



UNIVERSIDADE FEDERAL DE ALAGOAS – UFAL
CAMPUS DO SERTÃO
ENGENHARIA DE PRODUÇÃO

João Paulo Machado de Araújo

**ESTIMAÇÃO DO CONSUMO DE ENERGIA ELÉTRICA BASEADO EM MODELOS
DE PREVISÃO DE DEMANDA**

Delmiro Gouveia/AL
2022



JOÃO PAULO MACHADO DE ARAÚJO

**ESTIMAÇÃO DO CONSUMO DE ENERGIA ELÉTRICA BASEADO EM MODELOS
DE PREVISÃO DE DEMANDA**

Trabalho de Conclusão de Curso apresentado ao
Curso de Engenharia de Produção da Universidade
Federal de Alagoas – Campus Sertão para obtenção
do título de Bacharel em Engenharia de Produção.

Orientador: Prof. Dr. Jonhatan Magno Norte da
Silva

Delmiro Gouveia/AL
2022

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca do Campus Sertão
Sede Delmiro Gouveia

Bibliotecária responsável: Renata Oliveira de Souza CRB-4/2209

A663e Araújo, João Paulo Machado de

Estimação do consumo de energia elétrica baseado em modelos de previsão de demanda / João Paulo Machado de Araújo. – 2022.
77 f. : il. ; 30 cm.

Orientação: Jonhatan Magno Norte da Silva.
Monografia (Engenharia de Produção) – Universidade Federal de Alagoas. Curso de Engenharia de Produção. Delmiro Gouveia, 2022.

1. Energia elétrica. 2. Demanda energética. 3. Modelos de previsão de demanda. 4. Planejamento. I. Silva, Jonhatan Magno Norte da. II. Título.

CDU: 621.3.095.2


Folha de Aprovação

JOÃO PAULO MACHADO DE ARAÚJO


ESTIMAÇÃO DO CONSUMO DE ENERGIA ELÉTRICA BASEADO EM MODELOS DE PREVISÃO DE DEMANDA

Trabalho de Conclusão de Curso submetido ao corpo docente do Curso de Engenharia de Produção da Universidade Federal de Alagoas - Campus Sertão e aprovado em 04 de março de 2022.

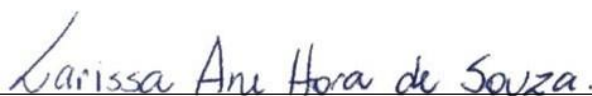
Banca Examinadora:

Documento assinado digitalmente
 JONHATAN MAGNO NORTE DA SILVA
Data: 04/03/2022 11:15:20-0300
Verifique em <https://verificador.iti.br>

Prof. Dr. Jonhatan Magno Norte da Silva, UFAL – Campus do Sertão (Orientador)

Documento assinado digitalmente
 Alline Thamyres Claudino da Silva
Data: 04/03/2022 11:25:48-0300
Verifique em <https://verificador.iti.br>

Prof^ª. MSc. Alline Thamyres Claudino da Silva, UFAL – Campus do Sertão (Avaliadora)



Larissa Ane Hora de Souza, Engenheira de Produção (Avaliador Externo)

“Lute com determinação, abrace a vida com paixão, perca com classe e vença com ousadia, porque o mundo pertence a quem se atreve e a vida é muito bela para ser insignificante.”

Charles Chaplin

RESUMO

Dada a evolução humana, os países estão a produzir e a consumir energia elétrica a todo o momento. O insumo energético envolve dimensões sociais, econômicas e ambientais que reverberam diretamente para o bem-estar da população e a competitividade de um país. O mercado tem a necessidade de um planejamento preciso sobre o abastecimento, o consumo e a expansão da eletricidade. Em tais termos, a previsão de demanda é fundamental para que ocorra uma gestão eficiente baseada em tomadas de decisões mais assertivas, com orientação de políticas públicas, para prever tendências, sazonalidades e ciclos futuros, de modo que os investimentos no setor elétrico sejam alocados corretamente. Considerando a importância e os impactos do planejamento eficiente da demanda de energia elétrica, este trabalho tem como objetivo analisar e comparar modelos de previsão de demanda a fim de determinar quais terão a maior eficiência ao medir o consumo de energia elétrica no Brasil. Para isso, foram retirados da base de dados aberta da Eletrobras, disponibilizados pelo Instituto de Pesquisa Econômica Aplicada – Ipeadata (2021), um conjunto de dados referente ao consumo de energia elétrica (GWh), sob uma frequência mensal definida de janeiro de 1976 até julho 2021. O desempenho das previsões realizadas foram comparadas utilizando as medidas de acurácia: o Erro Médio (ME); a Raiz do Erro Quadrático Médio (RMSE); a Média Absoluta dos Erros (MAE), a Média Absoluta Percentual dos Erros (MAPE) e o Erro Médio Absoluto em Escala (MASE). A partir da análise de tais medidas foram definidos os quatro melhores modelos. Em seguida, foi constatado que todos os modelos analisados se mostraram muito precisos e semelhantes, o que define que todas as previsões podem ser utilizadas, contudo, o modelo de Autorregressão da Rede Neural com Intervalos de Previsão foi definido como o mais adequado, com um erro percentual de 0,2%. Portanto, os resultados obtidos são relevantes para sinalizar as organizações sobre a possibilidade de aplicar métodos de baixo custo e com alto grau de assertividade que impactarão significativamente no planejamento e na tomada de decisões.

Palavras-chave: Consumo de Energia Elétrica; Modelos de Previsão de Demanda; Séries Temporais; Autorregressão da Rede Neural.

ABSTRACT

Given human evolution, countries are producing and consuming electrical energy at every moment. The energy input involves social, economic and environmental dimensions that reverberate directly for the well-being of the population and the competitiveness of a country. The market has the need for a precise planning on the supply, consumption and expansion of electricity. In such terms, demand forecasting is essential for an efficient management based on more assertive decision-making, guided by public policy guidance, to forecasting trends, seasonality and future cycles, so that investments in the electrical sector are correctly allocated. Considering the importance and the impacts of efficient planning of electrical energy demand, this work aims to analyze and compare forecast models in order to determine which ones will have the most efficiency when measuring electrical energy consumption in Brazil. For that, a set of data regarding electricity consumption (GWh) was collected from Eletrobras open database, made available by the Institute of Applied Economic Research - Ipeadata (2021), under a defined monthly frequency from January 1976 to July 2021. The performance of the forecasts performed were compared using the accuracy measures: the Mean Error (ME); the Root Mean Square Error (RMSE); the Mean Absolute Error (MAE), the Mean Absolute Percentage Error (MAPE) and the Mean Absolute Scaled Error (MASE). From the analysis of such measures, the four best models were defined. Then, it was found that all models analyzed proved to be very accurate and similar, which defines that all predictions can be used, however, the Neural Network Autoregression model with Forecast Intervals was defined as the most appropriate, with an error percentage of 0.2%. Therefore, the results obtained are relevant to signal the organizations about the possibility of applying low-cost methods with a high degree of assertiveness that will significantly impact on planning and decision-making.

Keywords: Electric Energy Consumption; Forecasting Models; Time Series; Neural Network Autoregression.

LISTA DE FIGURAS

Figura 1 – Padrões de demanda	20
Figura 2 – Funcionamento genérico do neurônio artificial e da rede neural	26
Figura 3 – Dados do consumo de energia no Brasil no período de janeiro de 1976 até julho de 2021	44
Figura 4 – Dados decompostos do consumo de energia no Brasil	45
Figura 5 – Representação gráfica do modelo Autorregressão da Rede Neural	48
Figura 6 – (a) Variação residual, (b) Correlograma e (c) Histograma do modelo Autorregressão da Rede Neural	48
Figura 7 – Representação gráfica do modelo ARIMA de Box-Jenkins	50
Figura 8 – (a) Variação residual, (b) Correlograma e (c) Histograma do modelo ARIMA de Box-Jenkins	50
Figura 9 – Representação gráfica do modelo Autorregressão da Rede Neural com Intervalos de Previsão.....	52
Figura 10 – (a) Variação residual, (b) Correlograma e (c) Histograma do modelo Autorregressão da Rede Neural com Intervalos de Previsão	52
Figura 11 – Representação gráfica do Método Naive	54
Figura 12 – (a) Variação residual, (b) Correlograma e (c) Histograma do Método Naive ...	54

LISTA DE QUADROS

Quadro 1 – Equações dos modelos de Holt-Winters.....	32
--	----

LISTA DE TABELAS

Tabela 1 – Medidas descritivas da série temporal	44
Tabela 2 – Resumo das medidas de acurácia dos modelos propostos.....	46
Tabela 3 – Resultado do modelo de Autorregressão da Rede Neural	47
Tabela 4 – Resultados do modelo ARIMA de Box-Jenkins.....	49
Tabela 5 – Resultados do modelo Autorregressão da Rede Neural com Intervalos de Previsão	51
Tabela 6 – Resultados do Método Naive.....	53
Tabela 7 – Comparação dos erros entre a demanda real e a demanda prevista.....	55
Tabela 8 – Resultados dos testes de normalidade e testes para amostras dependentes	56

LISTA DE ABREVIATURAS E SIGLAS

ACF	Autocorreção
ANACE	Associação Nacional dos Consumidores de Energia
AR	Autoregressão
ARIMA	Auto Regressivo Integrado de Média Móvel
ARMA	Autorregressivo de Média Móveis
CIA	<i>Central Intelligence Agency</i>
EPE	Empresa de Pesquisa Energética
I	Diferenciação
IEA	Agência Internacional de Energia
MA	Média Móvel
MAE	Média Absoluta dos Erros
MAPE	Média Absoluta Percentual dos Erros
MASE	Erro Médio Absoluto em Escala
ME	Erro Médio
MME	Ministério de Minas e Energia
MQE	Média do Quadrado dos Erros
NNAR	Autorregressão da Rede Neural
ODS	Objetivos para o Desenvolvimento Sustentável
ONU	Organização das Nações Unidas
PACF	Autocorrelação Parcial
RMSE	Raiz do Erro Quadrático Médio
RNA	Rede Neural Artificial

SUMÁRIO

1. INTRODUÇÃO.....	14
1.1 Justificativa	15
1.2 Problema de Pesquisa	16
1.3 Objetivos da Pesquisa	16
1.3.1 Objetivo geral	17
1.3.2 Objetivo geral	17
1.4 Delimitação do Trabalho.....	17
1.5 Estrutura do Trabalho	17
2. REFERÊNCIAL TEÓRICO	19
2.1 Padrões de Demanda	19
2.2 Previsão de Demanda	21
2.3 Métodos de Previsão de Demanda.....	22
2.3.1 Métodos Qualitativos	22
2.3.2 Métodos Quantitativos	23
2.3.2.1 <i>Métodos de Séries Temporais</i>	24
2.3.2.2 <i>Métodos Causais</i>	25
2.3.3 Métodos Híbridos	25
2.3.3.1 <i>Redes Neurais Artificiais</i>	26
2.4 Modelos de Previsão de Demanda.....	27
2.4.1 Média Móvel Simples	27
2.4.2 Média Móvel Ponderada	27
2.4.3 Método Naive	28
2.4.4 Método Naive Sazonal	28
2.4.5 Regressão Linear Simples.....	29
2.4.6 Suavização Exponencial Simples	30
2.4.7 Modelo de Holt-Winters	31
2.4.8 Modelo de Box-Jenkins	33
2.4.9 Método de Croston	36
2.4.10 Método Splinesf	37
2.4.11 Autorregressão da Rede Neural	37
2.5 Medidas de Acurácia	38
3. PROCEDIMENTOS METODOLÓGICOS.....	40
3.1 Caracterização do Estudo	40

3.2 Dados da Pesquisa.....	40
3.3 Análise e Tratamento dos Dados	41
3.3.1 Estrutura dos Modelos	41
3.3.2 Análise Residual	42
3.3.3 Desempenho dos Modelos	42
4. ANÁLISE E DISCUSSÃO DOS RESULTADOS.....	44
4.1 Análise Descritiva da Amostra	44
4.2 Análise Comparativa dos Modelos	46
4.2.1 Autorregressão da Rede Neural	47
4.2.2 ARIMA de Box-Jenkins	49
4.2.3 Autorregressão da Rede Neural com Intervalos de Previsão.....	51
4.2.4 Método de Naive.....	53
4.3 Definição do modelo mais adequado	55
5. CONSIDERAÇÕES FINAIS	58
REFERÊNCIAS	60
APÊNDICE A – Resultados do Método Splinesf	68
APÊNDICE B – Resultados do Método Sazonal	70
APÊNDICE C – Resultados do Método Groston	72
APÊNDICE D – Resultados do Método da Média Móvel.....	74
ANEXO A – Dados do Consumo de Energia no Brasil GWh	76

1. INTRODUÇÃO

A demanda e o consumo de energia elétrica se retroalimentam, um é consequência do outro, e estão diretamente associadas às necessidades humanas. A demanda antecede o consumo, pois a procura por algo ou bem só ocorre após o surgimento de uma necessidade que precisa ser satisfeita. Isto é, tanto a demanda quanto o consumo provoca uma busca intensa pela comodidade que a eletricidade gera (FINE; LEOPOLD, 1993; MARTINS et al., 2017).

