



UNIVERSIDADE ESTADUAL DO CEARÁ
CENTRO DE CIÊNCIAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO
MESTRADO ACADÊMICO EM CIÊNCIA DA COMPUTAÇÃO

DYEGO HENRIQUE LEONEL OLIVEIRA

**MODELO ADAPTATIVO PARA PREVISÃO DE DEMANDA POR RECURSOS DE
REDE EM PROVEDORES DE INTERNET MODERNOS**

FORTALEZA – CEARÁ

2020

DYEGO HENRIQUE LEONEL OLIVEIRA

MODELO ADAPTATIVO PARA PREVISÃO DE DEMANDA POR RECURSOS DE REDE
EM PROVEDORES DE INTERNET MODERNOS

Dissertação apresentada ao Curso de Mestrado Acadêmico em Ciência da Computação do Programa de Pós-Graduação em Ciência da Computação do Centro de Ciências e Tecnologia da Universidade Estadual do Ceará, como requisito parcial à obtenção do título de mestre em Ciência da Computação. Área de Concentração: Ciência da Computação

Orientador: Prof. Dr. Rafael Lopes Gomes

FORTALEZA – CEARÁ

2020

Dados Internacionais de Catalogação na Publicação

Universidade Estadual do Ceará

Sistema de Bibliotecas

Oliveira, Dyego Henrique Leonel .

Modelo Adaptativo para Previsão de Demanda por Recursos de Rede em Provedores de Internet Modernos [recurso eletrônico] / Dyego Henrique Leonel Oliveira. - 2020

Um arquivo no formato PDF do trabalho acadêmico com 56 folhas.

Dissertação (Mestrado Acadêmico) - Universidade Estadual do Ceará, Centro de Ciências e Tecnologia, Mestrado Acadêmico em Ciência da Computação, Fortaleza, 2020.

Área de concentração: Ciência da Computação.
Orientação: Prof. Dr. Rafael Lopes Gomes.

1. Série Temporal. 2. Predição. 3. Flexibilidade.
I. Título.

DYEGO HENRIQUE LEONEL OLIVEIRA

MODELO ADAPTATIVO PARA PREVISÃO DE DEMANDA POR RECURSOS DE REDE
EM PROVEDORES DE INTERNET MODERNOS

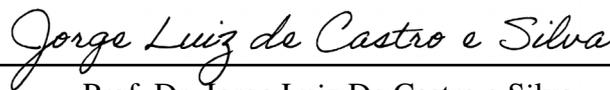
Dissertação apresentada ao Curso de Mestrado Acadêmico em Ciência da Computação do Programa de Pós-Graduação em Ciência da Computação do Centro de Ciências e Tecnologia da Universidade Estadual do Ceará, como requisito parcial à obtenção do título de mestre em Ciência da Computação. Área de Concentração: Ciência da Computação

Aprovada em: 10 de Julho de 2020

BANCA EXAMINADORA



Prof. Dr. Rafael Lopes Gomes (Orientador)
Universidade Estadual do Ceará – UECE



Prof. Dr. Jorge Luiz De Castro e Silva
Universidade Estadual do Ceará – UECE



Prof. Dr. Hítalo Josefeson Batista Nascimento
Centro Universitário da Grande Fortaleza – UNIGRANDE

À minha família, por sua capacidade de acreditar em mim e investir em mim. Minha esposa, seu cuidado, dedicação e apoio foi que deram, em alguns momentos, a esperança para seguir. Meus filhos, sinônimos de incentivo.

AGRADECIMENTOS

Primeiramente a Deus que permitiu que tudo isso acontecesse, ao longo de minha vida, e não somente nestes anos como universitário, mas que em todos os momentos é o maior mestre que alguém pode conhecer.

A minha esposa, pelo amor, incentivo e apoio incondicional.

Obrigado aos meus filhos e amigos, que nos momentos de minha ausência dedicados ao estudo superior, sempre fizeram entender que o futuro é feito a partir da constante dedicação no presente!

Ao meu professor e orientador, Rafael Lopes, pela orientação, confiança e apoio nos momentos em que precisei de ajuda.

Agradeço a todos os professores por me proporcionar o conhecimento direto e indiretamente.

Ao meu amigo, Mardônio Vieira, pelo companheirismo.

“A gravidade explica os movimentos dos planetas, mas não pode explicar quem colocou os planetas em movimento. Deus governa todas as coisas e sabe tudo que é ou que pode ser feito.”

(Isaac Newton)

RESUMO

A Internet hoje em dia conecta centenas de milhões de dispositivos computacionais ao redor do mundo. Estes dispositivos, considerados sistemas finais, acessam a internet por meio de Provedores de Serviços de Internet (*Internet Service Providers* - ISP), da mesma forma, empresas de TV a cabo, telefonia e universidades, por exemplo. As redes de provedores vem restringindo a vazão de dados (quantidade bits que podem ser transmitidos) entre sistemas finais, apresentando atrasos e perda de pacotes. Uma das alternativas que poderia ser aplicada para enfrentar esses problemas seria o planejamento ideal de largura de banda para cada cliente, ou sistema final. Desta forma, os ISPs tendem a evoluir para Provedores de Internet Modernos (MISPs), a fim de lidar com situações como a demanda elástica de recursos de rede que podem causar queda na Qualidade de Serviço (QoS) caso não seja tratado de forma eficiente. Uma abordagem promissora para lidar com demanda elástica é o uso de técnicas preditivas de tráfego. Contudo, tais técnicas não atingem fatores de correção necessários quando o comportamento da rede não segue um padrão claro (como nas situações de demanda elástica). Neste contexto, esta dissertação apresenta um modelo adaptável de previsão de rede para MISPs, que ajusta sazonalidade, tendência e remove os ciclos de erro da série temporal de acordo com o comportamento observado no tráfego de rede. Os resultados, usando um conjunto de dados real, retirados da Universidade Estadual do Ceará - (UECE), sugerem que o modelo proposto aprimora as porcentagens de acurácia das técnicas de previsão tradicionais.

Palavras-chave: Série Temporal. Predição. Flexibilidade.

ABSTRACT

The Internet today contains millions of computing devices around the world. These devices, end systems, access the Internet through Internet Service Providers (ISP), in the same way, cable TV companies, telephone companies and universities, for example. Provider networks have been restricting data throughput between end systems, exhibiting packet delays and losses. One of the alternatives that could be applied to these serious problems or the ideal bandwidth planning for each customer or final system. In this way, ISPs have evolved into Modern Internet Providers (MISPs), in order to deal with situations such as the elastic demand for network resources that can cause coming down quality of Service (QoS) if it is not treated efficiently. A promising approach to deal with elastic demand or the use of predictive traffic techniques. However, these techniques do not reach the correction factors allowed when the behavior of the network does not follow a clear pattern (as in situations of elastic demand). In this context, this dissertation presents an adaptive network forecasting model for MISPs, which adjusts seasonality, trend and removes the time series error cycles according to the behavior observed in the network traffic. The results, using a set of real data, retired from the State University of Ceará - (UECE), suggest the improvement model proposed as percentages of accuracy of traditional forecasting techniques.

Keywords: Time Series. Forecasting. Flexibility

LISTA DE FIGURAS

Figura 1 – Exemplos de Séries Temporais.	20
Figura 2 – Aplicação da função de autocorrelação a série Passageiros de Linhas Aéreas.	22
Figura 3 – Método de validação cruzada <i>k-fold</i>	27
Figura 4 – Método de validação cruzada <i>Hold-Out</i>	28
Figura 5 – Rede Neural Simples com quatro entradas, análoga a uma regressão linear.	31
Figura 6 – Rede Neural com quatro entradas e uma camada oculta com três neurônios.	31
Figura 7 – Funcionamento do modelo PRA proposto.	37
Figura 8 – Dados de largura de banda da série temporal contendo: valor mínimo, médio e máximo.	38
Figura 9 – Dados originais da série temporal demonstrando sazonalidade e tendência.	39
Figura 10 – Evolução da correção dos ciclos irregulares nas amostras da série.	40
Figura 11 – Sazonalidade constante e tendência estacionária da série temporal ajustada.	41
Figura 12 – Autocorrelation Function para cada conjunto, dos 21 disponíveis.	45
Figura 13 – Análise de resíduos do conjunto de amostras do modelo Arima.	46
Figura 14 – Análise de resíduos do conjunto de amostras do modelo Neural.	47
Figura 15 – Modelo submetido a previsão de 24 amostras a frente, utilizando PRA+Arima e PRA+NNAR.	48
Figura 16 – Comparação de previsão <i>PRA</i> junto aos dados originais, Teste.	49
Figura 17 – Comparação de Erro de Previsão.	50
Figura 18 – Relação entre os valores reais (Teste) e os valores previstos.	50

LISTA DE TABELAS

Tabela 1 – Técnicas de Predição	29
Tabela 2 – Trabalhos Relacionados	34

LISTA DE SÍMBOLOS

B_w	Largura de Banda
F	Grau Fahrenheit
\mathbb{R}	Conjunto dos números reais
S	Sazonalidade
T	Tendência
R	Residuais
C	Ciclos
Φ	proporção áurea

SUMÁRIO

1	INTRODUÇÃO	15
1.1	MOTIVAÇÃO	16
1.2	OBJETIVOS	17
1.2.1	Objetivo Geral	17
1.2.2	Objetivos Específicos	17
1.3	ESTRUTURA DO TRABALHO	18
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	ANÁLISE DE SÉRIES TEMPORAIS	19
2.1.1	Autocorrelação em Séries Temporais	21
2.1.2	Método de Decomposição Clássica	21
2.1.3	Sazonalidade em séries temporais	23
2.1.4	Componente de Tendência	23
2.1.4.1	Estacionariedade em séries temporais	24
2.1.4.2	<i>Argumented Dickey-Fuller</i> - ADF	24
2.1.4.3	Teste KPSS	25
2.1.4.4	Diferenciação	25
2.1.5	Ciclo	25
2.1.6	Variações Irregulares	26
2.2	MÉTRICAS DE DESEMPENHO E ERRO	26
2.2.1	Cross-Validation	26
2.2.1.1	Método <i>k-fold</i>	27
2.2.1.2	Método <i>Hold-Out</i>	27
2.2.1.3	Métricas de Erros	28
2.3	MODELOS AUTO-REGRESSIVOS	29
2.3.1	Modelo Auto-Regressivo Integrado de Médias Móveis	29
2.3.2	Rede Neural Auto-Regressiva	30
3	TRABALHOS RELACIONADOS	32
4	METODOLOGIA	35
5	PROPOSTA	37
5.1	DECOMPOSIÇÃO DE DADOS	38
5.1.1	Remoção de Erros de Ciclos	39

5.1.2	Teste de Estacionariedade	42
5.1.3	Avaliando Resíduos	43
5.2	TÉCNICAS DE PREDIÇÃO	44
6	RESULTADOS	45
6.1	CONTRIBUIÇÕES DO TRABALHO	49
7	CONCLUSÕES E TRABALHOS FUTUROS	52
	REFERÊNCIAS	53

1 INTRODUÇÃO

Recentemente, a Internet surgiu como o principal caminho para os serviços computacionais modernos (por exemplo, compartilhamento de conteúdo, sistemas inteligentes, automação de tarefas e outros), tornando-se um meio de comunicação crucial para a sociedade moderna. A maioria desses serviços são baseados em Serviço de Acesso a Internet (*Internet Access Service - IAS*) por meio de um Provedores de Internet (*Internet Service Provider - ISP*). Assim, os ISPs expandiram sua prestação de serviços, oferecendo diferentes alternativas para acesso a Internet (Ethernet e Wi-fi sem fio) de seus clientes (como residências, empresas, universidades, etc.) (FOUKAS *et al.*, 2017).

Independentemente do tipo de rede de acesso, todas essas formas de acesso precisam abordar aspectos chave: baixo atraso, flexibilidade, resiliência, despesas de capital (*Capital Expenditure - CAPEX*) e despesas operacionais (*Operational Expenditure - OPEX*) compatíveis. Esses recursos influenciam a qualidade de serviço (QoS) e a qualidade de experiência (QoE) dos usuários finais (HOU *et al.*, 2018).

Nesse novo cenário, surge a ideia de Provedores de Internet Modernos (*Modern Internet Service Providers - MISPs*), que precisam aprimorar o gerenciamento de recursos, a flexibilidade da rede e a customização do comportamento das infraestruturas de rede. Uma abordagem promissora para MISPs é a implantação de fatias de rede, ou seja, a divisão dos recursos em redes lógicas isoladas. Cada fatia de rede pode ter a configuração mais adequada para melhor atender aos requisitos do cliente (FOUKAS *et al.*, 2017).

Da mesma forma, um ponto importante para os MISPs manterem a qualidade do IAS é a demanda elástica por recursos de rede ao longo do dia, o que ocorre devido à mobilidade humana nas cidades e diferentes tipos de comportamento de aplicações a serem executadas. Nesse cenário, os MISPs precisam expandir ou reduzir dinamicamente a alocação de Largura de Banda (*Bandwidth - Bw*), caracterizando um comportamento elástico e permitindo um IAS sob demanda. Esse comportamento, quando não tratado adequadamente, pode causar problemas de lentidão, interrupção do serviço e desconexões constantes, resultando em usuários frustrados e quebra dos requisitos do Acordo de Nível de Serviço (*Service Level Agreement - SLA*), documento no qual descreve características do serviço de Tecnologia da Informação e garantias de serviços que são prestados, acordado entre as partes.

Uma abordagem promissora para lidar com serviços elásticos é o uso de um modelo de previsão de tráfego de rede (BAYATI; NGUYEN; CHERIET, 2018). Um modelo de previsão

de tráfego de rede permite a compreensão do comportamento da rede, por meio de observações anteriores do uso de recursos da rede (histórico), e a previsão de valores futuros da demanda da rede, permitindo a aplicação de tarefas proativas para evitar os problemas mencionados anteriormente e planejar a infraestrutura de rede.

As abordagens tradicionais, como modelos de média móvel e de regressão, não modelam as séries temporais para minimizar as baixas amplitudes dos ciclos regulares, usando apenas reduções automáticas baseadas na média móvel dos próprios modelos de previsão. Dessa maneira, os modelos tradicionais de previsão carecem de adaptabilidade para acompanhar as mudanças no comportamento das observações, uma vez que originalmente não realizam ajustes na sazonalidade e não removem possíveis ciclos de erro (ADHIKARI; AGRAWAL, 2013). Esse fato dificulta o uso dos modelos existentes nos MISPs para lidar com a situação de demanda elástica devido à variabilidade do comportamento do cliente ao longo do tempo (seja durante o dia, semana ou mês). Portanto, os MISPs precisam de uma solução para realizar uma previsão adaptativa.

Dentro deste contexto, esta dissertação apresenta um modelo de Previsão de Rede Adaptável, chamado *PRA*, para permitir a alocação adequada de recursos de rede e um planejamento estratégico da infraestrutura de rede. O modelo *PRA* proposto decompõe os dados originais da série, corrige os erros de ciclo, para, por fim, testar a estacionariedade. Depois de aplicado o modelo *PRA* proposto, o conjunto de dados pode ser submetido a técnicas de previsão, como por exemplo: Média Móvel Integrada Auto-Regressiva (ARIMA) (SU *et al.*, 2016) e Rede Neural Auto-Regressiva (NNAR) (MALEKI *et al.*, 2018), de acordo com o comportamento de tráfego de rede observado.

Os experimentos foram realizados usando um conjunto de dados de demanda de largura de banda real da Universidade Estadual do Ceará (UECE). Este conjunto de dados tem a utilização média da largura de banda para a Internet a cada hora dos primeiros seis meses de 2019. Os resultados indicam que o modelo de previsão adaptativa proposto minimiza a taxa de erro dos valores previstos, atingindo 30% de melhoria quando comparado aos modelos de previsão de rede existentes.

