2	0,2	0,8	0,1	0,1	0,1	0,2	0,2
Correlation	1,0	1,0	1,0	1,0	0,6	1,0	1,0	1,0	1,0	1,0

Exercício 25

Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Mem	Inputs	Hidden(1)	Hidden(2)
1 RBF s4 1:4-1-1:1	0,724612	0,998890	1,021902	0,196394	0,253140	0,282807	KM,KN,PI	1	1	0
2 RBF s4 1:4-2-1:1	0,606191	0,794431	0,494305	0,164298	0,179349	0,139676	KM,KN,PI	1	2	0
3 GRNN s4 1:4-15-2-1:1	0,679449	0,588451	0,644724	0,185307	0,171336	0,183890	SS	1	15	2
4 GRNN s4 1:4-15-2-1:1	0,674098	0,587372	0,640007	0,183835	0,171322	0,182547	SS	1	15	2
5 GRNN s4 1:4-15-2-1:1	0,675671	0,587652	0,641387	0,184268	0,171320	0,182941	SS	1	15	2
6 Linear 1:1-1:1	0,761766	0,580572	0,372042	0,191476	0,128332	0,131293	PI	1	0	0
7 Linear s2 1:2-1:1	0,687108	0,485068	0,482980	0,172710	0,122653	0,128559	PI	1	0	0
8 MLP s5 1:5-1-1:1	0,652106	0,605006	0,556758	0,173564	0,066510	0,171421	BP100,CG20b	1	1	0
9 MLP s5 1:5-8-1:1	1,044188	0,153906	0,965113	0,268256	0,020758	0,248342	BP13b	1	8	0
10 MLP s5 1:5-8-1:1	1,046621	0,116524	0,644935	0,276345	0,020038	0,167870	BP2b	1	8	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	10,67667	10,67667	10,67667	10,67667	10,67667	10,67667	10,67667	10,67667	10,67667	10,67667
Data S.D	3,94019	3,94019	3,94019	3,94019	3,94019	3,94019	3,94019	3,94019	3,94019	3,94019
Error Mean	0,62377	0,25932	-0,36959	-0,35627	-0,36022	-0,24610	-0,00524	-2,05702	-0,64697	-1,22825
Error S.D.	2,87706	2,00755	2,45130	2,42995	2,43620	2,39949	2,21274	2,39112	3,23849	3,27900
Abs. E. Mean	2,36678	1,66405	1,92045	1,89950	1,90567	1,92555	1,72163	2,47865	2,47876	2,60551
S.D. Ratio	0,73018	0,50950	0,62213	0,61671	0,61830	0,60898	0,56158	0,60685	0,82191	0,83219
Correlation	0,70359	0,86049	0,86940	0,86957	0,86952	0,79776	0,82904	0,87043	0,62829	0,58139