Dentro da teoria econômica, destaca-se a importância da energia elétrica, posto que é um indicador de bem-estar social. A sociedade utiliza de recursos naturais para aumentar a capacidade produtiva e intelectual através do consumo de eletricidade. O insumo energético é um fator determinante para analisar as disparidades socioeconômicas e tecnológicas entre as nações do mundo, pois o vasto ou escasso acesso a esse insumo reflete em países industrializados ou países em desenvolvimento (CARMINATI; SCALCO, 2013).

Corroborando, Correia et al. (2017) enfatiza que a noção de progresso ou desenvolvimento está atrelada ao consumo de bens duráveis, indústria e urbanização, nos quais, têm como insumo básico a eletricidade. O autor ainda complementa dizendo que a energia pode ser vista como melhoria de bem-estar social mediante avanços da saúde, educação, tecnologia e economia, como na facilitação da comunicação ou até mesmo na forma de conservar alimentos, por exemplo.

Nesse sentido ainda, desde a Revolução Industrial, no século XIX, a energia influencia na qualidade de vida da população e na competitividade econômica dos países. No mercado globalizado da sociedade moderna, o uso de energia se tornou ainda mais decisivo, devidas as inúmeras preocupações crescentes com o meio ambiente. Nessa circunstância, o posicionamento dos países acerca recursos energéticos de baixo custo e de baixo impacto ambiental é um ponto chave na vantagem competitiva em mercado econômico acirrado (TOLMASQUIM et al., 2007).

No cenário brasileiro, foi durante o século XX que o país passou por um intenso desenvolvimento econômico que provocou uma grande demanda de energia primária, substituindo parte do trabalho humano e animal. Em prol da trilha do progresso, apostou-se também na energia elétrica para impulsionar o setor industrial, aumentar a taxa de urbanização e obter uma expansão demográfica (LEITE, 2007; PINTO JR, 2007; TOLMASQUIM et al., 2007).

O sistema de energia elétrica do Brasil é estruturado pelo grande potencial hídrico, sendo que a base do seu desenvolvimento é constituída pelo revezamento entre a participação

do capital privado e capital público (SIFFERT FILHO et al., 2009).

No que se diz respeito ao consumo que compõe o estilo de desenvolvimento da sociedade, segundo a Empresa de Pesquisa Energética – EPE (2019), as indústrias que mais consomem energia elétrica são as de aço bruto, celulose e papel e cimento. Esses setores são os grandes fornecedores de insumos para outros segmentos como construção civil e fábricas que produzem máquinas e equipamentos.

De modo geral, o futuro do setor elétrico tem sido alvo recorrente de discussões nas últimas décadas, sendo um dos fatores apontados no Relatório Brundtland (ORGANIZAÇÃO DAS NAÇÕES UNIDAS - ONU, 1987), elaborado pela Comissão Mundial sobre o Meio Ambiente e o Desenvolvimento, ligados ao desenvolvimento sustentável e também a evolução tecnológica, conforme Davos (WORLD ECONOMIC FORUM, 2016). Nesse contexto, a Agência Internacional de Energia (IEA) e outros órgãos estão propondo metas e políticas a fim de reduzir a demanda de energia. Na ótica social, a energia é vinculada a um dos 17 Objetivos para o Desenvolvimento Sustentável (ODS) elencados na Agenda 2030 (ORGANIZAÇÃO DAS NAÇÕES UNIDAS - ONU, 2017).

Portanto, dada a sua importância socioeconômica, o mercado de energia elétrica tem a necessidade de um planejamento mais preciso sobre o abastecimento, o consumo e a expansão da eletricidade. Em tais termos, a utilização da previsão de demanda é fundamental para que ocorra uma gestão eficiente baseada em tomadas de decisões mais assertivas sobre todo o setor elétrico. Reforçando isso, o Ministério de Minas e Energia (MME, 2019) aponta que é imprescindível aperfeiçoar decisões já tomadas e incorporar questões de futuro, de modo que garanta a segurança energética e atenda aos objetivos do desenvolvimento sustentável.

1.1. Justificativa

No contexto mundial, o consumo de energia elétrica representa aproximadamente 21.771,69 bilhões kWh, no qual 43,26% representa o valor que é consumido por países desenvolvidos (CIA, 2018). Os principais setores no consumo energético são residencial, comercial e de serviços públicos, sendo o setor industrial o primeiro do *ranking* (IEA, 2018). Enquanto isso, no recorte brasileiro, o país em 2018 atingiu 601,4 TWh de geração de energia elétrica, com o subsistema Sudeste/Centro-Oeste operando em média com 60% do consumo nacional (EPE, 2019).

Tendo em vista esses dados de grande utilização da energia elétrica, é fundamental tratar de maneira correta a sua demanda, em razão de que em grandes quantidades a eletricidade não pode ser armazenada, logo, é vital que os desequilíbrios entre demanda e oferta sejam evitados, para que não ocorra elevados custos de produção que serão reverberados à população (VILAR et al., 2012). Corroborando, Tutun et al. (2015) frisa que o excesso ou a redução da produção de eletricidade provocam consequências como o desperdício ou o racionamento, por esse motivo é indispensável fazer um planejamento eficiente da demanda.

Nessa perspectiva, Wu et al. (2018) aponta que a demanda por eletricidade pode ser prevista por modelos matemáticos e/ou estatísticos, possibilitando identificar o comportamento e tendências futuras, de modo que os investimentos no setor elétrico sejam alocados corretamente. Coelho Júnior et al. (2018) complementa afirmando que a previsão de demanda é um fator fundamental para a promoção de estimativas para um determinado momento, pois auxilia na tomada de decisão, orientação de políticas públicas, e por prever tendências, sazonalidades e ciclos futuros.

Visto que a eletricidade envolve dimensões sociais, econômicas e ambientais, mostra-se relevante estimar o consumo de energia elétrica do Brasil baseado em modelos de previsão de demanda. Para isso, este trabalho irá utilizar métodos quantitativos e híbridos de previsão, que segundo Corrêa e Corrêa (2007) são métodos baseados em série de dados históricos que buscam identificar padrões de comportamentos projetados para o futuro. Serão construídos diversos modelos de previsão os quais passarão por uma análise de eficiência que apontará qual terá o menor erro e acurácia nos resultados.

1.2. Problema de Pesquisa

Através dos fatos expostos, percebe-se a necessidade e os impactos do planejamento eficiente da demanda de energia elétrica. Deste modo, surge a seguinte problemática: Qual método de previsão da demanda é o mais adequado para estimar o consumo de energia elétrica no Brasil?

1.3. Objetivos da Pesquisa

A seguir estarão dispostos os objetivos, de caráter geral e específico, que visam responder o problema de pesquisa.

1.3.1. Objetivo Geral

O proposto trabalho tem como objetivo geral analisar e comparar modelos de previsão de demanda a fim de determinar qual terá a maior eficiência ao medir o consumo de energia elétrica.

1.3.2. Objetivos Específicos

Os objetivos específicos desta pesquisa são:

- Levantar dados do período analisado;
- Testar modelos de previsão de demanda;
- Calcular parâmetros de comparação dos modelos de previsão de demanda;
- Avaliar o modelo de previsão de demanda mais efetivo.

1.4. Delimitação do Trabalho

Os dados utilizados para esta pesquisa delimitaram-se a apenas uma base, ao qual restringiu-se o horizonte de tempo de 1976 até 2021. Desse modo, o campo de aplicação deste trabalho limitou-se ao consumo de energia no Brasil, onde não serão consideradas outras variáveis além do consumo.

1.5. Estrutura do Trabalho

O trabalho está estruturado em cinco capítulos, dos quais visam atingir e expor os objetivos propostos.

O Capítulo 1 retrata a apresentação do trabalho, sendo composto pela introdução, justificativa, problema de pesquisa, objetivos gerais e específicos, delimitação do tema e uma breve descrição referente a estrutura do trabalho.

O Capítulo 2 aborda a revisão da literatura acerca do tema trabalhado, apresentando conceitos associados ao mercado e consumo de energia elétrica no Brasil, previsão de demanda; métodos de previsão e medidas de acuraria e erro.

O Capítulo 3 apresenta os delineamentos metodológicos utilizados para o desenvolvimento do estudo, assim como a caracterização do estudo, a coleta de dados, a análise

da consistência e tratamento dos dados, as previsões de demanda e as análises dos procedimentos de eficiência dos modelos.

O Capítulo 4 detalha os resultados obtidos por meio dos procedimentos metodológicos, como também realizar discussões acerca das previsões resultantes dos modelos utilizados.

O Capítulo 5 apresenta a conclusão a respeito das discussões dos resultados obtidos, retratando as contribuições científica, econômica e social, suas limitações e sugestões para trabalhos futuros.

2. REFERENCIAL TEÓRICO

A eletricidade rodeia a história e o desenvolvimento humano desde que o homem entendeu que precisava estabelecer uma relação direta com a natureza para obter recursos que proporcionassem a viabilização de atividades cotidianas e a melhoria da qualidade de vida. Em decorrência dessa evolução humana, as pessoas, em torno de todo o mundo, estão a produzir e a consumir energia elétrica, todos os dias e a qualquer momento. No Brasil, com o crescente consumo de energia, atrelado as necessidades e limitações experienciadas pelo país, provocam as crises energéticas que trazem insegurança e preocupação para toda a sociedade. Devido às ocorrências delas, há a adoção de medidas planejadas e coordenadas, de racionamento e planejamento futuro, em busca do melhor gerenciamento de um setor tão complexo e importante como o de energia elétrica (ASSOCIAÇÃO NACIONAL DOS CONSUMIDORES DE ENERGIA – ANACE, 2020).

A previsão de demanda do consumo de energia elétrica, como previamente abordado, é um artifício poderoso para a gestão desse setor tão imprescindível à população. Então, este capítulo tem a finalidade de tecer conceitos importantes que apoiarão a base de conhecimentos necessários para a realização da presente pesquisa, na seguinte sequência: conceitos sobre padrões de demanda e previsão de demanda, bem como os métodos de previsão (qualitativos e quantitativos) e os diversos modelos de previsão.

2.1. Padrões de Demanda

De acordo com Lustosa et al. (2008), pode-se definir demanda como a composição dos clientes ao consumo de bens e de serviços ofertados por uma organização. A mesma é influenciada por uma ordem de fatores que variam desde as condições macroeconômicas até questões operacionais, tais como produto e preço disponíveis no mercado. Ainda segundo o autor, a demanda pode ser diferenciada em duas situações: a primeira, classificada como pontual, ocorre um pico de demanda de forma concentrada no tempo e depois desaparece ou diminui consideravelmente; já a segunda situação, é a demanda repetitiva que pode ser classificada em dependente ou independente.