1.1 MOTIVAÇÃO

Devido ao crescente número de usuários de banda larga nos últimos anos, móvel e fixa, os provedores de internet enfrentam sérios problemas quanto a alocação de largura de banda

que seja compatível com a necessidade de cada usuário ou organização em diferentes partes do dia. As altas taxas de Download e Upload afetam diretamente os canais de comunicação pré estabelecidos pela operadora aos seus clientes.

Assim, os Provedores de Internet não conseguem alocar largura de banda suficiente para diferentes ocasiões, ocasionando alta latência, interrupções de serviço e descumprimento de SLAs. Dessa forma, é necessário o uso de algum método ou mecanismo que minimize o impacto negativo da falta de internet, interrupções e alta latência.

O sistema proposto nesse trabalho visa criar um modelo de previsão de recursos de rede, que irá auxiliar os ISPs atendendo uma demanda de recursos de rede elástica, onde os dados são recebidos por uma extremidade da arquitetura, analisados, tratados e submetidos a um processo de previsão.

1.2 OBJETIVOS

Os objetivos gerais e específicos deste trabalho serão representados a seguir.

1.2.1 Objetivo Geral

A criação de um modelo de previsão de largura de banda que compreenda o comportamento do uso da rede e auxilie as diferentes técnicas na predição de demanda de recursos em cenários de demanda elástica, dinamizando a alocação de recursos em tempo hábil e, potencializando o suporte a qualidade de serviço (*Quality of Service* - QoS).

1.2.2 Objetivos Específicos

Para elaboração de tal modelo, deve-se partir da recepção dos dados com as informações de rede, análise e tratamento dos dados, submissão às técnicas de predição.

- a) Pesquisar, de forma extensa, bibliograficamente a cerca de Séries Temporais e Técnicas Preditivas.
- b) Realizar a leitura dos dados de tráfego de rede. Plotar os dados em modelo de série temporal.
- c) Fazer análise das características dos dados em busca de padrões que possam ser compreendidos matematicamente.
- d) Modelar matematicamente aplicando testes estatísticos as amostras a fim de corrigir e padronizar os dados da Série Temporal.

- e) Submeter as amostras anteriormente tratadas aos algoritmos de predição estudados.
- f) Avaliar o desempenho do modelo quando aplicado em conjunto com as técnicas de predição existentes.

1.3 ESTRUTURA DO TRABALHO

Esta dissertação está organizada da seguinte forma: O capítulo 2 apresenta uma extensa visão sobre os principais conceitos que envolvem o estudo das Séries Temporais e suas características. Definições de métodos estatísticos e de métricas de avaliação de resultados, finalizando com uma abordagem aos algoritmos de predição utilizados na proposta.

No capítulo 3 realiza-se um levantamento a respeito dos principais trabalhos desenvolvidos que envolvem predição utilizando séries temporais, modelos auto regressivos, de classificação, redes heterogêneas e decomposição sazonal.

O capítulo 4 descreve a metodologia utilizada para criação do modelo de previsão proposto bem como métodos realizados na aferição e interpretação das amostras, detalhando cada etapa.

O capítulo 5 apresenta a descrição da proposta de forma específica, sequenciando as etapas que são realizadas pelo modelo.

O capítulo 6 descreve os experimentos realizados e discute os resultados obtidos pela aplicação do modelo proposto em comparação com abordagens tradicionais sem a aplicação do mesmo.

Por fim, o capítulo 7 irá reportar as conclusões desta dissertação sugerindo melhorias e experimentos que possam ser realizados em trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os conceitos fundamentais e necessários para a devida compreensão deste trabalho, detalhando o conceito de Séries Temporais, suas classificações e, as principais características dos algoritmos de predição Média Móvel Integrada Auto-Regressiva (ARIMA) e Rede Neural Auto-Regressiva (NNAR).

2.1 ANÁLISE DE SÉRIES TEMPORAIS

Uma Série Temporal pode ser definida como um conjunto de observações sobre uma variável aleatória ordenada no tempo, onde o registro dos períodos em que a variável é observada seja de forma regular (BOX; JENKINS, 1976). Assim, temos Y_t em que $(Y_t)_a^z = \{Y_a \dots Y_z\}$, onde Y_t é uma variável aleatória observada uma única vez. O conjunto de informações de variáveis que são coletadas ao longo de um ano Fenômenos que são monitorados e tem suas variáveis coletadas ao longo de períodos regulares como: ano, trimestre, mês, dia, minuto, segundo, etc. Podem ser classificados como um modelo de série temporal.

O tempo esta diretamente relacionado com a constância em que essas variáveis são observadas, exercendo influência sobre as observações passadas bem como influenciar as informações dos dados no futuro. Este processo pode criar padrões não aleatórios que são representados em gráficos ou processos estatísticos visuais para que sejam melhor compreendidos. Um dos objetivos da análise das Séries Temporais é o de encontrar padrões não aleatórios, interpretá-los e, utilizar essas informações para influenciar as previsões futuras. Os dados de Séries Temporais são advindos de várias situações e partes do conhecimento, tais como:

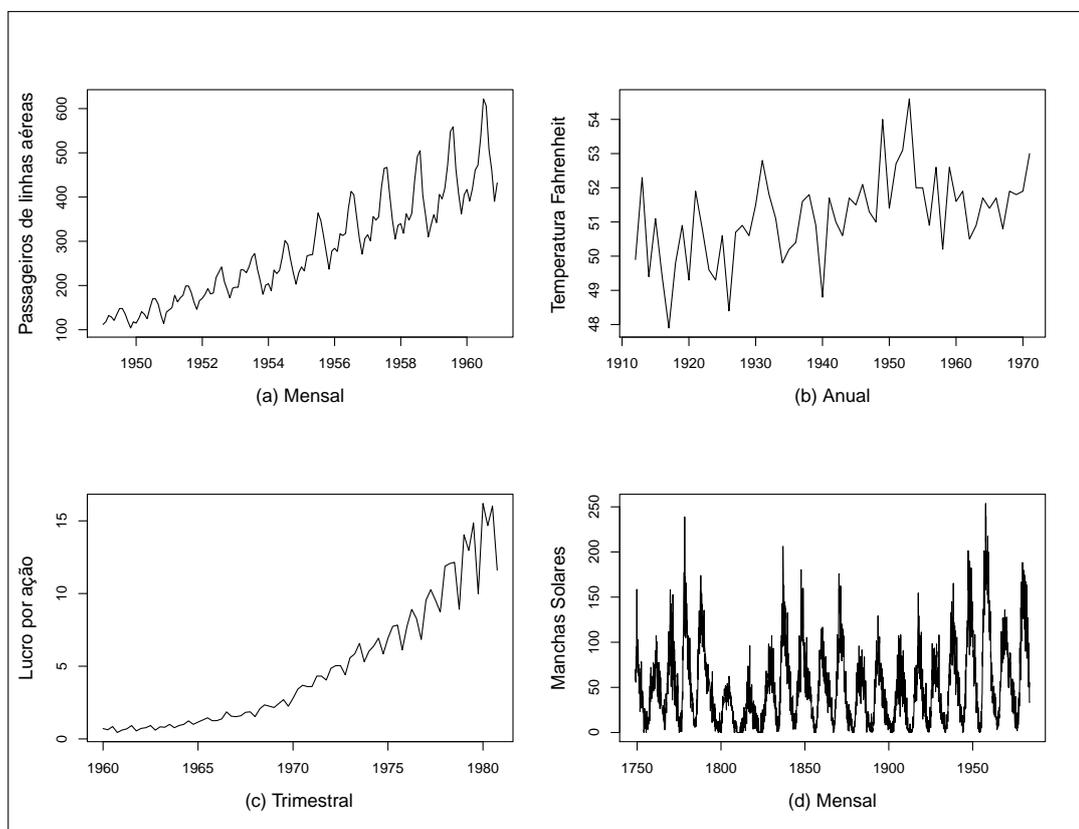
- Preço diário de ações;
- Passageiros transportados por mês;
- Manchas solar anual;
- Índice mensal pluviométrico;
- Morte por problemas cardíacos a cada minuto;
- Evasão de alunos por semestre;
- Tráfego de bits por segundo.

Um dos principais propósitos da análise de séries temporais é o de entender o comportamento e a estrutura temporal dos dados coletados, por tanto, a utilização de modelos estatísticos e ferramentas computacionais são aplicados a fim de interpretar e corrigir comportamentos não padronizados. O estudo de uma sequência única de dados é denominada de análise

de série temporal univariada, objetivando a construção de modelos para prever valores futuros. O processo estocástico é um modelo utilizado para representar séries temporais, através do controle probabilístico. Uma característica importante a respeito das variáveis coletadas em uma série temporal, é dependência que as amostras em tempo t exercem sobre as amostras adjacentes. Observações correlacionadas, ordem temporal das observações, tendência exponencial, sazonalidade, ciclos, são valiosas informações que influenciam na análise.

A criação de um modelo que forneça um padrão bem definido de variáveis que possam ser submetidos a um processo de previsão, depende da correta interpretação e possível correção desses valores. A Figura 1 mostra 4 exemplos de séries temporais, (a) Passageiros de linhas aéreas mensais entre 1949 a 1960, (b) Temperatura Fahrenheit em New Haven de 1912 a 1971, (c) Lucro trimestral por ação da Johnson & Johnson entre 1960 a 1980, (d) Mortes por doenças pulmonares no Reino Unido entre 1774 a 1979. Alguns componentes, características fundamentais de um modelo clássico de série temporal como: tendência, ciclo e sazonalidade, serão demonstrados nas próximas seções.

Figura 1 – Exemplos de Séries Temporais.



Fonte: (TEAM, 2019)

2.1.1 Autocorrelação em Séries Temporais

Séries Temporais podem ser explicadas estatisticamente através da autocorrelação de suas variáveis, indicando o nível de dependência ou relacionamento entre a variável Y_t e Y_{t-1} , demonstra o grau de dependência dos valores observados atualmente sobre os observados no passado. O modo simples de realizar essa operação é calculando a correlação de uma amostra entre os r pares distintos no tempo t . Ou seja, diante de observações sucessivas como y_1, y_2, y_3, \dots , a função é calculada para cada par $((y_1, y_2), (y_3, y_4), (y_5, y_6), \dots, (y_n, y_{n+1}))$ (CRYER; CHAN, 2008). Os coeficientes de autocorrelação que compõem a função (*Autocorrelation Function - ACF*) pode ser escrita, de acordo com (HYNDMAN; ATHANASOPOULOS, 2018), conforme Equação 2.1, onde T se refere ao comprimento da série temporal.

$$r_k = \frac{\sum_{t=k+1}^T (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2} \quad (2.1)$$

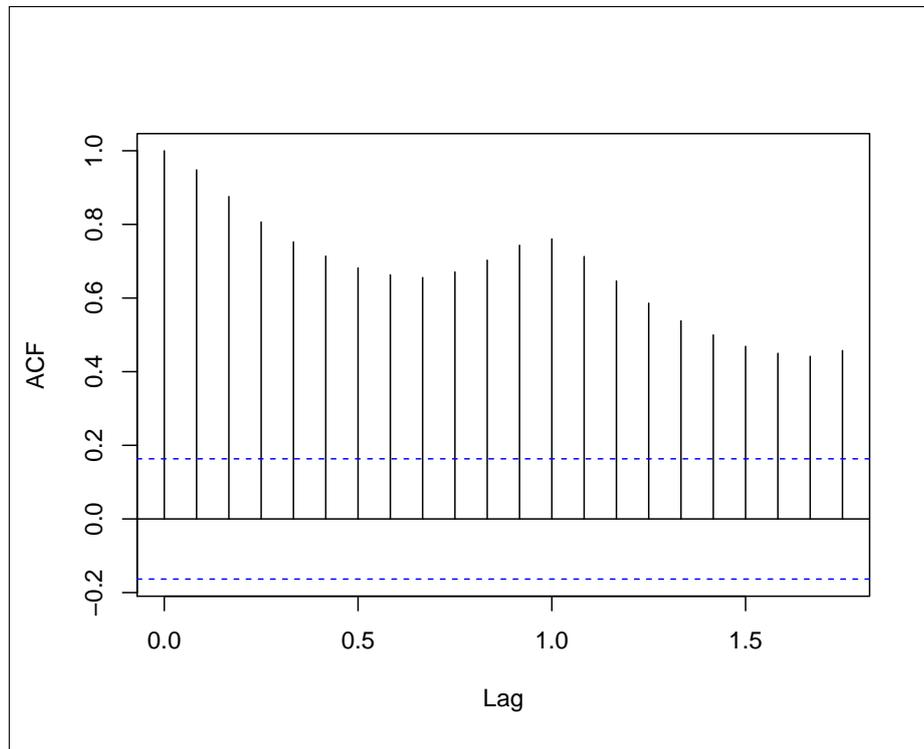
Os gráficos de autocorrelação demonstram o entendimento através da análise visual. Os valores podem estar em maior parte posicionados entre os limites de -1 e 1 por exemplo, para dados considerados fortemente autocorrelacionados e, entre os intervalos de confiança delimitados em 0 , para dados fracamente correlacionados, ou sem correlação. Através da Figura 2 é possível observar o gráfico de autocorrelação (*Autocorrelation Function - ACF*) da série *Passageiros de Linhas Aéreas*, demonstrado na Figura 1, que sugere um importante grau autocorrelação entre os pares (*Lag*) e identifica uma série não estacionária, pois, de forma lenta, o ACF diminui em torno dos limites segundo (HYNDMAN; ATHANASOPOULOS, 2018).

2.1.2 Método de Decomposição Clássica

A decomposição de séries temporais é aplicada ao conjunto de valores de séries de entrada $X \in \mathbb{R}$. Gerando três componentes de X , que são (S, T, R), (PICKERING *et al.*, 2018) correspondendo a Sazonalidade, Tendência e Residuais, respectivamente. O processo de decomposição é realizado a fim de separar os componentes da série empregando análises matemáticas para posterior análise, onde obtêm-se melhor compreensão de seus valores e propriedades, fato que nem sempre ocorre quando não se aplica o método. O processo de decomposição favorece o planejamento na escolha dos parâmetros quanto a criação de modelos de previsão, potencializando os resultados de predições futuras.

Após o processo de decomposição, a série pode ser definida como uma soma ou

Figura 2 – Aplicação da função de autocorrelação a série Passageiros de Linhas Aéreas.



Fonte: (TEAM, 2019)

multiplicação de componentes não observáveis. Tendências de inclinação ou declínio do nível série que são elevações que podem ser consideradas significativas observadas; padrões cíclicos onde observa-se flutuações nos valores das amostras com periodicidade constante em intervalos curtos ou longos, variações sazonais que consistem em flutuações nas amostras com periodicidade constante em intervalos fixos; residuais, sobra de amostras ou valores não compreendidos na decomposição de sazonalidade ou tendência e, irregulares, flutuações incompreensíveis fruto de fenômenos atípicos ou fatos fortuitos que ocorrem em intervalos não previstos, sem periodicidade. Contudo, ao observar tais características, pertencendo ao modelo clássico de decomposição similares, tem-se o modelo aditivo:

$$X_t = S_t + T_t + R_t \quad (2.2)$$

uma opção quando a sazonalidade ou tendência não é proporcional ao nível da série.

E o modelo multiplicativo:

$$X_t = S_t * T_t * R_t \quad (2.3)$$

quando o elemento sazonal ou tendência muda com o nível (valor médio) da série.