Exercício 26

Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1 Linear s2 1:2-1:1	0,206738	1,108655	2,702681	0,077851	0,289174	0,325949	PI	1	0	0
2 Linear 1:1-1:1	0,210312	1,254604	3,349213	0,079197	0,251545	0,288570	PI	1	0	0
3 MLP s5 1:5-8-8-1:1	0,121586	0,003106	3,184891	0,046891	0,000524	0,239090	BP87b	1	8	8
4 MLP s5 1:5-8-8-1:1	0,201447	0,002104	0,380896	0,076725	0,000374	0,145457	BP54b	1	8	8
5 RBF s5 1:5-1-1:1	0,885734	2,034936	7,504297	0,000015	0,000020	0,000019	KM,KN,PI	1	1	0
6 GRNN s10 1:10-6-2-1:1	0,182197	1,190629	5,051707	0,000003	0,000009	0,000012	SS	1	6	2
7 GRNN s10 1:10-6-2-1:1	0,187426	1,190505	5,064763	0,000003	0,000009	0,000012	SS	1	6	2
8 GRNN s10 1:10-6-2-1:1	0,185513	1,190516	5,059519	0,000003	0,000009	0,000012	SS	1	6	2
9 RBF s5 1:5-2-1:1	0,107544	0,564775	0,406897	0,000002	0,000007	0,000011	KM,KN,PI	1	2	0
10 RBF s5 1:5-2-1:1	0,107544	0,564775	0,406897	0,000002	0,000007	0,000011	KM,KN,PI	1	2	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	227378,8	227378,8	227378,8	227378,8	227378,8	227378,8	227378,8	227378,8	227378,8	227378,8
Data S.D	50630,7	50630,7	50630,7	50630,7	50630,7	50630,7	50630,7	50630,7	50630,7	50630,7
Error Mean	-13742,7	-10436,7	-4323,6	-2829,4	-14349,7	-5877,5	-5913,1	-5899,2	-9242,4	-9242,4
Error S.D.	22271,1	20867,0	13827,5	10944,3	45524,2	19186,0	19279,2	19243,7	13711,0	13711,0
Abs. E. Mean	18869,4	17107,0	8119,9	8306,0	37822,0	14727,3	14901,0	14836,5	11468,5	11468,5
S.D. Ratio	0,4	0,4	0,3	0,2	0,9	0,4	0,4	0,4	0,3	0,3
Correlation	0,9	0,9	1,0	1,0	0,5	0,9	0,9	0,9	1,0	1,0

Exercício 27

	Profile	Train. Perf.	Select Perf.	Test Perf.	Train error	Select error	Test error	Training/ Members	Inputs	Hidden(1)	Hidden(2)
1	Linear s2 1:2-1:1	0,217484	0,073456	0,075775	0,072041	0,093302	0,025722	PI	1	0	0
2	Linear 1:1-1:1	0,222678	0,081878	0,078682	0,073761	0,085849	0,020243	PI	1	0	0
3	MLP s5 1:5-8-1:1	0,293978	0,004574	0,116497	0,083207	0,000183	0,041901	BP58b	1	8	0
4	MLP s5 1:5-8-1:1	0,494686	0,000546	0,967338	0,165225	0,000112	0,157663	BP2b	1	8	0
5	RBF 1:1-1-1:1	0,879881	0,303493	1,502807	0,000071	0,000092	0,000033	KM,KN,PI	1	1	0
6	GRNN s10 1:10-6-2-1:1	0,060919	1,803930	0,142182	0,000005	0,000036	0,000003	SS	1	6	2
7	GRNN s10 1:10-6-2-1:1	0,063473	1,712233	0,150105	0,000005	0,000036	0,000003	SS	1	6	2
8	GRNN s10 1:10-6-2-1:1	0,061627	1,776656	0,144561	0,000005	0,000036	0,000003	SS	1	6	2
9	RBF 1:1-2-1:1	0,282482	0,176717	0,173768	0,000023	0,000016	0,000015	KM,KN,PI	1	2	0
10	RBF 1:1-2-1:1	0,282482	0,176717	0,173768	0,000023	0,000016	0,000015	KM,KN,PI	1	2	0

	1	2	3	4	5	6	7	8	9	10
Data Mean	284602,9	284602,9	284602,9	284602,9	284602,9	284602,9	284602,9	284602,9	284602,9	284602,9
Data S.D	10578,3	10578,3	10578,3	10578,3	10578,3	10578,3	10578,3	10578,3	10578,3	10578,3
Error Mean	739,4	656,1	-366,2	-1219,8	2447,9	847,7	862,5	852,0	785,5	785,5
Error S.D.	2084,5	2073,1	2602,1	4410,8	8698,9	1999,1	1998,9	1998,6	2477,5	2477,5
Abs. E. Mean	1641,1	1597,6	1834,9	3457,4	8034,1	1247,9	1271,4	1254,8	2263,2	2263,2
S.D. Ratio	0,2	0,2	0,2	0,4	0,8	0,2	0,2	0,2	0,2	0,2
Correlation	1,0	1,0	1,0	0,9	0,6	1,0	1,0	1,0	1,0	1,0