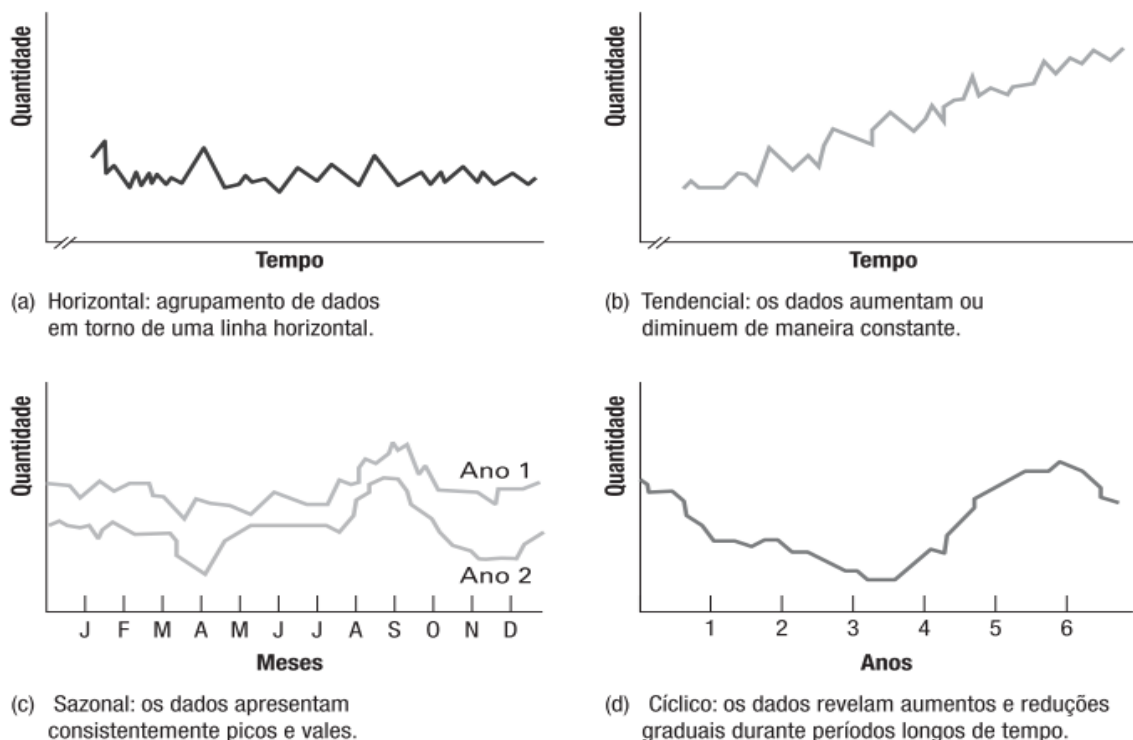
Ballou (2006) aponta que a demanda é considerada dependente quando pode ser associada às exigências especificadas em programas de produção, por exemplo, o número de pneus a serem comprados de um fornecedor é um múltiplo do número de carros que o fabricante irá produzir. Já a demanda independente é gerada a partir de muitos clientes, onde a maioria faz

compras individuais de apenas uma fração do volume total distribuído por uma organização.

Para Krajewski et al. (2009) as tomadas repetidas de demanda para um produto ou serviço em sua ordem de ocorrência consistem em um padrão definido como séries temporais. Há cinco padrões que identificam uma série temporal de demanda, são eles: 1) no Padrão Horizontal, a flutuação de dados ocorre em torno de uma média constante; 2) já no Padrão Tendencial ocorre o aumento ou a redução ordenada na média das séries ao longo do tempo; 3) no Sazonal acontece um padrão de aumentos ou reduções na demanda podendo ser repetido, dependendo da hora, do dia, da semana, do mês ou da estação; 4) enquanto o Padrão Cíclico apresentam aumentos ou reduções constantes menos previsíveis na demanda por períodos mais longos de tempo (anos ou décadas); 5) por fim, no Padrão Aleatório ocorre a variação imprevisível da demanda.

Krajewski et al. (2009), ainda ressaltam que os padrões de demanda se combinam em diversos pontos a fim de definir o padrão de tempo fundamental de demanda para um produto ou serviço, com exceção do padrão aleatório pois este é o resultado de causas eventuais, assim, não podendo ser previsto. A variação aleatória é uma perspectiva da demanda que torna todas as previsões incorretas. A Figura 1 representa os primeiros quatro padrões de uma série temporal de demanda, na qual todas contêm variação aleatória.

Figura 1 – Padrões de demanda



Fonte: Krajewski et al. (2009)

Para poder realizar uma previsão de demanda adequada é necessário possuir e analisar informações a respeito dos padrões de demanda (MARTINS; LAUGENI, 2005). A seguir será feito o aprofundamento teórico acerca da previsão de demanda, suas abordagens, modelos e particularidades.

2.2. Previsão de Demanda

Diariamente as organizações necessitam tomar decisões, essas devem basear-se em oportunidades de mercado, fatores contextuais e otimização de recursos financeiros, humanos, tecnológicos e produtivos. A previsão de demanda é fundamental no desenvolvimento de ações estratégicas, pois fornece informações com alto grau de relevância para o planejamento e controle de todas as áreas da organização, entre as quais logística, marketing, produção ou finanças (MAKRIDAKIS et al, 1998; BALLOU, 2006).

De acordo com Corrêa e Corrêa (2007), previsões são estimativas de como será o comportamento do mercado demandante no futuro. Corroborando, Martins e Laugeni (2005), definem previsão como sendo um processo metodológico que visa determinar dados futuros baseados em modelos estatísticos, matemáticos ou econométricos, ou também em modelos subjetivos apoiados em uma metodologia de trabalho clara e previamente definida.

Segundo Kotler (1998), a previsão de demanda pode variar em nível de produto (item, classe ou linha do produto), em nível de espaço (consumidor e região de consumo) e em nível de tempo (a curto, médio e longo prazos). Klassen e Flores (2001), apontam que a previsão de demanda é um processo cujo fator determinante é o tempo, ou seja, através dos métodos de previsão são viabilizadas previsões pontuais ou intervalos de previsão para um instante de tempo definido.

Com o avanço da tecnologia e dos pacotes computacionais, flexibilizou-se a utilização das previsões e tornou-a mais barata. Todavia, esses fatores juntos com os métodos não são suficientes para assegurar bons resultados para uma previsão. O claro entendimento dos princípios e do processo de previsão, além da experiência e do conhecimento de mercado do planejador são fundamentais para assertividade da mesma (FERNANDES; GODINHO, 2010).

Conforme Stevenson (2007) e Tubino (2007) um modelo de previsão de demanda pode ser representado em cinco etapas: Primeiramente, define-se e identifica o objetivo do modelo; ao qual servirá de base para a segunda etapa, a coleta e análise dos dados; em seguida, selecionam-se os métodos de previsão e estima-se os parâmetros; na sequência elaboram-se a previsão de demanda; por fim, como forma de controle, a previsão é monitorada, interpretada

e atualizada em critérios baseados na análise dos erros de previsão.

Nesse contexto, Peinado e Graeml (2007) afirmam que sempre haverá um erro de previsão, contudo, é essencial que esse erro seja medido, explicitado e avaliado. Tubino (2007) complementa afirmando que o valor previsto sempre será uma aproximação do valor real e que a avaliação do erro de previsão servirá como base para a tomada de decisão e escolha do método pelo planejador.

Em complemento, para que os resultados das previsões sejam condizentes com a realidade, é necessário fazer a escolha de um método de previsão adequado. De acordo com Fernandes e Godinho (2010) para escolher um método de previsão necessita-se de um maior conhecimento sobre cada método e do estudo do comportamento dos dados. Na seção seguinte serão explicitados os métodos de previsão de demanda e suas principais abordagens.

2.3. Métodos de Previsão de Demanda

A finalidade do profissional especialista em previsão é desenvolver uma previsão útil com os recursos e informações disponíveis, adequando o método aos diferentes padrões de demanda. Os métodos de previsão de demanda são caracterizados em dois tipos gerais: (a) métodos qualitativos, cuja base são fatores subjetivos ou de julgamento e (b) métodos quantitativos, baseados em séries históricas projetadas para o futuro segundo algum modelo (CORRÊA; CORRÊA, 2007; KRAJEWSKI et al., 2009).

Corroborando, Zhang et al. (1998) classificam mais um método de previsão de demanda: os métodos híbridos, estes são formados de modo adaptativo através da utilização de Redes Neurais Artificiais (RNAs) junto com estruturas lineares e não lineares de séries temporais. Para Ballou (2006), cada um dos métodos possuem diferentes pontos em termos de acurácia referente às previsões de curto a longo prazo, nível de sofisticação quantitativo utilizado e base lógica (dados históricos, opinião de especialistas ou pesquisas) cuja previsão é derivada.

2.3.1. Métodos Qualitativos

Para Montgomery et al. (2008), os métodos qualitativos baseiam-se em informações de natureza subjetiva e na experiência de especialistas. Tais técnicas são utilizadas em situações nas quais há pouco ou nenhum dado histórico disponível para embasar a previsão. Como por exemplo, a introdução de um novo produto, para qual não existe um histórico de dados relevantes, a empresa pode utilizar a opinião especializada da equipe de vendas e marketing a

fim de estimar subjetivamente as vendas do produto. Corroborando, Tubino (2007) aponta que as técnicas qualitativas por serem mais rápidas de se preparar são utilizadas quando não se dispõe de tempo para coleta e análise de dados da demanda passada. A seguir, serão descritos brevemente alguns dos principais modelos qualitativos de previsão de demanda.

O Método Delphi é um processo interativo que envolve a obtenção do consenso de um grupo de especialistas, consiste basicamente em duas etapas, na primeira etapa os participantes emitem sua opinião individual a respeito de um problema formulado, as informações são coletadas e analisadas por um mediador, na etapa seguinte busca-se o consenso das opiniões em reuniões envolvendo todos os participantes. Outro modelo muito utilizado é a Pesquisa de Mercado que consiste na criação e teste de hipóteses através de dados coletados diretamente dos possíveis clientes ou consumidores para determinar o interesse acerca de um produto ou serviço, nível de satisfação, participação no mercado e força da marca. Já na Analogia Histórica busca-se identificar produtos similares dos quais já se tem dados para, por analogia, estimar com maior precisão, essa técnica é muito utilizada para prever a demanda de novos produtos. Por último, a Simulação de Cenários procura estimar o comportamento dos dados por meio da construção de cenários futuros, estes são classificados como otimista, mais provável e pessimista, o processo de decisão ocorre após a análise subjetiva das probabilidades de cada cenário (CORRÊA; CORRÊA, 2007; LUSTOSA et al., 2008; MOREIRA, 2009).

2.3.2. Métodos Quantitativos

Os métodos quantitativos consistem em analisar através de modelos matemáticos séries de dados históricos com o intuito de projetar a demanda futura. Esses métodos podem ser subdivididos em métodos de séries temporais e métodos causais. Os métodos de séries temporais compreendem análise matemática de dados passados a fim de descrever o comportamento da demanda em função do tempo. Métodos causais são baseados em fazer correlações de dados passados junto com variáveis, de modo a se determinar padrões que tenham alguma relação com a demanda (TUBINO, 2007).

Complementando, Makridakis et al. (1998) apontam que os métodos quantitativos devem ser aplicados nas seguintes condições: 1) Deve haver informações históricas disponíveis; 2) Essas informações devem ser quantificadas em dados numéricos; 3) Podem ser presumidos que alguns aspectos do padrão da demanda anterior irão continuar no futuro.

2.3.2.1. Métodos de Séries Temporais

Moreira (2009) define uma série temporal como uma sequência de observações ordenadas ao longo do tempo t (horas, dias, semanas, meses etc.). Nelson (1975) descreve que tais observações são realizadas em intervalos de tempo discretos e equidistantes, podendo ser representada das seguintes formas: $\{Z_t, t = 1, 2, \dots, n\}$ ou $\{Z_1, Z_2, Z_3, \dots, Z_{n-1}, Z_n\}$. Quanto maior o número de dados históricos disponíveis, melhor será a efetividade da série em relação ao método (GUERRINI et al., 2014).

