



Pós-Graduação em Ciência da Computação

**Acurácia de previsões para vazão em redes: Um comparativo
entre ARIMA, GARCH e RNA**

Felipe Machado Duarte

Dissertação de Mestrado

Recife
2014

Universidade Federal de Pernambuco
Centro de Informática

Felipe Machado Duarte

**Acurácia de previsões para vazão em redes: Um comparativo
entre ARIMA, GARCH e RNA**

*Trabalho apresentado ao Programa de Pós-Graduação em
Ciência da Computação do Centro de Informática da
Universidade Federal de Pernambuco como requisito parcial
para obtenção do grau de Mestre em Ciência da Computação.*

Orientador: Prof. Dr. Stênio Flávio de Lacerda Fernandes

Recife
2014

Catálogo na fonte
Bibliotecária Jane Souto Maior, CRB4-571

D812a Duarte, Felipe Machado

Acurácia de previsões para vazão em redes: um comparativo entre ARIMA, GARCH e RNA / Felipe Machado Duarte. – Recife: O Autor, 2014.

80 f.: il. fig., tab., quadro

Orientador: Stênio Flávio de Lacerda Fernandes.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CIn, Ciência da computação, 2014.

Inclui referências e apêndice.

1. Avaliação de desempenho. 2. Análise de séries temporais.
I. Fernandes, Stênio Flávio de Lacerda (orientador). II. Título.

004.029

CDD (23. ed.)

UFPE- MEI 2015-146

Dissertação de Mestrado apresentada por **Felipe Machado Duarte** à Pós-Graduação em Ciência da Computação do Centro de Informática da Universidade Federal de Pernambuco, sob o título “**Acurácia de previsões para vazão em redes: Um comparativo entre ARIMA, GARCH e RNA**” orientada pelo **Prof. Stênio Flávio de Lacerda Fernandes** e aprovada pela Banca Examinadora formada pelos professores:

Prof. Djamel Fawzi Hadj Sadok

Centro de Informática/UFPE

Prof. Ramide Augusto Sales Dantas

Departamento de Análise e Desenvolvimento de Sistemas/IFPE

Prof. Stênio Fávio de Lacerda Fernandes

Centro de Informática /UFPE

Visto e permitida a impressão.

Recife, 29 de agosto de 2014.

Profa. Edna Natividade da Silva Barros

Coordenadora da Pós-Graduação em Ciência da Computação do
Centro de Informática da Universidade Federal de Pernambuco.

Dedico este trabalho à minha família e a todos que me ajudaram a chegar até aqui.

Agradecimentos

Ao professor Stênio Fernandes, pela orientação, confiança, paciência e dedicação dispensada durante a elaboração deste trabalho. Agradeço-o também pelos ensinamentos passados em todo o meu percurso pelo CIN no decorrer do mestrado.

Aos meus pais Maria do Socorro e José Duarte, por sempre acreditarem em mim e por me dar muito amor e carinho, ingredientes essenciais para enfrentar qualquer desafio imposto pela vida.

Aos meus irmãos Bruno e Rafael por sempre estarem presentes na minha vida, acompanhando a minha trajetória.

À minha noiva Heloísa Rodrigues por estar sempre ao meu lado, apoiando as minhas decisões e me ajudando a realizar nosso projeto de vida. Obrigado pelo incentivo, amor e companheirismo.

À Fátima, Cristina, Anália, César, Luciana, Luan, Letícia, Toninho e Marília pelo apoio e amizade.

Aos professores do CIN pela oportunidade de beber um pouco do saber deste corpo docente especialmente capaz.

Um agradecimento especial ao amigo Samuel Macêdo, por compartilhar a sua feliz experiência no CIN.

*“Falar sem aspas, amar sem interrogação, sonhar com reticências, viver sem ponto
final.”*

Charles Chaplin

Resumo

Em consequência da evolução da internet, causada por mudanças de paradigma como a Internet das coisas, por exemplo, surgem novas demandas tecnológicas por conta do crescimento do número de dispositivos conectados. Um dos novos desafios que vieram junto a esta demanda é gerenciar esta rede em expansão, de maneira a garantir conectividade aos dispositivos que a integram. Um dos aspectos que merecem atenção no gerenciamento da rede é o provisionamento da largura de banda, que deve ser realizado de maneira a evitar o desperdício de banda, sem por outro lado comprometer a conectividade ao restringi-la demais. No entanto, balancear esta equação não é uma tarefa simples, pois o tráfego de dados na rede é bastante complexo e exhibe componentes, como a volatilidade, que tornam difícil a sua modelagem. Já há algum tempo, estudos são publicados apresentando a utilização de ferramentas de análise de séries temporais para prever a vazão de dados em redes de computadores, e entre as técnicas aplicadas com mais sucesso estão os modelos ARMA, GARCH e RNA. Embora estas técnicas tenham sido discutidas como alternativa para modelar dados de tráfego de redes, pouco material está disponível sobre a comparação de suas acurácias, de maneira que neste estudo foi proposta uma avaliação das acurácias dos modelos ARIMA, GARCH e RNA. Esta avaliação foi realizada em cenários configurados em diferentes granularidades de tempo e para múltiplos horizontes de previsão. Para cada um destes cenários foram ajustados modelos ARIMA, GARCH e RNA, e a validação das métricas de acurácia das previsões obtidas se deu através do *Rolling Forecast Horizon*. Os resultados obtidos mostraram que a RNA exibiu melhor acurácia em grande parte dos cenários propostos, chegando a exibir RMSE até 32% menor que as previsões geradas pelos modelos ARIMA e GARCH. No entanto, na presença de alta volatilidade, o GARCH conseguiu apresentar as previsões com melhor desempenho, exibindo RMSE até 29% menores que os outros modelos estudados. Os resultados deste trabalho servem de auxílio para a área de gerenciamento de redes, em especial a tarefa de provisionamento de largura de banda de tráfego, pois trazem mais informações sobre os desempenhos dos modelos ARIMA, GARCH e RNA ao gerar previsões para este tipo de tráfego.

Palavras-Chave: Estimção de tráfego. Análise de séries temporais. Avaliação de desempenho. Modelo auto regressivo condicional heteroscedástico generalizado.

Abstract

The Internet evolution, caused by paradigm changes as the Internet of Things, fosters technological advances to cope with the rising number of connected devices. One of the new challenges that appeared with this new reality is the management of such expanding networks, assuring connectivity to every device within them. One of the major aspects of network management is bandwidth provisioning, which must be performed in a way to avoid bandwidth wasting, but without compromising connectivity by restricting it too much. Balancing such an equation is not a simple task, as network data traffic is very complex and presents property features, such as volatility, that turns its modeling rather difficult. It has been some time since research is published with the use of temporal analysis tools to predict data throughput in computer networks, among them, the most successful techniques employ the ARMA, GARCH and ANN models. Although these approaches have been discussed as alternatives do network data traffic modeling, there is little literature available concerning their accuracy, which motivated this work to perform an accuracy evaluation of the ARIMA, GARCH and ANN models. This evaluation was conducted in scenarios configured with different time granularities and for multiple forecast horizons. For each scenario, ARIMA, GARCH and ANN models were set, and the accuracy metrics evaluation was performed with a Rolling Forecast Horizon. Results show that ANN yielded better accuracy in most proposed scenarios, having a RMSE up to 32% lower than the forecasts generated by the ARIMA and GARCH models. However, when there is a high volatility, GARCH provided better forecasts, with a RMSE up to 29% lower than its counterparts. The results from this work provide a useful assistance to network management, especially to bandwidth provisioning, by shedding light on the accuracy presented by the ARIMA, GARCH and ANN models when generating forecasts for this type of traffic.

Keywords: Traffic estimation. Time series analysis. Performance evaluation. Generalized heteroscedastic conditional auto regressive model.

Lista de Figuras

<i>Figura 1- A evolução da internet: transferência eletrônica de dados (EDI). Internet, Internet móvel, Internet das coisas (IOT).....</i>	<i>15</i>
<i>Figura 2 – Estimativa de crescimento do número de dispositivos conectados globalmente. ...</i>	<i>16</i>
<i>Figura 3 – Evolução do tráfego IP global por tipo de aplicação</i>	<i>16</i>
<i>Figura 4 – Processo AR(1) simulado: $\phi = 0,9$ (gráfico superior); $\phi = - 0,9$ (gráfico inferior).</i>	<i>23</i>
<i>Figura 5 – Procedimento iterativo para a análise de séries temporais pela metodologia Box-Jenkins</i>	<i>24</i>
<i>Figura 6 - Rede neural recorrente para predição de séries temporais</i>	<i>28</i>
<i>Figura 8: Ilustração dos passos da técnica Rolling Forecast Origin para previsões de um passo adiante.</i>	<i>32</i>
<i>Figura 9 – Comportamento da série temporal MAWI</i>	<i>37</i>
<i>Figura 10 – Histogramas exibindo a distribuição dos dados da série temporal MAWI após a agregação dos dados nas escalas de 1, 2 ,3 ,4 e 5 segundos.</i>	<i>39</i>
<i>Figura 11 – Gráficos de ACF e PACF dos modelo BJI_M (acima) e BJ4_M (abaixo).....</i>	<i>44</i>
<i>Figura 12: Valores calculados de Umédia(h) para a série MAWI 1</i>	<i>47</i>
<i>Figura 13: Valores calculados de Umédia(h) para a série MAWI 2</i>	<i>48</i>
<i>Figura 14: Valores calculados de Umédia(h) para a série MAWI 3</i>	<i>49</i>
<i>Figura 15: Valores calculados de Umédia(h) para a série MAWI 4</i>	<i>49</i>
<i>Figura 16: Valores calculados de Umédia(h) para a série MAWI 5</i>	<i>50</i>
<i>Figura 17 - Valores de RMSE para as previsões obtidas pelos modelos GARCH, ARMA e RNA para a série MAWI 1.....</i>	<i>51</i>
<i>Figura 18 – Valores do RMSE para as previsões obtidas pelos modelos ARMA e RNA para a série MAWI 2.....</i>	<i>51</i>
<i>Figura 19 - Valores do RMSE para as previsões obtidas pelos modelos ARMA e RNA para a série MAWI 3.....</i>	<i>52</i>
<i>Figura 20 - Valores do RMSE para as previsões obtidas pelos modelos GARCH, ARMA e RNA para a série MAWI 4.....</i>	<i>52</i>
<i>Figura 21 - Valores do RMSE para as previsões obtidas pelos modelos ARMA e RNA para a série MAWI 5.....</i>	<i>53</i>
<i>Figura 22 - Valores do MASE para as previsões obtidas pelos modelos GARCH, ARMA e RNA para a série MAWI 1.....</i>	<i>54</i>

<i>Figura 23 - Valores do MASE para as previsões obtidas pelos modelos ARMA e RNA para a série MAWI 2.....</i>	<i>54</i>
<i>Figura 24 - Valores do MASE para as previsões obtidas pelos modelos ARMA e RNA para a série MAWI 3.....</i>	<i>55</i>
<i>Figura 25 - Valores do MASE para as previsões obtidas pelos modelos GARCH, ARMA e RNA para a série MAWI 4.....</i>	<i>55</i>
<i>Figura 26 - Valores do MASE para as previsões obtidas pelos modelos ARMA e RNA para a série MAWI 5.....</i>	<i>56</i>

Lista de Tabelas

<i>Tabela 1 – Medidas descritivas dos dados que compõem a série temporal MAWI</i>	38
<i>Tabela 2 – Características dos dados agregados nas escalas de tempo de 1, 2, 3, 4 e 5 segundos.</i>	39
<i>Tabela 3- Resultados do teste de Dickey-Fuller aplicado aos dados das séries temporais agregada nas escalas de tempo de 1, 2, 3, 4 e 5 segundos.</i>	40
<i>Tabela 4 - Resultados do teste de Normalidade de Jarque-Bera aplicado aos resíduos dos modelos ajustados aos dados das séries temporais agregada nas escalas de tempo de 1, 2, 3, 4 e 5 segundos.</i>	42
<i>Tabela 5- Resultados do Teste Arch para heteroscedasticidade condicional.</i>	43
<i>Tabela 6 – Especificação dos modelos ARMA selecionados para ajustar as séries temporais originadas do conjunto de dados MAWI</i>	43
<i>Tabela 7 - especificação dos modelos GARCH selecionados para ajustar as séries temporais MAWI 1 e MAWI 4.</i>	45

Lista de Quadros

<i>Quadro 1 - Características das funções de autocorrelação e autocorrelação parcial de processos AR e MA.....</i>	<i>25</i>
<i>Quadro 2 - Modelos ajustados para os dados das séries temporais agregada nas escalas de tempo de 1, 2, 3, 4 e 5. As denominações postas serão usadas sempre que necessário referenciar os modelos aqui exibidos.....</i>	<i>41</i>
<i>Quadro 3 - Especificação dos modelos ajustados por RNA para as séries MAWI.....</i>	<i>46</i>
<i>Quadro 4 – Resultados dos testes DM. (hipótese nula = acurácia modelo 1 > acurácia modelo 2).....</i>	<i>56</i>

Sumário

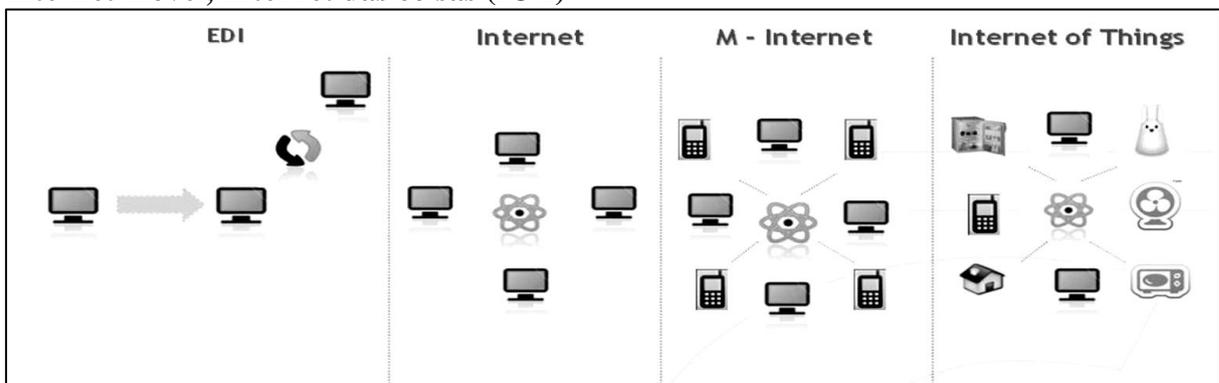
1. Introdução	15
1.1. Motivação	18
1.2. Objetivos.....	18
1.3. Estrutura da Dissertação	19
1.4. Suporte Computacional	20
2. Fundamentação Teórica.....	21
2.1. Análise de Séries Temporais	21
2.1.1. Metodologia Box-Jenkins.....	22
2.1.2. Modelos Heteroscedásticos	26
2.1.3. Ajuste de séries temporais usando Redes Neurais Artificiais	28
2.2. Comparação de modelos preditivos.....	29
2.2.1. <i>Rolling Forecast Origin</i>	30
2.2.2. Métricas para avaliar a acurácia de previsões.....	32
2.2.3. Teste Diebold-Mariano.....	34
2.3. Trabalhos relacionados	35
3. Metodologia e modelagem dos dados.....	37
3.1. Descrição dos dados utilizados	37
3.2. Construção dos modelos para a série temporal MAWI.....	38
3.2.1. Ajuste ARMA.....	39
3.2.2. Ajuste GARCH.....	43
3.2.3. Ajuste RNA	45

4. Resultados.....	47
4.1. Acurácia das previsões para a série MAWI.....	47
4.1.1. Utilização Média (<i>Umédia(h)</i>).....	47
4.1.2. RMSE	50
4.1.3. MASE	53
4.1.4. Teste de Diebold Mariano.....	56
4.2. Resumo	57
5. Conclusões e trabalhos futuros	58
6. Contribuições	60
Referências	61
Apêndice A. Decomposição da série MAWI.....	65
Apêndice B. Séries temporais resultantes da agregação da série MAWI.....	66
Apêndice C. Gráficos dos resíduos dos modelos ARMA ajustados.....	67
Apêndice D. Sumário do ajuste GARCH(1,1) aos dados da série MAWI 1	72
Apêndice E. Sumário do ajuste GARCH(1,0) aos dados da série MAWI 4	77

1. Introdução

A introdução da pilha de protocolos TCP/IP no começo dos anos 80 foi o ponto de largada necessário para o uso comercial da Internet, que se deu próximo do final desta mesma década. Alguns anos depois, em 1991, a World Wide Web (WWW) estava disponível, tornando a internet um meio de informação muito popular e estimulando o seu rápido crescimento (OLIFER; OLIFER, 2005). Em pouco tempo, dispositivos móveis, como celulares, foram conectados à grande rede e formaram uma rede de internet de dispositivos móveis. No início da década de 2000, com o surgimento das redes sociais, os usuários começaram a se conectar com frequências cada vez maiores, usando mais a forma síncrona de comunicação ao invés da forma assíncrona (KUROSE; ROSS, 2012). O próximo passo desta evolução, que já está sendo experimentada, é a chamada Internet das Coisas, em que diversos tipos de objetos podem se conectar a internet e enviar ou receber dados, interagindo com o usuário ou com outro dispositivo (ATZORI; IERA; MORABITO, 2010). A Figura 1 ilustra os passos da evolução da internet.

Figura 1- A evolução da internet: transferência eletrônica de dados (EDI). Internet, Internet móvel, Internet das coisas (IOT)



Fonte: Casaleggio Associati, 2011

Este novo paradigma está ganhando terreno muito rapidamente no cenário atual de telecomunicações sem fio, e já é bastante evidente o avanço de um de seus efeitos: um grande “boom” de dispositivos conectados, chegando a alcançar uma estimativa atual na escala dos bilhões. E a previsão é que até o ano de 2020 o número de dispositivos conectados ultrapasse a marca dos 50 bilhões (CISCO, 2013). A Figura 2 exhibe a evolução dos dispositivos conectados desde o ano de 2012 até o previsto para o ano de 2020 e Figura 3 ilustra a evolução do tráfego IP global entre os anos de 2013 a 2018.

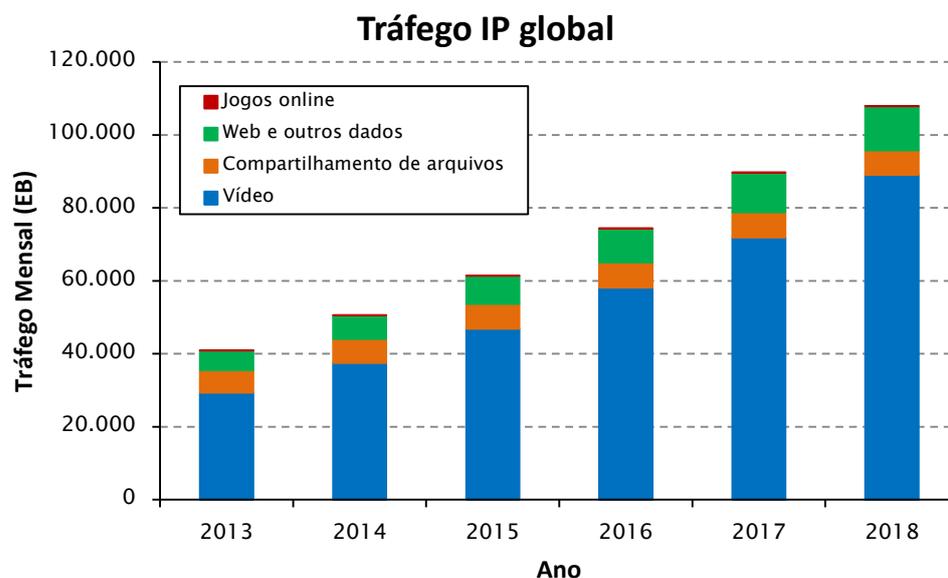
Figura 2 – Estimativa de crescimento do número de dispositivos conectados globalmente. Linha em vermelho sugere crescimento exponencial



Fonte: CCS, 2013

Como consequência deste grande aumento no número de dispositivos conectados, vários desafios técnicos surgem em decorrência das novas demandas instituídas por esta realidade de um mundo de “coisas” conectadas (ELKHODR; SHAHRESTANI; CHEUNG, 2013). Dentre os diversos desafios contemporâneos, garantir a conectividade para uma quantidade crescente de dispositivos está entre os que mais preocupam os pesquisadores da área de gerenciamento de redes (ZHANG; SUN, 2012).