REFERÊNCIAS

- ADAMOWSKI, J. et al. Comparison of multiple linear and nonlinear regression, autoregressive integrated moving average, artificial neural network, and wavelet artificial neural network methods for urban water demand forecasting in Montreal, Canada. **Water Resources Research**, v. 48, n. 1, p. 1–14, 2012.
- ADEBIYI, A. A.; ADEWUMI, A. O.; AYO, C. K. Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction. v. 2014, p. 9–11, 2014.
- AMEDI, H. R.; BAGHBAN, A.; AHMADI, M. A. Evolving machine learning models to predict hydrogen sulfide solubility in the presence of various ionic liquids. **Journal of Molecular Liquids**, v. 216, p. 411–422, 2016.
- BABU, C. N.; REDDY, B. E. A moving-average filter based hybrid ARIMA – ANN model for forecasting time series data. **Applied Soft Computing Journal**, v. 23, p. 27–38, 2014.
- BABU, C. N.; REDDY, B. E. Performance Comparison of Four New ARIMA-ANN Prediction Models on Internet Traffic Data. **Journal of telecommunications and information technology**, 2015.
- BASHEER, I. A.; HAJMEER, M. Artificial neural networks : fundamentals , computing , design , and application. v. 43, p. 3–31, 2000.
- BERTRAND, J. WILL, FRANSOO, J. C. Operations Management Research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, v. 22, n. 2, p. 241–264, 2002.
- BISHOP, C. M. **Neural Networks for Pattern Recognition**. 1a. ed. [s.l.] Clarendon Press, 1995.
- BOX, G. E. P.; JENKINS, G. M. **Time series analysis: Forecasting and control**. San Francisco: Holden Day, 1970.
- BOX, G. E. P.; JENKINS, G. M. **Time series analysis: Forecasting and control**. 2a. ed. San Francisco: Holden-Day, 1976.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. 4a. ed. [s.l.] Wiley, 2008.

- BOX, G. E. P.; PIERCE, D. A. Distribution of residual correlations in autoregressive-integrated moving average time series models. **Journal of the American Statistical Association**, v. 65, p. 1509–1526, 1970.
- CADENAS, E.; RIVERA, W. Wind speed forecasting in three different regions of Mexico, using a hybrid ARIMA-ANN model. **Renewable Energy**, v. 35, n. 12, p. 2732–2738, 2010.
- CARDOSO, C. V; CRUZ, G. L. Forecasting Natural Gas Consumption using ARIMA Models and Artificial Neural Networks. **Ieee Latin America Transactions**, v. 14, n. 5, p. 2233–2238, 2016.
- CHEN, A.-S.; LEUNG, M. T.; DAOUK, H. Application of neural networks to an emerging financial market: forecasting and trading the Taiwan Stock Index. **Computers & Operations Research**, v. 30, p. 901– 923, 2003.
- CHEN, K.-Y.; WANG, C.-H. A hybrid SARIMA and support vector machines in forecasting the production values of the machinery industry in Taiwan. **Expert Systems with Applications**, v. 32, p. 254–264, 2007.
- CHUNG, C. A. Simulation modeling handbook: a practical approach. **Florida CRC Press**, 2004.
- DANESE, P.; KALCHSCHMIDT, M. Int . J . Production Economics The role of the forecasting process in improving forecast accuracy and operational performance. **Intern. Journal of Production Economics**, v. 131, n. 1, p. 204–214, 2011.
- DATTA, T.; GHOSH, I. Artificial Neural Network and Time Series Modeling Based Approach to Forecasting the Exchange Rate in a Multivariate Framework. v. 1, n. 5, p. 92–123, 2016.
- DE GOOIJER, J. G.; HYNDMAN, R. J. 25 Years of Time Series Forecasting. **International Journal of Forecasting**, v. 22, n. 3, p. 443–473, 2006.
- DE OLIVEIRA, J. F. L.; LUDERMIR, T. B. A hybrid evolutionary decomposition system for time series forecasting. **Neurocomputing**, v. 180, p. 1–8, 2015.
- DEBBSKA, B.; GUZOWSKA-ŚWIDER, B. Application of artificial neural network in food classification. **Analytica Chimica Acta**, v. 705, n. 1, p. 283–291, 2011.
- EDIGER, V. S.; AKAR, S. ARIMA forecasting of primary energy demand by fuel in Turkey.

v. 35, p. 1701–1708, 2007.