2.1.3 Sazonalidade em séries temporais

A sazonalidade é um padrão que ocorre em intervalos fixos, ou seja, fenômenos que se repetem em uma determinada hora(s), dia(s), em determinado mês ou meses, anualmente. Uma sequência de dados dependentes no tempo t , onde o intervalo entre eles é constante, (GUTIERREZ; WIESINGER-WIDI, 2017). Esse padrão se repete periodicamente para cada p , isto é, para cada:

$$S_{t+p} = S_t \quad (2.4)$$

Onde S_t é representa o componente sazonal da série temporal. Um avaliador para encontrar esse componente pode ser através de uma regressão linear ou do cálculo de uma média móvel, por exemplo. Subtrai-se a componente sazonal dos dados originais, usando o modelo aditivo como exemplo, conforme Equação 2.5, obtendo a função com os componentes cíclicos, de tendência e irregular, apenas.

$$X_t - S_t = Ct + T_t + E_t \quad (2.5)$$

2.1.4 Componente de Tendência

Um aumento ou redução no valor comportamental das amostras de uma série a longo prazo. Revelando um comportamento exponencial na maioria dos vezes, com variações irregulares no tempo t . Quando a média dessas amostras são constantes para cada t , a tendência é dita estacionária, por outro lado, não apresentam tendências (YOU; CHANDRA, 1999). Essa representação pode ser escrita como:

$$Y_t = \mu + X_t \quad (2.6)$$

No qual $(X_t) = 0$ para todo t . Estimando μ pelo conjunto da série temporal observada Y_1, Y_2, \dots, Y_n , escrito pela Equação 2.7.

$$\bar{Y} = \frac{1}{n} \sum_{t=1}^n Y_t \quad (2.7)$$

O comportamento da componente de tendência é uma característica fundamental para análise e posterior predições. A remoção dessa característica facilita a obtenção e visualização dos outros componentes da série. Alguns dos métodos de obtenção da componente de tendência se dá através do modelo de regressão linear, médias móveis ou pelo ajuste exponencial.

2.1.4.1 Estacionariedade em séries temporais

A estacionariedade em uma série corresponde ao conjunto de variáveis que possuem média e variância constantes para todo t , ou seja, as amostras oscilam sobre uma média constante e, a variância dessas flutuações, permanecem as mesmas. Para realizar inferência sobre um conjunto de dados a estacionariedade é uma premissa fundamental. Dizemos que um processo é estacionário quando a distribuição conjunta de $Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}$ for a mesma para $Y_{t_1-k}, Y_{t_2-k}, \dots, Y_{t_n-k}$ em todos os pontos de t_1, t_2, \dots, t_n em todos os pontos de tempo k (CRYER; CHAN, 2008). Os testes que confirmam tais característica serão vistos nas seções 2.1.4.2 e 2.1.4.3, respectivamente. O processo existente para transformar séries não estacionárias em estacionárias, quando necessário, é abordado na seção 2.1.4.4.

2.1.4.2 *Argumented Dickey-Fuller* - ADF

Representando um teste de Raiz Unitária em séries temporais, o teste dickey-Fuller verifica se um modelo apresenta raiz unitária ou não. Atestando para característica em que a hipótese seja nula, ou seja, existindo raiz unitária, diz-se que a série ou o modelo Y_t , não apresenta ser estacionário. Onde, obtendo Φ e, atendendo a restrição de $|\Phi| < 1$, diz-se estacionário (REISEN *et al.*, 2017), portanto:

$$\begin{cases} H_0 \rightarrow \Phi = 1 & \text{não é estacionário} \\ H_1 \rightarrow |\Phi| < 1 & \text{é estacionário} \end{cases} \quad (2.8)$$

Outro fator importante a ser considerado é quanto ao grau de de diferenciações que a série pode ter que enfrentar para encontrar uma nova série estacionária, observação que será detalhada no tópico a seguir.

2.1.4.3 Teste KPSS

Criado por (KWIATKOWSKI *et al.*, 1992), o teste de raiz unitária tem por objetivo determinar a estacionariedade em séries temporais. As hipóteses para este teste são diferentes as de Dickey-Fuller, onde, para KPSS, H_0 não apresentando raiz unitária diz-se que não é estacionária, ao contrário de H_1 que é definido como processo estacionário, quando o mesmo apresenta raiz única. O KPSS é baseado em uma regressão linear em que a série submetida ao mesmo é dividida em três partes como: *tendência* βt , passeio aleatório r_t e erro estacionário ε_t , conforme Equação 2.9.

$$Y_t = r_t + \beta t + \varepsilon_t \quad (2.9)$$

2.1.4.4 Diferenciação

A propriedade em que a média, variância e autocorrelação não mudam no decorrer do tempo em uma série, é caracterizada como um processo estacionário. Alcançando valores sem tendência no decorrer do tempo, sem altas flutuações periódicas. Se $f(x) = ax + b$ estiver incrementando de forma linear em x , então, $f'(x) = a$ não está sendo aumentado, está constante no tempo. Por outro lado, se $f(x) = ax^2 + bx + c$ estiver aumentando quadraticamente em x , então, $f'(x) = ax + b$ está aumentando de forma linear, a segunda derivada, $f''(x) = 2a$, é uma constante, *meio estacionário*, isso se aplica de forma similar em séries temporais onde se deseja transformar uma série não estacionária em uma série estacionária (LEVENDIS, 2018), processo chamado de diferenciação. As novas amostras da série podem, também, ser representadas através da Equação 2.10.

$$Y_t = Z_t - Z_{t-1} \quad (2.10)$$

onde é criada uma nova série Y_t através da série original Z_t , ajudando a eliminar algum tipo de tendência periódica ou a longo prazo.

2.1.5 Ciclo

Flutuações de subida e descida em relação a componente de tendência da série temporal. O ciclo se apresenta de forma periódica, sendo tratado como componente cíclica

regular, enquanto flutuações inconstantes no tempo são tratadas como variações irregulares. A magnitude dessas flutuações interferem diretamente nos processos de predição, portanto, funções como médias móveis centradas bem como o desvio padrão, aplicados as amostras da série, demonstram a volatilidade da variável ao longo da tendência. Aparecendo, geralmente, durante longos intervalos de tempo, não se pode confundir com sazonalidade.

2.1.6 Variações Irregulares

Retirando os componentes sazonais, cíclicos e de tendência, o que resta, são as variações irregulares, também chamada de componente irregular ou ruído aleatório. Essas flutuações podem ser consideradas como incompreensíveis, pois as demais componentes já foram compreendidas e caracterizadas no processo de decomposição escolhido. A variação irregular exige independência entre as variáveis Y_{t1} e Y_{t2} , ou seja, não deve existir autocorrelação entre as amostras ao longo do tempo t . Se existir, esses valores deveriam estar presentes no modelo de predição.

2.2 MÉTRICAS DE DESEMPENHO E ERRO

Nesta seção será explicado algumas técnicas de como podemos medir a performance dos modelos de predição, através de métricas de desempenho, como Cross-validation e métricas de erro, como RMSE, por exemplo.

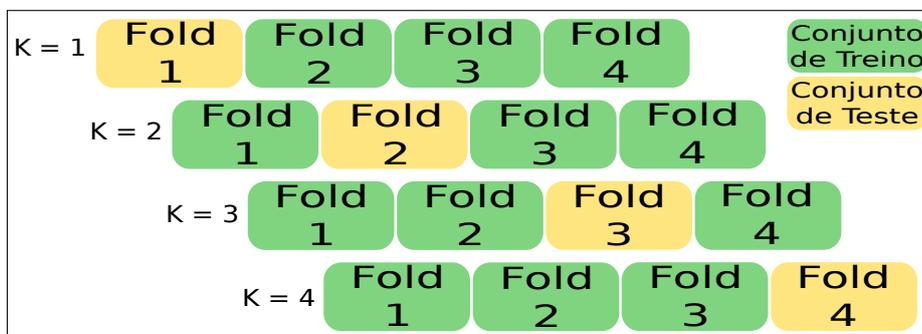
2.2.1 Cross-Validation

(*Cross-Validation - CV*) é uma metodologia simples e global para estimação da capacidade de generalização de um conjunto de amostras (JIANG; WANG, 2017). O conceito é estendido a um método de reamostragem de dados que avaliam a capacidade de generalização de modelos preditivos bem como evitar o overfitting (BERRAR, 2018). A técnica é utilizada em situações onde se deseja prever amostras adiante. A ideia principal é a divisão dos dados em subconjuntos respectivamente exclusivos, onde, a primeira parte é utilizada para estimação de parâmetros (treinamento) a segunda parte (teste) comparada aos dados de valores reais, utilizada para validação do modelo. Existem várias formas de separação dos dados, *holdout* e *k-fold*, sendo as mais utilizadas.

2.2.1.1 Método *k-fold*

É uma técnica intensiva que utiliza todas amostras livres como treinamento e teste. Primeiramente, os dados são igualmente particionados em k elementos. O treinamento e teste são executados em k iterações, sendo que, para a parte de teste (validação) é deixado uma parte e, para treinamento do modelo é deixado a outra parte $k - 1$ restantes (YADAV; SHUKLA, 2016). O processo é realizado k vezes alternando o conjunto de testes particionado e avaliando sua respectiva acurácia para obter a precisão do modelo. A Figura 3 demonstra um exemplo com $k = 4$.

Figura 3 – Método de validação cruzada *k-fold*.

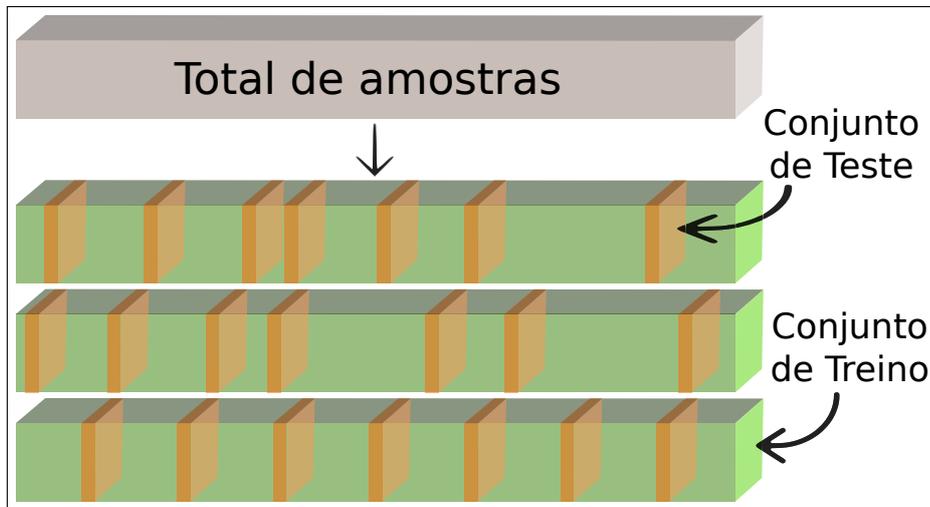


Fonte: Elaborado pelo autor

2.2.1.2 Método *Hold-Out*

No processo de *Hold-Out* os dados são divididos em duas partes não sobrepostas, treinamento e teste, respectivamente. A primeira parte, utilizada para treinamento, a segunda parte é retida e, utilizada para teste. Essa validação pode ter várias porcentagens de amostras sendo retidas para teste, pode se utilizar 10 ou 20% de validação, e 80 ou 90% para aprender o modelo, tendo o cuidado para não ocorrer excesso de ajuste, caso a quantidade de dados para aprender o modelo não for distribuída de forma adequada (YADAV; SHUKLA, 2016). O método se assemelha ao *k-fold*, onde $k = 2$, com a peculiaridade de que a base de dados é dividida em duas partes, sem alternância, realizado apenas uma vez. O tempo relativo para aprendizado do modelo é relativamente menor se comparado a validação cruzada *k-fold* (YADAV; SHUKLA, 2016). A representação do modelo é observável na Figura 4.

Figura 4 – Método de validação cruzada *Hold-Out*.



Fonte: Elaborado pelo autor

2.2.1.3 Métricas de Erros

O erro é a medida que demonstra a diferença entre a estimacão de uma variável (y_t) de seu valor real (x_t). O erro médio ou (*Mean Error* - ME) é utilizado para se referir a média de todos os erros em um conjunto, porém, não é indicado pelo cancelamento de amostras positivas e negativas. O erro médio absoluto (*Mean Absolute Error* - MAE) é utilizado para contornar esse problema, pois usa valores absolutos, conforme Equacão 2.11.

$$MAE = \frac{\sum_{t=1}^n |y_t - x_t|}{n} \quad (2.11)$$

O erro médio percentual absoluto (*Mean Absolute Percentage Error* - MAPE) faz o cálculo da média percentual do desvio absoluto entre o previsto e o realizado. Uma medida de precisão do que foi previsto pelo modelo criado, dado pela Equacão 2.12, Onde a variável Y_t é o valor real ou seja, valor realizado, X_t o que foi previsto e n o total de elementos.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - X_t}{Y_t} \right| \quad (2.12)$$

O erro quadrático médio da raiz (*Root Mean Squared Error* - RMSE) observa a média quadrática da diferença entre o previsto e o observado, ou seja, o desvio padrão da amostra da diferença entre esses valores. É uma medida de precisão para comparar erros de diferentes modelos, pois independe de escala. Onde \hat{y}_t é o valor estimado e y_t é o valor real do uso da

largura de banda no momento t .

$$\text{RMSE}(T) = \frac{1}{\sqrt{T}} \left(\sum_{t=1}^T (\hat{y}_t - y_t)^2 \right)^{\frac{1}{2}}. \quad (2.13)$$

Por ser uma métrica muito aplicada em avaliação de desempenho de modelos de regressão, ser independente de escala e bastante utilizado nas pesquisas que foram realizadas até o momento, esta equação, 2.13, foi adotada no processo de comparação de desempenho dos modelos propostos neste trabalho.

2.3 MODELOS AUTO-REGRESSIVOS

Existem várias técnicas de predição que podem ser aplicadas a séries temporais, desde as consideradas mais simples como a utilização de uma *média aritmética* das amostras até as técnicas mais robustas que envolvem regressão linear e autorregressão. Desta forma, seguindo informações do (TEAM, 2019) e referências dos trabalhos apresentados no Capítulo 3, uma lista caracterizando diversas técnicas conforme seu desempenho e relevância pode ser vista na tabela 1, como **Simples**, **Clássicas** e **Robustas**, respectivamente.

Tabela 1 – Técnicas de Predição

Simples	Clássicas	Robustas
Mean (média dos dados históricos e faz previsão)	Arima (autoregressivo)	Arima (autoregressivo)
Naive (prioridade ao último valor observado)	Holt-Winters (suavização exponencial)	Redes Neurais (autoregressivo)
Snaive (método Naive com sazonalidade)	Decomposição STL (resazonalização usando último período)	
Drift (variação do Naive com tendência)		

Fonte: Elaborado pelo autor

Sera detalhado, a seguir, as características principais das técnicas consideradas *robustas*, pois fazem parte da aplicação deste trabalho, fugindo o escopo do mesmo o detalhamento das demais.