Figura 3 – Evolução do tráfego IP global por tipo de aplicação



Fonte: CISCO VNI, 2014

Neste contexto, o planejamento da capacidade das redes é um problema que tem atraído bastante atenção, principalmente dos provedores de acesso, pois a disponibilização eficiente da banda de dados deve ser feita baseada na análise do tráfego de dados, caso contrário os riscos são que haja um provisionamento excessivo (*waste*) ou o contrário (*starvation*) (KRITHIKAIVASAN *et al.*, 2007). Com o intuito de prover subsídios para um provisionamento de banda mais eficiente, muitos estudos são realizados na área de gerenciamento e monitoramento do tráfego de redes. O monitoramento visando a previsão do tráfego de dados em uma rede pode ser realizado com base na observação dos dados históricos e, desta forma, é possível estimar o tráfego de dados para um determinado espaço de tempo futuro. Para tal, é necessário empregar modelos aptos a, com base nas observações de tráfego passadas, prever as demandas tráfego para tempos futuros (PAPAGIANNAKI *et al.*, 2003). Contudo, para que um modelo seja considerado eficiente, ele precisa ser capaz de capturar as principais características dos dados, sendo esta propriedade requisito para viabilizar o gerenciamento eficiente de tráfego de dados em uma rede complexa como a internet (SZYMANSKI; BEHDIN, 2012).

Os dados obtidos pela observação da vazão de dados em redes de computadores exibem propriedades bastante semelhantes às que são observadas em dados financeiros, a exemplo da presença de volatilidade e não estacionariedade dos dados. Por conta destas semelhanças, ferramentas estatísticas de análise de séries temporais foram experimentadas na tentativa de modelar os dados provenientes de tráfego de redes, e este caminho se mostrou bastante frutífero (PAPAGIANNAKI *et al.*, 2003).

Os modelos Auto Regressivos de Médias Móveis (ARMA) se mostraram úteis em modelar os dados não estacionários provenientes das observações da vazão de dados em redes de computadores (PAPAGIANNAKI *et al.*, 2003), porém esta classe de modelos não consegue lidar de forma satisfatória com a presença de volatilidade e por conta disso algumas suposições necessárias para sua aplicação podem ser violadas. Para tratar da presença de volatilidade, foi trazido, das ferramentas de análise de séries temporais econométricas, uma classe de modelos adequados para lidar com dados com este componente de volatilidade, os chamados modelos heteroscedásticos. Estes modelos foram empregados na modelagem de dados de tráfego de rede com volatilidade, apresentando bons resultados (KRITHIKAIVASAN *et al.*, 2007). Outra ferramenta que é utilizada em análise de séries temporais, mas que tem origem nas ciências da computação, são os modelos de análise de

séries temporais baseados em rede neural artificial (RNA). Estes modelos têm a vantagem de conseguir capturar a estrutura das séries temporais sem que para executar esta tarefa seja necessário se apoiar em muitas suposições sobre os dados (QI; ZHANG, 2008).

1.1. Motivação

Embora exista muito material disponível descrevendo o uso de ferramentas com a finalidade de modelar o tráfego de dados em redes de computadores, pouco existe na literatura sobre a comparação entre estes métodos. Em relação a análise de séries temporais aplicadas a previsão de vazão de dados, alguns estudos descrevem os resultados das comparações entre o desempenho das previsões obtidas pela aplicação de modelos ARMA e RNA, mas não são unânimes nas suas conclusões sobre qual modelo apresenta melhor acurácia nas previsões (XIANG *et al.*, 2010). Além disso, estes estudos são baseados em cenários de certa forma limitados, principalmente em relação ao horizonte de previsão utilizado para medir a acurácia – quase sempre restrito a previsões para apenas uma unidade de tempo à frente. Sobre a modelagem de dados de redes de computadores usando redes neurais, ainda é pequena a gama de material que apresentem medidas de acurácia consistentes a respeito do desempenho desta ferramenta ao lidar com esta classe de dados.

Diante da relativa ausência de material trazendo informações que subsidiem comparações entre as ferramentas de análise de séries temporais utilizadas para modelar dados de vazão em redes de computadores, e com a finalidade de obter avaliações mais ricas, que proporcionem medidas de desempenho relevantes para cenários diversificados, foi proposto neste trabalho realizar um estudo comparativo exaustivo entre as acurácias das previsões obtidas para estes dados, utilizando os modelos Auto Regressivos de Médias Móveis (ARMA), Heteroscedásticos Generalizados de Variância Condicional (GARCH) e Redes Neurais Artificiais (RNA). Para tal, foi idealizada a avaliação do desempenho dos modelos sob variados cenários, a fim de conseguir o máximo de informações sobre a acurácia das previsões obtidas por estes modelos.

1.2. Objetivos

Objetivo principal

Avaliar a acurácia das previsões para vazão de dados em redes de computadores obtidas por três diferentes técnicas de modelagem.

Objetivos Secundários

Ajustar modelos de análise de séries temporais usando as metodologias:

- ARMA
- GARCH
- RNA

Comparar, por meio de métricas de acurácia e testes estatísticos, as previsões obtidas pelos modelos em diferentes agregações e horizontes de tempo.

1.3. Estrutura da Dissertação

Esta dissertação foi estruturada da seguinte maneira:

O Capítulo 2 contém a descrição dos conceitos relacionados às ferramentas de análise de séries temporais, às métricas e aos testes estatísticos que serviram de base para a avaliação realizada neste estudo. São apresentadas as definições mais importantes relacionadas à análise de séries temporais, de um modo geral, e em seguida, com maior detalhamento, cada um dos modelos empregados é descrito. Por fim, as métricas de avaliação de acurácia serão apresentadas assim como também o teste estatístico utilizado.

No terceiro capítulo é pormenorizado todo o processo de ajustes dos modelos aos dados utilizados, passando por todas as etapas necessárias para obter as previsões. Neste capítulo também é feita a apresentação das principais características dos dados que compõem as séries temporais analisadas.

O Capítulo 4 expõe os resultados relativos ao desempenho das previsões obtidas por cada um dos três modelos empregados. São exibidas métricas de acurácia para diversos cenários, com diferentes horizontes de previsão e para variadas granularidades do tempo base das séries temporais.

As conclusões mais relevantes sobre as avaliações realizadas, as principais contribuições do presente estudo e as indicações de trabalhos futuros são discutidas no quinto capítulo.

1.4. Suporte Computacional

Nos Capítulos 3 e 4, referentes aos ajustes dos modelos e aos resultados, respectivamente, todos os cálculos foram realizados utilizando o software gratuito R em sua versão 3.1.1 para o sistema operacional Windows, que pode ser obtido pelo endereço <http://www.r-project.org>. O software R é um ambiente para computação científica e gráfica baseado no software comercial S, sendo amplamente utilizado por pesquisadores de diversas áreas do conhecimento.

2. Fundamentação Teórica

Este capítulo apresenta o resumo da base teórica e principais conceitos necessários para o desenvolvimento e entendimento do presente estudo, além de trazer referências sobre os estudos na área.

2.1. Análise de Séries Temporais

Desde a época da Babilônia que os cientistas se utilizam da análise de séries temporais em seus estudos, quando, por exemplo, se utilizavam das séries temporais das posições relativas dos astros celestes para prever eventos astronômicos (KIRCHGÄSSNER; WOLTERS; HASSLER, 2013). A análise de séries temporais é uma área tradicionalmente relevante entre os estatísticos, analistas financeiros e econométricos e durante os últimos anos tem rendido muitos resultados em termos de pesquisas e aplicações práticas (PEDRYCZ; CHEN, 2013).

Uma série temporal pode ser definida como um conjunto de dados obtido a partir de observações realizadas sequencialmente ao longo do tempo, ou outra variável de interesse como o espaço ou profundidade, e mensuradas em intervalos fixos. A característica mais marcante deste tipo de conjunto de dados é que as observações vizinhas são dependentes, de forma tal que o valor da observação atual é obtido a partir de uma combinação dos valores das observações passadas da série temporal, e o interesse se concentra em modelar o comportamento desta dependência. Para tal, é investigada a presença e o funcionamento de certas estruturas intrínsecas a este tipo de dados, tais como autocorrelação, tendência e variação sazonal, e as formas destas estruturas são reveladas no decorrer da análise de séries temporais (BOX; JENKINS; REINSEL, 2008). Com isso, a análise de séries temporais ajuda a detectar as regularidades dos dados da série estudada e proporciona os meios para se derivar as leis que regem o seu comportamento. Desta forma é possível extrair informações importantes, como a obtenção de previsões para os valores futuros da série (KIRCHGÄSSNER; WOLTERS; HASSLER, 2013).

A despeito de diversos modelos de análise de séries temporais terem suas raízes na área da estatística, a análise de séries temporais também tem atraído bastante a atenção dos pesquisadores da área de inteligência computacional. Entre os métodos estudados por estes pesquisadores para analisar séries temporais, a RNA tem se destacado por sua habilidade em

lidar com tarefas complexas, como prever dados futuros em uma série temporal. (PEDRYCZ; CHEN, 2013).

Nas Seções 2.1.1 e 2.1.2 serão apresentados os fundamentos básicos sobre as metodologias de Box-Jenkins e sobre modelos heteroscedásticos, respectivamente, e a aplicação de Redes Neurais Artificiais em análise de séries temporais será apresentada na Seção 2.1.3.

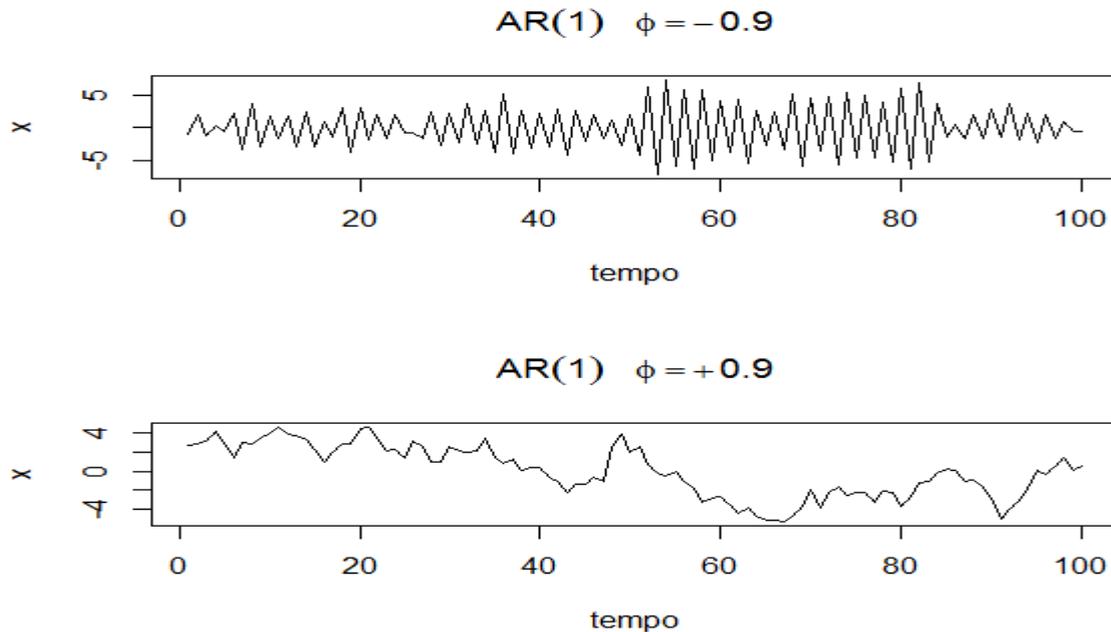
2.1.1. Metodologia Box-Jenkins

Um marco no desenvolvimento da análise de séries temporais foi a formalização da ideia de prever os valores futuros da série a partir da combinação dos seus valores observados. Esta metodologia foi devida a Box e Jenkins, nas formas das famílias de modelos Auto Regressivos (AR), de Médias Móveis (MA) e ARMA (PANKRAN, 1994). Durante a década de 70, os professores George E. P. Box e Gwilym M. Jenkins apresentaram esta metodologia para a análise de séries temporais, que rapidamente se tornou muito popular. O grande mérito desse trabalho foi reunir as técnicas anteriormente existentes numa metodologia mais robusta que permite a construção de modelos que descrevem com precisão e de forma parcimoniosa o processo gerador da série temporal, proporcionando a construção de previsões acuradas de valores futuros de uma série temporal (BOX; JENKINS; REINSEL, 2008). A metodologia de Box-Jenkins apresenta modelos de séries temporais na forma

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \dots + \beta_q \varepsilon_{t-q} \quad (2.1)$$

Da equação 2.1 tem-se que o termo α_0 representa uma constante no modelo estimado e $\alpha_1, \dots, \alpha_p$ são parâmetros que ajustam os valores passados, do instante imediatamente anterior, $t - 1$, até o mais distante p . Os valores de ε_t representam uma sequência de choques aleatórios, independentes entre si, e correspondem a uma porção não controlável do modelo, normalmente denominada Ruído Branco. Os parâmetros β_1, \dots, β_q possibilitam escrever a série em função dos choques aleatórios passados e os parâmetros $\alpha_1, \dots, \alpha_q$ são responsáveis em modelar a componente auto regressiva e os parâmetros β_1, \dots, β_q modelam a componente de médias móveis (HAMILTON, 1994). A Figura 4 mostra o comportamento, para diferentes valores do parâmetro, de uma série AR(1) gerada por simulação.

Figura 4 – Processo AR(1) simulado: $\phi = -0,9$ (gráfico superior); $\phi = +0,9$ (gráfico inferior).



Uma consideração de extrema importância sobre esta classe de modelos é que a sequência ε_t , exibida na equação 2.1, é considerada um ruído branco apenas se tiver distribuição Normal e, adicionalmente, para todo instante de tempo t for verificado que:

$$E[\varepsilon_t] = E[\varepsilon_{t-1}] = \dots = 0 \quad (\text{média zero})$$

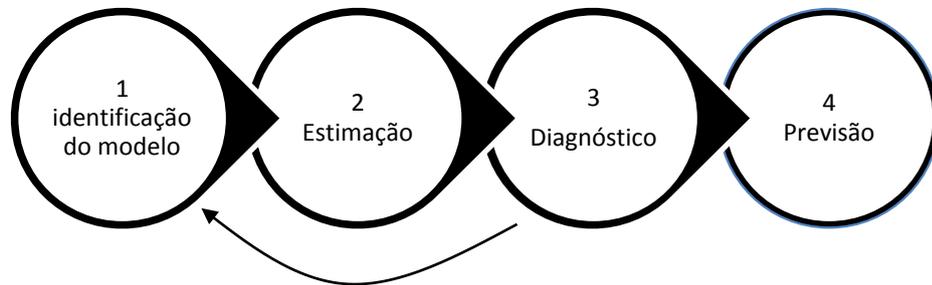
$$E[\varepsilon_t^2] = E[\varepsilon_{t-1}^2] = \dots = 0 \quad (\text{variância constante})$$

$$E[\varepsilon_t \cdot \varepsilon_{t-1}] = E[\varepsilon_{t-j} \cdot \varepsilon_{t-j-s}] = \dots = 0 \quad (\text{covariância nula para todo valor de } s)$$

em que estas mesmas condições formam a base para a realização da análise de diagnóstico dos modelos, conforme será detalhado mais adiante. Estas suposições podem ser condensadas na expressão $\varepsilon_t \sim^{iid} N(0, \sigma^2)$ (BOX; JENKINS; REINSEL, 2008).

Na prática, o que se terá em mãos é uma série temporal, resultante da observação dos dados do fenômeno estudado, e pretende-se inferir qual processo ARMA poderia ter gerado esta série. A seleção do modelo ARMA apropriado para os dados que se busca analisar é realizada por intermédio de um procedimento iterativo, seguindo quatro etapas (TSAY, 2005):

Figura 5 – Procedimento iterativo para a análise de séries temporais pela metodologia Box-Jenkins



O primeiro passo antes de realizar a identificação do modelo é verificar se a suposição de variância estacionária (constante) pode ser considerada válida. A série temporal irá violar esta suposição se a dispersão dos dados variar significativamente ao longo do tempo, e caso isso ocorra, pode-se utilizar uma transformação de Box-Cox adequada para estabilizar a variância da série. Além de estacionária na variância, a série precisa ser estacionária na média, e o teste da raiz unitária, também conhecido com teste de Dickey-Fuller, é usado para se verificar se a série é estacionária na média e, caso esta suposição não seja válida, pode-se aplicar o operador diferença, $\Delta y_t = y_t - y_{t-1}$, na série temporal até que a estacionariedade seja obtida (BROCKWELL; DAVIS, 2002).

Após obter a estacionariedade da variância e da média, o próximo passo é identificar a ordem dos parâmetros do modelo mediante análise gráfica da função de autocorrelação e autocorrelação parcial amostrais da série temporal. O Quadro 1 mostra que a ordem p da componente auto regressiva da série pode ser identificada pelo decaimento da função de autocorrelação parcial e de forma análoga a ordem q da componente de médias móveis pode ser identificada pela função de autocorrelação (HYNDMAN; KHANDAKAR, 2008). No entanto, este processo de identificação do modelo pela análise gráfica pode ser bastante trabalhoso e demorado, pois nem sempre é fácil, na primeira tentativa, identificar corretamente as ordens dos parâmetros do modelo e por isso este processo tende a se tornar demasiadamente repetitivo. Outra maneira de se realizar a identificação, mais automatizada, é por meio da procura iterativa da ordem dos parâmetros, usando para isso a comparação dos critérios de informação AIC, AICc ou BIC. Será escolhido o modelo que apresentar o menor valor para o AIC, AICc ou BIC, a depender de qual destes critérios seja mais adequado para a situação e dados em análise (BURNHAM; ANDERSON, 1998).

Quadro 1 - Características das funções de autocorrelação e autocorrelação parcial de processos AR e MA

	Função de autocorrelação	Função de autocorrelação parcial
MA(q)	Declina a partir de q	Não declina rápido
AR(p)	Não declina rápido	Declina a partir de p

Fonte: Adaptado de Kirchgassner (2013)

Os parâmetros do modelo $ARMA(p,q)$ selecionado podem ser estimados usando o método de Mínimos Quadrados ou Máxima Verossimilhança. Ao usar quaisquer destes dois métodos, o procedimento para a estimação será sempre baseado no cálculo dos resíduos ε_t , obtidos a partir dos valores da série estacionária.

A estimação dos parâmetros de um modelo ARMA pela metodologia de mínimos quadrados é realizada através do processo de minimizar a soma de quadrados dos resíduos,

$$\sum_t \varepsilon_t^2 \quad (2.2)$$

e a função de Log-verossimilhança pode ser derivada a partir da função de densidade de probabilidade conjunta das inovações $\varepsilon_1, \dots, \varepsilon_t$, que, sob a suposição de serem independentes e identicamente distribuídas, com distribuição Normal($0, \sigma^2$), tem a forma

$$f(\varepsilon_1, \dots, \varepsilon_t) \propto \sigma_\varepsilon^{-t} \exp \left\{ - \sum_{t=1}^T \frac{\varepsilon_t^2}{2\sigma_\varepsilon^2} \right\} \quad (2.3)$$

Para resolver o problema de estimar os parâmetros, as equações 2.2 e 2.3 tem que ser escritas em função dos dados observados da série temporal e dos parâmetros do modelo.

O último estágio na construção de um modelo de análise de séries temporais usando a metodologia de Box-Jenkins, antes de se realizar as previsões, é a fase de diagnóstico, chamada comumente de análise de resíduos. Neste estágio são realizados os testes para checar a validade das suposições feitas acerca dos resíduos: independência, normalidade e homoscedasticidade. A validade destas suposições precisa ser confirmada, sob pena de comprometer os resultados das etapas anteriores (HAMILTON, 1994).

Existem diversos testes estatísticos e análises gráficas desenvolvidas para verificar a validade das suposições inerentes a um modelo ARMA. Para testar a independência dos resíduos, costuma-se empregar o Teste de Ljung-Box, em que é checado se as auto correlações dos resíduos, até um lag k , são consideradas conjuntamente nulas. A distribuição dos resíduos pode ser confrontada com uma distribuição Normal através de um teste de aderência, a exemplo do teste de Jarque-Bera. Para confrontar a última suposição, a de homoscedasticidade dos resíduos, é realizado um teste de homoscedasticidade no quadrado dos resíduos, pois mesmo que os resíduos sejam não correlacionados, ainda assim pode haver efeito heteroscedástico condicional auto regressivo. Este teste é chamado de Teste Arch de Engle, e é um teste derivado do Multiplicador de Lagrange (LABYS; TERRAZA, 1994).

Por fim, e somente após ter realizado todas as etapas anteriores, é que será possível obter as previsões utilizando os modelos ARMA ajustados. A falha em seguir estes passos torna as previsões encontradas sem valor, pois será impossível inferir sobre a sua significância estatística de forma segura (PANKRAN, 1994).

2.1.2. Modelos Heteroscedásticos

Muitas séries temporais exibem períodos de grande volatilidade seguidos de períodos de relativa tranquilidade. Nestes casos, a suposição de variância constante (homoscedasticidade) pode não ser apropriada. Embora a variância incondicional dos erros ainda possa ser assumida constante, sua variância condicional pode estar mudando ao longo do tempo. Para casos em que isto acontece, ou quando se procura prever a variância condicional da série além da série propriamente dita, os modelos heteroscedásticos se mostram como uma alternativa aos modelos de Box-Jenkins, vistos na seção anterior (HAMILTON, 1994).

Os modelos heteroscedásticos costumam ser separados em duas categorias: os que pertencem a primeira, denominados ARCH, são caracterizados por utilizarem uma função determinística para capturar a evolução de σ^2 , enquanto que os modelos da segunda categoria, GARCH, utilizam uma função estocástica para explicitar σ^2 (PEÑA; TIAO; TSAY, 2001).