EL DESOUKY, A. A.; ELKATEB, M. M. Hybrid adaptive techniques for electric-load forecast using ANN and ARIMA. **Generation, Transmission and Distribution, IEE Proceedings-**, v. 147, n. 4, p. 213–217, 2000.

FULLER, W. A. **Introduction to Statistical Time Series**. New York: [s.n.].

GAJEWSKI, J.; JONAK, J. Utilisation of neural networks to identify the status of the cutting tool point. **Tunnelling and Underground Space Technology**, v. 21, n. 2, p. 180–184, 2006.

GOLUB, G.; KAHAN, W. Calculating the singular values and pseudo-inverse of a matrix. **J. Siam Number Anal**, v. 2, 1965.

GUJARATI, D. N. **Econometria Basica**. [s.l.: s.n.].

HAYKIN, S. O. **Neural Networks: A Comprehensive Foundation**. 2a. ed. [s.l.] Prentice Hall, 1998.

HIPEL, K. W.; MCLEOD, A. D. Time series modelling of water resources and enviromental systems. **Developments in Water Science**, v. 45, 1994.

HUANG, W.; XU, B.; CHAN-HILTON, A. Forecasting flows in Apalachicola River using neural networks. **Hydrological Processes**, v. 18, n. 13, p. 2545–2564, 2004.

HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. v. 22, p. 679–688, 2006.

KALCHSCHMIDT, M., ZOTTERI, G., VERGANTI, R. Inventory management in a multi-echelon spare parts supply chain. **International Journal of Production Economics**, v. 81/82, n. 165–181, 2003.

KARAMOUZ, M.; ARAGHINEJAD, S. Advance Hydrology. **Amirkabir University of Technology Press**, 2012.

KENDALL, M. G. **Rank correlation methods**. 2a. ed. New York: [s.n.].

LEE, T.-H.; WHITE, H.; GRANGER, C. W. J. Testing for neglected nonlinearity in time series models: A comparison of neural network methods and alternative tests. **Journal of Econometrics**, v. 56, n. 3, p. 269–290, 1993.

LI, P. Structural damage localization using probabilistic neural networks. **Mathematical and**

Computer Modelling, v. 54, n. 3–4, p. 965–969, 2011.

LJUNG, G. M.; BOX, G. E. P. On a measure of lack of fit in time series models. **Biometrika**, v. 65, p. 297–303, 1978.

LÚCIO, P. S. et al. UM MODELO ESTOCÁSTICO COMBINADO DE PREVISÃO SAZONAL PARA A PRECIPITAÇÃO NO BRASIL Coordenação de Desenvolvimento e Pesquisa, Instituto Nacional de Meteorologia (CDP / INMET), Brasília, DF. Departamento de Ciências Atmosféricas, Instituto de Astronom. p. 70–87, 2010.

MAKRIDAKIS, S. WHEELWRIGHT, S. C.; HYDMAN, J. R. **Forecasting methods and applications**. 3a. ed. New Jersey: John Wiley & Sons, 1998.

MANN, H. B. Nonparametric tests against trend. **Econometrica**, v. 13, 1945.

MARTINS, R. A.; MELLO, C. H. P.; TURRIONI, J. B. **Guia para elaboração de monografia e TCC em Engenharia de Produção**. São Paulo: [s.n.].

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

MCLEOD, A. I.; LI, W. K. Diagnostic checking ARMA time series models using squared residual autocorrelations. **Journal of Time Series Analysis**, v. 4, n. 4, p. 269–273, 1983.