2.3.1 Modelo Auto-Regressivo Integrado de Médias Móveis

O modelo *Autoregressive Integrated Moving Average* - ARIMA refere-se a clássica metodologia de Box & Jenkins, que começa por identificar o modelo, estimando, realizando verificação de diagnóstico, considerando modelos alternativos se necessário e, por fim, aprova o melhor modelo considerado nas regressões, aplicando-a como modelo de previsão (THOPLAN, 2014). A estratégia para esta construção é baseada em um ciclo iterativo, onde a escolha da

estrutura do modelo é através dos próprios dados amostrais. Algumas das parametrizações do Arima podem ser citadas como (AR, I, MA), propostos por Box & Jenkins (BOX; JENKINS, 1976). De forma que (AR), (I), (MA) são denotados pelas letras p , d , q , respectivamente. A parte autoregressiva, denotado por $(AR)_p$, $(I)_d$ representa a ordem de diferenciação, citata em 2.1.4.4 e $(MA)_q$ a ordem de média móvel, usada para suavizar flutuações na série e destacar tendências a longo prazo. O modelo (ARMA), autoregressivo e médias móveis é sugerido por Box & Jenkins quando a série é estacionária, dado pela Equação 2.14, caso a série apresente tendência ou não estacionariedade, o modelo não estacionário, com a inclusão de $(I)_d$ é sugerido, que inclui o procedimento demonstrado em 2.1.4.4.

$$X_t = \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.14)$$

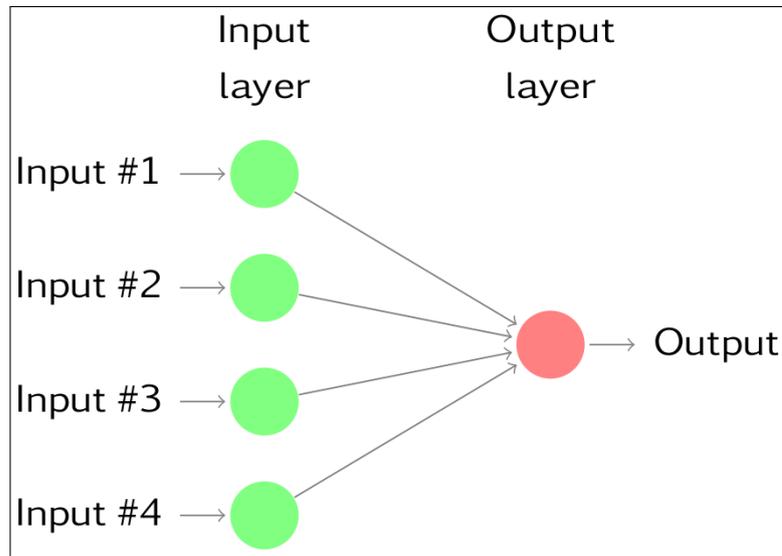
Em que ϕ 's é a parte autoregressiva a ser estimada, θ 's são os parâmetros de média móvel a ser estimados, X 's representa a série original e a 's são erros aleatórios ou resíduos, pressupondo seguir uma probabilidade de distribuição normal (BOX; JENKINS, 1976).

2.3.2 Rede Neural Auto-Regressiva

As Redes Neurais Artificiais permitem a modelagem de complexas relações não lineares entre variáveis de entrada e saída (THOPLAN, 2014). Uma Rede Neural pode ser entendida como uma rede de *neurônios* que são organizados em camadas. As entradas de dados das camadas de baixo e as previsões das camadas de cima, bem como camadas intermediárias, que contém *neurônios ocultos* de acordo com (HYNDMAN; ATHANASOPOULOS, 2018). Redes mais simples são análogas a *regressão linear* pois não possuem camadas ocultas. Adicionando camadas com *neurônios ocultos*, a rede se torna não linear. Com dados de séries temporais os valores defasados das séries podem ser utilizados como entrada para uma rede neural, dado o nome de *Neural network autoregression* - NNAR. As previsões são obtidas pela combinação linear ou não linear das entradas. A ilustração de uma rede neural simples equivalente a uma regressão linear e uma rede neural contendo uma camada oculta pode ser visto nas figuras 5 e 6, respectivamente.

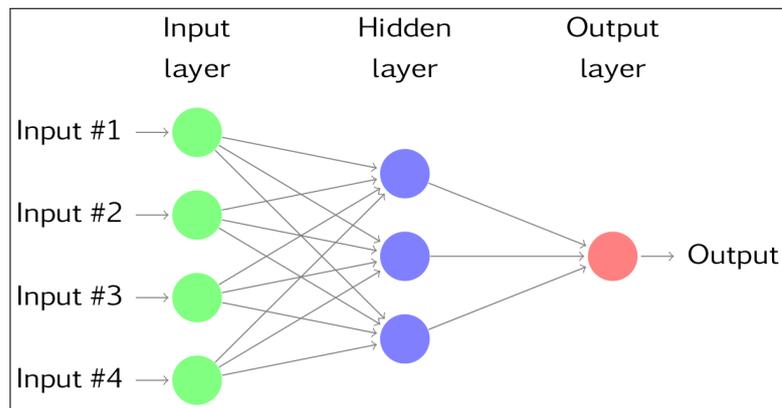
O modelo NNAR é tratado como uma rede avançada de multiplas camadas, envolve combinação linear como função e uma função de ativação. As saídas dos pontos em uma camada são entradas para a próxima. Segundo (THOPLAN, 2014) a função de combinação linear é dada

Figura 5 – Rede Neural Simples com quatro entradas, análoga a uma regressão linear.



Fonte: (HYNDMAN; ATHANASOPOULOS, 2018)

Figura 6 – Rede Neural com quatro entradas e uma camada oculta com três neurônios.



Fonte: (HYNDMAN; ATHANASOPOULOS, 2018)

pela Equação 2.15.

$$z_j = b_j + \sum_{i=1} w_{i,j} x_i \quad (2.15)$$

No qual as entradas no neurônio oculto j são combinadas linearmente, os parâmetros b e os pesos w são aprendidos a partir dos dados. Nas camadas ocultas é utilizado uma função não linear como uma *sigmoid* ou seja, a função de ativação, dada pela Equação 2.16.

$$f(z) = \frac{1}{1 + e^{-z}} \quad (2.16)$$

3 TRABALHOS RELACIONADOS

Esta seção descreve os principais trabalhos relacionados sobre a demanda de recursos e estratégias de previsão para redes de computadores. A Tabela 2 resume os trabalhos existentes na literatura, destacando as diferenças em relação a proposta, onde a coluna *Contexto* apresenta o ambiente em que o trabalho relacionado atua, enquanto as colunas *Estratégia* e *Foco* informam a estratégia aplicada e o objetivo deste trabalho, respectivamente.

Bayati et al. (BAYATI; NGUYEN; CHERIET, 2018) propõem um algoritmo, para redes de alta velocidade, para modelar diferentes escalas de tempo usando a Regressão de Processo Gaussiana (*Gaussian Process Regression - GPR*), abordando a propagação de erros na previsão de tráfego com várias etapas à frente. A previsão em uma escala de tempo é feita usando os dados dessa escala e os resultados da previsão em escalas de tempo maiores. No entanto, esse algoritmo não considera uma abordagem adaptativa para lidar com o comportamento da demanda de recursos.

Hou et al. (HOU *et al.*, 2018) aplicam o método Neyman-Pearson para classificar o processo de chegada de cada usuário, criando uma reserva de largura de banda com reconhecimento de rajadas para cenários da Internet Tátil. Os autores diferenciam os usuários nos estados de alto e baixo tráfego e otimizam a largura de banda reservada para atender aos requisitos de latência e confiabilidade. Contudo, a abordagem aplicada pelos usuários considera apenas a chegada de pacotes de acordo com o comportamento das rajadas de tráfego, limitando sua aplicabilidade em MISPs.

Ruan et al. (RUAN; MONDAL; WONG, 2018) apresentam uma abordagem de aprendizado de máquina para prever a demanda de largura de banda em redes ópticas sem fio heterogêneas na Internet Tátil, chamada MLP-DBA. O MLP-DBA concentra-se nos requisitos de minimização de atraso de upstream através da alocação de largura de banda preditiva de acordo com o status de cada unidade de rede óptica. Todavia, a aplicação do MLP-DBA nos MISPs é comprometida por sua restrição às informações das redes óptico-sem fio.

Wang et al. (WANG *et al.*, 2018) propõem o BWManager, que mitiga os ataques de negação de serviço (DoS) no controlador de redes SDN. Basicamente, o BWManager prevê o consumo de largura de banda dos usuários para determinar os valores de confiança e as filas de prioridade para proteção. O mecanismo prevê a utilização da largura de banda para cada usuário com base em dados históricos do contador de bytes dos switches, analisando a diferença em dois momentos através das técnicas ARIMA e Heteroskedasticity Condicional AutoRegressiva

(*Autoregressive Conditional Heteroskedasticity* - ARCH).

Yoo et al. (YOO; SIM, 2015) desenvolveram um modelo para prever a utilização esperada da largura de banda em redes de alta velocidade, com o objetivo de melhorar a eficiência da utilização de recursos e agendar movimentos de dados científicos em larga escala. O modelo de previsão é baseado na decomposição sazonal de séries temporais por Loess (STL) e ARIMA, nos quais são submetidos os dados de utilização do caminho SNMP (Simple Network Management Protocol). O modelo desenvolvido trabalha especificamente com os dados do protocolo SNMP, ou seja, é limitado à redes baseadas em SNMP. Esse fato restringe a aplicação do modelo desenvolvido nos MISPs.

Aldhyani et al. (ALDHYANI; JOSHI, 2017) propõem um modelo de previsão que combina modelos de séries temporais com abordagens de agrupamento suave (como Fuzzy C-Means - FCM e Rough K-Means - RKM) para permitir a alocação de largura de banda e controle de congestionamento. Esse modelo integrado evita que os dados não-lineares e voláteis afetem as escolhas realizadas pelos modelos de previsão. No entanto, esse modelo integrado não executa uma abordagem adaptativa para atender aos requisitos de demanda de recursos elásticos.

Katris et al. (KATRIS; DASKALAKI, 2019) desenvolveram modelos de séries temporais no tráfego de vídeo como parte de três esquemas de alocação dinâmica de largura de banda. Os autores tentam melhorar a precisão das previsões de tráfego de vídeo usando a Média Móvel AutoRegressiva Integrada Fracionada (FARIMA) e a Heterocedasticidade Condicional Autoregressiva Generalizada (GARCH) com redes neurais. As previsões de tráfego aplicam um método de seleção de não linearidade a ser combinado com o modelo. O uso do modelo de previsão implementado é específico para o tráfego de vídeo, uma vez que considera informações de buffer e taxa de utilização. Desta forma, a sua aplicação no contexto MISP é limitada.

Harstead et al. (HARSTEAD; SHARPE, 2015) descrevem um modelo que prevê demandas de largura de banda de assinantes agregados em redes residenciais de acesso fixo. O modelo permite que os operadores de rede dimensionem suas redes e façam os investimentos corretos para o futuro. Os autores usaram técnicas estatísticas para quantificar o número de fluxos de vídeo simultâneos, a mistura de resoluções padrão, alta definição e ultra-alta definição, ganho de multicast e a tendência de entrega multicast para unicast desses fluxos.

Daly et al. (DALY; MOORE; HADDAD, 2017) propõe o uso de um modelo de rede neural auto-regressivo não linear para prever largura de banda em vídeos H.265, otimizando a transmissão em Redes Ópticas Passivas Ethernet (*Ethernet Passive Optical Networks* - EPONs). A utilização do modelo auto-regressivo não linear reduz o atraso na fila de pacotes de vídeo nas

EPONs não comprometendo a capacidade máxima do link. Sua utilização não pode ser orientada ao MISP pelo fato de utilizar apenas uma abordagem de previsão e estar direcionada a pacotes de vídeo.

Tabela 2 – Trabalhos Relacionados

Referência	Estratégia	Foco
Bayati et al. (BAYATI; NGUYEN; CHERIET, 2018)	Escalas de tempo usando GPR	Previsão de várias etapas à frente
Hou et al. (HOU <i>et al.</i> , 2018)	Método de Neyman-Pearson	Reserva de Bw
Ruan et al. (RUAN; MONDAL; WONG, 2018)	Alocação de Bw preditiva	Minimização de atraso do <i>Upstream</i>
Wang et al. (WANG <i>et al.</i> , 2018)	ARIMA e ARCH	Mitigação de ataques DoS
Yoo et al. (YOO; SIM, 2015)	ARIMA e STL	Utilização de recursos e escalonamento
Aldhyani et al. (ALDHYANI; JOSHI, 2017)	Agrupamento suave e séries temporais	Previsão de tráfego de vídeo
Katris et al. (KATRIS; DASKALAKI, 2019)	FARIMA e GARCH com redes neurais	Predição de tráfego de vídeo
Harstead et al. (HARSTEAD; SHARPE, 2015)	Técnicas estatísticas para quantificação	Planejamento de infraestrutura de rede
Este Trabalho	Modelo Adaptativo	Predição de Recursos em Demanda Elástica

Fonte: Elaborado pelo autor

4 METODOLOGIA

Para o desenvolvimento desta proposta foi realizada uma extensa pesquisa bibliográfica a respeito do tema: Séries Temporais — observações feitas de forma sequencial na frequência em que são medidas —, Técnicas e Algoritmos Preditivos, métodos estatísticos de predição de valores futuros através da modelagem de amostras do passado e, métodos de validação, capazes de demonstrar a eficácia de um modelo. A partir disso, foi adquirido o conhecimento adequado para que, de forma metodológica, fosse determinado o melhor modelo de previsão aos algoritmos preditivos, validando as saídas previstas de acordo com testes em uma base de dados reais.

Foram realizados casos de testes e análises estatísticas em vários dados de séries temporais já existentes usando a ferramenta R¹ software, as principais séries estudadas no caso de uso elaborado são descritas a seguir.

AirPassengers passageiros de linhas aéreas mensal entre 1949 – 1960;

austres residentes australianos medidos trimestralmente entre março de 1971 – março de 1994;

fdeaths mortes mensais por doenças pulmonares no Reino Unido de 1974 – 1979;

JohnsonJohnson lucro trimestral por ação da *JohnsonJohnson* entre 1960 – 1980;

nhtemp temperatura anual Fahrenheit em *New Heaven* de 1912 – 1971;

Seatbelts morte mensal de motoristas na *Great Britain* de Janeiro de 1969 – Dezembro de 1984;

sunspots número mensal de manchas solares medidos pelo *World Data Center - SIDC*.²

Foram elaborados cenários de previsão, avaliação de métricas de desempenho, erro, variação em critérios de configuração, decomposição de dados e análises estatísticas dos dados amostrais, para, a partir disto, compreender o comportamento e características das amostras, sendo possível fazer ajustes necessários afim de melhorar o aprendizado dos modelos de predição. Estas atividades, realizadas através da importação e pré-processamento dos dados, são descritas de forma sequencial logo abaixo:

1. Histograma dos valores da série;
2. Análise de hipóteses para identificar a padronização de amostras;

¹ <https://www.r-project.org/>

² <http://www.sidc.be/silso/datafiles>

3. Análises de relação e correlação de variáveis;
4. Avaliação de residuais;
5. Avaliação de índices sazonais presentes na série;
6. Observação de tendências a longo prazo, devido a grande quantidade de amostras;
7. Elaboração de modelos de previsão através de técnicas clássicas e robustas conforme Tabela 1;
8. Previsões a curto e longo prazo sobre as várias séries descritas no item 4.

Como proposta, foi desenvolvido um modelo de Previsão de Rede Adaptável - PRA, que poderá ser aplicado aos MISPs como uma etapa prévia a análise preditiva de disponibilização de demandas em enlaces de redes Gigabit Ethernet, trabalhando com a demanda elástica em detrimento a insuficiência de recursos de rede, levando em consideração a falta ou a não previsão de tráfego de internet que vários provedores enfrentam.

O PRA foi criado para auxiliar as técnicas de predição existentes quanto ao processo de busca pelo melhor modelo de análise preditiva, disseminando a ideia de que um bom modelo sempre pode ser melhorado. Paralelamente às técnicas preditivas o PRA fornece confiabilidade e aumento de precisão quando se deseja prever o tráfego futuro em *slices* (fatias) de rede Gigabit, diminuindo o tempo de treinamento dos modelos em detrimento dos ajustes pré estabelecidos.

Nos casos de teste, etapa embrionária ao PRA, utilizou-se o *RStudio*³ e a linguagem *R*. O *RStudio* é um software livre integrado ao *R* que oferece um ambiente de desenvolvimento integrado ao *R* (*integrated development environment* - IDE) rico em gráficos e cálculos estatísticos. A linguagem *R*, por sua vez, uma linguagem de programação, dinâmica, que oferece centenas de pacotes orientados a solução de problemas computacionais matemáticos, análise de dados e, análise de séries temporais (*time series analysis*), por exemplo.