ARCH

O modelo ARCH tem inspiração nos modelos ARMA, porém, diferente deste último, modela a variação de σ^2 como um modelo MA com base nas observações passadas da série

temporal. Este tipo de modelo surgiu da necessidade de se validar a suposição que a imprevisibilidade da inflação estaria na origem dos ciclos econômicos e que esta variação influencia o comportamento dos investidores, sendo então necessário idealizar um modelo que modelasse a evolução dessa imprevisibilidade (ENGLE, 2004).

Uma estratégia utilizada para modelar a variância condicional consiste em assumir que ela depende dos quadrados dos erros passados, através de uma auto regressão dada por

$$\varepsilon_t = v_t \sqrt{c + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_p \varepsilon_{t-p}^2}$$

de forma tal que a variância condicional será modelada como

$$\sigma_t^2 = E[\varepsilon_t^2 | I_{t-1}] = c + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_p \varepsilon_{t-p}^2$$

e neste caso é convencionalizado que a variância segue um processo auto regressivo condicionalmente heteroscedásticos, denominado de modelo ARCH(p), e esta sua modelagem tem muita semelhança aos procedimentos descritos na Seção 2.1.1, ressaltando as devidas particularidades (ENGLE, 1982).

GARCH

Nas situações em que o *lag* máximo em um modelo ARCH(q) seja muito alto, problemas na estimação dos parâmetros podem ocorrer, caso não se tenha o devido cuidado com as restrições de não-negatividade. Com o objetivo de se obter um modelo que seja mais parcimonioso frente a blocos de alta volatilidade de longa duração, e que problemas de estimação não ocorram com tanta frequência, foram desenvolvidos os modelos GARCH.

Os modelos GARCH podem ser vistos como uma generalização dos modelos ARCH em que é assumido que a variância condicional se comporta como um processo ARMA, dependendo também de seus valores passados. Um modelo GARCH é expresso da seguinte forma

$$Z_t = \sqrt{h_t} \varepsilon_t$$

$$h_t = \alpha_0 + \sum_{i=1}^p \alpha_i Z_{t-i}^2 + \sum_{j=1}^q \beta_j h_{t-j}$$

em que $\varepsilon_t \sim IID(0,1)$, $\alpha_0 > 0$, $\alpha_i \geq 0$ e $\beta_i \geq 0$ são constantes com a condição

$$\sum_{i=1}^p \alpha_i + \sum_{j=1}^q \beta_j > 1$$

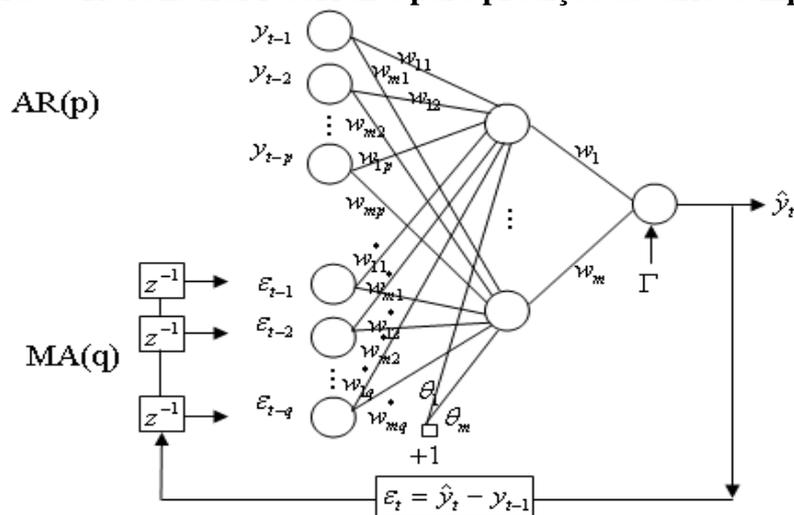
e ε_t é independente de $Z_{t-k}, k \geq 1$.

Um processo estocástico definido da forma anterior é chamado de ARCH generalizado, ou GARCH, de ordem (p, q) e a sua vantagem sobre o modelo ARCH é em maior parte devido à maior parcimônia, no sentido em que este modelo pode ser usado para descrever a volatilidade com bem menos parâmetros. O modelo GARCH se vale de que a variância condicional do erro não está relacionada apenas com os quadrados dos valores passados da série, mas também com as variâncias condicionais passadas (TAYLOR, S., 1986).

2.1.3. Ajuste de séries temporais usando Redes Neurais Artificiais

As redes neurais artificiais têm como uma das suas aplicações principais o campo do reconhecimento de padrões e previsão, e para realizar esta tarefa é necessário utilizar uma arquitetura de rede denominada como rede neural recorrente. Este tipo de rede tem como particularidade possuir um ou mais enlaces de realimentação. A Figura 6 apresenta um exemplo de rede recorrente utilizada para aproximar um modelo equivalente a um ARMA não estacionário (DROSSU; OBRADOVIC, 1996).

Figura 6 - Rede neural recorrente para predição de séries temporais



Para o modelo referenciado na figura anterior, tem-se que a saída \hat{y}_t é dada pela seguinte equação

$$\hat{y}_t = h(y_{t-1}, \dots, y_{t-p}, \varepsilon_{t-1}, \dots, \varepsilon_{t-q}) \approx \sum_{i=1}^m W_i f \left\{ \sum_{j=1}^p w_{ij} y_{t-j} + \sum_{j=1}^q w_{ij}^* (y_{t-j} - \hat{y}_{t-j}) + \theta_i \right\} + \tau$$

em que f é uma função não linear, W_i representa os pesos entre os neurônios da camada intermediária e os da camada de saída, w_{ij} são os pesos entre as camadas externas e a camada escondida, w_{ij}^* são os pesos entre a primeira camada de neurônios com entrada recorrente e a camada escondida, os θ_i são os termos que modificam a saída dos neurônios da camada escondida e τ é o viés do neurônio de saída.

2.2. Comparação de modelos preditivos

A comparação entre modelos pode ser realizada com ênfase em diferentes critérios:

- **Acurácia** – mede a capacidade do modelo de prever valores que sejam mais próximos dos valores reais do atributo modelado;
- **Velocidade** – é referente aos custos computacionais envolvidos na construção e uso do modelo;
- **Robustez** – é a habilidade do modelo de realizar previsões corretamente mesmo na presença de “sujeira” nos dados e valores ausentes;
- **Escalabilidade** – define-se como a capacidade do modelo se mostrar eficiente ao ser usado em um volume grande de dados;
- **Interpretabilidade** – indica o nível de clareza e o *insight* propiciado pelo modelo (HAN; KAMBER, 2006).

Tendo em foco explorar o quanto cada modelo pode fornecer em termos de qualidade das previsões do tráfego de dados em redes de computadores, as comparações dos modelos propostas neste estudo se darão no campo da acurácia.

Como requisito para se calcular a acurácia, é necessário ter disponível os valores preditos para as observações futuras da série de dados em questão. Segundo Hyndman (2006), existem três maneiras possíveis para se obter as previsões (F) dos dados (Y) de uma dada série temporal:

1. Podemos calcular as previsões a partir de uma mesma origem t para uma sequência de horizontes de previsão F_{n+1}, \dots, F_{n+m} usando como referência as observações passadas Y_1, \dots, Y_n .
2. Podemos variar a origem t em que as previsões se baseiam, mas mantendo fixo o horizonte de previsão. Podemos, por exemplo, gerar uma série de previsões de um período de tempo à frente, F_{1+h}, \dots, F_{m+h} em que cada F_{j+h} é baseado nos dados dos tempos $t = 1, \dots, j$.
3. Podemos construir previsões para um único período de tempo usando diferentes séries temporais.

Mesmo que existam diferentes formas de se obter previsões a partir de modelos preditivos, a maneira de medir a acurácia destas previsões é essencialmente a mesma (ARMSTRONG, 1992).

2.2.1. *Rolling Forecast Origin*

É prática bastante comum, principalmente no campo da mineração de dados, o emprego de técnicas que possam validar os resultados obtidos pelos modelos ajustados. Uma técnica muito popular é a aplicação da validação cruzada dos dados, de maneira que o conjunto de dados de treinamento (aqueles que servirão para ajustar o modelo) e o conjunto de dados de teste (dados não usados no ajuste e serão comparados com os dados previstos pelo modelo) serão construídos repetidas vezes, de maneiras diferentes, através de processos de amostragem, a fim de eliminar os efeitos de algum possível viés de seleção. No entanto, esta técnica não pode ser aplicada em modelos que ajustam dados de uma série temporal, pois estes dados apresentam forte autocorrelação entre observações vizinhas e a aplicação da validação cruzada iria causar uma degeneração irrecuperável nesta componente ((BERGMEIR; BENÍTEZ, 2010)).

Como uma alternativa a validação cruzada para ser utilizada em análise de previsões de séries temporais, existe a técnica denominada *rolling forecast origin*. Nesta técnica, considera-se como conjunto de treinamento apenas os dados anteriores às observações que irão compor o conjunto de teste, tomando-se o cuidado de não tornar o conjunto de treinamento muito pequeno a ponto de comprometer o ajuste do modelo. Considerando que

sejam necessárias k observações para se ajustar um determinado modelo, o procedimento para aplicar o *rolling forecast origin* se resume a:

1. Selecionar a observação do tempo $k + i$ para compor o conjunto de teste e usar as observações dos tempos $1, \dots, k + i - 1$ para ajustar o modelo e obter a previsão para $k + i$. Calcular o erro da previsão para o tempo $k + i$;
2. Repetir o passo acima para $i = 1, \dots, n - k$, onde n é a quantidade total de observações da série de dados.
3. Calcular as medidas de acurácia de previsão usando os erros obtidos

Ao seguir estes procedimentos, a observação após a qual a previsão será feita estará sempre sendo movida um passo a frente no tempo e conseqüentemente as previsões também serão realizadas seguindo esta origem, ou seja, rolando no tempo.

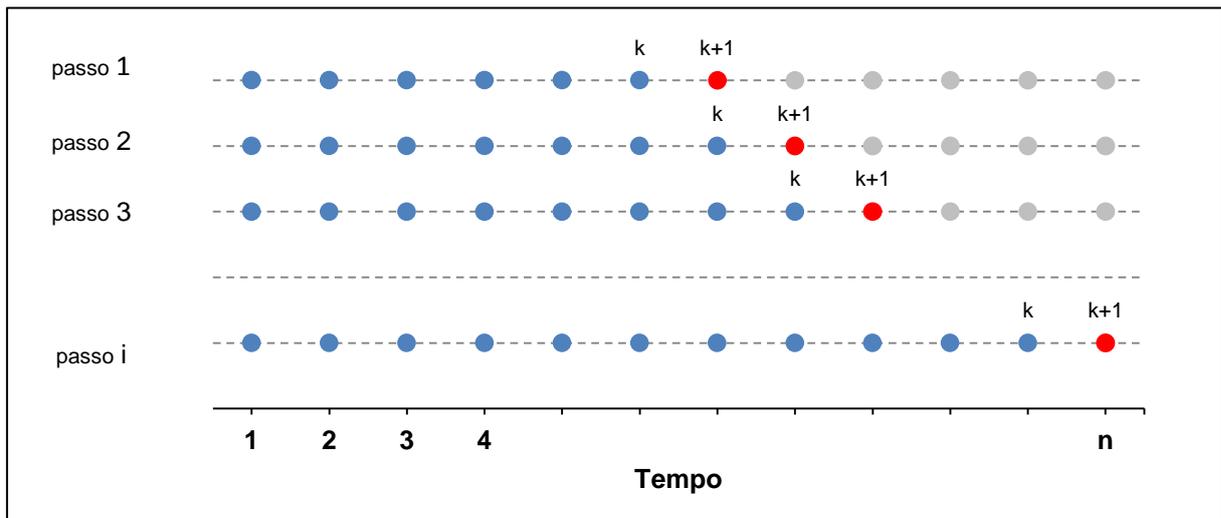
Estes passos descritos anteriormente são para previsões de um passo adiante. No entanto, em análise de séries temporais, estas previsões não são consideradas tão relevantes quando as de vários passos adiante (RAPACH; WOHAR, 2006). A fim de tornar esta técnica compatível com previsões de mais de um passo adiante, uma pequena modificação nos passos descritos anteriormente se faz necessária, de forma que o procedimento modificado será:

1. Selecionar a observação do tempo $k + h + i - 1$ para compor o conjunto de teste e usar as observações dos tempos $1, \dots, k + i - 1$ para ajustar o modelo e obter a previsão para $k + h + i - 1$. Calcular o erro da previsão de h passos para o tempo $k + h + i - 1$;
2. Repetir o passo acima para $i = 1, \dots, n - k - h + 1$, onde n é a quantidade total de observações da série de dados;
3. Calcular as medidas de acurácia de previsão usando os erros obtidos (HYNDMAN; ATHANASOPOULOS, 2013).

A aplicação da técnica de *rolling forecast origin*, descrita pelos procedimentos descritos, é imprescindível para que os resultados obtidos a partir das análises de acurácia das previsões dadas por modelos sejam robustos a possíveis vieses de seleção do ponto de origem das

previsões (ARLOT; CELISSE, 2010). Na Figura 7 é ilustrado o procedimento para o *Rolling Forecast Origin* para previsões de um passo adiante.

Figura 7: Ilustração dos passos da técnica *Rolling Forecast Origin* para previsões de um passo adiante. Pontos azuis representam as observações da série temporal usadas no ajuste do modelo; ponto vermelho indica o horizonte de previsão; pontos cinza são observações não utilizadas no respectivo passo



2.2.2. Métricas para avaliar a acurácia de previsões

Como explicado anteriormente, existem diversas maneiras de se calcular as previsões obtidas a partir de modelos ajustados. No entanto, independentemente da maneira como a previsão foi obtida, o erro de uma previsão é calculado diretamente por $e_t = Y_t - F_t$. Este erro de previsão, e_t , pode ser avaliado através de diferentes métricas, e estas são classificadas de acordo com suas características, e podem ser escala dependentes, baseadas em erros percentuais, baseadas em erros relativos e por último podem ser independentes de escala. Abaixo segue uma descrição destes tipos de métricas:

Escala dependentes

- MAE (Mean Absolute Error) = $\frac{1}{n} \sum_{i=1}^n |e_i|$
- MSE (Mean Squared Error) = $\frac{1}{n} \sum_{i=1}^n e_i^2$
- RMSE (Root Mean Squared Error) = $\sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2}$

O uso de valores absolutos ou valores quadráticos impede que valores positivos e negativos dos erros anulem um ao outro. As métricas dependentes de escala não podem ser aplicadas para se comparar previsões entre diferentes séries, pois os seus resultados estarão sempre atrelados à escala usada em cada série.

Erros percentuais

A métrica baseada em erro percentual mais usada é o MAPE, e seu cálculo é obtido pela média do erro percentual:

- $$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n p_i \quad (p_i = 100e_t/Y_t)$$

Os erros percentuais tem a vantagem de não dependerem de escala e, portanto podem ser usados com o objetivo de comparar a acurácia de previsões em diferentes séries de dados. Sua desvantagem é que na presença de valores nulos na série, o erro percentual absoluto médio pode exibir resultados indefinidos ou infinitos.

Erros relativos

Métricas constituídas de erros relativos são frequentemente usadas para comparar a acurácia de previsões em diferentes séries de dados, pois não dependem da escala utilizada. Duas métricas utilizadas são:

- MdRAE = mediana(|r|)
- GMRAE = média geométrica (|r|)

Em que $r = e/e^*$ em que e^* é o erro de previsão dado pelo método de referência – normalmente o passeio aleatório. Uma desvantagem desta métrica é que, na existência de erros muito pequenos, ao se utilizar do método simplório como referência pode ocorrer divisão por zero, impossibilitando o uso desta métrica nesta situação.

Independentes de escala

Uma métrica criada para tentar superar as situações em que as métricas anteriormente apresentadas não são eficientes é o MASE. Esta métrica foi construída tomando o MAE dentro da amostra e escalando este erro, q_t , da seguinte forma:

$$q_t = \frac{e_t}{\frac{1}{n-1} \sum_{i=2}^n |Y_i - Y_{i-1}|}$$

Este erro calculado é independente de escala e o seu resultado será menor que um se a previsão for melhor que a previsão dada pelo método simplório, e será maior que um caso contrário. Desta forma, o MASE será dado por:

- $MASE = média(|q_t|)$

A única situação em que esta métrica pode ser indefinida ou infinita é se todos os valores da série de dados forem iguais (HYNDMAN; KOEHLER, 2006).

Duas métricas específicas figuraram neste trabalho, pois foram utilizadas em Krithikaivasan et al. (2007) e seu cálculo foi necessário para proporcionar o confronto dos resultados expostos. A primeira é a Utilização Média, que mensura quanto da banda prevista é utilizada pelos dados no instante de tempo observado, e é definida como

$$U_{média(h)} = \frac{1}{N} \sum_{i=1}^N \min\left(\frac{Y_{h,i}}{F_{h,i}}, 1\right)$$

em que h indica o horizonte de previsão e foi adicionado na fórmula original, pois no referido trabalho as previsões foram feitas para apenas um passo adiante. A segunda métrica empregada foi a Taxa de Sub-Provisionamento, que se refere à perda de dados em decorrência da banda prevista pelo modelo ter sido inferior ao necessário para a vazão de dados observada. Sua fórmula é dada por

$$TSP_{média(h)} = \frac{1}{N} \sum_{i=1}^N \max\left(\frac{Y_{h,i} - F_{h,i}}{F_{h,i}}, 0\right)$$

2.2.3. Teste Diebold-Mariano

Na avaliação da acurácia das previsões obtidas a partir de diferentes modelos, é importante determinar se os resultados encontrados são devidos apenas ao acaso ou se de fato existe significância estatística no que foi observado, ou seja, se os resultados tem validade científica. Para esta finalidade, existem testes estatísticos especificamente construídos para

comparar as previsões obtidas para séries temporais e fornecer níveis de significância que possam proporcionar mais poder de discernimento ao avaliar diferentes modelos em relação às suas habilidades preditivas. Entre os testes estatísticos aplicados na comparação de previsões, o teste de Diebold-Mariano (DM) vem sendo amplamente utilizado, pois possui fácil interpretação e não requer suposições muito rígidas sobre os dados para que sua aplicação seja válida (MARIANO; PREVE, 2012).

O teste estatístico DM averigua a hipótese de igualdade entre as acurácias de dois diferentes métodos de previsão. Considerando-se a série temporal gerada a partir dos erros de previsão e_{11}, \dots, e_{1t} e e_{21}, \dots, e_{2t} obtidas de dois modelos distintos, a qualidade de cada previsão é avaliada por uma função perda do erro de previsão. A hipótese nula para o teste DM será $E[d(t)] = 0$ para todo t , em que $d(t) = g(e_1) - g(e_2)$, contra a hipótese alternativa de que $E[d(t)] = \mu$, em que $g(\cdot)$ É uma função perda arbitrada (DIEBOLD; MARIANO, 1995).

2.3. Trabalhos relacionados

Em estudos anteriores, Papagiannaki et al. (2003), Krithikaivasan et al. (2004) e Szymanski et al. (2012) empregaram com sucesso os modelos ARMA na modelagem de dados de tráfego de rede. No primeiro trabalho, modelos ARMA de ordem baixa conseguiram ser utilizados de forma apropriada na estimação dos valores futuros do tráfego inter-PoP. Os dados analisados foram provenientes de *traces* obtidos do *backbone* Sprint, no período de 1999 até Julho de 2002, correspondendo a mais de 2.000 links ativos à época e foram agregados em intervalos de tempo de 90 minutos para cada observação. Foi notado neste trabalho que, embora também tenha sido realizada a modelagem dos dados por intermédio de *wavelets*, não houve nenhum tipo de comparação das previsões entregadas por estes diferentes métodos. No segundo trabalho, Krithikaivasan et al. (2004) desenvolveram uma modificação no algoritmo de estimação dos parâmetros do modelo ARMA, com o intuito de diminuir a quantidade de previsões abaixo do tráfego de dados observado. Esta modificação se mostrou bastante eficiente, conforme indicam os resultados apresentados no trabalho.

Como fora discutido em Krithikaivasan et al. (2007), os dados provenientes da observação do tráfego em redes costumam ter volatilidade, ou seja, os segundos momentos da

correlação destes dados são diferentes de zero. Este fato traz consequências para a utilização de modelos ARMA, pois as inovações não mais serão consideradas independentes e as previsões obtidas por meio desta classe de modelos podem não ser mais apropriadas. Para contornar este problema, alguns autores como Kim (2011) e Krithikaivasan et al. (2007) propuseram a aplicação de modelos GARCH, que são aplicados na área de econometria para modelar dados na presença de volatilidade. Em Kim (2011) foi utilizado um conjunto de dados composto de 4.080 observações da vazão entre o link que conecta a Universidade Chung-Ang, situada em Seul, e a Internet. Estas observações foram realizadas no intervalo de tempo de 5 minutos e se deram entre 15 de Dezembro de 2010 e 2 de Junho de 2011. A modelagem destes dados usando GARCH mostrou que a acurácia das previsões, mensurada por meio do RMSE, obtidas por este modelo foi melhor que as obtidas pelo modelo ARMA. No trabalho realizado por Krithikaivasan et al. (2007), foi proposto um esquema de provisionamento de banda baseado nas previsões de tráfego obtidas por intermédio de modelos GARCH. Neste trabalho, além da introdução do GARCH para modelar dados de tráfego de redes, também foram criadas métricas de desempenho específicas para avaliar o desempenho das previsões realizadas. Os seus resultados indicam que a modelagem dos dados de rede por meio do GARCH apresentou bom desempenho.