A previsão baseada em séries temporais segue o princípio de que os fatores que influenciarão o futuro são os mesmos que influenciaram o passado. Dessa forma, os métodos baseados em séries temporais, de início, requerem que seja reconhecido o padrão de comportamento da série temporal, de modo a definir os modelos de previsão a serem utilizados. A identificação dos padrões pode ser feita e analisada plotando os dados da série temporal em um gráfico de dispersão (FERNANDES; GODINHO, 2010).

De acordo com Bruni (2007), uma série temporal pode ser decomposta em quatro componentes: tendência (T_t), variações cíclicas (C_t), variações sazonais (S_t) e variações irregulares ou aleatórias (I_t). Para realizar a análise das séries temporais deve-se compreender a decomposição dos seus componentes e a análise individual de cada um deles. Em seguida, os componentes são combinados com o intuito de se observar o efeito conjunto. Nesse contexto, como pode ser verificado nas Equações 1 e 2, são empregadas duas formas na decomposição das séries temporais: a forma aditiva atribui que a série temporal é uma soma dos quatro componentes, já a forma multiplicativa considera que a série temporal é a multiplicação dos seus componentes.

$$Z_t = T_t + C_t + S_t + I_t \quad (1)$$

$$Z_t = T_t * C_t * S_t * I_t \quad (2)$$

Pindyck e Rubinfeld (2004) retratam que os modelos de previsões de séries temporais são classificados em dois tipos: modelos determinísticos e modelos estocásticos. Para Pellegrini e Fogliatto (2001), os modelos determinísticos apresentam estimativas exatas, não fazendo o uso de variáveis aleatórias em sua elaboração, já os estocásticos são caracterizados por meio de um conjunto de variáveis aleatórias que representam a evolução de algum fenômeno de interesse. Os modelos estocásticos são válidos quando aplicados em séries estacionárias, isso

porque o conceito é descrito quando a média e a variância mantêm-se constantes ao longo do tempo e a covariância entre os valores da série dependem apenas da distância que os separa no decorrer do tempo (HILL et al., 2003).

2.3.2.3. Métodos Causais

Os modelos causais buscam estabelecer regras para compreender a relação existente entre a rede de variáveis e o impacto que uma variável possui sobre a outra (SLACK et al., 2009). Corroborando, Lustosa et al. (2008) descreve que a partir da identificação da existência de correlação, deve-se construir um modelo de regressão a fim de prever os valores da variável dependente em função das variáveis independentes. Os métodos causais possuem as ferramentas de previsão mais sofisticadas, são úteis ao prever pontos de inflexão na demanda e para realizar previsões de longo alcance (KRAJEWSKI et al., 2009).

Segundo Guerrini et al. (2014), os métodos causais são qualificados como análise de regressão e os métodos econométricos. A análise de regressão tem o intuito de determinar a previsão do comportamento futuro de um fator através do relacionamento algébrico desse comportamento com outros fatores causais, tais como fatores de natureza econômica, tecnológica ou sociopolítica, que possuam influência significativa no comportamento do primeiro fator. Enquanto os modelos econométricos são determinados tendo como base um sistema de Equações de regressão independentes, que retratam uma extensão da autorregressão para casos em que ocorrem fortes interdependências entre os fatores causais determinados. Deste modo, a previsão final é a união das previsões dos fatores que compõem a expressão, normalmente exponencial, tendo como exemplo a equação $P = A^\alpha \cdot B^\beta \cdot C^\delta$ onde cada um dos fatores A, B, e C, elevados a termos aleatórios, explicam parte do valor da previsão.

2.3.3. Métodos Híbridos

Os modelos tradicionais de previsão de demanda pressupõem que a série temporal é gerada a partir de um processo linear, entretanto, essa muitas vezes apresenta variabilidade temporal e espacial, tendo em vista que as observações no cotidiano exibem padrões de não linearidade. As RNAs possuem recursos poderosos para a classificação e o reconhecimento de padrões, sendo capazes de aprender e generalizar com sua experiência (ZHANG et al., 1998).

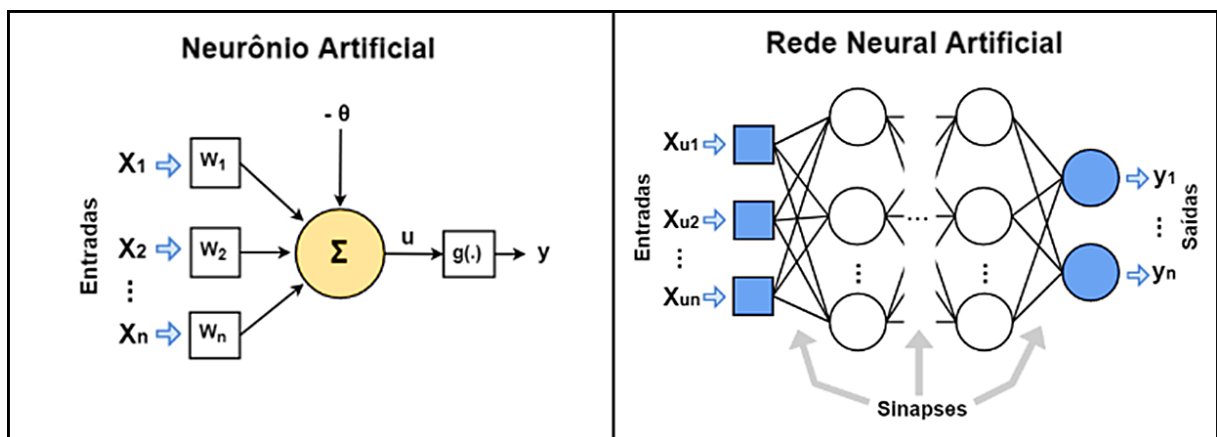
Apesar de todos os recursos vantajosos o modelo de redes neurais artificiais (ANN) sozinho não apresenta bons resultados quando os dados apresentam padrões não lineares.

Portanto, para uma utilização prática os métodos híbridos são vantajosos, pois apresentam recursos de modelagem linear e não linear (ZHANG, 2003; ALADAG et al., 2009).

2.3.2.1. Redes Neurais Artificiais

As redes neurais artificiais são modelos computacionais com capacidade para adquirir e manter conhecimento baseado em informações (SILVA et al., 2016). O seu princípio de funcionamento é inspirado no sistema nervoso dos seres vivos, sendo composto por um conjunto de unidades de processamento (neurônios artificiais) que são interligados por conexões sinápticas associadas a vetores/matrizes de pesos (HAYKIN, 2008). A Figura 2 é a representação genérica de um neurônio artificial e de um conjunto de neurônios trabalhando juntos, formando uma rede neural.

Figura 2 – Funcionamento genérico do neurônio artificial e da rede neural



Fonte: Adaptado de Silva et al. (2016)

As redes neurais são organizadas em camadas que permitem relacionamentos não lineares complexos entre a variável de resposta e seus preditores. A camada inferior é formada pelos preditores (ou entradas), a camada superior é formada pelas previsões (ou saídas) e a depender da arquitetura da rede pode haver camadas intermediárias contendo neurônios ocultos (HYNDMAN; ATHANASOPOULOS, 2018).

A arquitetura de uma rede neural é definida por meio dos seguintes parâmetros: pela determinação da topologia da rede, podendo ter conexões do tipo *feed-forward* (acíclica) ou *feedback* (cíclica), também denominada como recorrente; através da escolha da função de ativação, que podem ser linear, degrau, logística, tangente hiperbólica, gaussiana, entre outras; pelo tipo de treinamento, definidos como supervisionado ou não-supervisionado; e pela

estimativa dos demais parâmetros necessários para cada técnica (BRAGA et al., 2007).

As RNAs podem ser aplicadas em diversas áreas do conhecimento, dentre as quais se enquadra a previsão de séries temporais, pois possuem habilidades como adaptação por experiência, capacidade de aprendizado e generalização, organização de dados, reconhecimento de padrões, tolerância a falhas, armazenamento distribuído e facilidade de prototipagem (SILVA et al., 2016).

2.4. Modelos de Previsão de Demanda

Adiante serão descritos os modelos de previsão de demanda pertencentes aos métodos quantitativos e híbridos utilizados neste trabalho.

2.4.1. Média Móvel Simples

O modelo da média móvel simples é constantemente utilizado nas organizações por ser bastante simples e necessitar de poucos dados históricos. O mesmo é adequado para previsões de curto prazo em que as variáveis de tendência e sazonalidade são inexistentes ou possam ser descartadas (MAKRIDAKIS et al., 1998).

O modelo consiste na média aritmética de n períodos de tempo a fim de gerar a previsão para o próximo período. A medida que um novo valor é adicionado à série, o valor da demanda mais antigo é substituído pelo valor da demanda mais recente, e a média é recalculada. Desse modo, o modelo utiliza os dados das n demandas mais recentes no instante t conforme é determinado na Equação 3 (LUSTOSA et al., 2008; KRAJEWSKI et al., 2009).

$$F_{t+1} = \frac{D_t + D_{t+1} + \dots + D_{t-n+1}}{n} \quad (3)$$

Onde:

F_{t+1} = previsão para o período $t + 1$;

D_t = demanda real no período t ;

n = número total de períodos da média.

2.4.2. Média Móvel Ponderada

De acordo com Moreira (2009), a média móvel ponderada é uma variação da média

móvel simples em que se atribui diferentes pesos a partir do grau de relevância dos períodos da previsão, normalmente com pesos maiores para os períodos mais recentes. A soma dos pesos deve ser igual a 1. Peinado e Graeml (2007), ressaltam que quando são atribuídos maiores pesos aos últimos períodos, resulta em uma maior influência na previsão de demanda. Conforme a Equação 4, a média é obtida multiplicando o peso de cada período pelo valor da demanda deste período, e somando os produtos.

$$P_j = (D_1 * PE_1) + (D_2 * PE_2) + (D_3 * PE_3) + \dots + (D_n * PE_n) \quad (4)$$

$$\text{Sendo: } PE_1 + PE_2 + PE_3 + \dots + PE_n = 1$$

Onde:

P_j = previsão para o período j ;

PE_i = peso atribuído ao período i ;

D_i = demanda do período i .

2.4.3. Método Naive

No método Naive simplesmente é definido que o valor da previsão é igual ao valor da última observação (CHEN; BLOOMFIELD; CUBBAGE, 2008). Na Equação 5 o modelo é definido matematicamente.

$$F_{t+h} = Y_t \quad (5)$$

Onde:

F_{t+h} = previsão para o período $t + h$;

t = observação do período;

h = valores futuros ($h = 1, 2, \dots$);

Y_t = demanda do período t .

2.4.4. Método Naive Sazonal

O método naive sazonal é semelhante ao modelo anterior, porém é utilizado para dados altamente sazonais. Consiste dos valores futuros serem iguais aos das últimas observações do período sazonal, por exemplo, para uma série com sazonalidade de 12 meses, a previsão para todos os valores de fevereiro futuro é igual ao último valor de fevereiro observado e assim

sucessivamente (HYNDMAN; ATHANASOPOULOS, 2018). A Equação 6 demonstra o modelo como:

$$F_{t+h} = Y_{t+h-m(k+1)} \quad (6)$$

Onde:

m = período sazonal, por exemplo ($m = 12$ meses);

k = é o inteiro do número de anos antes do período $t + h$, dado por: $k = (h - 1)/m$.

2.4.5. Regressão Linear Simples

De acordo com Montgomery (2008), a regressão linear é uma ferramenta estatística que tem o objetivo de modelar e investigar a relação entre diferentes variáveis. Krajewski et al. (2009) relatam que neste modelo existe uma relação linear entre uma variável dependente e uma independente. Deste modo, a relação entre as duas variáveis é uma linha reta conforme a Equação 7.

$$y = a + bx \quad (7)$$

Onde:

y = variável dependente;

x = variável independente;

a = intersecção da linha no eixo y ;

b = Inclinação da linha.