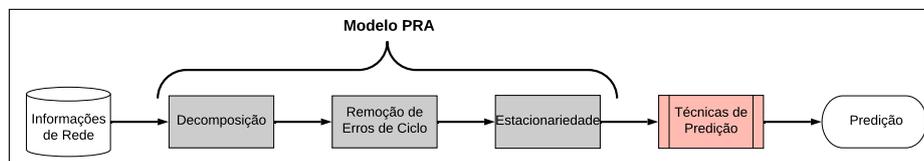
³ <https://rstudio.com/>

5 PROPOSTA

Este capítulo apresenta a descrição detalhada do modelo de Previsão de Rede Adaptável (*PRA*) proposto. O modelo *PRA* proposto tem por objetivo ajustar o conjunto de dados referente à utilização de largura de banda para situações de demanda elástica, possibilitando assim uma maior eficiência das técnicas de predição existentes. Tais técnicas tentam lidar com os aspectos de sazonalidade e tendência, mas não atingem fatores de correção necessários e, conseqüentemente, não conseguem prever o comportamento dos dados de forma adequada quando estes não demonstram um padrão bem claro (como nas situações de demanda elástica).

O modelo *PRA* realiza as seguintes tarefas sequencialmente: (1) Decomposição de dados, (2) Remoção de Ciclos e (3) Teste de Estacionariedade. Posteriormente, após a aplicação do modelo *PRA*, os dados podem ser inseridos em alguma técnica de predição, para a predição ser realizada. A Figura 7 ilustra o processo descrito, onde as caixas em cinza representam as tarefas do modelo *PRA* proposto.

Figura 7 – Funcionamento do modelo *PRA* proposto.

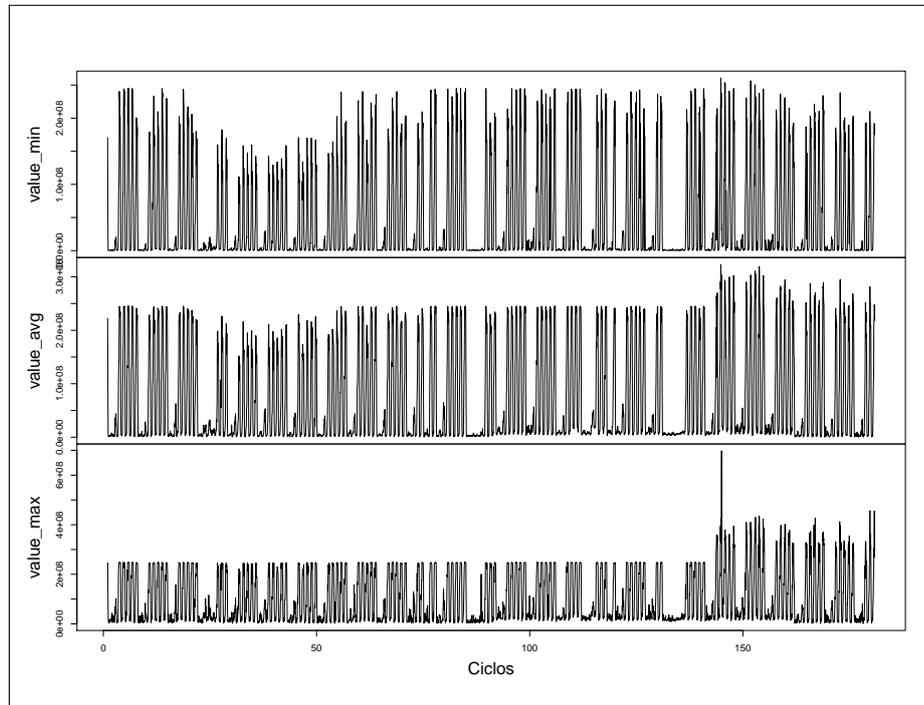


Fonte: Elaborado pelo autor

Inicialmente, o modelo recebe o conjunto de dados original referente a utilização de largura de banda, constituindo uma série temporal a ser analisada e ajustada de forma adaptável pelo modelo. Uma mostra com os dados originais da série, sem ajustes, pode ser visualizada na Figura 8. Durante este capítulo serão apresentados os resultados das etapas realizadas utilizando essa mesma amostra de dados, a fim de ilustrar de forma prática o funcionamento do modelo proposto.

A seguir serão detalhadas cada uma das etapas realizadas pelo modelo, onde a Decomposição dos dados, Remoção de Erros de Ciclo e Testes de Estacionariedade são descritas nas Seções 5.1, 5.1.1 e 5.1.2, respectivamente. A seção 5.1.3 demonstra a avaliação dos residuais e, por fim, a Seção 5.2 apresenta o papel das técnicas de predição, bem como a interação das mesmas com o modelo *PRA* proposto.

Figura 8 – Dados de largura de banda da série temporal contendo: valor mínimo, médio e máximo.



Fonte: Elaborado pelo autor

5.1 DECOMPOSIÇÃO DE DADOS

O objetivo da etapa de decomposição dos dados é compreender a série temporal presente no conjunto de dados de entrada. O método estatístico de decomposição clássica onde utiliza-se de médias móveis para extrair e examinar os componentes de sazonalidade (S_t), ciclos de tendência (R_t), e erro (N_t), onde (L_t) corresponde aos dados da série observados, descritos pela Função 5.1.

$$L_t = f(S_t, R_t, N_t) . \quad (5.1)$$

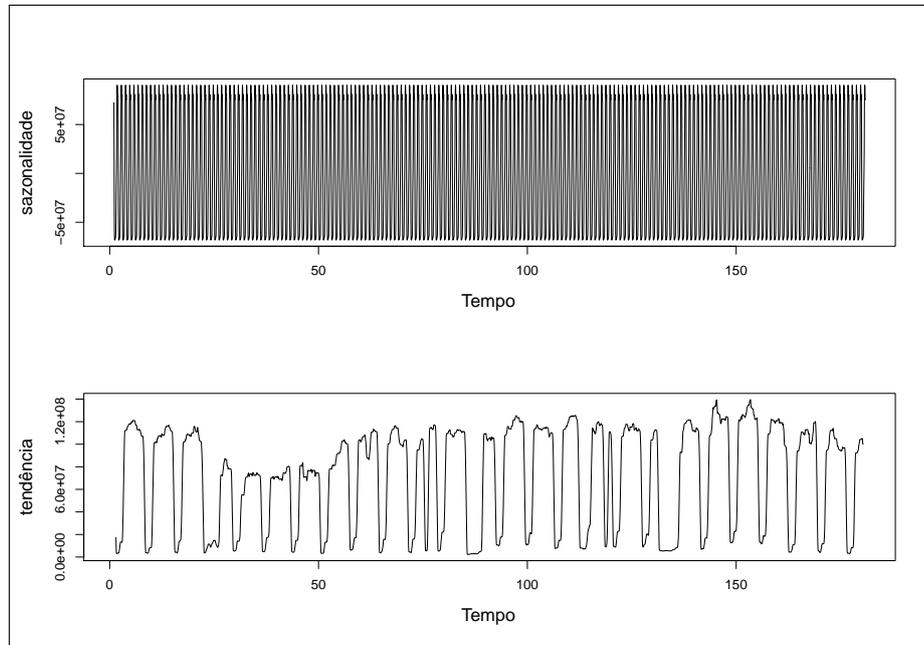
A *sazonalidade* (S_t) em uma série corresponde às oscilações que sempre ocorrem em um determinado período p do ano, do mês, da semana ou do dia, para cada:

$$S_{t+p} = S_t . \quad (5.2)$$

A *tendência* de uma série indica o seu comportamento a longo prazo (se ela cresce, decresce ou permanece estável) e qual a frequência de mudanças. Os *ciclos* são caracterizados

pelas oscilações de subida e de queda nas séries, de forma suave e repetida, ao longo da componente de tendência. A Figura 9 ilustra um exemplo de *sazonalidade* e *tendência* da série temporal do conjunto de dados apresentado na Figura 8.

Figura 9 – Dados originais da série temporal demonstrando sazonalidade e tendência.



Fonte: Elaborado pelo autor

De posse dessas informações, pode-se encontrar *Erros*, que são informações/valores não compreendidos na sazonalidade e na tendência. Para isso, um componente de tendência é determinado usando uma média móvel, em seguida, o valor sazonal é calculado pela média, em cada unidade de tempo e em todos os períodos, centralizando o componente sazonal. Por fim, após remover tendência e sazonalidade das amostras originais, o erro é calculado.

A partir da obtenção desse conhecimento (sazonalidade, tendência, ciclos e erros) o modelo proposto passa para a etapa relacionada a Remoção de Erros de Ciclo, descrita a seguir.

5.1.1 Remoção de Erros de Ciclos

Devido às características do uso da largura de banda em situações de demanda elástica, o uso médio de largura de banda em dias regulares atingem valores muito maiores que o uso médio em dias irregulares (finais de semana, feriados, eventos, etc.). Neste tipo de situação, as técnicas de predição não conseguem distinguir a baixa amplitude dos sinais em dias de ciclos irregulares.

Esses ciclos de baixa amplitude interferem na análise de tendência e sazonalidade

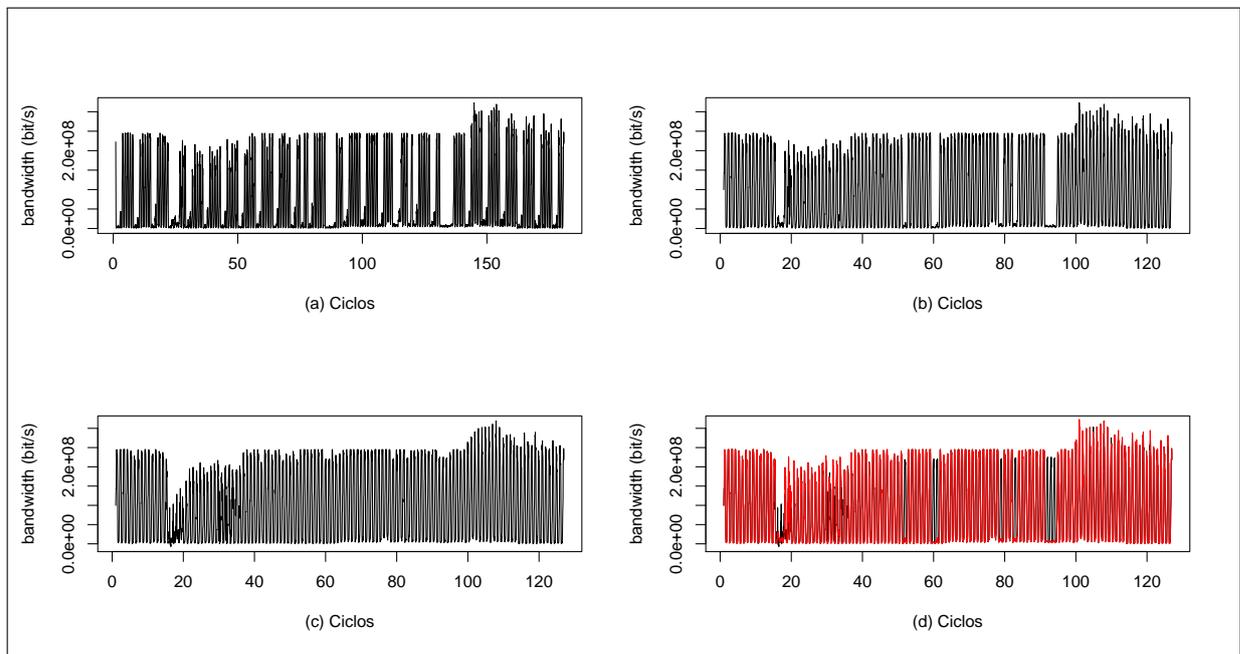
e devem ser removidos. No modelo PRA proposto é aplicada uma técnica de média móvel centrada de ordem 24 para analisar a tendência a longo prazo e, a partir disso, remover as amostras correspondentes aos ciclos de baixa amplitude da série. Em séries temporais a fórmula geral é definida de acordo com a Equação 5.3, onde a média dada pela ordem S é calculada sobre o conjunto de amostras em cada período t .

$$MMC_t^S = \frac{y_{t+\frac{s}{2}} \cdots + y_{t+1} + y_t + y_{t-1} + \cdots + y_{t-\frac{s}{2}}}{S}. \quad (5.3)$$

Os períodos extremos são somados e multiplicados por 0,5, então, guarda-se o valor da média nesse índice. Se a ordem da média fosse ímpar, $s - 1$ seria utilizado no numerador. Entretanto, a aplicação da técnica não é suficiente para remover todas as imperfeições

A partir disso, o modelo executa adicionalmente uma robusta decomposição sazonal e de tendência usando Loess (DOKUMENTOV; HYNDMAN, 2015) para estimar as relações de variáveis não lineares (valores omissos), removendo os *outliers* existentes. A mudança na configuração da série de dados original e da série pós aplicação do modelo proposto (sem os ciclos de baixa amplitude) podem ser vistas na Figura 10.

Figura 10 – Evolução da correção dos ciclos irregulares nas amostras da série.



Fonte: Elaborado pelo autor

A Figura 10(a) ilustra a série original sem ajustes. A partir da Figura 10(b) é possível observar o efeito da série temporal submetida ao algoritmo de correção de baixas amplitudes

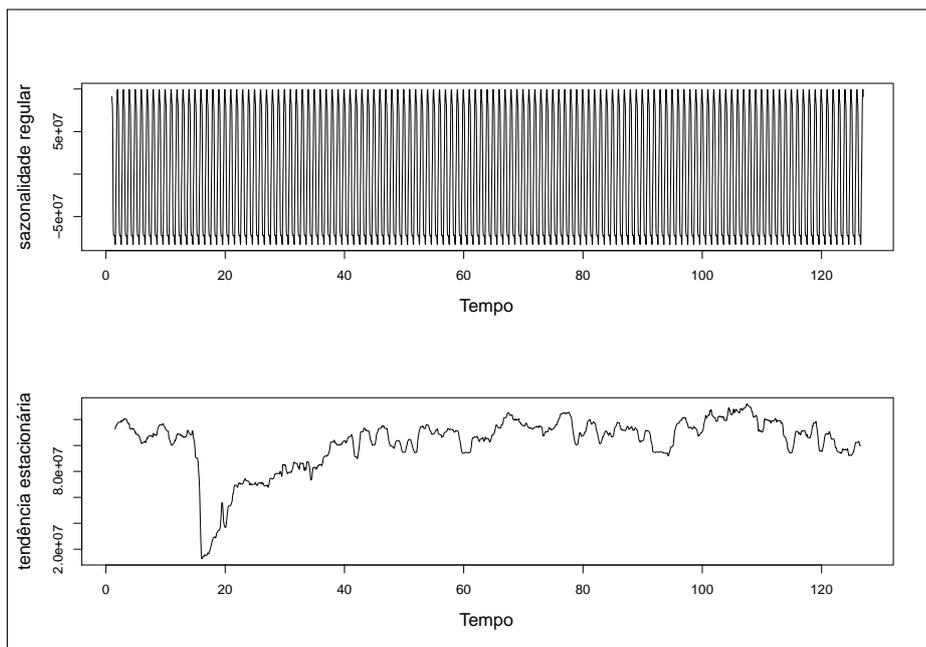
(ciclos irregulares). Posteriormente, na Figura 10(c), a série aparece praticamente livre de erros de ciclos, quando submetida ao processo de remoção de erros de ciclo. Por fim, é possível observar na Figura 10(d) que a etapa de remoção de ciclos completa as lacunas baseando-se em valores da série original. Uma vez removidos os ciclos de baixa amplitude, pode-se prosseguir com a análise da tendência e sazonalidade da série.