Os trabalhos discutidos anteriormente deixam algumas perguntas sem resposta que serviram de pontos de investigação do presente estudo. Um deles é verificar o desempenho, através das métricas propostas em Krithikaivasan et al. (2007), de previsões obtidas por modelos GRACH para um horizonte de previsão de mais de um passo. Adicionalmente, ficou em aberto a avaliação de desempenho entre diferentes métodos de previsão por meio destas métricas. Outro fator de investigação é variar a agregação de tempo dos dados, a fim de checar seus possíveis efeitos na modelagem dos dados e nas previsões obtidas por seu intermedio. Tendo em vista estes importantes pontos de investigação em aberto, este trabalho propõe uma avaliação de desempenho que subsidie as respostas a estas questões, conforme objetivos descritos na Seção 1.2.

3. Metodologia e modelagem dos dados

Este capítulo apresenta os detalhes da metodologia aplicada para realizar o ajuste dos modelos cujos desempenhos preditivos são objeto de estudo do presente trabalho.

Para que seja possível realizar as avaliações das previsões propostas, é necessário previamente que as séries temporais sejam ajustadas de acordo com os três modelos utilizados: ARMA, GARCH e RNA. Na seção seguinte será realizada uma breve apresentação das séries temporais que serviram de base para as avaliações deste trabalho e em seguida serão mostrados os procedimentos adotados e os modelos obtidos após o ajuste dos modelos para cada uma destas séries temporais.

3.1. Descrição dos dados utilizados

O conjunto de dados utilizado para realizar a avaliação de desempenho entre os modelos propostos neste trabalho foi derivado do repositório mantido pelo MAWI e será doravante referenciado como série MAWI. Este conjunto de dados tem 9.006 medições na escala de décimo de segundo da taxa de transferência dos fluxos registrados no link entre o WIDE e o provedor de acesso, no dia 21 de Dezembro de 2012, com coleta iniciada as 14:00:00 e encerrada as 14:15:01, totalizando 900,69 segundos. A Figura 8 exibe o comportamento no tempo desta série e na Tabela 1 as suas principais medidas descritivas são apresentadas.

Figura 8 – Comportamento da série temporal MAWI

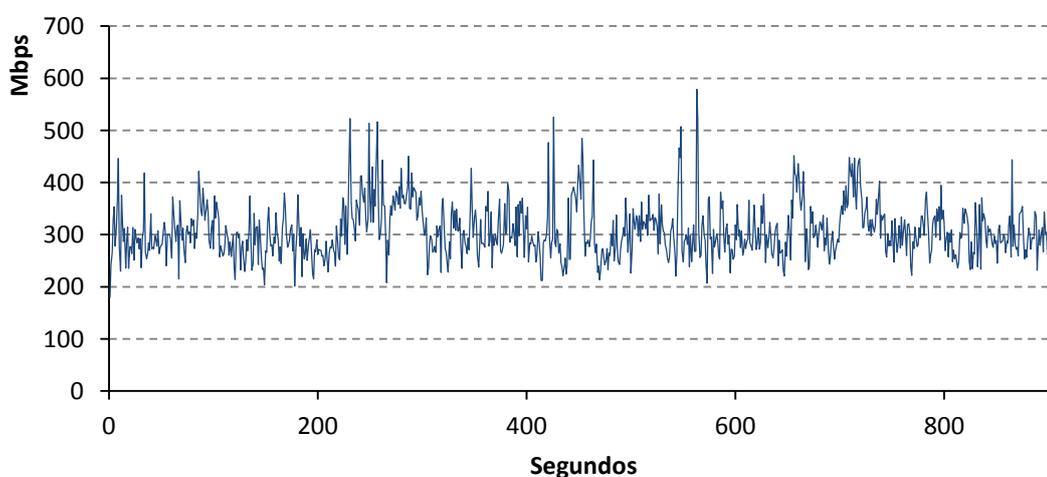


Tabela 1 – Medidas descritivas dos dados que compõem a série temporal MAWI

# observações	Medidas descritivas (Mbps)						
	Mínimo	1º quartil	Mediana	Média	3º quartil	Máximo	Desvio Padrão
9.007	107,07	216,36	246,08	253,26	282,84	578,95	51,65

No Apêndice A é exibido a decomposição da série MAWI nas suas componentes sazonal e de tendência.

3.2. Construção dos modelos para a série temporal MAWI

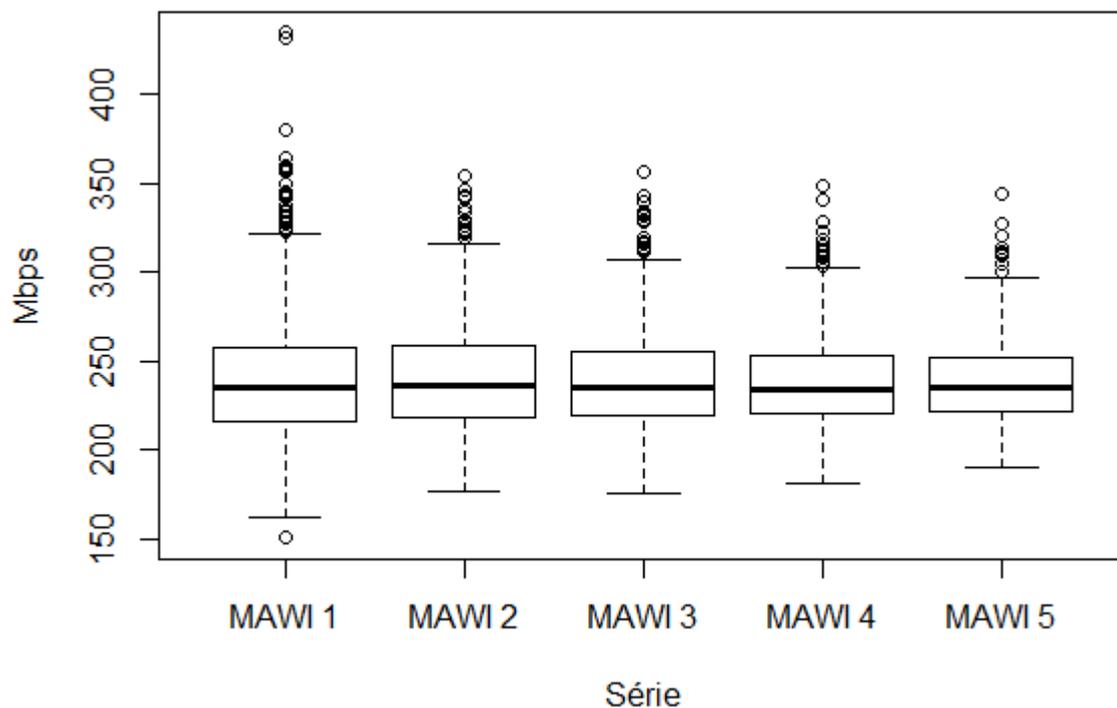
Nesta seção serão mostrados os procedimentos utilizados para ajustar os modelos aos dados da série temporal MAWI. Na subseção 3 os dados foram ajustados usando a modelagem ARMA, na subseção 3.2.2 foi usado GARCH e na subseção 3.2.3 a técnica de Redes Neurais Artificiais foi empregada para ajustar os dados.

Antes de iniciar a sua análise, os dados da série temporal MAWI foram agregados em escalas de tempo de 1, 2, 3, 4 e 5 segundos, com a finalidade de verificar o comportamento das previsões obtidas em relação a estas diferentes granularidades do tempo. Apenas as primeiras observações, correspondentes a aproximadamente 2/3 do total dos dados foram utilizadas no ajuste, e as observações restantes foram empregadas na fase de validação, conforme descrito na Seção 2.1. A Tabela 2 exhibe as características das séries resultantes das agregações dos dados originais nestas escalas de tempo e a Figura 9 ilustra o impacto dessa agregação na distribuição dos dados das séries temporais. Pode-se perceber um efeito de suavização, em que os valores extremos foram diminuindo à medida que a escala de tempo aumenta, sendo este comportamento natural e esperado para dados que foram agregados em escalas de tempo maiores que a original. Outro detalhe, visível na Figura 9, é que as curtoses das séries aparentam não terem sido comprometidas pela agregação em diferentes escalas de tempo e continuam com indícios de serem platicúrtica, o que também é comum já que estamos lidando com dados de tráfego de redes que tendem a ter caudas pesadas. No Apêndice B são apresentados os gráficos das cinco séries temporais resultantes desta agregação e é possível visualizar o efeito de alisamento.

Tabela 2 – Características dos dados agregados nas escalas de tempo de 1, 2, 3, 4 e 5 segundos.

Escala	Denominação	Medidas descritivas (Mbps)						Desvio Padrão
		Mínimo	1º quartil	Mediana	Média	3º quartil	Máximo	
1 segundo	MAWI1	157,65	226,11	246,83	253,26	270,60	456,08	39,20
2 segundos	MAWI2	185,72	228,84	247,18	253,26	270,09	327,12	35,40
3 segundos	MAWI3	184,63	230,47	246,09	253,26	267,82	373,40	33,97
4 segundos	MAWI4	190,03	230,88	245,90	253,26	265,44	366,07	32,68
5 segundos	MAWI5	199,19	232,79	246,61	253,26	264,13	361,04	30,73

Figura 9 – Histogramas exibindo a distribuição dos dados da série temporal MAWI após a agregação dos dados nas escalas de 1, 2, 3, 4 e 5 segundos



3.2.1. Ajuste ARMA

Seguindo os fundamentos descritos no Capítulo 2, Seção 1, o primeiro passo dado para realizar o ajuste dos modelos nos dados estudados foi verificar se as séries temporais são

estacionárias. No Apêndice C são mostrados os gráficos das funções de autocorrelação (FAC) e as funções de autocorrelação parciais (FACP) das séries temporais originais e das séries transformadas, depois de se aplicar a transformação de Box-Cox usando um lambda de $-0,39$. A partir da análise visual destes gráficos é possível identificar que todas as séries são estacionárias após a aplicação da transformação, pois, diferente das séries originais, as suas respectivas FAC's e FACP's decaem muito rápido após os primeiros *lags* e os seus valores seguem abaixo ou muito próximos dos intervalos em que devem estar incluídos caso a suposição de estacionariedade seja verdadeira.

Adicionalmente aos gráficos exibidos no Apêndice C, com o intuito de confirmar com mais robustez a suposição de estacionariedade das séries temporais estudadas, o Teste de Dickey-Fuller aumentado foi aplicado e a Tabela 3 exhibe os resultados dos testes para cada série temporal. Dos resultados desta tabela pode-se concluir que todas as séries temporais são estacionárias, pois os valores de p apresentados são todos abaixo de $0,05$, o que leva a rejeitar que a série temporal tem raiz unitária. Isto implica que a série temporal é estacionária e desta forma é possível prosseguir com a sua modelagem por meio do ARMA.

Tabela 3- Resultados do teste de Dickey-Fuller aplicado aos dados das séries temporais agregada nas escalas de tempo de 1, 2, 3, 4 e 5 segundos.

Série	Valor da estatística de Dickey-Fuller	lag	Valor de p	Interpretação a 5% de confiança
MAWI1	-6,73	6	0,01	A série é estacionária
MAWI2	-6,68	3	0,01	A série é estacionária
MAWI3	-6,83	2	0,01	A série é estacionária
MAWI4	-6,23	2	0,01	A série é estacionária
MAWI5	-6,12	1	0,01	A série é estacionária

Em seguida, após verificar que a série é estacionária, o próximo passo na metodologia de Box-Jenkins é identificar a ordem dos modelos. Esta etapa foi realizada por intermédio do procedimento de escolha da ordem dos parâmetros usando como referencia para a seleção os valores do AIC resultantes dos modelos ajustados, e para executar esta tarefa foi aplicada a rotina *auto.arima* do pacote *forecast* do programa R. O AIC foi escolhido como referência pois é tido como melhor que o BIC em se tratando de acurácia de previsões. O Quadro 2

abaixo exibe os parâmetros selecionados para os modelos ajustados e os seus valores de AIC e log-verossimilhança. Os parâmetros selecionados são a ordem p do componente auto regressivo e a ordem q do componente de médias móveis e não será selecionada a ordem d da diferença, pois a etapa de seleção deste parâmetro já foi realizada ao identificar a série estacionária. Após a seleção dos parâmetros dos modelos pela rotina, foi observado que os modelos ajustados para as séries MAWI 3 e MAWI 4 exibiram alguns coeficientes não significativos e por isso tiveram seus parâmetros estimados novamente, desta vez de forma manual, excluindo-se os coeficientes que não foram significativos, de maneira tal que os modelos finais nestes dois casos foram os selecionados manualmente. Os modelos ajustados receberam denominações, vide Quadro 2, para facilitar as referências futuras a estes modelos.

Quadro 2 - Modelos ajustados para os dados das séries temporais agregada nas escalas de tempo de 1, 2, 3, 4 e 5. As denominações postas serão usadas sempre que necessário referenciar os modelos aqui exibidos.

Denominação do modelo	Escala de tempo	Modelo	AIC	Log-Verossimilhança	Seleção dos parâmetros
BJ1_M	1 segundo	ARMA(2,1)	-3579,33	1806,61	Automática
BJ2_M	2segundos	ARMA(2,1)	-1809,67	923,09	Automática
BJ3_M	3segundos	ARMA(2,1)*	-1186,39	607,36	Automática
		ARMA(2,1)	-1235,45	629,98	Manual
BJ4_M	4segundos	ARMA(2,0)*	-872,13	446,8	Automática
		ARMA(2,0)	-926,12	470,18	Manual
BJ5_M	5segundos	ARMA(1,0)	-709,42	362,4	Automática

* modelo descartado porque apresentou algum coeficiente não significativo.

Após a escolha dos modelos para ajustar os dados, e da estimação dos seus parâmetros, é necessário realizar a análise de diagnóstico dos modelos. Para isso, primeiramente foi realizado o teste de Ljung-Box nos resíduos, a fim de identificar desvios na suposição de independência dos resíduos. No Apêndice C são exibidos os gráficos de resíduos com os valores de p resultantes do teste em cada um dos modelos que foram ajustados para as séries temporais.

Sabendo que a hipótese nula do Teste de Ljung-Box é de independência dos resíduos do modelo, os valores de p obtidos, todos acima de 0,05, indicam que não existem indícios suficientes para se rejeitar esta hipótese e, conseqüentemente, pode-se considerar que a suposição de independência dos resíduos é válida para todos os modelos ajustados.

Dando sequencia a análise de diagnóstico dos modelos ajustados, o passo seguinte é checar se os resíduos obtidos pelos modelos seguem uma distribuição normal. Para confirmar esta suposição foi empregado o Teste de Normalidade de Jarque-Bera e os resultados são apresentados na Tabela 4

Tabela 4 - Resultados do teste de Normalidade de Jarque-Bera aplicado aos resíduos dos modelos ajustados aos dados das séries temporais agregada nas escalas de tempo de 1, 2, 3, 4 e 5 segundos.

Modelo	Qui-Quadrado	Valor de p
BJ1_M	30,91	< 0,001
BJ2_M	2,27	0,321
BJ3_M	2,98	0,2261
BJ4_M	1,89	0,389
BJ5_M	2,54	0,281

Dos resultados exibidos na tabela verifica-se que apenas no caso do modelo BJ1_M a hipótese de normalidade da distribuição dos resíduos foi rejeitada, com p valor abaixo de 0,05. Para todos os outros modelos os valores de p do teste foram maiores que 0,05 e assim considera-se válida a suposição que os resíduos destes modelos tem distribuição normal. Esta violação da suposição de normalidade do modelo BJ1_M será tratada quando foram ajustados os modelos GARCH correspondentes.

A última verificação a ser realizada na análise dos resíduos é checar se a suposição de homoscedasticidade é válida e para isso foi utilizado o Teste Arch de Engle. A Tabela 5 exhibe os resultados deste teste nos modelos encontrados e verificou-se que apenas no modelo BJ1_M e BJ4_M esta suposição foi violada, e com isso fica evidente a presença de efeito

Arch residual. Na próxima seção será mostrado como contornar este problema, empregando os modelos GARCH.

Tabela 5- Resultados do Teste Arch para heteroscedasticidade condicional.

Modelo	Qui-Quadrado	Valor de p
BJ1_M	30,91	< 0,001
BJ2_M	2,27	0,321
BJ3_M	2,98	0,2261
BJ4_M	1,89	0,389
BJ5_M	2,54	0,281

Após passar pelo crivo da análise de resíduos, os modelos ARMA selecionados para gerar as previsões para as séries são os descritos na Tabela 6.

Tabela 6 – Especificação dos modelos ARMA selecionados para ajustar as séries temporais originadas do conjunto de dados MAWI

Série	Ordem	Modelo	σ^2
MAWI 1	(2,1)	$Y_t = 1,368Y_{t-1} - 0,416Y_{t-2} - 0,781\epsilon_{t-1}$	7,3665E+6
MAWI 2	(2,1)	$Y_t = 0,553Y_{t-1} + 0,198Y_{t-2} + 0,207\epsilon_{t-1}$	7,1328E+6
MAWI 3	(2,0)	$Y_t = 0,472Y_{t-1} + 0,144Y_{t-2}$	8,0981E+6
MAWI 4	(1,0)	$Y_t = 0,423Y_{t-2}$	7,5663E+6
MAWI 5	(1,0)	$Y_t = 0,534Y_{t-1}$	6,7123E+6

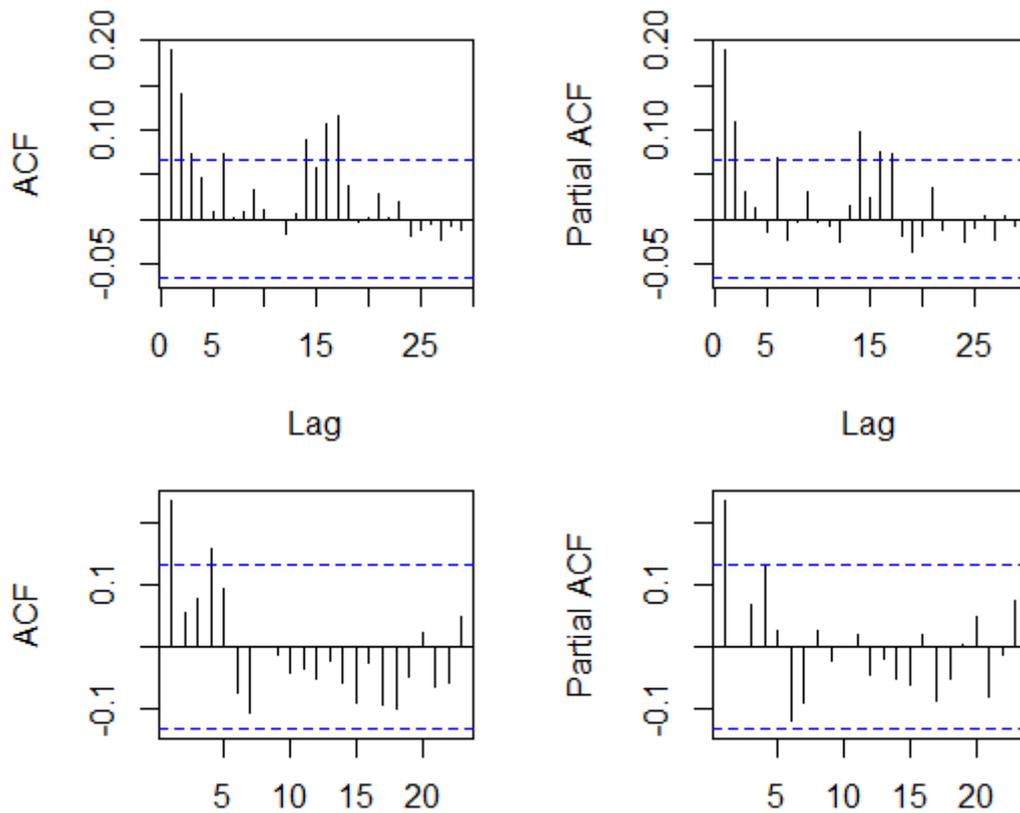
3.2.2. Ajuste GARCH

Como fora apontado na seção anterior, alguns dos modelos ARMA ajustados para os dados exibiram efeito Arch residual nos seus resíduos. Isto é causado pela natureza dos dados ajustados, que apresentam componentes heteroscedásticos na sua variância que não

conseguem ser modelados corretamente por modelos ARMA. Por conta disso, para os dados agregados em 1 e 4 segundos serão ajustados utilizando-se modelos GARCH.