Os valores de a e b são calculados por meio do método dos mínimos quadrados, que consiste em minimizar a somatória dos quadrados dos desvios, sendo estes as diferenças entre o valor real e o valor estimado. As expressões são definidas por meio das Equações 8 e 9 (GUERRINE et al., 2014).

$$b = \frac{n(\sum xy) - (\sum x)(\sum y)}{n(\sum x^2) - (\sum x)^2} \quad (8)$$

$$a = \frac{\sum y - b(\sum x)}{n} \quad (9)$$

Para medir o relacionamento entre as duas variáveis, deve ser utilizados os coeficientes de correlação (r) e de determinação (r^2). O coeficiente de correlação avalia a direção e força da relação entre as duas variáveis. O valor de r pode variar entre -1 a 1, sendo que quanto mais próximo de 1 indica que a correlação positiva é mais forte entre as variáveis, todavia, quando mais os valores se aproximarem de -1 indica que a correlação negativa é mais forte. Já quando os valores estão próximos de 0, a correção não existe ou é muito baixa. A Equação 10 representa a expressão para se calcular o valor de r (FERNANDES; GODINHO, 2010).

$$r = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n(\sum x^2) - (\sum x)^2][n(\sum y^2) - (\sum y)^2]}} \quad (10)$$

O coeficiente de determinação (r^2) é quadrado do coeficiente de correlação r e mede o grau de qualidade que a linha de regressão se adequa aos dados. O r^2 varia entre 0 e 1, se o seu valor for maior ou igual a 0,85 significa que é uma boa previsão (SIPPER; BULFIN, 1997).

2.4.6. Suavização Exponencial Simples

O modelo de suavização exponencial é estruturado na ponderação dos dados de uma série temporal, onde para cada observação é atribuído um peso que decresce no tempo em progressão geométrica ou de forma exponencial. Conforme demonstra a Equação 11, cada nova previsão é obtida conforme o erro cometido pela previsão anterior, que utiliza um coeficiente de ponderação para corrigir a diferença entre a previsão e o realizado (TUBINO, 2007).

$$M_t = M_{t-1} + \alpha(D_{t-1} - M_{t-1}) \quad (11)$$

Onde:

M_t = previsão para o período t ;

M_{t-1} = previsão para o período $t - 1$;

α = coeficiente de ponderação;

D_{t-1} = demanda do período $t - 1$.

O valor do coeficiente de ponderação varia entre zero e um. Quanto maior o seu valor, o modelo reagirá com maior prontidão as alterações da demanda. Já se o valor de α for muito pequeno, indica que a última observação um ponto fora da curva e que a demanda deve voltar ao padrão anterior (FERNANDES; GODINHO, 2010). Krajewski et al. (2009) ressaltam que a

escolha do coeficiente de ponderação é análoga e que na prática diversos valores de α são testados, sendo escolhido o que gera as melhores previsões.

2.4.7. Modelo de Holt-Winters

O modelo de Holt possibilita a previsão de demandas que apresentam tendência linear, sendo tratado como uma extensão do modelo de suavização simples. O modelo utiliza duas constantes de suavização, estas são denominadas como α para o nível e β para a tendência, ambas podendo apresentar variações entre 0 e 1 (HYNDMAN et al., 2008; HYNDMAN; ATHANASOPOULOS, 2018). Neste contexto, Samohyl et al. (2008) descrevem as Equações 12, 13 e 14 para representar o modelo.

$$F_{t+m} = L_t + T_t \quad (12)$$

Sendo que:

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} - T_t) \quad (13)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (14)$$

Onde:

F_{t+m} = previsão para o período $t + m$;

m = horizonte de previsão;

L_t = estimativa do nível série temporal;

T_t = estimativa do nível da série no período t ;

T_{t-1} = estimativa da inclinação da série no período $t-1$;

α = coeficiente de ponderação da média;

β = coeficiente de ponderação da tendência;

Y_t = demanda do período t .

Winters (1960), adaptou o modelo desenvolvido por Holt adicionando uma componente de sazonalidade aos dados da série temporal. Deste modo, o modelo de Holt-Winters é composto por três constantes de suavização: α , β e γ , relacionadas ao nível, tendência e sazonalidade respectivamente, todas variando em torno de 0 e 1 (MAKRIDAKIS et al., 1998). Veríssimo et al. (2012), retratam que existem duas versões desse modelo: uma para a sazonalidade aditiva e a outra para a multiplicativa.

O modelo aditivo é utilizado quando as amplitudes das variações sazonais são praticamente constantes ao longo da série temporal (HYNDMAN; ATHANASOPOULOS, 2018). Já o modelo multiplicativo é indicado quando a amplitude da variação da sazonalidade cresce com relação ao avanço no nível médio da série (KOEHLER et al., 2001). O Quadro 1 descreve as Equações voltadas aos dois modelos.

Quadro 1 - Equações dos modelos de Holt-Winters

	Holt-Winters Aditivo	Holt-Winters Multiplicativo
Nível	$L_t = \alpha(Z_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1})$ (15)	$L_t = \alpha \frac{Z_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + T_{t-1})$ (19)
Tendência	$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$ (16)	$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$ (20)
Sazonalidade	$S_t = \gamma(Z_t - L_t) + (1 - \gamma)S_{t-1}$ (17)	$S_t = \gamma \frac{Z_t}{L_t} + (1 - \gamma)S_{t-1}$ (21)
Previsão	$\hat{z}_{t+k} = L_t + kT_t + S_{t-s+k}$ (18)	$\hat{z}_{t+k} = (L_t + kT_t)S_{t-s+k}$ (22)

Fonte: Adaptado de Pellegrini e Fogliatto (2001)

Onde:

L_t = componente de nível;

T_t = componente de tendência;

S_t = componente de sazonalidade;

Z_t = valor observado;

s = período sazonal;

h = horizonte de previsão;

$k = 1, 2, \dots, h$;

\hat{z}_{t-k} = previsão para o período k ;

α = constante de suavização da componente de nível;

β = constante de suavização da componente de tendência;

γ = constante de suavização da componente de sazonalidade.

Em ambos os modelos, as constantes de suavização são estimadas de modo a minimizar o erro da previsão, quanto mais próximas do valor um, maior será o peso para as informações mais recentes. Para tais estimativas ferramentas como o Solver do *software Microsoft Excel* são

constantemente utilizadas. Para que se possa ser feita a estimativa inicial dos componentes de demanda L_0 , T_0 e S_0 devem existir registros de pelo menos um ciclo sazonal completo, desta forma possibilitando observar os pesos sazonais de cada período (PELLEGRINI; FOGLIATTO, 2001; CHOPRA; MEINDL, 2016).

2.4.8. Modelo Box-Jenkins

De acordo com Wanke (2011), o modelo de Box-Jenkins, também conhecido como modelo Auto Regressivo Integrado de Média Móvel (ARIMA), foi desenvolvido na década de 70 por George Box e Gwilym Jenkins, o mesmo é o resultado da combinação de três componentes (filtros), são elas: autoregressão (AR), diferenciação (I) e média móvel (MA).

Utiliza-se a notação ARIMA (p, d, q), sendo: (p) a ordem máxima dos parâmetros de autorregressão; (d) o número de diferenciações para tornar a série estacionária; e (q) a ordem máxima de médias móveis. Devido a sua generalidade o modelo pode ser aplicado a qualquer série temporal, sendo estacionária ou não, com ou sem elementos de tendência e sazonalidade (BOX et al., 2016).

No modelo AR (p) a previsão é expressa como uma combinação linear finita de valores prévios junto com um ruído aleatório. A sua representação matemática é dada pela Equação 23, logo após, o coeficiente autoregressivo de ordem “p” é expresso utilizando o operador B, conforme a Equação 24, deste modo, simplificando representação do modelo na Equação 25 (PELLEGRINI; FOLGIATTO, 2001).

$$\hat{Z}_t = \phi_1 \hat{Z}_{t-1} + \phi_2 \hat{Z}_{t-2} + \dots + \phi_p \hat{Z}_{t-p} + a_t \quad (23)$$

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (24)$$

$$\phi(B) \hat{Z}_t = a_t \quad (25)$$

Onde:

\hat{Z}_t = série temporal notada no momento t ;

$\phi_1, \phi_2, \dots, \phi_p$ = coeficientes de autoregressivos;

a_t = ruído aleatório.

O modelo MA (q) é o resultado da combinação dos ruídos brancos do período atual com aqueles que ocorreram anteriormente (WERNER; RIBEIRO, 2003). Assim, de acordo com Lee e Ko (2011), o modelo é representado pela Equação 26, como \hat{Z}_t é obtido aplicando os pesos $1, -\theta_1, -\theta_2, \dots, -\theta_q$ o coeficiente de média móvel de ordem “q” pode ser expresso utilizando o operador B, conforme a Equação 27, resumindo a representação matemática para a Equação 28.

$$\hat{Z}_t = a_t - \theta_1 a_t - \theta_2 a_t - \dots - \theta_q a_{t-q} \quad (26)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (27)$$

$$\hat{Z}_t = \theta(B) a_t \quad (28)$$

Onde:

\hat{Z}_t = série temporal notada no momento t ;

$\theta_1, \theta_2, \dots, \theta_q$ = coeficientes de média móvel;

a_t = ruído aleatório.

Para alguns casos, pode-se haver a necessidade de utilizar um grande número de parâmetros em modelos AR ou MA. Sendo a solução adequada unir os componentes autoregressivos com os de médias móveis, resultando, no modelo autorregressivo de média móveis (ARMA). O modelo pode ser expresso pela Equação 29, como $\phi(B)$ e $\theta(B)$ são os operadores de AR e MA, é possível representar a expressão de forma compacta na Equação 30 (MORETTIN; TOLOI, 2006).

$$\hat{Z}_t = \phi_1 \hat{Z}_{t-1} + \phi_2 \hat{Z}_{t-2} + \dots + \phi_p \hat{Z}_{t-p} + a_t - \theta_1 a_t - \theta_2 a_t - \dots - \theta_q a_{t-q} \quad (29)$$

$$\phi(B) \hat{Z}_t = \theta(B) a_t \quad (30)$$

Segundo Gujarati e Porter (2011), os modelos AR, MA e ARMA são utilizados apenas em séries estacionárias. Entretanto, quando uma série não apresenta um comportamento estacionário, ela é transformada em uma série estacionária por meio da diferenciação (I). Deste modo, resultando no modelo ARIMA (WALTER et al., 2013; MARTIN et al., 2016).

Morettin e Toloi (2006), ressaltam que a transformação mais comum de uma série não estacionária é feita tomando diferenças sucessivas da série original até obter uma série

estacionária. A primeira diferença é definida pela Equação 31 e segunda dada pela Equação 32.

$$\Delta Z_t = Z_t - Z_{t-1} \quad (31)$$

$$\Delta^2 Z_t = \Delta[\Delta Z_t] = \Delta[Z_t - Z_{t-1}] = Z_t - 2Z_{t-1} - Z_{t-2} \quad (32)$$

Ainda segundo os autores citados, normalmente bastará tomar uma ou duas diferenças para que a série se torne estacionária. Depois incluir a ordem de integração, que é o número “d” de diferenças necessárias para tornar a série estacionária, é possível utilizar o modelo ARIMA (p, d, q), dado pela Equação 33.

$$W_t = \phi_1 w_{t-1} + \dots + \phi_p w_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (33)$$

$$\text{Sendo: } W_t = \Delta^d Z_t$$

O modelo ARIMA (p, d, q) pode ser reescrito assumindo que W_t seja estacionária, pode-se representar um modelo ARMA (p, q), expresso pela Equação 28. Se W_t for uma diferença de Z_{t1} , logo Z_t é uma integral de W_t , portanto é definido que Z_t segue um modelo autoregressivo integrado de médias móveis, conforme a Equação 29 (MORETTIN; TOLOI, 2006).

$$\phi(B)W_t = \theta(B)a_t \quad (34)$$

$$\phi(B)\Delta^d Z_t = \theta(B)a_t \quad (35)$$

Para que seja possível a aplicação do modelo de Box-Jenkins, deve-se seguir as etapas a seguir: inicialmente dispor de no mínimo 50 tomadas da série temporal; posteriormente, verificar se a série é estacionária ou não; além disso, analisar se o modelo apresenta autocorrelações (ACF) e autocorrelações parciais (PACF), essa etapa é a mais crítica porque pode-se encontrar diferentes modelos para a mesma série de dados; em seguida, deve-se estimar os parâmetros do modelo; e para finalizar, analisar se o modelo é adequado ou não por meio da análise de resíduos (PELLEGRINI; FOLGIATTO, 2001; GUJARATI; PORTER, 2011; BOX et al., 2016).