Apos a decomposição, consideramos o modelo aditivo para relacionar as componentes não observáveis (fatos atípicos ou fortuitos) com as amostras que serão criadas pelo modelo de previsão, por identificar que as flutuações sazonais e tendência não variam com o nível da série, são constantes e regulares. Caso contrário, o modelo multiplicativo poderia ser utilizado. Este processo é representado na Equação 5.4, onde L_t são os dados no tempo t , com $t \in \{1, \dots, T\}$, S_t é o componente sazonal, R_t é a tendência, e N_t é uma média zero com ruído aleatório e variância constante.

$$L_t = S_t + R_t + N_t. \quad (5.4)$$

As Figuras 11(a) e 11(b) mostram a sazonalidade e a tendência, respectivamente, dos dados ajustados (sem os ciclos de baixa amplitude).

Figura 11 – Sazonalidade constante e tendência estacionária da série temporal ajustada.



Fonte: Elaborado pelo autor

5.1.2 Teste de Estacionariedade

O Teste de Estacionariedade visa verificar o comportamento a longo prazo da série temporal do conjunto de dados, sendo este um comportamento exponencial ou regular/constante. A série temporal pode não ser estacionária, implicando na mudança de nível ou inclinação em períodos curtos ou longos. Este fato afeta a capacidade de predição das técnicas existentes (SCHMIDT; SADRE; PRAS, 2013).

Esta etapa do modelo PRA proposto é baseada no teste Kwiatkowski-Phillips-Schmidt-Shin (KPSS) (CARRION-I-SILVESTRE; SANSÓ-I-ROSSELLÓ; ORTUÑO, 2001), o qual verifica a hipótese de estacionariedade dos dados. O teste aplicado assume que a série temporal do comportamento da largura de banda (X_i , para $i = 1, 2, \dots, n$) pode ser representada pela soma de uma tendência determinística (k), uma caminhada aleatória (W_k) e um erro estacionário (E_k), de acordo com a Equação 5.5.

$$X_i = k + W_k + E_k. \quad (5.5)$$

Adicionalmente, considera-se uma caminhada aleatória como representado na Equação 5.6, onde U_k são uma coleção de variáveis aleatórias Independentes e Distribuídas Identicamente (*Independent and Identically Distributed* - IID) entre zero e σ_{U}^2 , ou seja, $U_k = IID(0, \sigma^2)$.

$$W_k = W_{k-1} + U_k. \quad (5.6)$$

A partir disso, a hipótese de estacionariedade é $\sigma^2 = 0$, visto que assume-se que E_k é estacionário sobre a hipótese nula que X_i tem tendência estacionária. Portanto, o resultado do teste KPSS revela o fator de estacionariedade da série temporal em todo o conjunto de ciclos, não rejeitando a hipótese nula (KWIATKOWSKI *et al.*, 1992). Caso não seja atestada a estacionariedade, a série pode ser corrigida pelo processo de diferenciação, subtraindo o valor de um período t do seu antecessor, como mostra a Equação 5.7.

$$Y_{d_t} = Y_t - Y_{t-1}. \quad (5.7)$$

A fim de aumentar a confiabilidade do modelo e padronização das amostras, o teste de estacionariedade proposto é aplicado em todos os conjuntos de treinamento, aceitando a

estacionariedade e avaliando a presença de raiz unitária como nulas. Essa comprovação é obtida quando o teste de hipótese da série temporal atinge valores abaixo de 0,383, que é considerado crítico para um nível de confiança de confirmação conjunta (CARRION-I-SILVESTRE; SANSÓ-I-ROSSELLÓ; ORTUÑO, 2001). Foi aplicado adicionalmente aos conjuntos de treinamento o teste *DICKEY-FULLER*, a fim de validar os testes realizados anteriormente ou encontrar algum ponto de desigualdade que pudesse ser corrigido. Para todos os conjuntos, os valores *p-value* ficaram abaixo de 0.01 fator que representa hipótese alternativa como estacionária, conforme as amostras de (REISEN *et al.*, 2017) e definições de (CRYER; CHAN, 2008).

5.1.3 Avaliando Resíduos

Outro passo importante na elaboração de um modelo que possa ser submetido as técnicas preditivas é o diagnóstico do mesmo, que pode demonstrar ou comprovar a qualidade do ajuste deste modelo. Se o ajuste for ruim, pode-se modificar de forma a aprimorar o modelo criado. Nos modelos autorregressivos os residuais que não apresentam autocorrelação, são considerados modelos bem ajustados. Portanto, propriedades que são encontradas nas regressões dependem da suposição de que X_t é um ruído aleatório, ainda, de que X_t seja normalmente distribuído e portanto deveria fazer parte do modelo, conforme Capítulo 2 Seção 2.1.6. De acordo com (HYNDMAN; ATHANASOPOULOS, 2018), o componente estocástico X_t pode ser previsto pelo valor residual.

$$\hat{X}_t = Y_t - \hat{\mu}_t \quad (5.8)$$

Chamamos o resíduo correspondente a terceira observação de 5.4. Caso o modelo de tendência esteja correto, o componente estocástico for ruído aleatório, os resíduos deverão se comportar como variáveis aleatórias independentes, média zero e constante variância. Os modelos de previsão foram submetidos ao teste de Ljung-Box (BURNS, 2005), com análise de correlações e histograma das amostras. Posteriormente, o teste de hipótese Shapiro – Wilk (ROYSTON, 1992) foi aplicado a todos os resíduos de todos os conjuntos, afim de verificar a normalidade dos resíduos. Caso contrário, um novo treinamento, com alterações de parâmetros, poderia ser aplicado às amostras.

5.2 TÉCNICAS DE PREDIÇÃO

As técnicas de predição calculam passos adiante através de amostras passadas. Tais técnicas tentam acompanhar sazonalidade e tendência, mas possuem limitações de capacidade de correção em casos de séries temporais que não possuem um padrão bem definido.

Como exemplo de técnicas de predição tem-se ARIMA (SU *et al.*, 2016) e NNAR, descritas na seção 2.3 do capítulo 2. ARIMA é um modelo clássico da estatística que lida com sazonalidade $(p,d,q)(P,D,Q)$, onde as letras minúsculas se referem aos operadores não-sazonal, as maiúsculas à parte sazonais, onde, p é a ordem da parte autorregressiva, d o grau de diferenciações e q , ordem de média móvel.

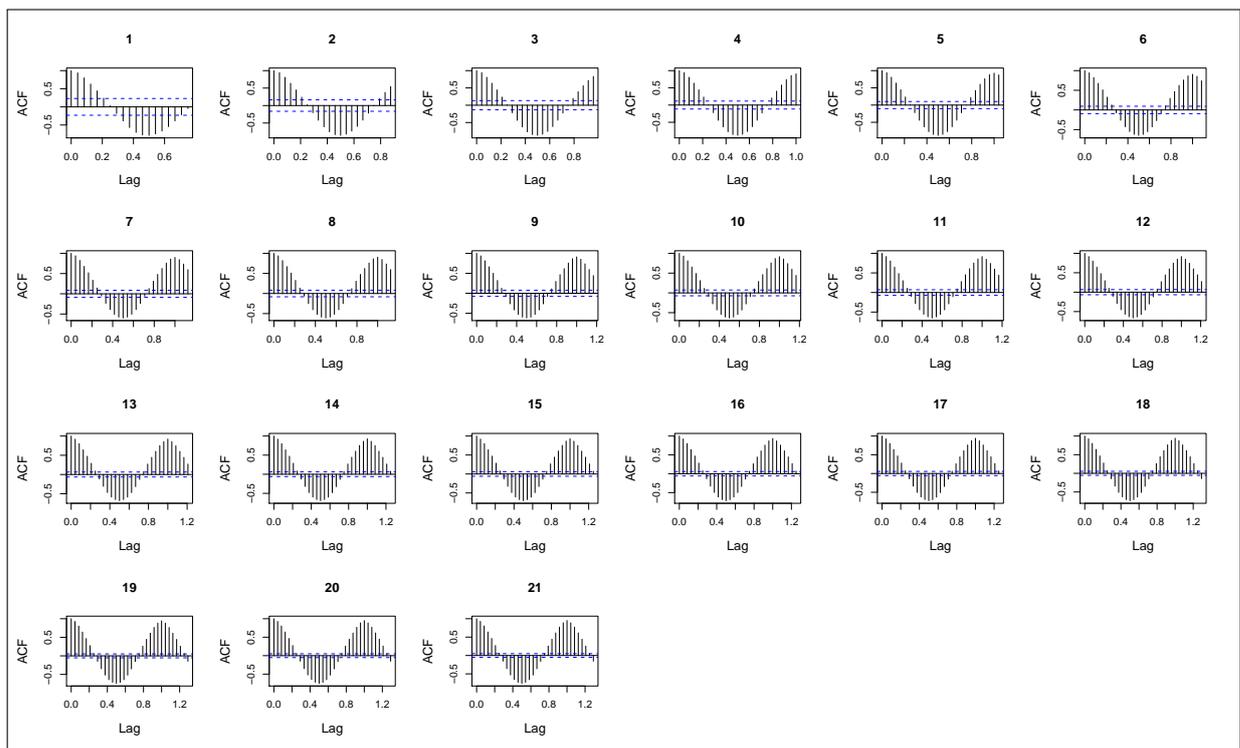
Por outro lado, NNAR (p,P,K) (MALEKI *et al.*, 2018) é um método de previsão que se baseia em modelos matemáticos simples do cérebro, permitindo relacionamentos não lineares entre a variável de resposta e seus preditores, análogo ao ARIMA citado anteriormente. No Capítulo 6 Através das figuras 13, 14, 15 e 16 observa-se uma sequência de etapas que foram sequencialmente efetuadas para todos os conjunto de treinamento, a fim de validar e acompanhar a evolução da proposta.

6 RESULTADOS

Este capítulo mostrará os resultados obtidos a partir da análise dos experimentos realizados a partir de um conjunto de dados real. O conjunto de dados descreve o uso da largura de banda (volume de tráfego) no *backbone* central da Universidade Estadual do Ceará (UECE) medidos em bits por segundo – *bps*. Os dados foram monitorados em tempo real durante um período de seis meses, com uso médio, mínimo e máximo sendo calculados a cada 60 minutos. Um período de 24 horas conclui um ciclo, portanto, todo o conjunto de dados consiste em 4320 amostras.

Devido à dependência de tempo das séries, uma variação da técnica de Validação Cruzada de Série Temporal (TSCV) (MALEKI *et al.*, 2018) foi usada na previsão. Ambos os modelos (ARIMA e NNAR) foram utilizados para modelar as amostras afim de serem submetidas a previsão (ou seja, as próximas 24 horas de uso da largura de banda). Através do método *HoldOut*, os subconjuntos Treino (utilizados na criação do modelo) e Teste (utilizados na validação) foram selecionados devido a grande quantidade de amostras. Primeiro usando 72 amostras anteriores como conjunto de treinamento, depois 144 amostras e assim por diante (72, 144, 216, ...).

Figura 12 – Autocorrelation Function para cada conjunto, dos 21 disponíveis.

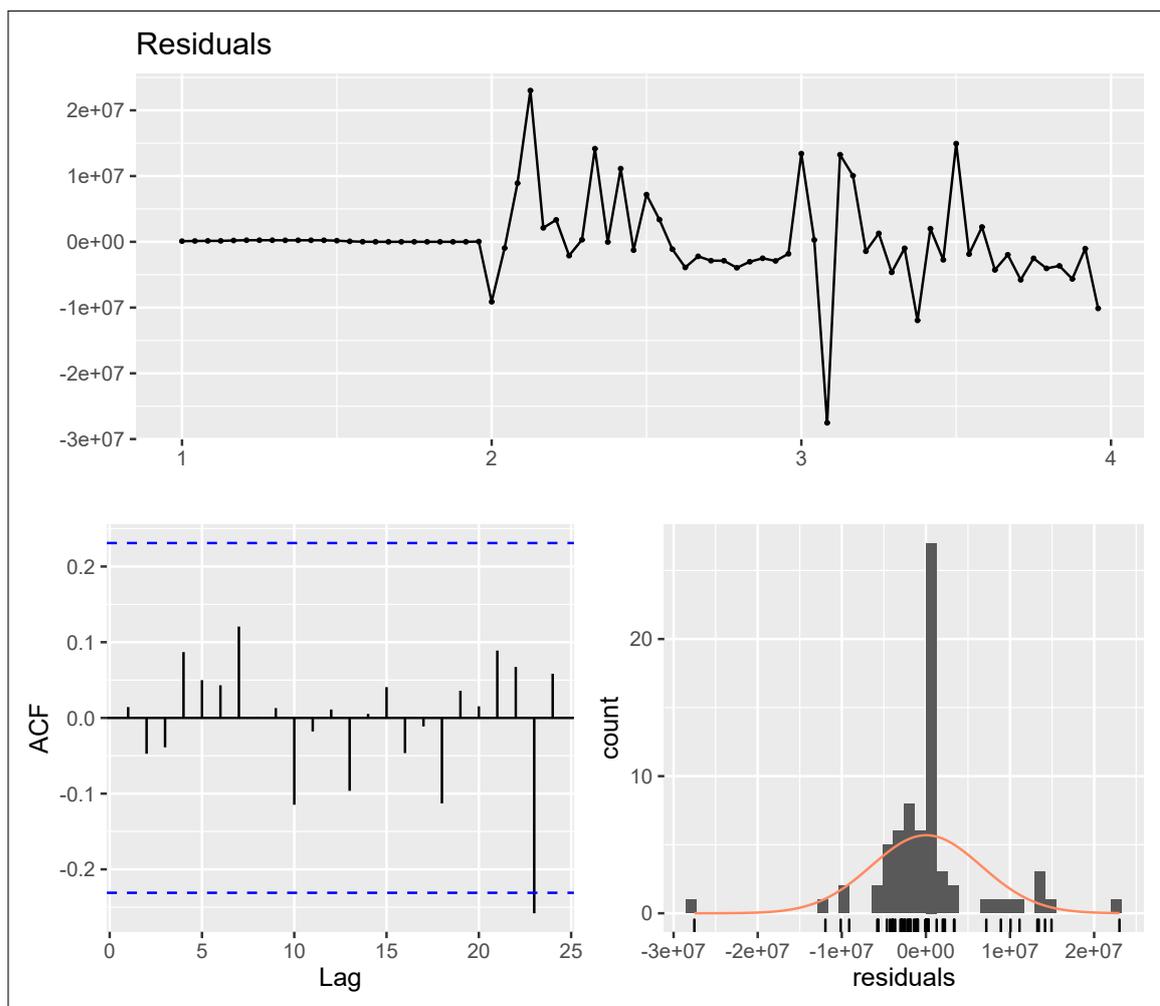


Fonte: Elaborado pelo autor

Através da figura 12 é possível observar o gráfico *ACF* para todos os 21 conjuntos de treinamentos separados para validação, o comportamento de subida e descida em cada conjunto (fora dos limites pontilhados em azul) demonstra a correlação entre as amostras. Sua estacionariedade é reforçada pela descida repentina e o fator sazonal diário, presente na série temporal conforme (HYNDMAN; ATHANASOPOULOS, 2018).

As Figuras 13, 14, 15 e 16 no entanto, referem-se ao primeiro conjunto. É possível observar análise de resíduos (PRA+ARIMA e PRA+NNAR), previsão de 24 amostras a frente usando a abordagem (PRA+ARIMA) e previsão de 24 amostras a frente usando (PRA+NNAR), ainda, uma visão de validação, com as duas abordagens comparando-as ao ciclo de teste original, para o primeiro conjunto de treinamento criado, respectivamente.