O primeiro passo ao ajustar um modelo GARCH é analisar os gráficos da ACF e PACF dos quadrados dos resíduos obtidos após o ajuste dos dados pelo modelo ARMA. Na Figura 10 são exibidos estes gráficos para os resíduos dos modelos BJ1_M e BJ4_M, e da sua visualização pode-se perceber que existem picos mais destacados nos *lags* 1 e 2, sugerindo um modelo ARCH(2) para o primeiro caso e um modelo ARCH(1) para o segundo caso..

Figura 10 – Gráficos de ACF e PACF dos modelo BJ1_M (acima) e BJ4_M (abaixo).



Após ajustar o modelo ARCH(2) aos dados, é necessário verificar se ainda existe indícios da existência de efeitos Arch residual. Com esta finalidade, foi realizado o teste do Multiplicador de Lagrange para heteroscedasticidade condicional nos resíduos do modelo ajustado. Como este é um procedimento iterativo, em que é necessário verificar repetidas vezes a existência do efeito Arch após ajustar um modelo ARCH candidato, não será apresentado aqui os resultados dos repetidos testes até a obtenção dos modelos finais. Após diversas tentativas, o modelo mais adequado para modelar o efeito Arch nos dados agregados em 1 segundo foi o GARCH(1,1), e para a agregação em 4 segundos foi um ARCH(1), como

pode ser visto na Tabela 7, pois nestes casos este modelo foi capaz de eliminar satisfatoriamente o efeito Arch residual e é o mais parcimonioso entre os testados. Nos Apêndices D e E foram disponibilizados as saídas com as informações do ajuste dos modelos GARCH selecionados.

Tabela 7 - especificação dos modelos GARCH selecionados para ajustar as séries temporais MAWI 1 e MAWI 4

Denominação do modelo	Modelo	AIC	Log-Verossimilhança
BJ1_M	GARCH(1,1)	-0,587	2651,759
BJ4_M	ARCH(1,0)	-872,13	446,8

3.2.3. Ajuste RNA

Nesta seção serão mostrados os modelos ajustados empregando RNA. Como este é um método que não requer muita interação, diferentemente dos modelos ARMA e GARCH, os resultados exibidos nesta seção serão descritos sem a explicação dos passos da modelagem, como fora feito para os outros modelos.

A função utilizada para modelar as séries temporais estudadas usando RNA, *nnetar*, emprega uma rede *feed-forward* com uma camada escondida e é possível apenas indicar a quantidade de nós desta camada, k , e a quantidade de entradas da rede, ρ . Caso nenhuma destas informações seja determinada, os valores serão selecionados automaticamente pela própria função. O valor de ρ é dado pela quantidade de lags ideal para um modelo $Ar(\rho)$ linear, de acordo com o AIC. O valor de k é calculado pela fórmula

$$k = \frac{(\rho + 1)}{2}$$

e neste trabalho foi utilizado sempre os valores padrão da função para estes parâmetros, conforme indicação do seu autor. O Quadro 3 mostra os modelos ajustados por RNA para as séries temporais avaliadas.

Quadro 3 - Especificação dos modelos ajustados por RNA para as séries MAWI

Série	Ordem	Modelo	σ^2
MAWI 1	NNAR(6)	6-4-1	7.366.537
MAWI 2	NNAR(3)	3-2-1	7.132.884
MAWI 3	NNAR(2)	2-2-1	8.098.172
MAWI 4	NNAR(2)	2-2-1	7.566.360
MAWI 5	NNAR(1)	1-1-1	6.712.380

4. Resultados

Neste capítulo serão apresentados os resultados das métricas calculadas para avaliar o desempenho dos modelos ajustados no capítulo anterior, no que concerne as suas previsões. Os valores expressos neste capítulo foram calculados empregando o método de validação descrito na Seção 2.1.

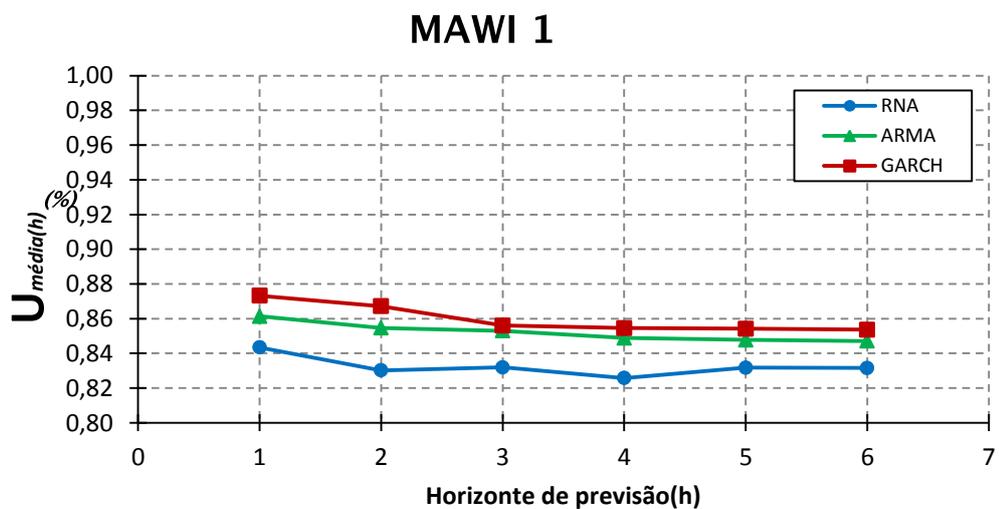
4.1. Acurácia das previsões para a série MAWI

Com base nos modelos ajustados para a série MAWI, conforme descrito na Seção 3.2, foram calculadas previsões para os valores futuros das séries, para um horizonte de até seis passos à frente. Como foram criadas séries com diferentes granularidades de tempo, com base na série original, estes passos representam uma janela de tempo diferente em cada uma delas. Por exemplo, na série MAWI 1, agregada em escala de 1 segundo, cada passo no horizonte de previsão representa 1 segundo, na MAWI 2 representa 2 segundos e assim sucessivamente.

4.1.1. Utilização Média ($\mathcal{U}_{média(h)}$)

Para cada uma das séries agregadas em diferentes granularidades de tempo, foram calculados os valores de $\mathcal{U}_{média(h)}$ para os horizontes de previsão de um a seis passos. A Figura 11 mostra estes valores para as previsões calculadas para a série MAWI1.

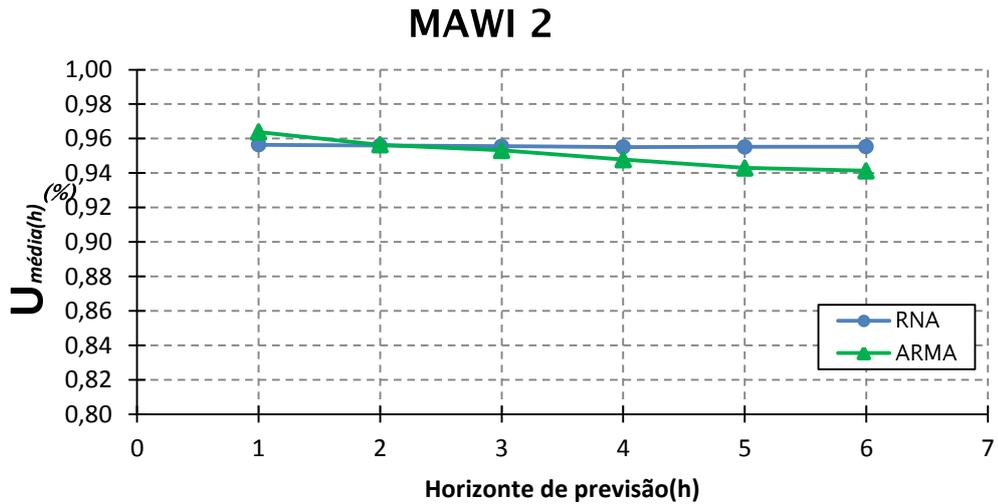
Figura 11: Valores calculados de $\mathcal{U}_{média(h)}$ para a série MAWI 1



Pode-se observar que as previsões de todos os modelos ajustados alcançaram mais de 84% de utilização média da banda para o horizonte de um passo adiante, em que os melhores

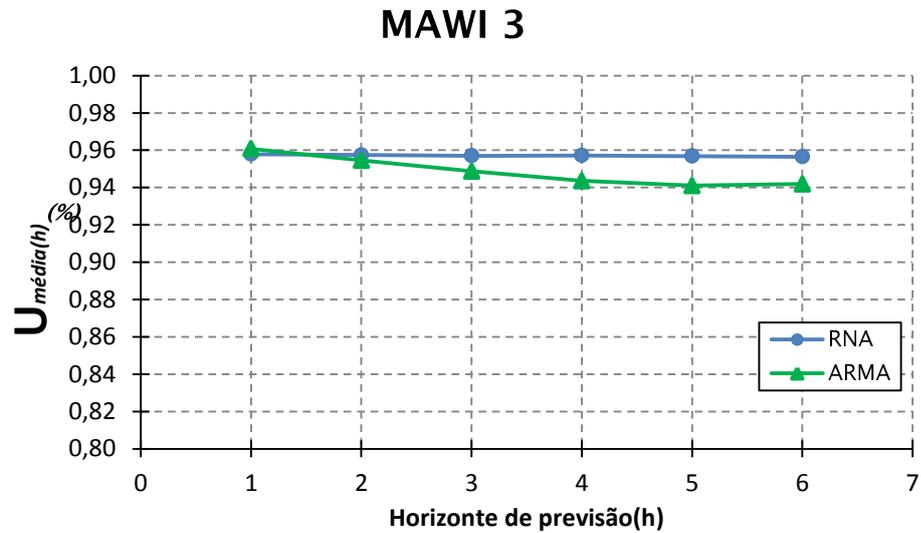
resultados foram alcançados pelo ARCH, seguido do ARMA e RNA. Com a extensão do horizonte de previsão, os valores de $\mathcal{U}_{média(h)}$ decrescem, provavelmente como consequência do aumento da incerteza das previsões com o distanciamento da última observação. Porém, mesmo com o aumento do horizonte de previsão, o GARCH continua exibindo os maiores valores para esta métrica.

Figura 12: Valores calculados de $\mathcal{U}_{média(h)}$ para a série MAWI 2



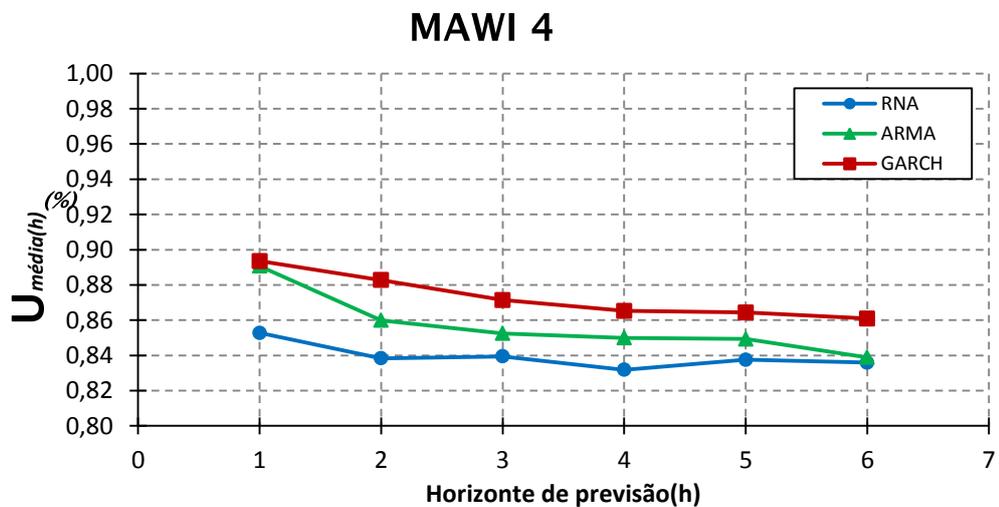
Os resultados encontrados para $\mathcal{U}_{média(h)}$ em relação às previsões fornecidas para a série MAWI 2 indicam que o modelo ajustado por RNA exibiu os maiores valores, mesmo considerando que para o primeiro passo no horizonte de previsão o ARMA obteve a previsão com maior $\mathcal{U}_{média(h)}$, conforme ilustrado na Figura 12. Comportamento muito semelhante pode ser observado na Figura 13, onde são exibidos os valores desta métrica em relação às previsões obtidas para a série MAWI 3. Observa-se que tanto para a série MAWI 2 quanto a MAWI 3 os valores observados para esta métrica foram altos, acima de 93%.

Figura 13: Valores calculados de $\mathcal{U}_{média(h)}$ para a série MAWI 3



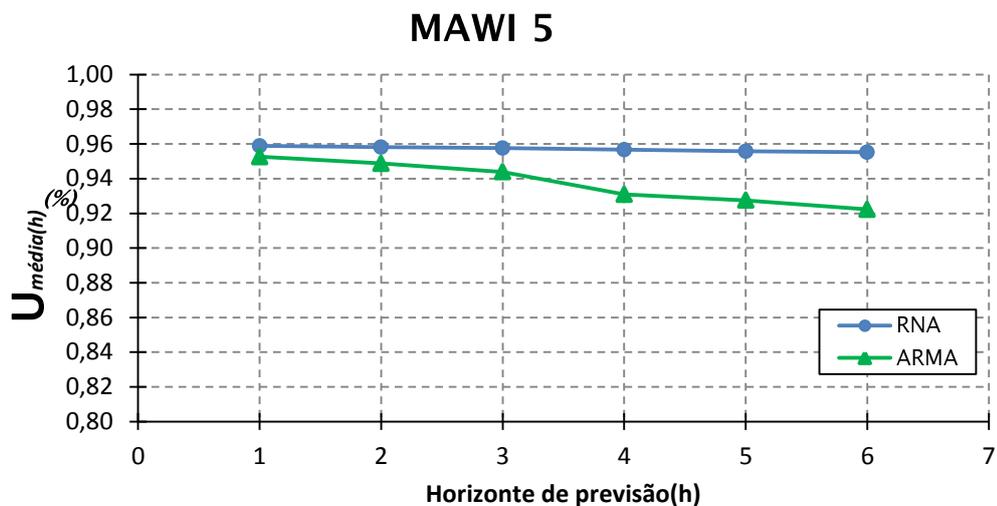
Os resultados obtidos para a série MAWI 4 são mostrados na Figura 14. De maneira análoga ao que foi observado nas previsões da série MAWI 1, que compartilha com esta série a presença de volatilidade, os valores de $\mathcal{U}_{média(h)}$ calculados para as previsões entregues pelo GARCH foram melhores em todos os horizontes de previsão, muito embora no primeiro passo o modelo ARMA tenha apresentado um valor muito próximo. Outro ponto que chama a atenção é que a utilização média para estas duas séries foram bem mais baixos que os apresentados para as séries MAWI 2 e MAWI 3, possivelmente indicando que a presença de volatilidade torna as previsões menos precisas.

Figura 14: Valores calculados de $\mathcal{U}_{média(h)}$ para a série MAWI 4



A última série para a qual foi calculada esta métrica foi a MAWI 5. Os valores obtidos podem ser observados na Figura 15, e indicam comportamento parecido ao visto nas séries sem volatilidade anteriores, a MAWI 2 e MAWI 3, ou seja, os valores apresentados pelo RNA foram melhores que o ARMA. A única diferença observada é que para esta série, os valores calculados para o ARMA foram um pouco menores, chegando a 92% no sexto passo da previsão.

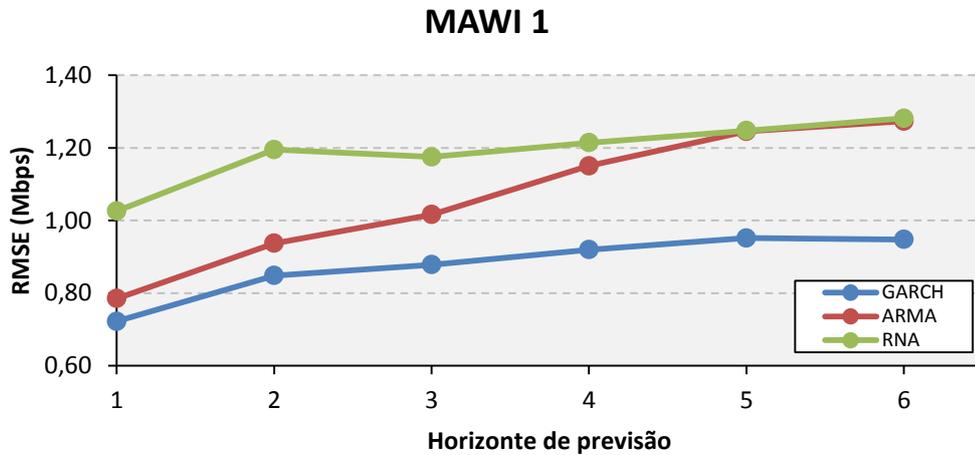
Figura 15: Valores calculados de $\mathcal{U}_{média(h)}$ para a série MAWI 5



4.1.2. RMSE

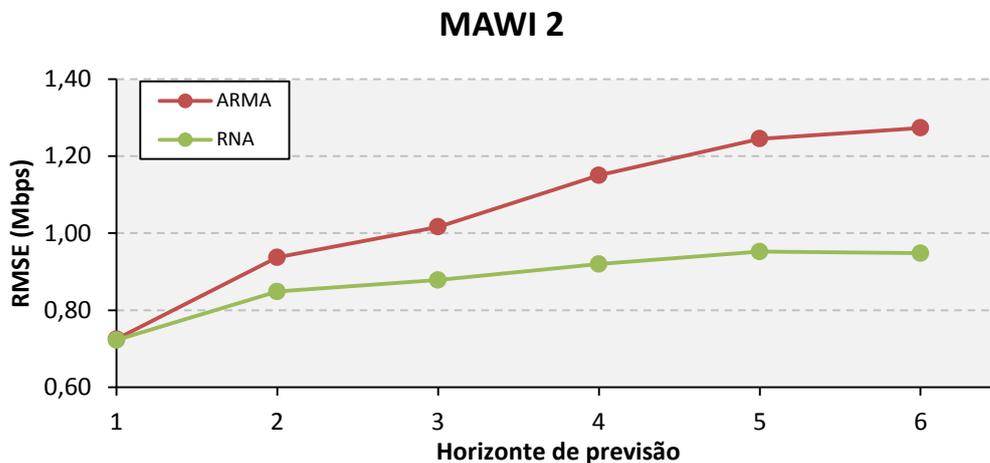
A fim de comparar os erros das previsões para as séries, foi calculado o RMSE, que avalia a raiz quadrada do erro médio quadrático, para cada modelo utilizado neste estudo. Na Figura 16 é ilustrado o RMSE calculado para as previsões dos modelos ajustados para a série MAWI1, lembrando que esta série apresenta volatilidade e além dos modelos ajustados usando ARMA e RNA, também foi ajustado um modelo GARCH. É possível observar que as previsões obtidas por este último modelo apresentaram os menores erros, seguido dos modelos ARMA e RNA, respectivamente. Para as previsões em um horizonte de cinco e seis passos, estes dois últimos modelos apresentaram erros quase idênticos.

Figura 16 - Valores de RMSE para as previsões obtidas pelos modelos GARCH, ARMA e RNA para a série MAWI 1.



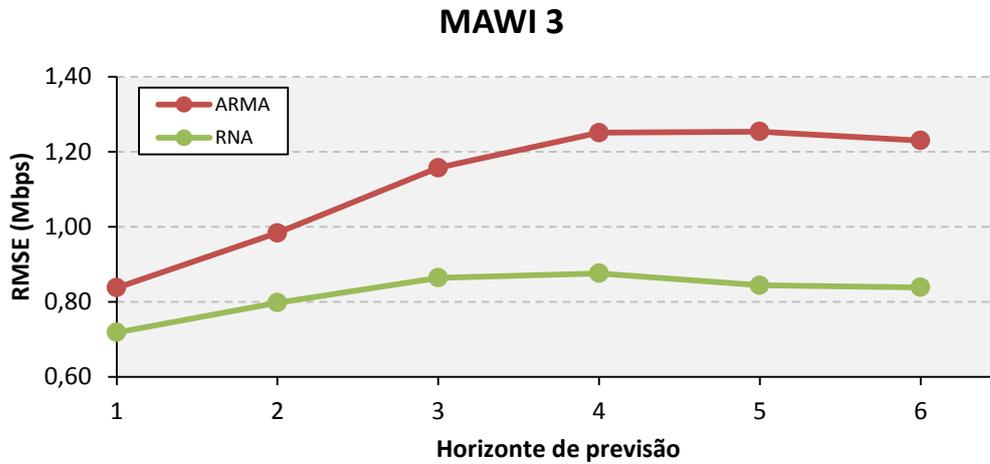
Os resultados do RMSE para a série MAWI 2 são exibidos na Figura 17. Observa-se que os valores desta métrica são menores para o modelo RNA, e embora para as primeiras previsões a diferença seja pequena, os seus valores deste erro vão se distanciando um do outro à medida que o horizonte de previsão expande, chegando a diferir em mais de 0,3Mbps.

Figura 17 – Valores do RMSE para as previsões obtidas pelos modelos ARMA e RNA para a série MAWI 2.