2.4.9. Método de Croston

O método de Croston foi criado com o intuito de solucionar algumas falhas que os métodos de suavização exponencial apresentavam ao prever demandas intermitentes (séries com alta incidência de ocorrências nulas), para isso, o modelo utiliza de estimadores independentes para o tamanho e frequência de demanda (CROSTON, 1972).

Segundo Baziewicz (2019), o método consiste em analisar se no período anterior a demanda D_t foi nula ou não nula, e estimar para cada período a demanda esperada das ocorrências não nulas S_t e o intervalo entre demandas não nulas I_t . A previsão M_t é a razão entre as estimativas, todavia, o método considera no cálculo apenas o número de períodos em que a demanda não for nula, conforme é demonstrado pelas seguintes Equações:

Se $D_t = 0$

$$S_{t+1} = S_t \quad (36)$$

$$I_{t+1} = I_t \quad (37)$$

$$M_{t+1} = M_t \quad (38)$$

$$q = q + 1 \quad (39)$$

Se $D_t \neq 0$

$$S_{t+1} = \alpha * D_t + (1 - \alpha) * S_t \quad (40)$$

$$I_{t+1} = \beta * q + (1 + \beta) * I_t \quad (41)$$

$$M_{t+1} = \frac{S_{t+1}}{I_{t+1}} \quad (42)$$

$$q = 1 \quad (43)$$

Onde:

D_t = demanda real ocorrida no período t ;

M_t = previsão de demanda para o período t ;

S_t = estimativa da demanda média para demanda não nula no período t ;

I_t = estimativa do intervalo médio entre demandas não nulas no período t ;

α = constante de suavização exponencial para demandas;

β = constante de suavização exponencial para intervalo entre demandas.

Os parâmetros para se aplicar o método de Croston são: a estacionariedade da série temporal; a demanda e os intervalos entre demandas devem possuir média e variância constantes e serem mutuamente independentes; o processo de geração de demandas deve seguir

uma distribuição de Bernoulli; o intervalo entre demandas deve seguir uma distribuição geométrica; e o tamanho das demandas deve seguir uma distribuição normal (BOYLAN; SYNTETOS, 2008).

2.4.10. Método Splines

Splines são funções polinomiais por partes que possuem boas propriedades de aproximação, convergência e estabilidade. Essas funções *splines* são um método de interpolação que estima valores utilizando uma função que minimiza a curvatura da superfície, resultando em superfície suave que passa precisamente pelos pontos de entrada (MARCUSO et al., 2012).

Uma *spline* cúbica é definida quando a função g é um polinômio cúbico e a primeira e a segunda derivada são contínuas em cada t_i , que devem estar contidos dentro de um intervalo $[a, b]$, satisfazendo a condição $a < t_1 < t_2 < \dots < t_n < b$ e sendo t_1, t_2, \dots, t_n números reais (ALVES et al., 2005).

Para uma previsão com tendência não linear pode-se ajustar uma tendência linear por partes que se curvam em algum ponto no tempo (nó). O método de Splines utiliza *splines* de suavização cúbica, é equivalente a um modelo ARIMA (0, 2, 2), mas com um espaço de parâmetro restrito. Nele são utilizados mais nós, os coeficientes são restritos para evitar o sobreajuste e a curva é linear em ambas as extremidades. Dessa forma, fornecem previsões melhores sem comprometer o ajuste (HYNDMAN et al., 2005; HYNDMAN, R. J.; ATHANASOPOULOS, 2018).

2.4.11. Autorregressão da Rede Neural

As redes neurais são aplicadas para previsões não lineares complexas. Assim, no modelo de autorregressão da rede neural (NNAR) os valores defasados dos dados da série temporal são utilizados como entradas para a rede, do mesmo modo que são utilizados em um modelo de autorregressão linear (DEMIR; KIRIŞCI, 2021).

De acordo com Hyndman e Athanasopoulos (2018), o modelo NNAR (p, k) é uma rede neural do tipo *feed-forward* tendo uma camada oculta, onde p são as entradas defasadas e k é o número de nós (conjunto de neurônios) na camada oculta. Por exemplo, um modelo NNAR (9, 5) é uma rede neural que usa as últimas nove observações $(y_{t-1}, y_{t-2}, \dots, y_{t-9})$ como entradas para prever a saída com cinco neurônios na camada oculta. Para dados sazonais, é utilizado o

modelo NNAR $(p, P, k)_m$ que possui entradas $(y_{t-1}, y_{t-2}, \dots, y_{t-p}, y_{t-m}, y_{t-2m}, \dots, y_{t-pm})$ e k neurônios na camada oculta.

Numa rede *feed-forward* cada camada de nós recebe entradas das camadas anteriores e as saídas de uma camada são entradas para a próxima. As entradas para cada nó são ajustadas utilizando uma combinação linear ponderada, conforme é demonstrado na Equação 44, já a sua saída é modificada antes de ser produzida por uma função não linear, descrita como função de ativação e definida pela Equação 45 (HYNDMAN; ATHANASOPOULOS, 2018).

$$z_j = b_j + \sum_{eu=1}^4 C_{eu,j} * x_{eu} \quad (44)$$

$$s(z) = \frac{1}{1+e^{-z}} \quad (45)$$

Onde:

z_j = saídas de cada nó;

b_j = constante de polarização ou viés;

C_{eu} = valores das entradas;

x_{eu} = pesos sinápticos;

$s(z)$ = função de ativação.

2.5. Medidas de Acurácia

De acordo com Miranda et al. (2011), quanto maior for o erro de previsão, maior será o desafio para se realizar um planejamento eficiente, desta forma, gerando perdas financeiras, falta de confiabilidade e redução da competitividade. Para selecionar quais os melhores modelos de previsão é necessário estabelecer quais medidas de acurácia utilizar, visto que essas fornecem parâmetros que auxiliarão na quantificação e na qualidade da previsão (MANCUSO; WERNER, 2013).

Para Ballou (2006), o erro de previsão é definido como a diferença, ou desvio, entre a demanda real e a que foi prevista, o mesmo é expresso matematicamente pela Equação 36.

$$e_t = Z_t - \hat{Z}_t \quad (46)$$

Onde:

e_t = erro de previsão para o período t ;

Z_t = demanda real para o período t ;

\hat{Z}_t = previsão para o período t .

Segundo Pellegrini (2001) e Hyndman et al. (2008), existem diferentes critérios para se medir os erros de previsão, os mais utilizados são: o erro médio (ME); a raiz do erro quadrático médio (RMSE); a média absoluta dos erros (MAE), a média absoluta percentual dos erros (MAPE) e o erro médio absoluto em escala (MASE). Ambos, são definidos pelas Equações 42, 37, 38 e 39.

$$ME = \frac{1}{n} \sum_{t=1}^n e_t \quad (47)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (48)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (49)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{z_t} * 100 \right| \quad (50)$$

$$MASE = (|q_t|) \mid q_t = \frac{e_t}{\frac{1}{n-1} \sum_{t=2}^n |y_t - y_{t-1}|} \quad (51)$$

No ME é aplicado a média dos erros. Na RMSE é avaliado a radiciação do quadrado dos erros, nele os desvios maiores acabam tendo um peso maior, ocorrendo o inverso com os desvios menores. O MAE representa a média dos desvios absolutos. O MAPE apresenta o mesmo resultado do MAE porém descrito em termos percentuais. O MASE se propõe a escalonar os erros com base no MAE (HYNDMAN; KOEHLER, 2006; LUSTOSA et al., 2008; CHOPRA; MEINDL, 2016). De tal modo, o modelo que tiver o menor erro associado será considerado o mais adequado para a previsão.

3. PROCEDIMENTOS METODOLÓGICOS

Este capítulo descreve os procedimentos metodológicos utilizados para alcançar o objetivo deste trabalho. Primeiramente, é exposto à caracterização do estudo, em seguida explicita-se sobre os dados utilizados e, por fim, como estes foram tratados através da análise estatística para gerar as previsões de demanda.

3.1. Caracterização do Estudo

Este trabalho enquadra-se como uma pesquisa exploratória porque tem a finalidade de desenvolver conceitos e ideias, proporcionando uma visão geral, de tipo aproximativo, acerca de determinado fato, a formulação de problemas mais precisos ou de hipóteses pesquisáveis para estudos futuros (GIL, 2008).

Com relação à abordagem do problema, a pesquisa caracterizou-se como quantitativa, pois possui o foco na representatividade numérica, com medição objetiva e quantificação dos resultados (ZANELLA, 2013). O método quantitativo utilizado foi o experimento, que tem como base a observação do fenômeno em um ambiente controlado, em que são definidas as variáveis a serem observadas e os sujeitos a serem analisados (DIAS; SILVA, 2009).

Do ponto de vista da natureza, foi utilizada uma pesquisa aplicada, pois tem o objetivo de gerar conhecimentos para aplicação prática e dirigidos à solução de problemas específicos (MARCONI; LAKATOS, 2009). Já do ponto de vista dos procedimentos técnicos, a pesquisa enquadra-se como bibliográfica, pois foi fundamentada na exploração de materiais científicos já publicados. Experimental, pois foi definido um objeto de estudo e foram analisados através de ferramentas quantitativas e simulações o efeito que variáveis produzem no objeto (SILVA; MENEZES, 2005).

3.2. Dados da Pesquisa

Os dados utilizados neste trabalho foram retirados da base de dados aberta da Eletrobras disponibilizados pelo Instituto de Pesquisa Econômica Aplicada – Ipeadata (2021). Os dados são definidos como abertos quando qualquer pessoa pode livremente acessá-los, modificá-los e compartilhá-los para qualquer finalidade, estando sujeito a exigências que visem preservar sua proveniência e sua abertura (PORTAL BRASILEIRO DE DADOS ABERTOS, 2021).

O conjunto de dados é referente ao consumo de energia elétrica (GWh) no Brasil, sob

uma frequência mensal definida de janeiro de 1976 até julho de 2021. O consumo analisado foi proveniente tanto de pessoa física quanto jurídica, responsável por uma unidade consumidora ou por um conjunto de unidades consumidoras reunidas por comunhão de fato, ou de direito, legalmente representada, e que estejam localizadas em áreas contíguas, podendo ser atendidas por meio de um único ponto de entrega e cuja medição seja única.

3.3. Análise e Tratamento dos Dados

A escolha de *softwares* estatísticos é de grande importância para a análise e interpretação dos resultados, principalmente quando se propõe construir uma ferramenta efetiva, de fácil utilização e compreensão. Neste trabalho, os dados foram compilados e organizados em uma planilha do *Microsoft Office Excel 2016*®, em seguida, foram transferidos para o *software R*® 4.1.1 (R Core Team 2021) para fazer o tratamento dos dados, desenvolver os modelos, e, por fim, analisar os resultados obtidos.

O R é uma linguagem e um *software* livre que permite ao usuário um ambiente integrado que manipule e analise dados, realize cálculos e gere gráficos (R DEVELOPMENT CORE TEAM, 2021). O mesmo possui vários pacotes com conjuntos de funções que permitem a realização de diversas análises e testes estatísticos. Hyndman e Athanasopoulos (2018) descrevem que o pacote *Forecast* possui o objetivo de fornecer métodos e ferramentas para exibir e avaliar previsões de séries temporais univariadas, incluindo suavização exponencial através de modelos de espaço de estado e modelagem automática ARIMA.