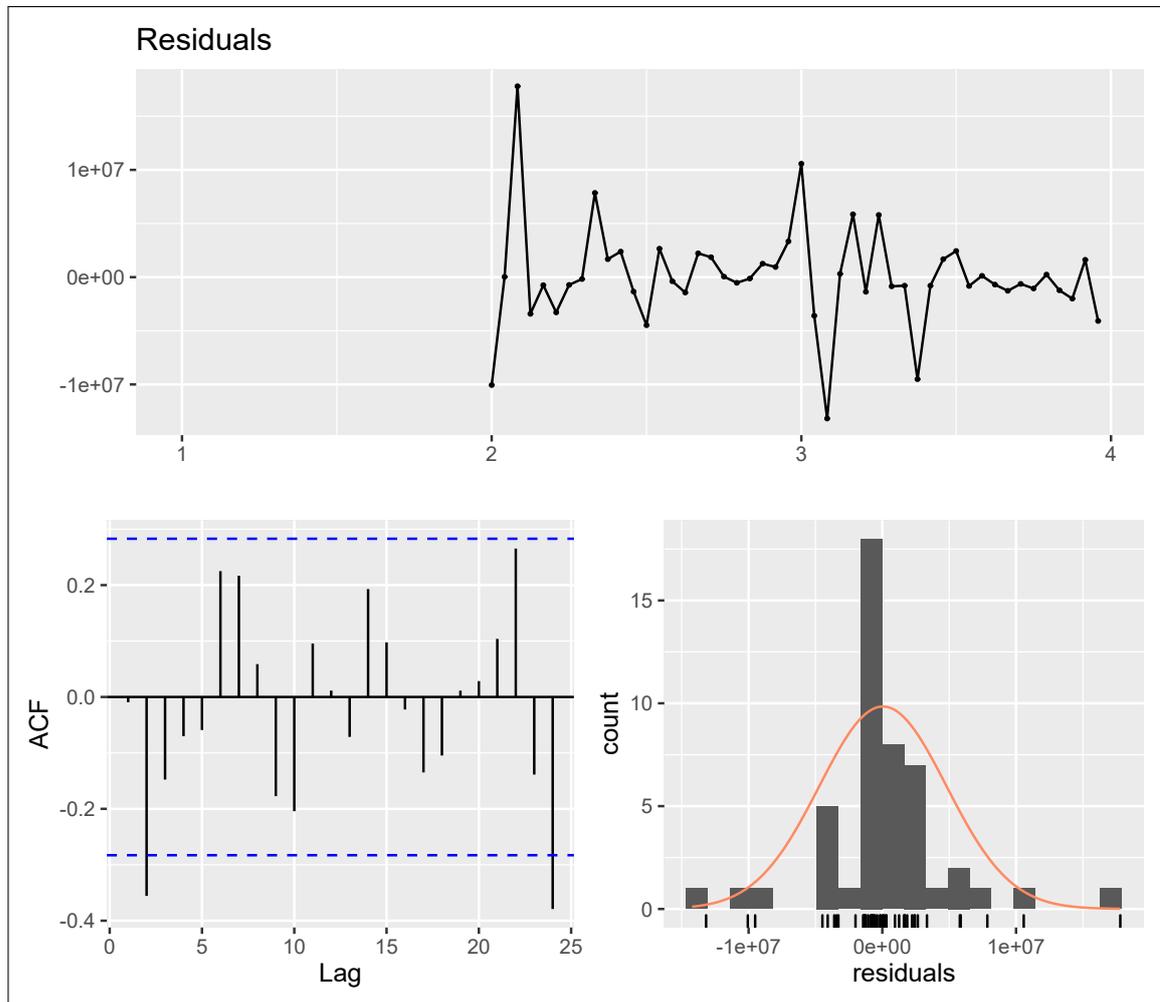
Figura 13 – Análise de resíduos do conjunto de amostras do modelo Arima.



Fonte: Elaborado pelo autor

O *PRA* é usado como etapa prévia a aplicação de uma técnica de predição, a fim de avaliar o incremento na capacidade de modelagem das mesmas, ARIMA e NNAR, com a

Figura 14 – Análise de resíduos do conjunto de amostras do modelo Neural.



Fonte: Elaborado pelo autor

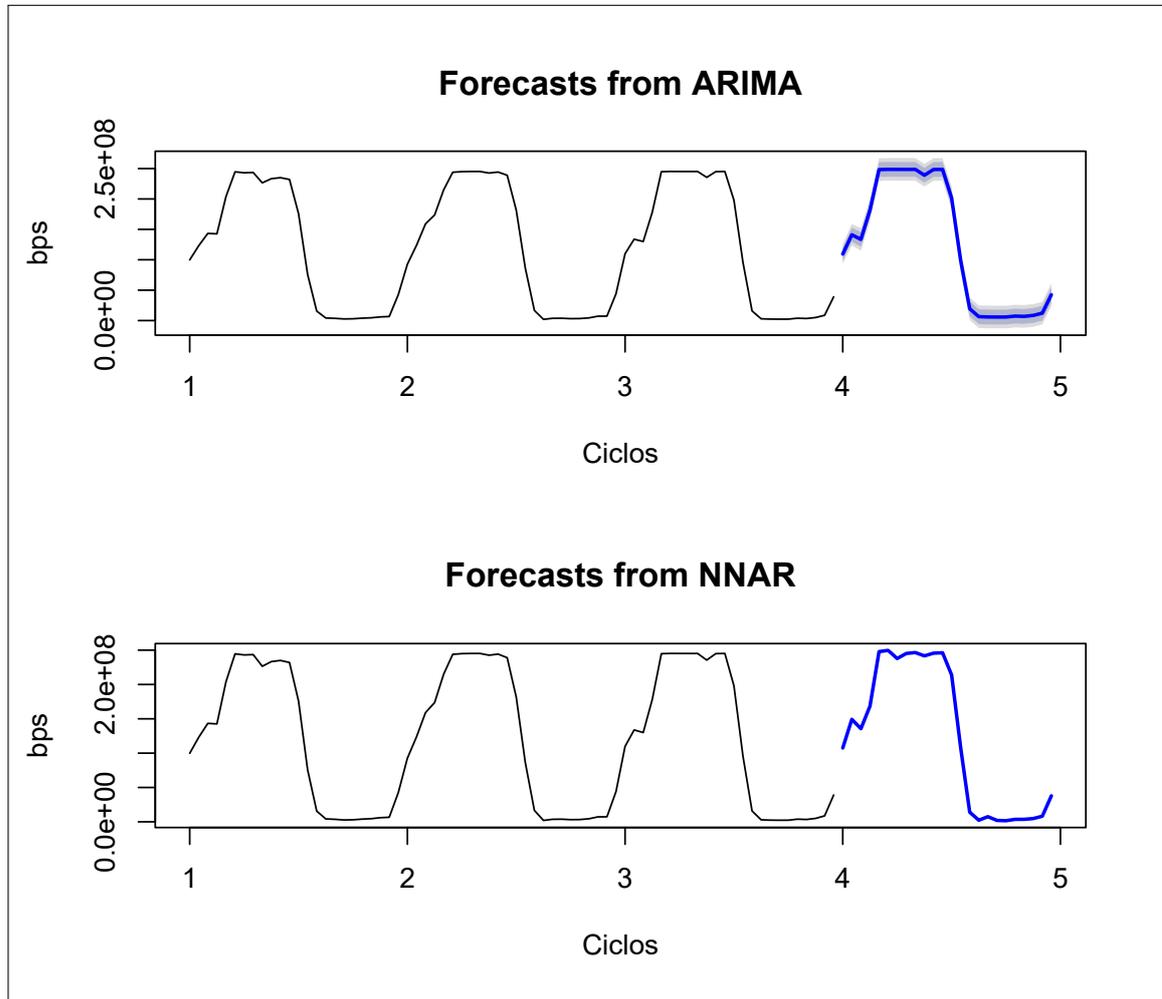
aplicação do modelo proposto (assim como ilustrado na Figura 7).

A partir disso, o Erro Quadrático Médio Raiz (RMSE) por um período T foi usado como métrica de avaliação, seguindo a Equação 2.13 presente no capítulo 2, seção 2.2.1.3.

A Figura 17 mostra os resultados de RMSE para previsão de 1 ciclo usando o modelo proposto e para o ARIMA e o NNAR tradicionais (sem a utilização do PRA). Similarmente, a Figura 18 ilustra o comportamento das previsões realizadas pelo modelo proposto para determinados ciclos.

Usando ARIMA e NNAR como técnicas de modelagem para previsão, obtêm-se os valores aceitáveis de generalização de 87% e 85%, respectivamente. Esse desempenho, que foi comparado ao conjunto de *Teste*, demonstra similaridade entre as duas técnicas, devido ao fato de a série temporal ser sido submetida ao *PRA*. É possível observar que os maiores erros obtidos, com 360 e 432 amostras de treinamento são efeitos do padrão que não fora corrigido o bastante,

Figura 15 – Modelo submetido a previsão de 24 amostras a frente, utilizando PRA+Arima e PRA+NNAR.



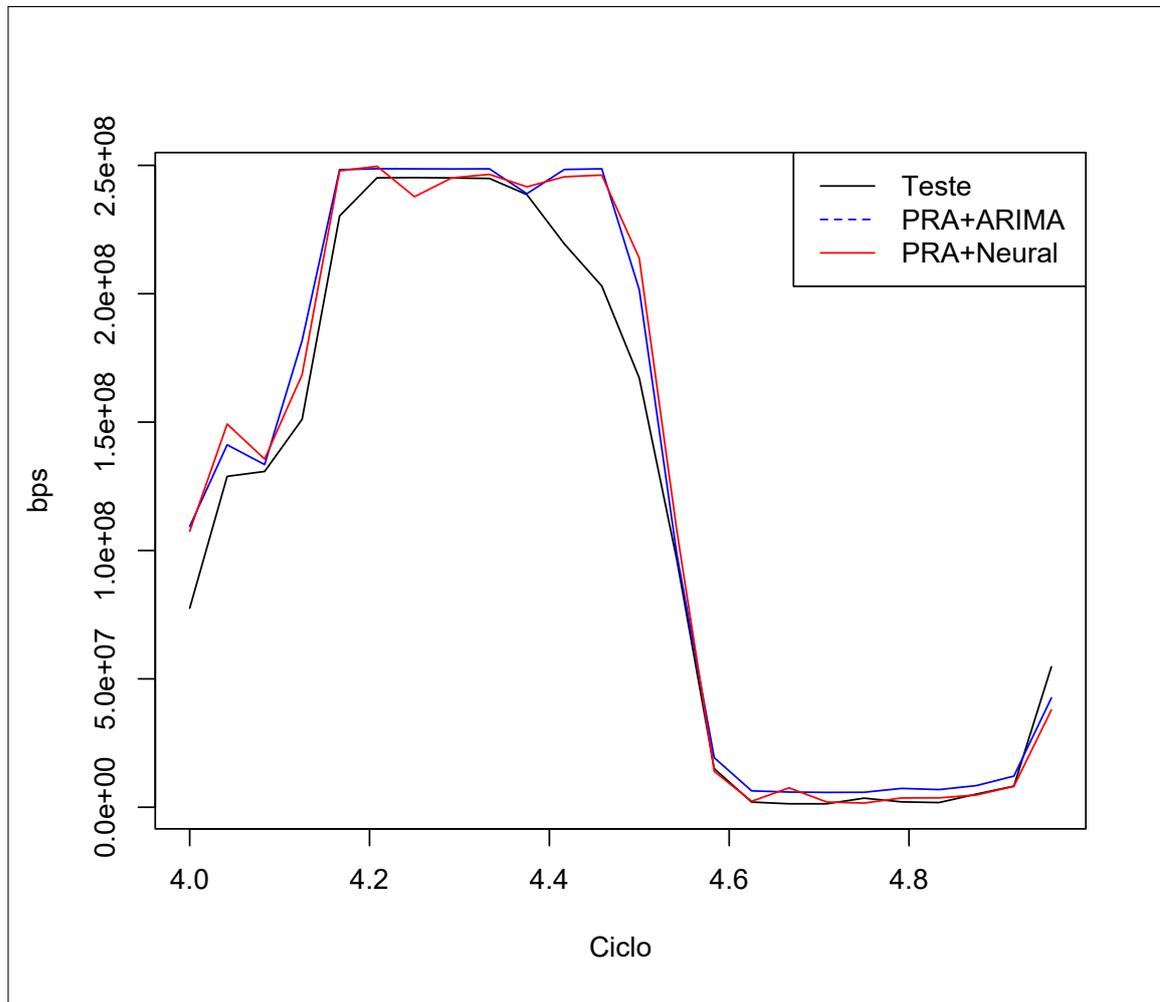
Fonte: Elaborado pelo autor

devido a grandes flutuações nos tempos 16 a 19 (similarmente ao ilustrado na Figura 10).

Adicionalmente, a partir dos dados apresentados na Figura 17, percebe-se que os resultados de RMSE demonstraram uma proximidade entre as técnicas ARIMA e NNAR quando o modelo PRA é aplicado em conjunto (“PRA+ARIMA” e “PRA+NNAR”, respectivamente). Por outro lado, este fato não acontece quando as técnicas são usadas sozinhas. Desta forma, pode-se concluir que o modelo PRA proposto possui flexibilidade e independência em relação às técnicas de previsão usadas.

Como pode ser visualizado na Figura 18, o modelo PRA consegue acompanhar as amostras da série temporal do conjunto de dados real, seguindo o comportamento sazonal e flutuações de amplitude, dando importância à variação das amostras, com aproximadamente 2, 4, 6 e 8 semanas.

Figura 16 – Comparação de previsão *PRA* junto aos dados originais, Teste.



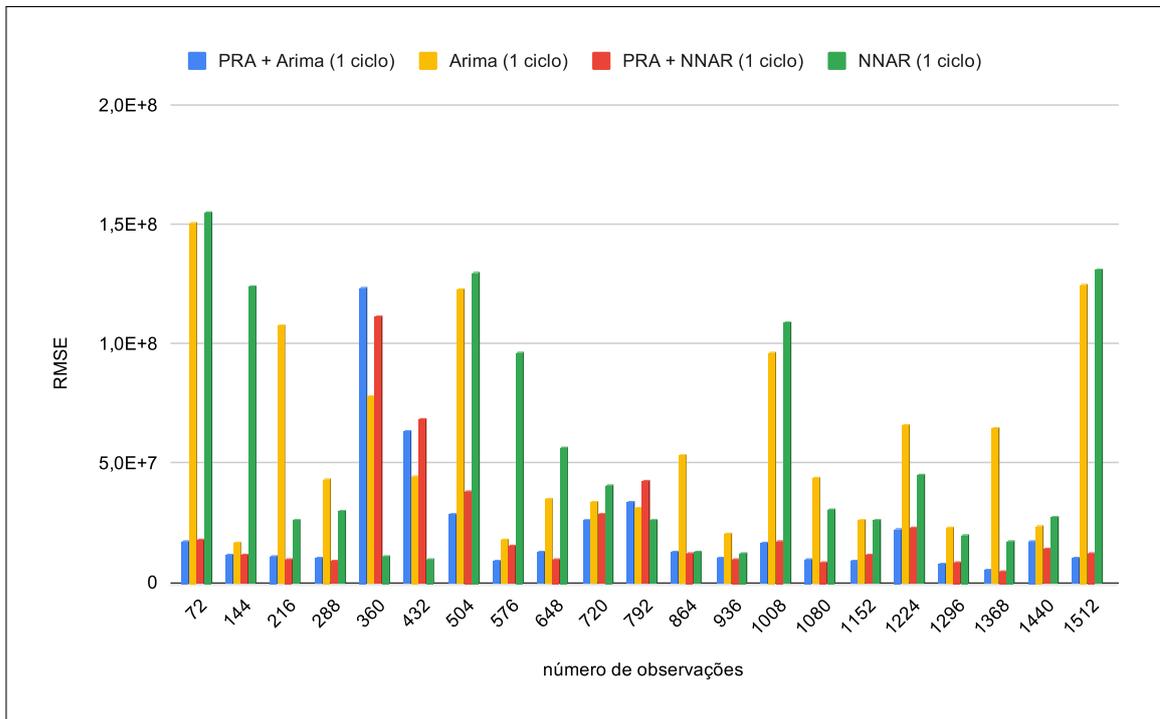
Fonte: Elaborado pelo autor

Além disso, o modelo *PRA* proposto conseguiu reduzir o processamento computacional na fase de treinamento (estimação dos parâmetros) em cerca de 85% utilizando o ARIMA e cerca de 12% utilizando NNAR. Esta situação ocorre pois o modelo *PRA* remove as variáveis de baixa importância durante a retirada dos erros de ciclos, ausentando variáveis utilizadas pelo método regressivo das técnicas de predição. Esse fato indica que o modelo *PRA* é capaz de reduzir o tempo de processamento para outros métodos de previsão, habilitando assim sua aplicação em um cenário de previsão em tempo real.