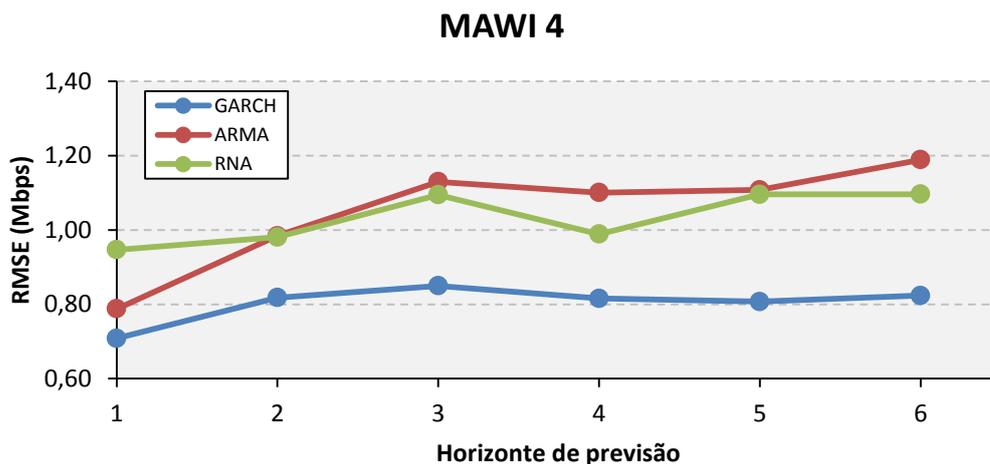
Os resultados desta medida de acurácia para a série MAWI 3 continuam exibindo valores menores para o modelo ajustado por RNA, e a partir do 4º passo no horizonte de previsão, a distancia entre o RMSE exibido entre as previsões por RNA e ARIMA já ultrapassa os 0,3Mbps. Estes resultados podem ser consultando a Figura 18.

Figura 18 - Valores do RMSE para as previsões obtidas pelos modelos ARMA e RNA para a série MAWI 3.



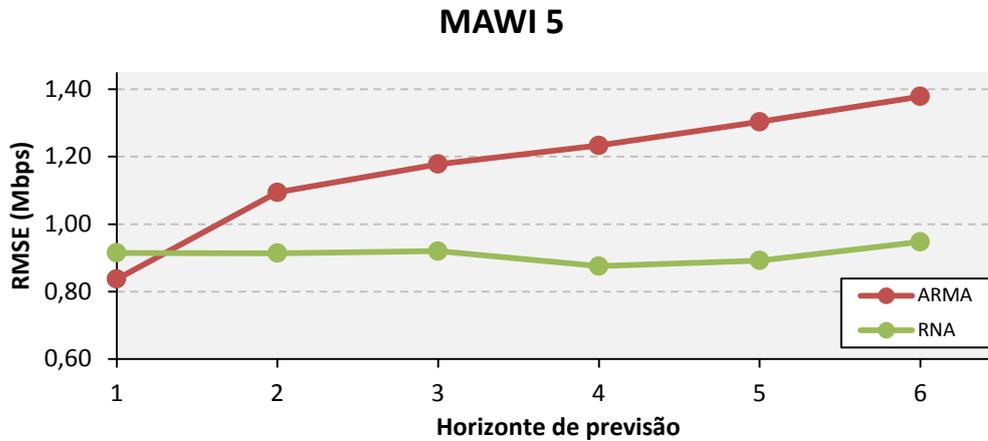
Como a série MAWI 4 também apresentou efeito Arch residual após o ajuste ARMA, para esta série também foi ajustado um modelo GARCH. Os valores do MAPE para as previsões construídas para esta séries são mostrados na Figura 19. Assim como ocorreu na série MAWI 1, o modelo GARCH exibiu os menores erros de previsão. Os outros dois modelos apresentaram valores de erro semelhantes, embora a previsão de um passo adiante do RNA tenha resultado num RMSE de 0,95Mbps, bem maior que os outros dois modelos.

Figura 19 - Valores do RMSE para as previsões obtidas pelos modelos GARCH, ARMA e RNA para a série MAWI 4.



A última série de dados analisada, a MAWI 5, apresentou valores de RMSE com padrão parecido ao encontrado para as outras séries, ou seja, o modelo ajustado por RNA entregou previsões com RMSE menores que o modelo ARIMA. Entretanto, no primeiro passo de previsão, o valor apresentado pelo ARIMA foi menor.

Figura 20 - Valores do RMSE para as previsões obtidas pelos modelos ARMA e RNA para a série MAWI 5..

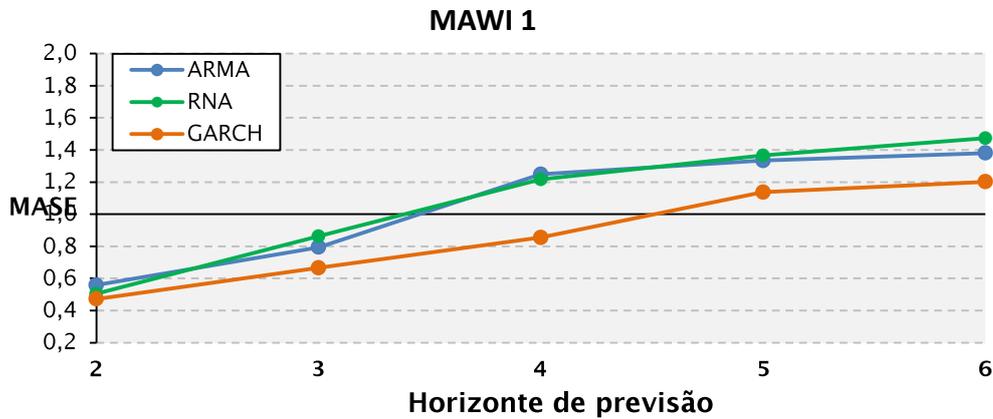


Pode-se observar que em geral, o valor do RMSE aumenta a medida que o horizonte de previsão se estende, fato esperado, pois a incerteza da previsão aumenta com o número de passos adiante. No entanto não foi observado nenhum aumento descontrolado nesta métrica em nenhum dos casos, fato que conta a favor da robustez dos modelos ajustados. Outro detalhe importante que pode ser observado é que o RMSE para as previsões obtidas por RNA foram, na maior parte das situações apresentadas, menores que os valores de RMSE apresentados pelo ARMA. No entanto, nos ajustes das séries que apresentaram volatilidade, os modelos RNA não conseguiram apresentar previsões com baixos RMSE, situação em que os modelos GARCH sobressairam-se com valores baixos para seus erros de previsão.

4.1.3. MASE

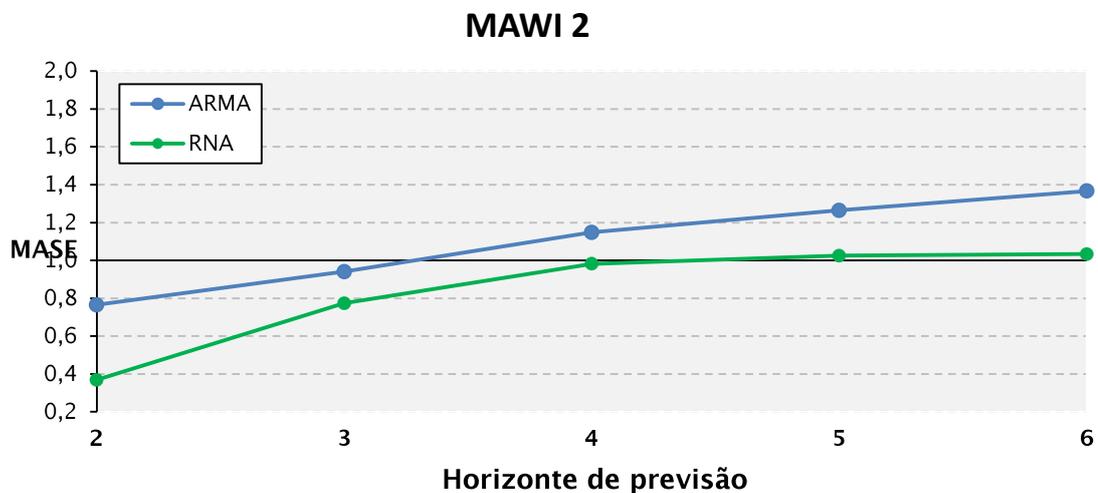
Além do RMSE, também foram calculados os valores do MASE para as previsões obtidas por meio dos modelos ajustados para cada série temporal. A Figura 21 exibe os valores obtidos para esta medida de acurácia em relação às previsões obtidas para a série agregada em 1 segundo, MAWI 1. Nela é possível observar que até o horizonte de previsão com quatro passos adiante ainda existem previsões melhores que a estimativa simplória, o último valor da série, porém apenas o modelo GARCH apresentou tal resultado, possivelmente resultado da volatilidade presente nesta série. Não obstante, até o horizonte 3, todos os modelos entregaram previsões com melhor desempenho que a estimativa simplória.

Figura 21 - Valores do MASE para as previsões obtidas pelos modelos GARCH, ARMA e RNA para a série MAWI 1.



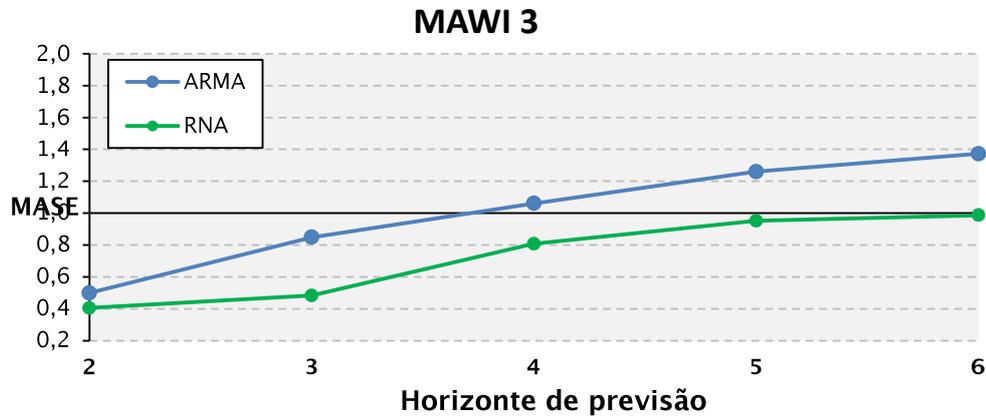
Em relação às previsões obtidas para a série MAWI 2, os resultados ilustrados na Figura 22 sugerem um comportamento parecido com o apresentado na série anterior, porém neste caso as previsões melhores foram apresentadas pelo modelo ajustado por meio de RNA.

Figura 22 - Valores do MASE para as previsões obtidas pelos modelos ARMA e RNA para a série MAWI 2.



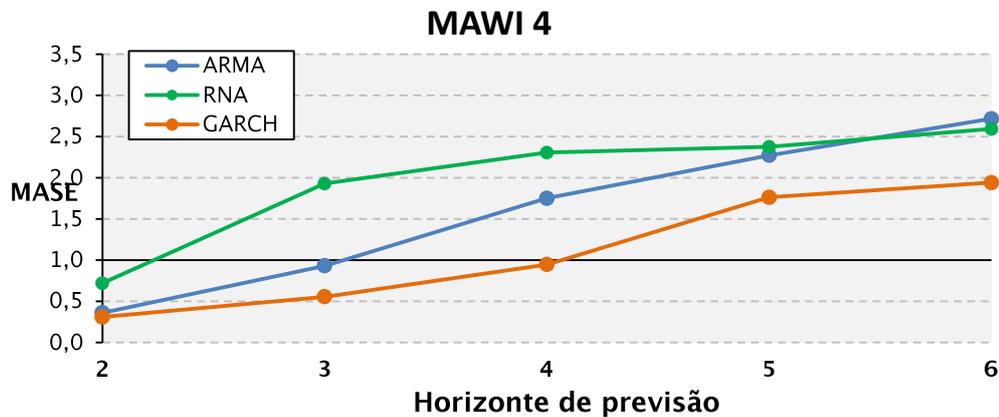
Na Figura 23 pode-se constatar que as previsões conseguidas por RNA exibiram valores do MASE abaixo de 1 até um horizonte de previsão de cinco passos, enquanto o modelo ajustado pela metodologia ARMA só apresentou previsões nestes patamares até o segundo passo.

Figura 23 - Valores do MASE para as previsões obtidas pelos modelos ARMA e RNA para a série MAWI 3.



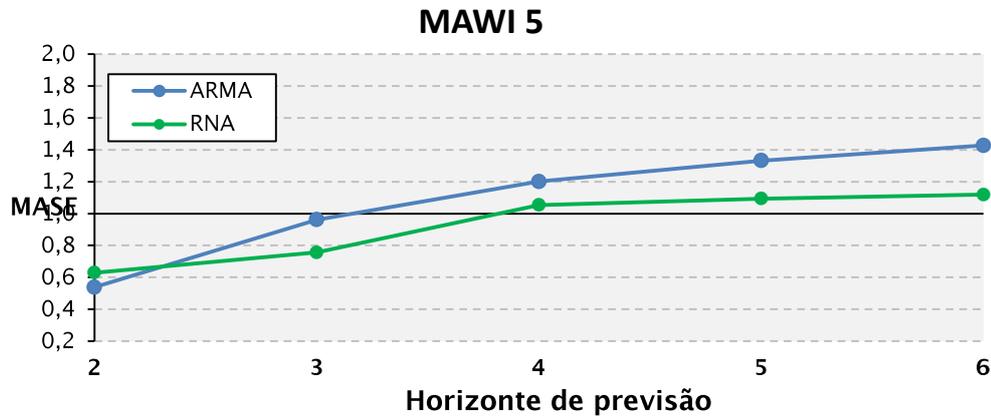
A série MAWI 4, que acomoda componente heteroscedástico em seus dados, conforme visto no Capítulo 3, apresentou os valores do MASE ilustrados na Figura 23. Evidencia-se desta maneira que as previsões obtidas pelo modelo GARCH se mostraram superiores às encontradas pelos outros modelos, de forma que apenas este modelo conseguiu previsões com valor menor que 1 para a métrica em questão até o horizonte de previsão 4.

Figura 24 - Valores do MASE para as previsões obtidas pelos modelos GARCH, ARMA e RNA para a série MAWI 4.



Para a última série temporal analisada, a MAWI 5, os valores do MASE se mantiveram abaixo de 1 apenas até o passo 3 no horizonte de previsão, o que evidencia um desempenho menor que o apresentado em relação as séries anteriores. De toda forma as previsões conseguidas por meio do modelo ajustado usando RNA se mostraram melhores que as obtidas pelo modelo ARMA.

Figura 25 - Valores do MASE para as previsões obtidas pelos modelos ARMA e RNA para a série MAWI 5.



4.1.4. Teste de Diebold Mariano

Nesta seção serão apresentados os resultados dos testes de comparação entre as acurácias obtidas pelos modelos ajustados. Como função perda, foi escolhido o RMSE.

Quadro 4 – Resultados dos testes DM. (hipótese nula = acurácia modelo 1 > acurácia modelo 2)

Série	ARMA vs GARCH	ARMA vs RNA	GARCH vs RNA	Melhor acurácia
MAWI 1	< 0,0001	0,0258	0,2511	GARCH
MAWI 2	-	0,0034	-	RNA
MAWI 3	-	0,0075	-	RNA
MAWI 4	0,0021	0,0432	0,3229	GARCH
MAWI 5	-	0,0098	-	RNA

Dos resultados ilustrados no Quadro 4, é possível confirmar que os modelos ajustados por meio de RNA exibiram as melhores medidas de acurácia, quando os dados não exibem volatilidade. Quando existe componente heteroscedástica nos dados, a exemplo dos dados MAWI 1 e MAWE 2, as previsões entregadas pelo modelo GARCH foram as que exibiram melhor acurácia, segundo evidencia o resultado do teste DM.

4.2. Resumo

Os resultados expostos anteriormente neste capítulo são exibidos, de forma sintética, no Quadro 5.

Quadro 5 – Síntese das ferramentas de análise de séries temporais que exibiram os melhores resultados de previsão em cada série estudada.

Métrica	Série				
	MAWI 1	MAWI 2	MAWI 3	MAWI 4	MAWI 5
$u_{média(h)}$	GARCH	RNA	RNA	GARCH	RNA
RMSE	GARCH	RNA	RNA	GARCH	RNA
MASE	GARCH	RNA	RNA	GARCH	RNA
Teste DM	GARCH	RNA	RNA	GARCH	RNA

Novamente, fica evidente que os modelos GARCH se destacam na sua capacidade de lidar com séries temporais que exibem componentes de volatilidade, a exemplo das séries MAWI 1 e MAWI 4. Já nas séries sem volatilidade, a RNA exibiu os melhores resultados.

5. Conclusões e trabalhos futuros

Neste trabalho foi apresentada uma avaliação de desempenho das previsões obtidas por meio dos modelos GARCH, ARMA e RNA para os valores futuros dos dados relacionados à vazão em rede. Para realizar esta avaliação foram propostos cenários em que a série de dados original foi agregada em diferentes bases de tempo e foram construídas previsões para horizontes de até seis passos adiante.

A primeira descoberta foi que das cinco séries temporais agregadas em diferentes granularidades de tempo, apenas duas exibiram componente de volatilidade, ou efeito ARCH, após o ajuste ARMA. Este fenômeno pode ter origem no efeito de alisamento consequente da agregação no tempo, que diminui discretamente os valores extremos exibidos nas séries temporais.

As previsões foram avaliadas por intermédio das métricas $\mathcal{U}_{média(h)}$, RMSE e MASE. Os resultados do $\mathcal{U}_{média(h)}$, revelam que:

- Na ausência de heteroscedasticidade, os ajustes por RNA entregaram previsões com melhor utilização média que o ARMA;
- Nas séries que apresentaram volatilidade, o GARCH obteve os melhores valores para esta métrica;
- As previsões para as séries com volatilidade apresentaram valores significativamente menores que para as séries sem esta componente.
- Os valores encontrados para esta métrica foram bastante elevados, chegando a 96% em alguns casos, maiores que os observados em Krithikaivasan et al. (2007), e este fato pode estar relacionado ao presente estudo ter utilizado dados em uma pequena faixa de tempo, totalizando 15 minutos, enquanto os dados do referido artigo totalizam 10 dias.

Os resultados do RMSE evidenciaram que:

- Na ausência de heteroscedasticidade, os ajustes por RNA entregaram previsões mais acuradas que os outros modelos;

- Na presença de heteroscedasticidade, a modelagem por GARCH foi substancialmente melhor que as outras metodologias, comprovando a sua eficácia em lidar com a volatilidade presente neste tipo de dados;
- As previsões resultantes da modelagem ARMA foram melhores para o primeiro passo, em alguns poucos casos, mas se deterioraram rapidamente à medida que o horizonte de previsão se estendeu.

Os resultados do MASE mostram que:

- Todos os modelos ajustados foram capazes de entregar previsões melhores que a estimativa simplória para pelo menos três passos adiante;
- Os modelos ajustados por RNA conseguiram valores abaixo de 1,0 para esta métrica para um horizonte de previsão de até cinco passos;
- Na presença de volatilidade, apenas os modelos ajustados por GARCH apresentaram previsões melhores que a estimativa simplória para o horizonte de quatro passos adiante.

Além das observações das métricas, também foi aplicado o teste estatístico DM para confirmar se existiu significância estatística nos resultados exibidos. A aplicação do teste confirmou as afirmações expostas anteriormente, reafirmando o melhor desempenho dos modelos ajustados por meio de RNA quando da ausência de volatilidade, e na sua presença, o GARCH apresentou melhor acurácia.

Para trabalhos futuros, fica a proposição de utilizar dados com maior extensão, na escala de meses, para que se possa realizar esta avaliação de desempenho sob a perspectiva da sazonalidade diária dos dados de tráfego de redes, e também comparar os valores obtidos para a métrica $\mathcal{U}_{média(h)}$ em relação ao presente estudo, para verificar se o impacto desta sazonalidade faz os valores serem menores .

6. Contribuições

Os resultados expostos neste trabalho tiveram como principal objetivo trazer mais informações que possam contribuir na avaliação do comportamento dos modelos de análise de séries temporais ao serem utilizados para gerar previsões para vazão de dados em redes. Como diferencial, foram construídos cenários para avaliar as previsões em horizontes de previsão de até seis passos adiante, enquanto que em Krithikaivasan et al. (2007) os resultados apenas contemplaram previsões de uma passo adiante. Também foram realizadas agregações dos dados originais em diferentes granularidades de tempo, e foi identificado que estas agregações tiveram impacto na componente heteroscedástica dos dados e conseqüentemente os valores de acurácia obtidos tiveram desvios em função deste componente de volatilidade.

Outro fator de destaque no presente trabalho foi a utilização da técnica *Rolling Forecast Origin* para validar as previsões e as métricas empregadas, algo que não foi observado com frequência nos trabalhos que trouxeram medidas de acurácia sobre a aplicação destes modelos e não tinha sido observado até o momento em nenhum trabalho referente a modelagem de dados de vazão em redes.