3.3.1. Estruturação dos Modelos

Foram desenvolvidos oito modelos de previsão de demanda, ambos descritos a seguir: Média Móvel, Método Naive, Método Naive Sazanol, ARIMA de Box-Jenkins, Método Croston, Método Splinesf, Autorregressão da Rede Neural e Autorregressão da Rede Neural com Intervalos de Previsão.

Para aplicar os métodos de previsão é necessário que os dados sejam divididos em dois conjuntos: treinamento e teste. Segundo Silva et. al. (2016), a amostra de dados utilizada para treinamento deve ser composta por aproximadamente 60% até 90% do número de amostras disponíveis, conseqüentemente, o conjunto de teste é composto de 10 % a 40% das amostras restantes.

Por meio desse processo é possível identificar se a generalização dos resultados está

com um erro considerável para antecipar o comportamento da série em situações reais. Para essa pesquisa, separaram-se os dados da seguinte forma: (a) Treinamento, dados definidos entre o intervalo de janeiro de 1976 até dezembro de 2019, totalizando 528 amostras; (b) Teste, dados definidos entre o intervalo de janeiro de 2020 até julho de 2021, totalizando 19 amostras.

3.3.2. Análise Residual

Após o processamento dos dados, foi realizada a análise residual para identificar a adequabilidade de cada modelo desenvolvido. Os resíduos são o que sobra após o ajuste de um modelo e são úteis para verificar se um modelo capturou adequadamente as informações nos dados. Um bom método de previsão produzirá resíduos com as seguintes propriedades: 1) Os resíduos não estão correlacionados, pois, se existir correlação então há informações deixadas nos resíduos que devem ser utilizadas nas previsões; 2) Os resíduos têm média zero, se a média for diferente de zero as previsões são enviesadas; 3) Os resíduos têm variância constante; 4) Os resíduos seguem uma distribuição normal (HYNDMAN; ATHANASOPOULOS, 2018).

Os resíduos têm um importante papel no julgamento de ajustes do modelo, por meio de observações em seus comportamentos através de gráficos, é possível analisar como o modelo pode ser melhorado com a adição de variáveis candidatas. Através da plotagem dos resíduos no tempo é possível analisar o comportamento da variância residual. Já por meio do correlograma, verifica-se se a média dos resíduos é próxima de zero e se existe correlação significativa. O histograma demonstra se os resíduos são normalmente distribuídos (MONTGOMERY; RUNGER, 2009).

3.3.3. Desempenho dos Modelos

O desempenho das previsões realizadas foi comparado utilizando as seguintes medidas de acurácia: o Erro Médio (ME); a Raiz do Erro Quadrático Médio (RMSE); a Média Absoluta dos Erros (MAE), a Média Absoluta Percentual dos Erros (MAPE) e o Erro Médio Absoluto em Escala (MASE). A partir da análise de tais medidas foram definidos os quatro melhores modelos de previsão.

Foram comparados os dados das previsões dos quatro melhores modelos com os dados de teste (reais). Foi utilizado o teste de Shapiro-Wilk para verificar a normalidade dos dados, esse teste verifica a medida do grau de concordância entre os dados e a Hipótese Nula (H_0). Quanto menor for o *p-value*, menor é a relação entre os dados e a hipótese nula (KIM, 2011).

Logo, a regra de decisão adotada no teste é:

- $H_0: p\text{-value} \geq 0,05 \rightarrow$ Os dados seguem distribuição normal;
- $H_1: p\text{-value} < 0,05 \rightarrow$ Os dados não seguem distribuição normal.

Posteriormente, os dados foram submetidos ao teste de Wilcoxon a fim de analisar a diferença entre as duas amostras pareadas. De acordo com Siegel & Castellan (2006), este teste não paramétrico é indicado para verificar se duas amostras independentes são provenientes da mesma população ou de populações idênticas. Para realizar a comparação, este teste analisa pares de variáveis e demonstra duas hipóteses, a Hipótese Nula (H_0) e Hipótese Alternativa (H_1), submetidas aos indicadores de estatística do teste de Wilcoxon e o valor da significância ($p\text{-value}$). Dessa forma, as duas hipóteses são consideradas como:

- $H_0: p\text{-value} \geq 0,05 \rightarrow$ Não existem diferenças significativas entre as variáveis;
- $H_1: p\text{-value} < 0,05 \rightarrow$ Existem diferenças significativas entre as variáveis.

Após a análise dos testes citados, foram calculados o erro percentual e o erro percentual acumulado dos dados reais sobre os dados previstos dos quatro modelos de previsão selecionados, a partir da análise desses parâmetros determinou-se o melhor modelo de previsão.


4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

Neste capítulo serão apresentadas análises e discussões acerca dos resultados obtidos pela aplicação dos métodos de previsão e medidas de acurácia.

4.1. Análise Descritiva da Amostra

De posse dos dados coletados (ver Anexo A), inicialmente foi identificada a regularidade dos mesmos e então foi elaborado o gráfico da série temporal (Figura 3).

Figura 3 – Dados do consumo de energia no Brasil no período de janeiro de 1976 até julho de 2021



Fonte: Autor (2021)

Na Tabela 1 são expostas as principais medidas descritivas obtidas da série, possibilitando uma visão geral do seu comportamento ao longo do tempo. Percebe-se que durante os 45 anos analisados o consumo de energia elétrica aumentou significativamente, causando uma grande variabilidade nos dados, conforme o coeficiente de variação de 46,87%.

Tabela 1 – Medidas descritivas da série temporal


Parâmetros	Média	Mediana	Desvio Padrão	Mínimo	Máximo	1º Quartil	3º Quartil	Coeficiente de Variação
Valores	23,75	23,25	1.089,87	5,53	43,42	15,11	34,13	46,87%

Fonte: Autor (2021)

Em seguida, a série foi decomposta com o intuito de analisar e identificar as suas

componentes. A decomposição foi realizada por meio do modelo aditivo no qual a tendência, a sazonalidade e os resíduos são apresentados na Figura 4.

Figura 4 – Dados decompostos do consumo de energia no Brasil



Fonte: Autor (2021)

Pela análise gráfica da Figura 4, verificou-se que a série de dados é composta por uma tendência de crescimento, ciclos que variam ao longo do tempo e padrões de sazonalidade que se repetem. Hyndman e Athanasopoulos (2018), propõem que não é adequado utilizar os métodos de suavização exponencial para séries temporais muito longas que possuem tendência clara ou padrão sazonal. Portanto, modelos que têm a sua mecânica derivada da suavização exponencial não foram utilizados neste trabalho.

4.2. Análise Comparativa dos Modelos

Após a modelagem e análise das técnicas propostas foi possível comparar os resultados obtidos com o intuito de selecionar o modelo de previsão mais adequado para o caso em estudo. Foram previstos os valores referentes aos 19 dados de teste (janeiro de 2020 até julho de 2021), deste modo, obteve-se a demanda prevista, sendo possível ser feita a comparação com a demanda real, os limites inferiores e superiores de previsão, os pressupostos dos erros e a plotagem de gráficos exibindo o comportamento da previsão.

A Tabela 2 apresenta os resultados das medidas de acurácia para cada modelo proposto, os modelos foram ranqueados conforme a combinação dos menores erros, sendo considerados os quatro que apresentaram os melhores resultados.

Tabela 2 – Resumo das medidas de acurácia dos modelos propostos

Modelo	ME	RMSE	MAE	MAPE	MASE
NNAR1	0,0034	0,4456	0,3116	1,3789	0,2858
ARIMA	-0,0001	0,5475	0,3916	1,8038	0,3592
NNAR2	-0,0002	0,5719	0,4173	1,9291	0,3828
NAIVE	0,0664	0,6201	0,4604	2,1227	0,4223
SPLINEF	0,0046	0,7430	0,5288	2,2703	0,4851
CROSTON	0,6482	1,0735	0,8809	4,3162	0,8080
SNAIVE	0,7929	1,3644	1,0902	5,3966	1,0000
MÉDIA	0,0000	10,6095	9,1154	57,9075	8,3610

Fonte: Autor (2021)

Diante desta análise, verificou-se que o modelo que apresentou os menores erros foi o de Autorregressão da Rede Neural (NNAR1), seguido pelos modelos ARIMA de Box-Jenkins, Autorregressão da Rede Neural com Intervalos de Previsão (NNAR2) e o Método Naive também apresentaram resultados significativos.

Nas seções seguintes serão descritos os modelos com os melhores resultados, sendo apresentadas as suas previsões, o seu comportamento e a análise dos seus resíduos. Os resultados dos demais modelos estão disponíveis nos Apêndices, identificou-se que esses apresentaram maiores erros, os seus resíduos apresentam menor correlação ao longo do tempo, menor variação ou não seguem distribuição normal.

4.2.1. Autorregressão da Rede Neural

Na Tabela 3 são apresentadas as previsões geradas a partir do modelo Autorregressão da Rede Neural.

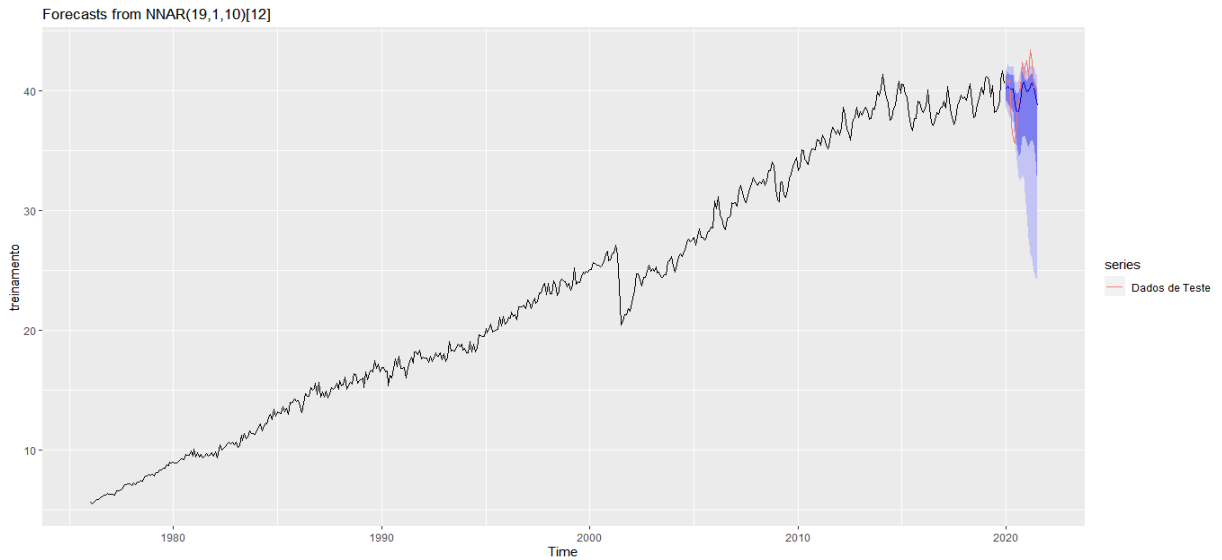
Tabela 3 – Resultados do modelo Autorregressão da Rede Neural

Ano	Mês	Previsão
2020	Janeiro	40,221
	Fevereiro	40,369
	Março	40,170
	Abril	40,174
	Maio	40,185
	Junho	38,898
	Julho	38,321
	Agosto	38,282
	Setembro	39,139
	Outubro	40,541
	Novembro	40,738
	Dezembro	40,360
2021	Janeiro	39,934
	Fevereiro	40,002
	Março	40,364
	Abril	40,686
	Maio	40,416
	Junho	39,525
	Julho	38,765

Fonte: Autor (2021)

O R identificou o melhor modelo para os dados como sendo NNAR(19,1,10)[12], que é uma rede neural para dados sazonais com as últimas 19 observações utilizadas como entradas, a ordem $P=1$, com dez neurônios na camada oculta e com o tamanho da sazonalidade de doze meses. A Figura 5 traz a representação gráfica das previsões realizadas e os dados reais separados para teste.