MITROFF, I. I.; HLUPIC, V.; PAUL, R. J. On managing science in the systems age: two schemas for the study of science as a whole systems phenomenon. **Interfaces**, v. 4, n. 3, p. 46–58, 1974.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to time series analysis and forecasting**. 2a. ed. New Jersey: Wiley-Interscience, 2008.

MORETTIN, C. M.; TOLOI, P. A. **Previsão de séries temporais**. 2a. ed. São Paulo: Atual Editora, 2006.

OSBORN, D. R.; HERAVI, S.; BIRCHENHALL, C. R. Linear versus neural network forecasting for European industrial production series. **International Journal of Forecasting**, v. 20, p. 435–446, 2004.

PAO, H. Forecasting electricity market pricing using artificial neural networks. v. 48, p. 907–912, 2007.

PIERCE, D. Seasonal adjustment when both deterministic and stochastic seasonality are

present. **Season Analysis of Economic Time Series**, p. 242–269, 1979.

PRIESTLEY, M. B. **Spectral analysis and Time series**. London: Academic Press, 1981.

PRYBUTOK, V. R.; YI, J.; MITCHELL, D. Comparison of neural network models with ARIMA and regression models for prediction of Houston's daily maximum ozone concentrations. v. 122, p. 31–40, 2000.

SAAD, E. W.; PROKHOROV, D. V; WUNSCH, D. C. Comparative Study of Stock Trend Prediction Using Time Delay , Recurrent and. v. 9, n. 6, p. 1456–1470, 1998.

SCHUSTER, A. On the investigation of hidden periodicities with application to a supposed 26 day period of meteorological phenomena. **Ter. Mag. Atmos. Elect.**, v. 3, p. 13–41, 1998.

SEILA, A. F. Introduction to simulation. **Winter Simulation Conference**, 1995.

SPECHT, D. F. A general regression neural network. **Neural Networks, IEEE Transactions on**, v. 2, n. 6, p. 568–576, 1991.

STATSOFT. **Statistica**, 2005.

SWANSON, N. R.; WHITE, H. Forecasting economic time series using flexible versus fixed specification and linear versus nonlinear econometric models. **International Journal of Forecasting**, n. 13, p. 439–461, 1997.

VALIPOUR, M. et al. Comparison of the ARMA , ARIMA , and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir. **Journal of Hydrology**, v. 476, p. 433–441, 2013.

WAGNER, N. et al. Intelligent techniques for forecasting multiple time series in real-world systems. **International Journal of Intelligent Computing and Cybernetics**, v. 4, n. 3, p. 284–310, 2011.

WANG, W. et al. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. **Journal of Hydrology**, v. 374, n. 3–4, p. 294–306, 2009.

WANG, Y. et al. Application of residual modification approach in seasonal ARIMA for electricity demand forecasting : A case study of China. **Energy Policy**, v. 48, p. 284–294, 2012.

WERBOS, P. J. Backpropagation Through Time : What It Does and How to Do It. v. 78, n. October, p. 1550–1560, 1990.

WONGSATHAN, R.; SEEDADAN, I. A hybrid ARIMA and Neural Networks model for PM-10 pollution estimation : The case of Chiang Mai city moat area. v. 86, n. March, p. 273–276, 2016.

YULE, G. U. On the method of investigating periodicities in disturbed series, with special reference to Wolfer's sunspot numbers. **Philosophical Transactions of the Royal Society London**, v. 226, p. 267–298, 1927.

ZHANG, G. P. et al. A Hybrid ARIMA and Neural Network Model for Short-Term Price Forecasting in Deregulated Market. v. 25, n. 1, 2010.

ZHANG, G.; PATUWO, B. E.; HU, M. Y. Forecasting with artificial neural networks : The state of the art. v. 14, p. 35–62, 1998.

ZOTTERI, G.; KALCHSCHMIDT, M. Forecasting practices : Empirical evidence and a framework for research. v. 108, p. 84–99, 2007.