Referências

ANAND, N. C.; SCOGLIO, C.; NATARAJAN, B. **GARCH - Non-Linear Time Series Model for Traffic Modeling and Prediction**. NOMS, 2008.

ARLOT, S.; CELISSE, A. **A survey of cross-validation procedures for model selection**, 4, 2010. 40,79.

ARMSTRONG, J. S. **Error Measures for Generalizing About Forecasting Methods: Empirical Comparisons**. International Journal of Forecasting, Junho 1992. 69-80.

ASSOCIATI, C. **The Evolution of Internet of Things**. [S.l.]. 2011.

ATZORI, L.; IERA, A.; MORABITO, G. **The Internet of Things: A survey**. Computer Networks, 54, Outubro 2010. 2787–2805.

BERGMEIR, C.; BENÍTEZ, J. M. **On the use of cross-validation for time series predictor evaluation**. Information Sciences, 2010. 192-213.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time series analysis: forecasting and control**. 4ª. ed. [S.l.]: John Wiley & Sons, 2008.

BROCKWELL, P. J.; DAVIS, R. A. **Introduction to time series and forecasting**. New York: Springer-Verlag, 2002.

BURNHAM, K. P.; ANDERSON, D. R. **Inference, Model Selection and Multimodel**. 2ª. ed. [S.l.]: Springer-Verlag, 1998.

CISCO. Connections Counter: The Internet of Everything in Motion. **The Network**, 2013. Disponível em: <<http://newsroom.cisco.com/feature-content?type=webcontent&articleId=1208342>>. Acesso em: 19 Julho 2014.

DIEBOLD, F. X.; MARIANO, R. S. **Comparing Predictive Accuracy**. Journal of Business and Economic Statistics, 1995. 253-265.

DROSSU, R.; OBRADOVIC, Z. **Rapid design of neural networks for time series prediction**. IEEE, 3, 1996. 78-89.

ELKHODR, M.; SHAHRESTANI, S.; CHEUNG, H. **The Internet of Things: Vision & Challenges**. TENCON Spring Conference, 2013 IEEE, Abril 2013. 218,222.

ENGLE, R. **Risk and Volatility: Econometric Models and Financial Practice**. American Economic Review, 94, Junho 2004. 405-420.

ENGLE, R. F. **Autoregressive conditional heteroscedasticity with estimates of the variance of U.K. inflation**. Econometrica, 50, 1982. 987-1007.

HAMILTON, J. D. **Time series analysis**. [S.l.]: Prince University, 1994.

HAN, J.; KAMBER, M. **Data Mining: Concepts and Techniques**. [S.l.]: Morgan Kaufmann Publishers, 2006.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. [S.l.]: OTexts , 2013.

HYNDMAN, R. J.; KHANDAKAR, Y. **Automatic Time Series Forecasting: The forecast package for R**. Journal of Statistical Software, 27, 2008.

HYNDMAN, R. J.; KOEHLER, A. B. **Another Look at Measures of Forecast Accuracy**. International Journal of Forecasting, 22, 2006. 679,688.

KIM, S. **Forecasting Internet Traffic by Using Seasonal GARCH Models**. Journal of communications and networks, 13, 2011.

KIRCHGÄSSNER, G.; WOLTERS, J.; HASSLER, U. **Introduction to Modern Time Series Analysis**. 2^a. ed. [S.l.]: Springer Heidelberg, 2013.

KRITHIKAIVASAN, B. **Adaptive bandwidth provisioning envelope based on discrete temporal network measurements**. IEEE, 2004.

KRITHIKAIVASAN, B. et al. **ARCH-Based Traffic Forecasting and Dynamic Bandwidth Provisioning for Periodically Measured Nonstationary Traffic**. [S.l.]: [s.n.]. 2007.

KUROSE, J. F.; ROSS, K. W. **Computer Networking: A Top-Down Approach**. 6^a. ed. [S.l.]: Addison-Wesley, 2012.

LABYS, J. B. C.; W. C.; TERRAZA, M. **Univariate tests for time series models**. Londres: SAGE, v. 99, 1994.

MARIANO, R. S.; PREVE, D. **Statistical tests for multiple forecast comparison**. Journal of Econometrics, 2012. 123-130.

MCGORMAN, R.; J. ALMHANA, V. C.; LIU, Z. **Empirical Bandwidth Provisioning Models for High Speed Internet Traffic**. Communication Networks and Services Research Conference, 2006. CNSR 2006. Proceedings of the 4th Annual, 2006. 195.

OLIFER, N.; OLIFER, V. **Computer Networks: Principles, Technologies and Protocols for Network Design**. [S.l.]: Wiley, 2005.

PANKRAN, A. **Forecasting with univariate Box-Jenkins models**. [S.l.]: JOHN WILLEY & SONS, 1994.

PAPAGIANNAKI, K. et al. **Long-Term Forecasting of Internet Backbone Traffic: Observations and Initial Models**. INFOCOM 2003. Twenty-Second Annual Joint Conference of the IEEE Computer and Communications. IEEE Societies, 2, Março 2003. 1178,1188.

PEDRYCZ, W.; CHEN, S.-M. **Time Series Analysis, Modeling and Applications**. [S.l.]: Springer Heidelberg, 2013.

PEÑA, D.; TIAO, G. C.; TSAY, R. S. **A Course in Time Series Analysis**. [S.l.]: Wiley, 2001.

PERERA, C. **Context Aware Computing for The Internet of Things: A Survey**. IEEE COMMUNICATIONS SURVEYS & TUTORIALS, 16, 2014.

QI, M.; ZHANG, G. P. **Trend Time-Series Modeling and Forecasting With Neural Networks**. IEEE TRANSACTIONS ON NEURAL NETWORKS, 19, 2008. 808,816.

RAPACH, D. E.; WOCHAR, M. E. **In-Sample vs. Out-of-Sample Tests of Stock Return Predictability in the Context of Data Mining**. Journal of Empirical Finance, 13, Março 2006. 231,247.

SHUMWAY, R. H.; STOFFER, D. S. **Time Series Analysis and Its Applications**. 3^a. ed. [S.l.]: Springer, 2011.

SUNDMAEKER, H. et al. **Vision and challenges for realising the internet of things**. Bruxelles. 2010.

SZYMANSKI, T. H.; BEHDIN, S. **Traffic Provisioning in a Future Internet**. international Workshop on the Network of the Future, Junho 2012. 5872,5878.

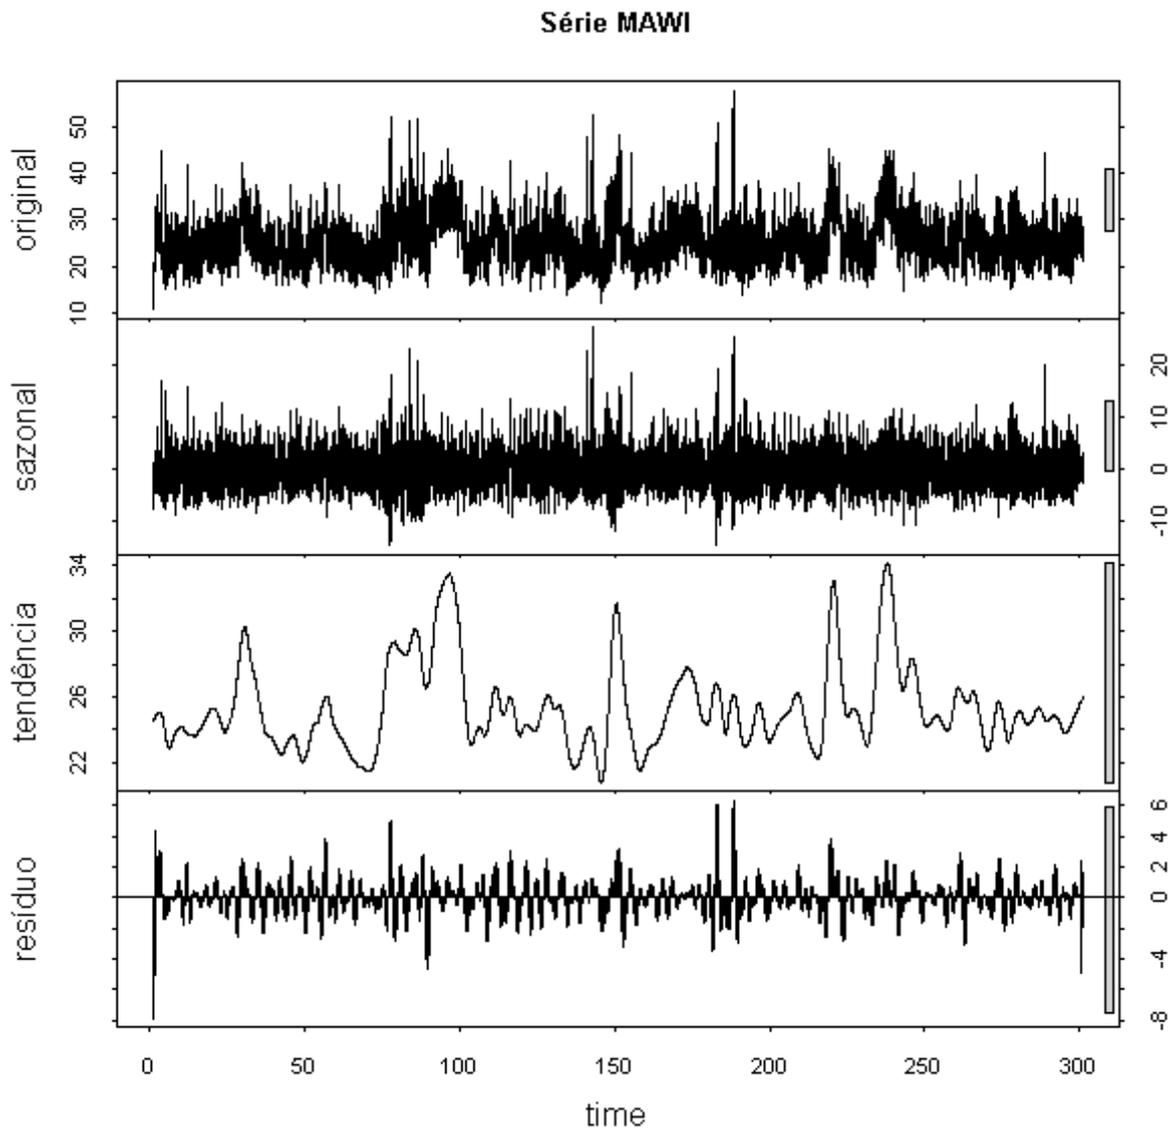
THE research and implement of smart home system based on internet of things.

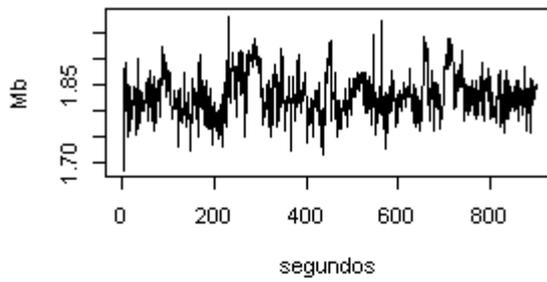
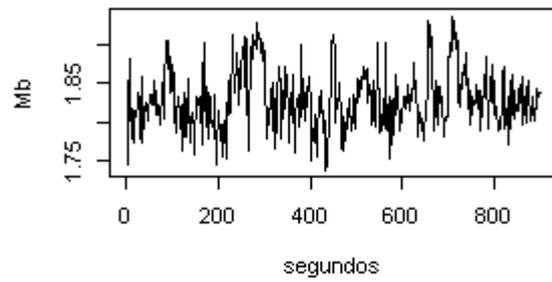
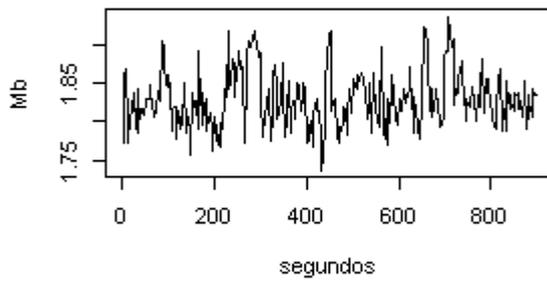
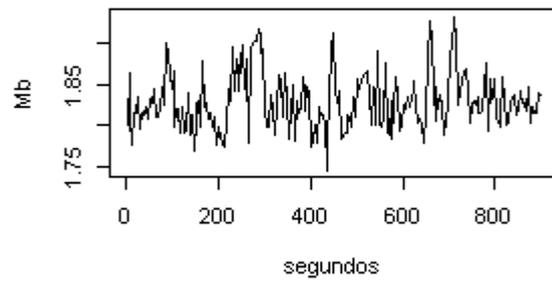
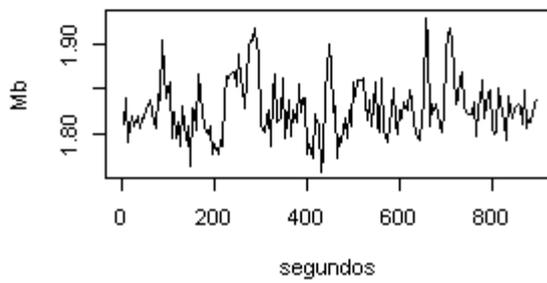
TSAY, R. S. **Analysis of Financial Time Series**. 3^a. ed. Chicago: Wiley, 2005.

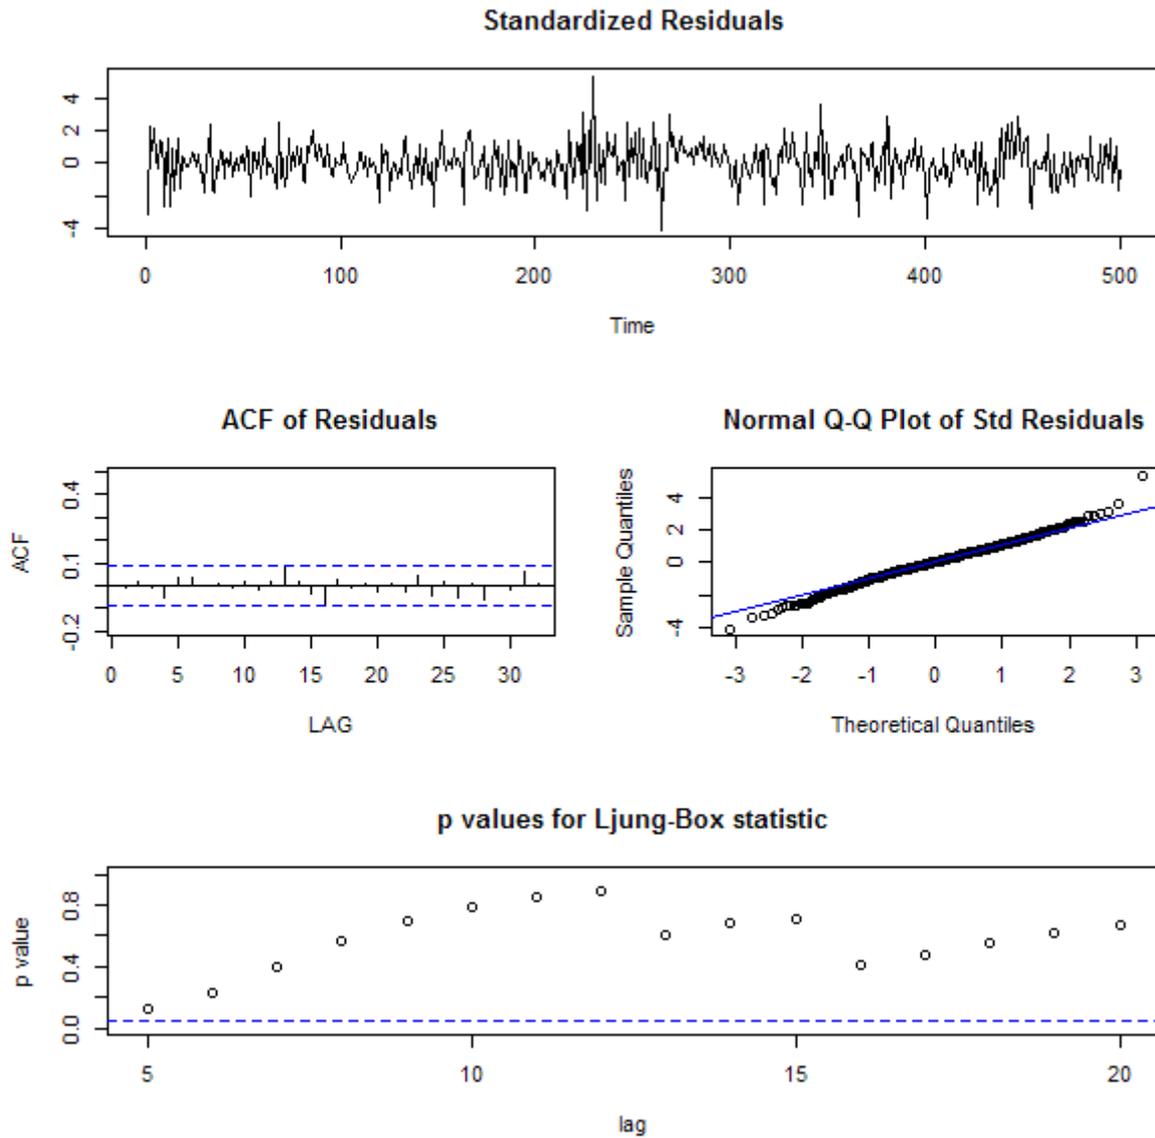
WEI, W. W. S. **Time Series Analysis**. New York: Addison-, 1990.

XIANG, L. et al. **A New hybrid network traffic Prediction method**, 2010. 1-5.

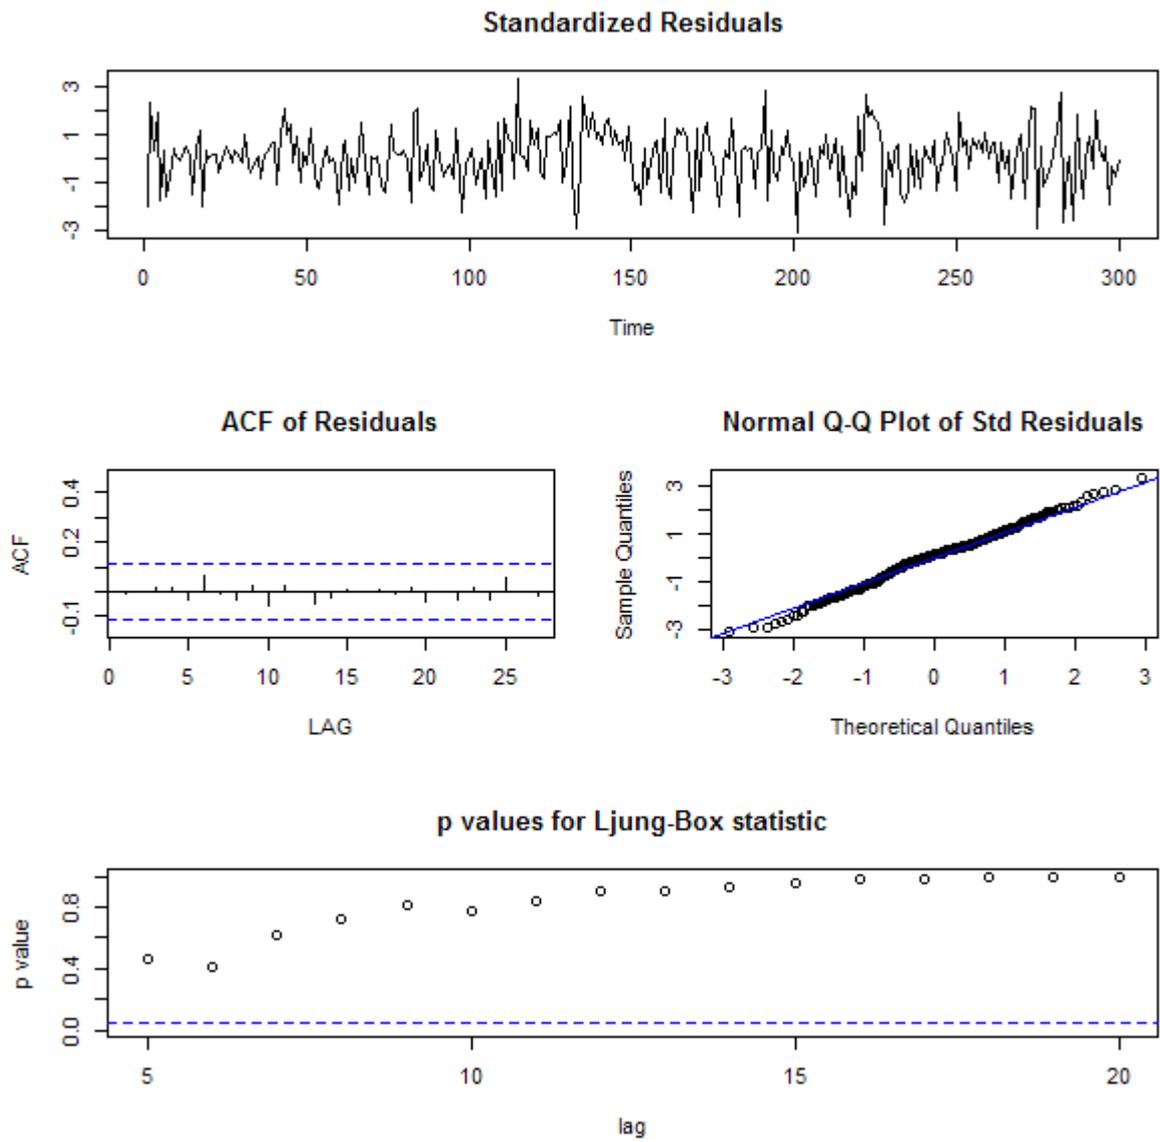
ZHANG, J.; SUN, Y. **Managing Resources in Internet of Things with Semantic Hyper-Network Model**. Enabling Technologies: Infrastructure for Collaborative Enterprises (WETICE), 2012 IEEE 21st International Workshop on, Toulouse, 2012. 318,323.