6.1 CONTRIBUIÇÕES DO TRABALHO

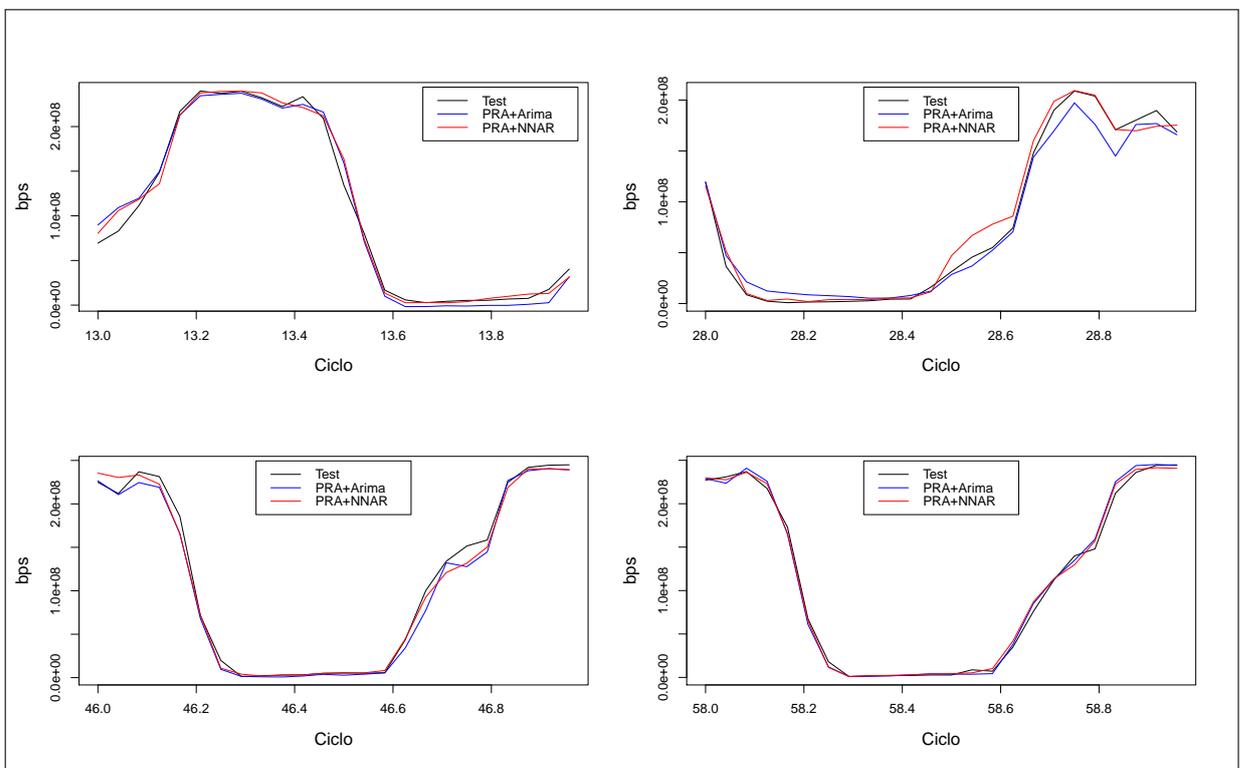
Em tempos no qual grande parte da população tabalha em casa, home office, nas comunidades acadêmicas, mediante usufruto da infraestrutura de Internet, com grandes taxas de download e upload, aumento no streaming de vídeos, servidores de nuvem *cloud servers*

Figura 17 – Comparação de Erro de Previsão.



Fonte: Elaborado pelo autor

Figura 18 – Relação entre os valores reais (Teste) e os valores previstos.



Fonte: Elaborado pelo autor

recebendo altas taxas de upload, faz-se necessário um planejamento para alocação de recursos de Internet, por parte dos provedores modernos. Estes, precisam otimizar suas alocações de recursos de rede onde a maior concentração de tráfego exija melhor eficiência. Sendo capaz de resolver os ajustes na alocação desses recursos, principalmente em horários de pico, considerado o maior problema pelos especialistas de análise de Internet.

Nesse sentido, esta dissertação propõe o modelo *PRA* com análises estatísticas e modelagem dos dados amostrais de tráfego de internet obtidos, é de grande importância e influência quanto a preparação de alocação de recursos, podendo essa alocação ser realizada mediante análise prévia do resultado de previsão desses dados. A redução no número de erros de previsão que o *PRA* consegue efetuar em contraponto às metodologias tradicionais, servirá de entrada para projeção de uma rede de infraestrutura capaz de suportar as reais demandas e necessidades dos usuários de internet. Com diminuição de latência, quedas nos links de dados e distribuição de QoS que ficam a cargo dos links de distribuição de *bandwidth* dos Provedores de Serviços de Internet.

7 CONCLUSÕES E TRABALHOS FUTUROS

A Internet se tornou uma ferramenta crucial para a prestação de serviços de rede. Os ISPs tendem a evoluir MISPs, a fim de lidar com situações que podem influenciar a QoS da prestação de serviço. Uma delas é demanda elástica de recursos de rede, que pode causar problemas como lentidão, interrupção e desconexões constantes.

Nesta dissertação de mestrado, apresentamos o modelo de Previsão de Rede Adaptável (PRA) para aprimorar as técnicas de predição existentes e assim tornar-se uma abordagem eficaz para lidar com as situações de demanda elástica. O modelo proposto adapta-se a utilização de diferentes médias de largura de banda por diferentes intervalos de ciclos. Adicionalmente, o modelo PRA realiza sequencias de ajustes que podem ser submetidas, atingindo valores ótimos de generalização.

Os experimentos realizados, com uma base de dados real, mostraram que a aplicação do modelo em conjunto com técnicas de predição evolui a capacidade de predição dessas técnicas quando comparado a utilização delas isoladamente. A utilização do modelo PRA proposto diminuiu em cerca de 30% a taxa de erros RMSE. Além disso, os resultados de RMSE demonstraram uma proximidade entre as técnicas utilizados na previsão, o que não ocorre quando as técnicas são usada sozinhas, comprovando flexibilidade do modelo proposto e a independência do mesmo em relação as técnicas de predição usadas.

Como trabalho futuro, pretende-se estender a forma de predição, incluindo aspectos como variáveis independentes e amostras da base de dados real. Espera-se que esta inclusão gere um novo modelo com maior capacidade de entender o comportamento elástico da largura de banda. Além disso, faz-se necessário a avaliação do modelo em outros conjuntos de dados para uma melhor análise da proposta.

REFERÊNCIAS

- ADHIKARI, R.; AGRAWAL, R. K. An introductory study on time series modeling and forecasting. **CoRR**, [S.l.], v. 1302, n. 6613, 2013. Disponível em: <http://arxiv.org/abs/1302.6613>. Acesso em: 5 fev. 2020.
- ALDHYANI, T. H.; JOSHI, M. R. Integration of time series models with soft clustering to enhance network traffic forecasting. In: IEEE INTERNATIONAL CONFERENCE ON RESEARCH IN COMPUTATIONAL INTELLIGENCE AND COMMUNICATION NETWORKS, 2., 2016. [S.l.], **Anais... [S.l.]**: ICR-CICN, 2016. p. 212–214.
- BAYATI, A.; NGUYEN, K. K.; CHERIET, M. Multiple-Step-Ahead Traffic Prediction in High-Speed Networks. **IEEE Communications Letters**, [S.l.], v. 22, n. 12, p. 2447–2450, 2018.
- BERRAR, D. Cross-validation. **Encyclopedia of Bioinformatics and Computational Biology: ABC of Bioinformatics**, [S.l.], v. 1, n. 3, p. 542–545, 2018.
- BOX, G.; JENKINS, G. M. **Time Series Analysis: Forecasting and Control**. [S.l.]: Holden-Day, 1976.
- BURNS, P. J. Robustness of the Ljung-Box Test and its Rank Equivalent. **SSRN Electronic Journal**, [S.l.], v. 1, p. 1–17, 2005.
- CARRION-I-SILVESTRE, J. L.; SANSÓ-I-ROSSELLÓ, A.; ORTUÑO, M. A. Unit root and stationarity tests' wedding. **Economics Letters**, [S.l.], v. 70, n. 1, p. 1–8, 2001.
- CRYER, J. D.; CHAN, K.S. **[CN]Time Series Analysis: With Applications to R**. [S.l.: s.n.], 2008. 487 p.
- DALY, C.; MOORE, D. L.; HADDAD, R. J. Nonlinear auto-regressive neural network model for forecasting Hi-Def H.265 video traffic over Ethernet Passive Optical Networks. **Conference Proceedings - IEEE SOUTHEASTCON, IEEE**, [S.l.], v. 2, p. 1–7, 2017.
- DOKUMENTOV, A.; HYNDMAN, R. J. **STR: A Seasonal-Trend Decomposition Procedure Based on Regression**. [S.l.:s.n.], 2015.
- FOUKAS, X.; PATOUNAS, G.; ELMOKASHFI, A.; MARINA, M. K. Network slicing in 5g: Survey and challenges. **IEEE Communications Magazine**, [S.l.], v. 55, n. 5, p. 94–100, maio 2017.
- GUTIERREZ, N.; WIESINGER-WIDI, M. AUGURY: A time series based application for the analysis and forecasting of system and network performance metrics. In: INTERNATIONAL SYMPOSIUM ON SYMBOLIC AND NUMERIC ALGORITHMS FOR SCIENTIFIC COMPUTING, 18., 2017. [S.l.], **Anais... [S.l.]**: SYNASC, 2016. p. 351–358.
- HARSTEAD, E.; SHARPE, R. Forecasting of access network bandwidth demands for aggregated subscribers using Monte Carlo methods. **IEEE Communications Magazine**, [S.l.], v. 53, n. 3, p. 199–207, 2015.

HOU, Z.; SHE, C.; LI, Y.; QUEK, T. Q.; VUCETIC, B. Burstiness aware bandwidth reservation for uplink transmission in tactile internet. *In: INTERNATIONAL CONFERENCE ON COMMUNICATIONS WORKSHOPS, ICC WORKSHOPS 2018 - PROCEEDINGS, 2., 2018. [S.l.], Anais... [S.l.]: IEEE, 2018. p. 1–6.*

HYNDMAN, R.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice.** 2. ed. Australia: OTexts, 2018.

JIANG, G.; WANG, W. Markov cross-validation for time series model evaluations. **Information Sciences**, *[S.l.]*, v. 375, p. 219–233, 2017.

KATRIS, C.; DASKALAKI, S. Dynamic bandwidth allocation for video traffic using farima-based forecasting models. **Journal of Network and Systems Management**, *[S.l.]*, v. 27, n. 1, p. 39–65, jan 2019. Disponível em: <https://doi.org/10.1007/s10922-018-9456-1>. Acesso em: 6 mar. 2020.

KWIATKOWSKI, D.; PHILLIPS, P. C.; SCHMIDT, P.; SHIN, Y. Testing the null hypothesis of stationarity against the alternative of a unit root. How sure are we that economic time series have a unit root? **Journal of Econometrics**, *[S.l.]*, v. 54, n. 1-3, p. 159–178, 1992.

LEVENDIS, J. D. Non-stationarity and arima(p,d,q) processes. *In: LEVENDIS, J. D. Time Series Econometrics: Learning Through Replication.* Cham: Springer International Publishing, 2018. p. 101–122. Disponível em: https://doi.org/10.1007/978-3-319-98282-3_5. Acesso em: 6 mar. 2020.

MALEKI, A.; NASSERI, S.; AMINABAD, M. S.; HADI, M. Comparison of ARIMA and NNAR Models for Forecasting Water Treatment Plant's Influent Characteristics. **KSCE Journal of Civil Engineering**, *[S.l.]*, v. 22, n. 9, p. 3233–3245, 2018.

PICKERING, E. M.; HOSSAIN, M. A.; FRENCH, R. H.; ABRAMSON, A. R. Building electricity consumption: Data analytics of building operations with classical time series decomposition and case based subsetting. **Energy and Buildings**, *[S.l.]*, v. 177, p. 184 – 196, 2018. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0378778818306029>. Acesso em: 8 abr. 2020.

REISEN, V. A.; LÉVY-LEDUC, C.; BOURGUIGNON, M.; BOISTARD, H. Robust Dickey–Fuller tests based on ranks for time series with additive outliers. **Metrika**, Heidelberg, v. 80, n. 1, p. 115–131, 2017.

ROYSTON, P. Approximating the Shapiro-Wilk W-test for non-normality. **Statistics and Computing**, *[S.l.]*, v. 2, n. 3, p. 117–119, 1992.

RUAN, L.; MONDAL, S.; WONG, E. Machine learning based bandwidth prediction in tactile heterogeneous access networks. **Conference on Computer Communications Workshops**, *[S.l.]*, v. 2, p. 1–2, 2018.

SCHMIDT, R. D. O.; SADRE, R.; PRAS, A. Gaussian traffic revisited. **Networking Conference, IFIP Networking**, *[S.l.]*, v. 1, p. 1–9, 2013.

SU, F.; DONG, H.; JIA, L.; QIN, Y.; TIAN, Z. Long-term forecasting oriented to urban expressway traffic situation. **Advances in Mechanical Engineering**, [S.l.], v. 8, n. 1, p. 1–16, 2016.

TEAM, R. C. R. **A Language and Environment for Statistical Computing**. Vienna: [s.n.], 2019. Disponível em: <https://www.R-project.org>. Acesso em: 8 mar. 2020.

THOPLAN, R. Simple v/s sophisticated methods of forecasting for mauritius monthly tourist arrival data. **International Journal of Statistics and Applications**, [S.l.], v. 4, p. 217–223, 09 2014.

WANG, T.; GUO, Z.; CHEN, H.; LIU, W. BWManager: Mitigating Denial of Service Attacks in Software-Defined Networks Through Bandwidth Prediction. **IEEE Transactions on Network and Service Management**, [S.l.], v. 15, n. 4, p. 1235–1248, 2018.

YADAV, S.; SHUKLA, S. Analysis of k-Fold Cross-Validation over Hold-Out Validation on Colossal Datasets for Quality Classification. In: INTERNATIONAL ADVANCED COMPUTING CONFERENCE, 6., 2016, [S.l.], **Anais...** [S.l.:s.n.], 2016. p. 78–83.

YOO, W.; SIM, A. Network bandwidth utilization forecast model on high bandwidth networks. In: INTERNATIONAL CONFERENCE ON COMPUTING, NETWORKING AND COMMUNICATIONS, 1., 2015, [S.l.], **Anais...** [S.l.:s.n.], 2015. p. 494–498.

YOU, C.; CHANDRA, K. Time series models for Internet data traffic. **Conference on Local Computer Networks**, [S.l.], v. 2, p. 164–171, 1999.