Apêndice A. Decomposição da série MAWI

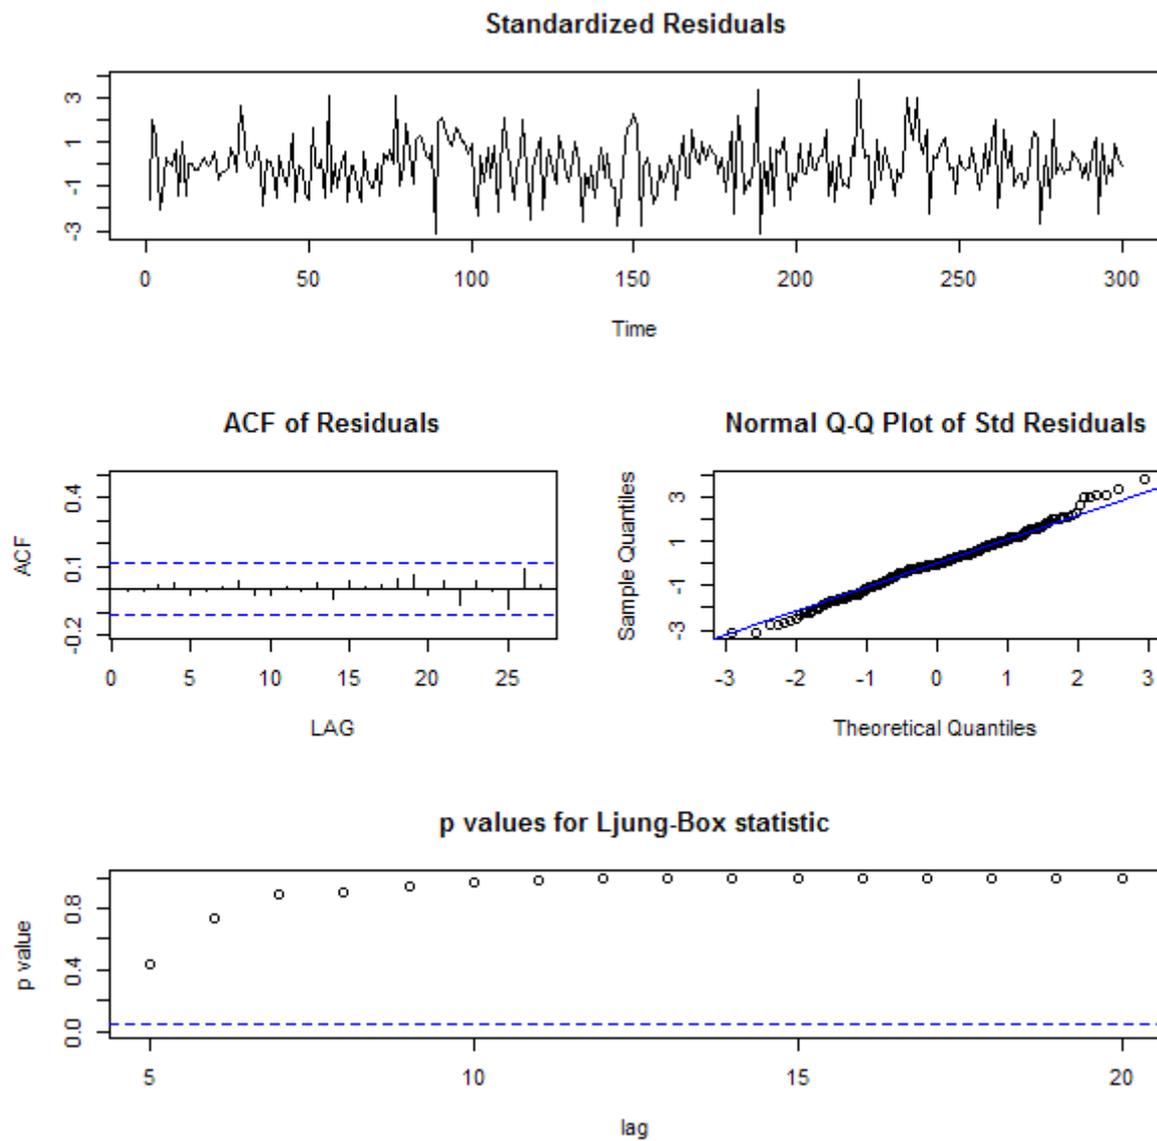
Apêndice B. Séries temporais resultantes da agregação da série MAWI**Agregação em 1 segundo****Agregação em 2 segundos****Agregação em 3 segundos****Agregação em 4 segundos****Agregação em 5 segundos**

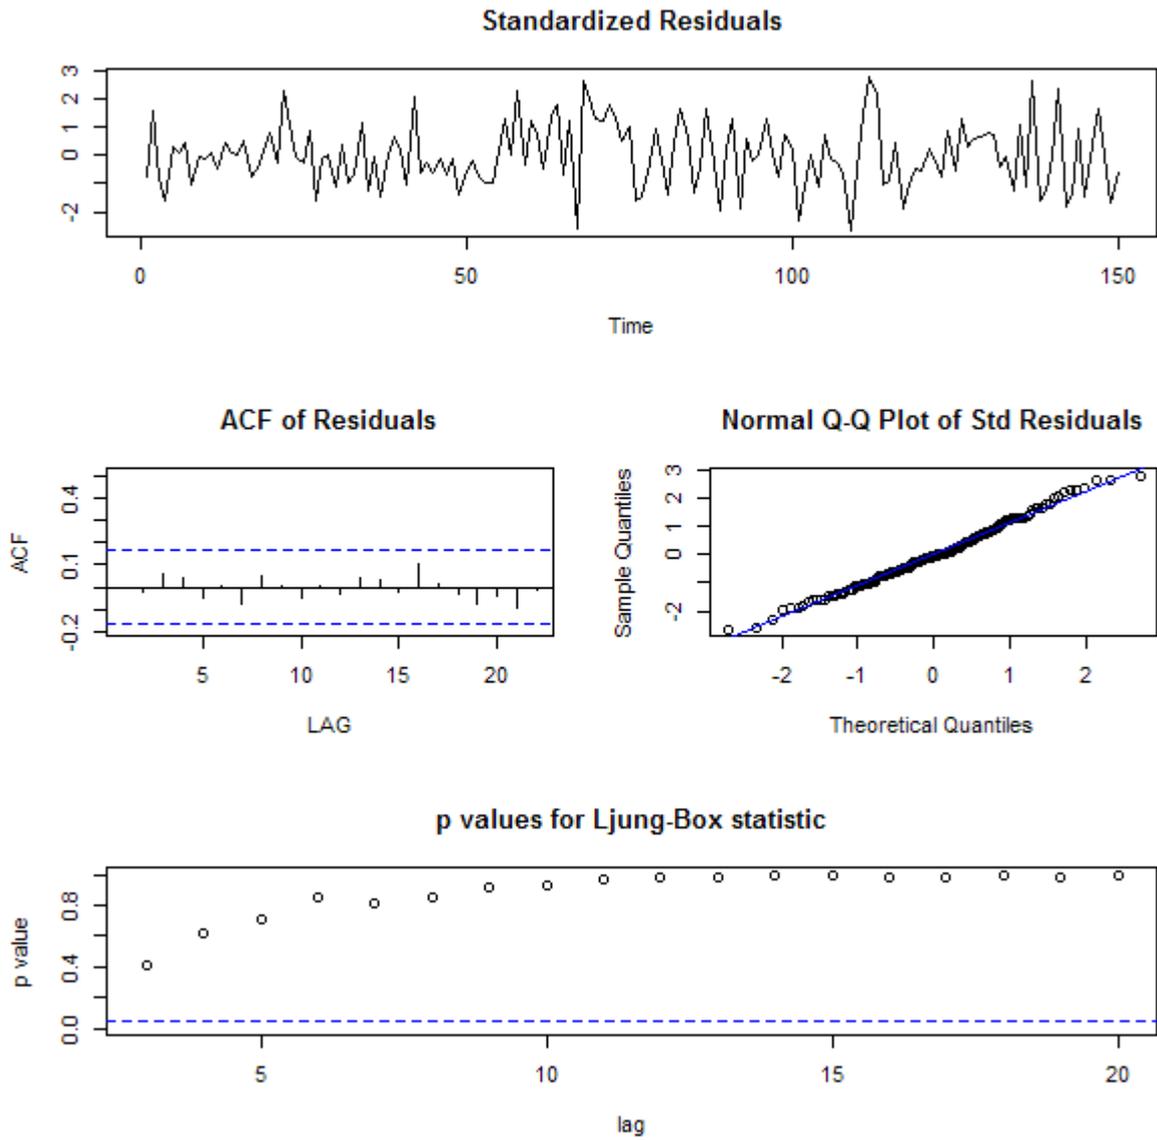
Apêndice C. Gráficos dos resíduos dos modelos ARMA ajustados**MAWI 1:**

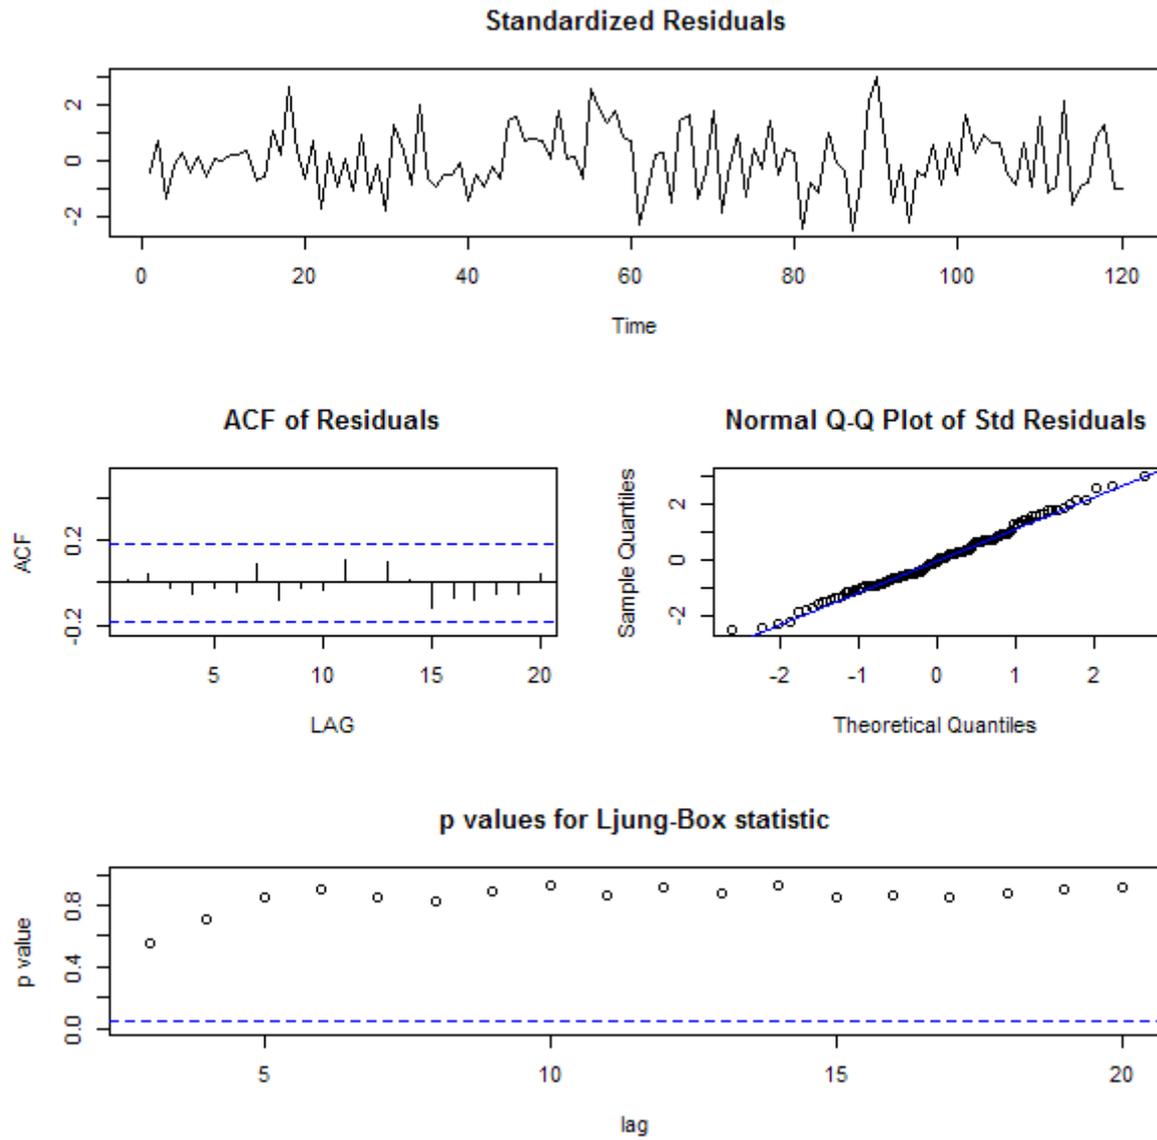
MAWI 2:



MAWI 3:



MAWI 4:

MAWI 5:

Apêndice D. Sumário do ajuste GARCH(1,1) aos dados da série MAWI 1

```

*-----*
*          GARCH Model Fit          *
*-----*

Conditional Variance Dynamics
-----

GARCH Model      : fGARCH(1,1)

fGARCH Sub-Model      : GARCH

Mean Model        : ARFIMA(2,0,2)

Distribution       : std

Optimal Parameters
-----

      Estimate  Std. Error    t value Pr(>|t|)
mu          0.000194   0.003002    0.06461 0.948484
ar1         0.910960   0.009633   94.56410 0.000000
ar2        -0.512193   0.009293  -55.11846 0.000000
ma1        -0.998236   0.001305 -764.65712 0.000000
ma2         0.987918   0.000025 39201.70914 0.000000
omega       0.001716   0.000248    6.92608 0.000000
alpha1      0.060708   0.006261    9.69618 0.000000
beta1       0.888377   0.010717   82.89100 0.000000
shape      28.949421   7.145952    4.05116 0.000051

Robust Standard Errors:

      Estimate  Std. Error    t value Pr(>|t|)

```

mu	0.000194	0.002211	8.7702e-02	0.930113
ar1	0.910960	0.013297	6.8511e+01	0.000000
ar2	-0.512193	0.011161	-4.5891e+01	0.000000
ma1	-0.998236	0.001518	-6.5777e+02	0.000000
ma2	0.987918	0.000028	3.5025e+04	0.000000
omega	0.001716	0.000271	6.3228e+00	0.000000
alpha1	0.060708	0.007002	8.6696e+00	0.000000
beta1	0.888377	0.012340	7.1990e+01	0.000000
shape	28.949421	8.152551	3.5510e+00	0.000384

LogLikelihood : 2651.759

Information Criteria

Akaike	-0.58721
Bayes	-0.58011
Shibata	-0.58722
Hannan-Quinn	-0.58480

Weighted Ljung-Box Test on Standardized Residuals

	statistic	p-value
Lag[1]	3.27e-02	0.8565
Lag[2*(p+q)+(p+q)-1][11]	1.03e+03	0.0000
Lag[4*(p+q)+(p+q)-1][19]	1.38e+03	0.0000

d.o.f=4

H0 : No serial correlation

Weighted Ljung-Box Test on Standardized Squared Residuals

```

-----
                statistic  p-value
Lag[1]                8.53 3.493e-03
Lag[2*(p+q)+(p+q)-1][5] 12.25 2.400e-03
Lag[4*(p+q)+(p+q)-1][9] 22.28 5.128e-05
d.o.f=2

```

Weighted ARCH LM Tests

```

-----
                Statistic Shape Scale P-Value
ARCH Lag[3]    0.1444 0.500 2.000 0.703925
ARCH Lag[5]    7.8034 1.440 1.667 0.022377
ARCH Lag[7]   16.6219 2.315 1.543 0.000456

```

Nyblom stability test

```

-----

```

Joint Statistic: 9.9448

Individual Statistics:

```

mu      0.02454
ar1     4.69522
ar2     0.94111
ma1     0.36318
ma2     2.84255
omega   0.07299

```

alpha1 0.08386

beta1 0.08059

shape 0.17698

Asymptotic Critical Values (10% 5% 1%)

Joint Statistic: 2.1 2.32 2.82

Individual Statistic: 0.35 0.47 0.75

Sign Bias Test

```
-----
                t-value    prob sig
Sign Bias          0.9469 0.343736
Negative Sign Bias 0.5789 0.562672
Positive Sign Bias 3.0332 0.002427 ***
Joint Effect      12.5614 0.005688 ***
```

Adjusted Pearson Goodness-of-Fit Test:

```
-----
group statistic p-value(g-1)
1    20    50.21    0.0001222
2    30    61.69    0.0003789
3    40    61.99    0.0110187
4    50    86.98    0.0006767
```

Elapsed time : 10.84983

Apêndice E. Sumário do ajuste GARCH(1,0) aos dados da série MAWI 4

* GARCH Model Fit *

Conditional Variance Dynamics

GARCH Model : fGARCH(1,0)

fGARCH Sub-Model : GARCH

Mean Model : ARFIMA(2,0,2)

Distribution : snorm

Optimal Parameters

	Estimate	Std. Error	t value	Pr(> t)
mu	0.000156	0.000485	3.2104e-01	0.74818
ar1	1.043787	0.012215	8.5455e+01	0.00000
ar2	-0.077372	0.011910	-6.4961e+00	0.00000
ma1	-0.992621	0.000006	-1.7138e+05	0.00000
omega	0.040058	0.000661	6.0646e+01	0.00000
alpha1	0.125114	0.002153	5.8103e+01	0.00000
skew	0.981162	0.014754	6.6502e+01	0.00000

Robust Standard Errors:

	Estimate	Std. Error	t value	Pr(> t)
mu	0.000156	0.000482	3.2321e-01	0.746537
ar1	1.043787	0.026312	3.9670e+01	0.000000

ar2	-0.077372	0.026308	-2.9410e+00	0.003272
ma1	-0.992621	0.000009	-1.0654e+05	0.000000
omega	0.040058	0.000970	4.1317e+01	0.000000
alpha1	0.125114	0.006023	2.0774e+01	0.000000
skew	0.981162	0.014318	6.8529e+01	0.000000

LogLikelihood : 1165.338

Information Criteria

Akaike	-0.25738
Bayes	-0.25185
Shibata	-0.25738
Hannan-Quinn	-0.25550

Weighted Ljung-Box Test on Standardized Residuals

	statistic	p-value
Lag[1]	3.415e-02	0.8534
Lag[2*(p+q)+(p+q)-1][8]	1.884e+03	0.0000
Lag[4*(p+q)+(p+q)-1][14]	2.629e+03	0.0000

d.o.f=3

H0 : No serial correlation

Weighted Ljung-Box Test on Standardized Squared Residuals

	statistic	p-value
Lag[1]	2.931	0.08688
Lag[2*(p+q)+(p+q)-1][2]	94.951	0.00000
Lag[4*(p+q)+(p+q)-1][5]	172.971	0.00000

d.o.f=1

Weighted ARCH LM Tests

	Statistic	Shape	Scale	P-Value
ARCH Lag[2]	184.0	0.500	2.000	0
ARCH Lag[4]	208.3	1.397	1.611	0
ARCH Lag[6]	343.8	2.222	1.500	0

Nyblom stability test

Joint Statistic: 8.1584

Individual Statistics:

mu	0.18068
ar1	0.34197
ar2	0.16324
ma1	1.27119
omega	0.94944
alpha1	0.36675
skew	0.06871

Asymptotic Critical Values (10% 5% 1%)

Joint Statistic: 1.69 1.9 2.35

Individual Statistic: 0.35 0.47 0.75

Sign Bias Test

	t-value	prob	sig
Sign Bias	1.0736	0.2830	
Negative Sign Bias	0.5000	0.6171	
Positive Sign Bias	0.7731	0.4395	
Joint Effect	1.1998	0.7531	

Adjusted Pearson Goodness-of-Fit Test:

	group	statistic	p-value(g-1)
1	20	9.961	0.9539
2	30	21.954	0.8221
3	40	30.010	0.8489
4	50	33.368	0.9571

Elapsed time : 11.64243