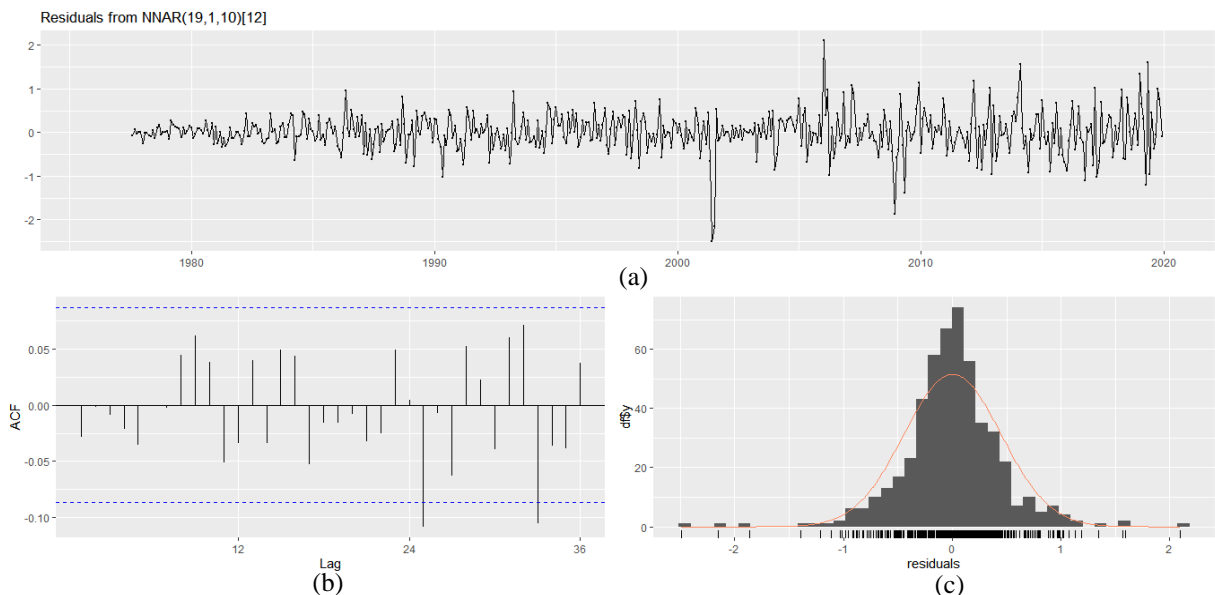
Figura 5 – Representação gráfica do modelo Autorregressão da Rede Neural



Fonte: Autor (2021)

Pode-se verificar um comportamento semelhante das previsões com a demanda real, porém, quando os dados sofrem grandes variações a previsão tende a apresentar maiores erros. Apesar disso, o modelo apresentou resultados significativos para as previsões. Na Figura 6 são apresentadas as representações gráficas da análise residual.

Figura 6 – (a) Variação residual, (b) Correlograma e (c) Histograma do modelo Autorregressão da Rede Neural



Fonte: Autor (2021)

Com base na Figura 6, pode-se observar que a variação dos resíduos permanece praticamente a mesma ao longo do tempo, entretanto, existem alguns *outliers*. O correlograma

mostra que duas *lag's* saíram dos limites indicando que pode haver correlação entre os dados. O histograma demonstra que o comportamento dos resíduos está bem próximo a uma distribuição normal.

4.2.2. ARIMA de Box-Jenkins

Serão demonstradas na Tabela 4 as previsões realizadas por meio do modelo ARIMA de Box-Jenkins.

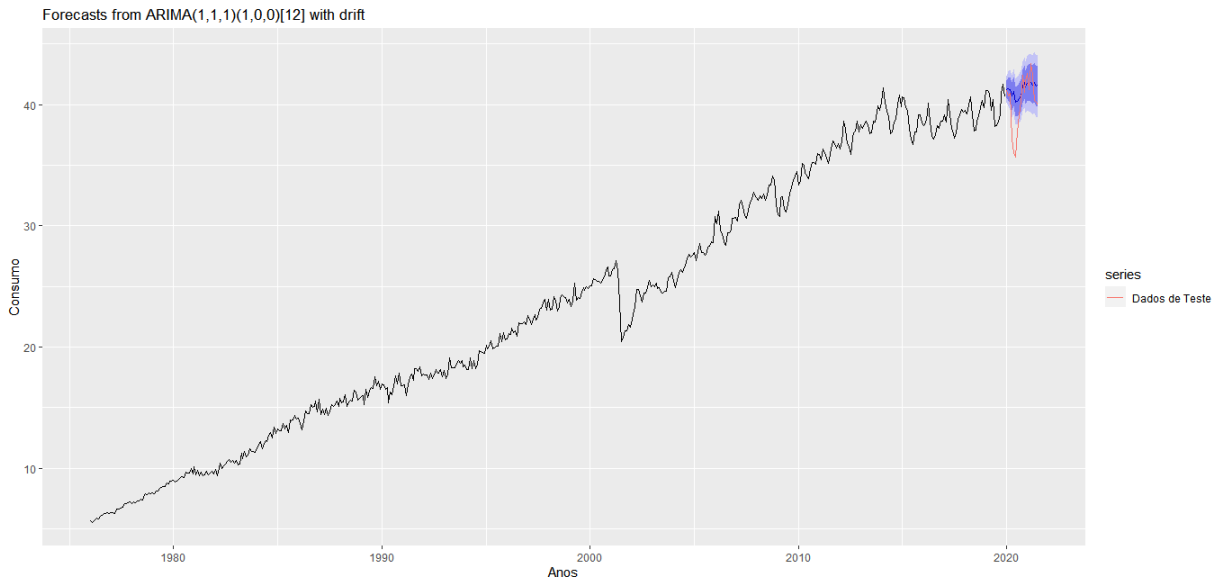
Tabela 4 – Resultados do modelo ARIMA de Box-Jenkins

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Sup (90%)
2020	Janeiro	41,237	40,532	41,942	40,158	42,315
	Fevereiro	41,280	40,357	42,203	39,869	42,691
	Março	41,224	40,171	42,277	39,613	42,834
	Abril	40,682	39,542	41,822	38,939	42,425
	Mai	41,090	39,888	42,291	39,252	42,927
	Junho	40,212	38,965	41,459	38,305	42,120
	Julho	40,272	38,990	41,553	38,311	42,232
	Agosto	40,453	39,143	41,762	38,450	42,456
	Setembro	40,726	39,394	42,058	38,689	42,763
	Outubro	41,496	40,145	42,846	39,429	43,562
	Novembro	41,839	40,472	43,206	39,748	43,930
	Dezembro	41,441	40,059	42,822	39,328	43,553
2021	Janeiro	41,726	40,264	43,187	39,491	43,961
	Fevereiro	41,782	40,260	43,304	39,455	44,110
	Março	41,798	40,229	43,367	39,398	44,198
	Abril	41,614	40,007	43,221	39,156	44,072
	Mai	41,821	40,182	43,460	39,315	44,327
	Junho	41,499	39,833	43,164	38,951	44,046
	Julho	41,562	39,873	43,251	38,979	44,145

Fonte: Autor (2021)

A modelagem no R testou vários modelos e selecionou o ARIMA(1,1,1)(1,0,0)[12] como o mais próximo da realidade, para tomar a série estacionária o modelo utilizou um parâmetro autoregressivo, um parâmetro de média móvel e uma única diferenciação, além de um parâmetro autoregressivo sazonal, cujo período da sazonalidade é de doze meses. A representação gráfica das suas previsões é exibida na Figura 7.

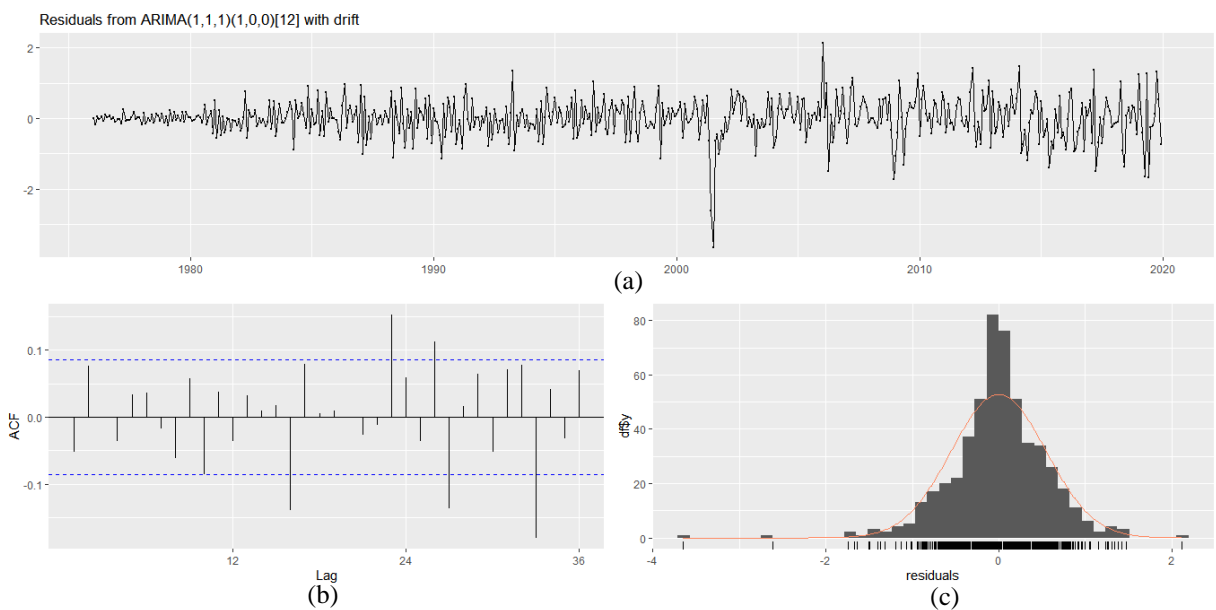
Figura 7 – Representação gráfica do modelo ARIMA de Box-Jenkins



Fonte: Autor (2021)

Pela análise gráfica, percebe-se que tanto as previsões quanto os limites de previsão não seguem fielmente a demanda real, apresentando valores mais discretos e próximos da média dos dados anteriores, a previsão é satisfatória, mas não é tão confiável quanto o modelo anterior. Com o intuito de diagnosticar o modelo, foram representados na Figura 8 a sua análise residual.

Figura 8 – (a) Variação residual, (b) Correlograma e (c) Histograma do modelo ARIMA de Box-Jenkins



Fonte: Autor (2021)

Observa-se que a variação residual é praticamente constante, exceto por dois *outliers*. Conforme o correlograma várias *lag's* saíram dos limites indicando que há correlação entre os

dados, sendo assim, podendo haver informações deixadas nos resíduos que devem ser usadas nas previsões. O histograma aponta que os resíduos seguem uma distribuição normal.

4.2.3. Autorregressão da Rede Neural com Intervalos de Previsão

As previsões realizadas pelo modelo Autorregressão da Rede Neural com Intervalos de Previsão estão disponíveis na Tabela 5.


Tabela 5 – Resultados do modelo Autorregressão da Rede Neural com Intervalos de Previsão

Ano	Mês	Previsão
2020	Janeiro	40,652
	Fevereiro	40,664
	Março	40,624
	Abril	40,287
	Mai	40,284
	Junho	39,771
	Julho	39,466
	Agosto	39,355
	Setembro	39,417
	Outubro	39,849
	Novembro	40,278
	Dezembro	40,323
2021	Janeiro	40,354
	Fevereiro	40,375
	Março	40,379
	Abril	40,308
	Mai	40,263
	Junho	40,121
	Julho	39,964

Fonte: Autor (2021)

A modelagem utilizada pelo R definiu o modelo de rede neural NNAR(1,1,2)[12] como mais adequado aos dados, a rede utilizou uma observação como entrada, a ordem $P=1$, e uma camada oculta contendo dois neurônios, também utilizou uma sazonalidade com o tamanho de doze meses. Na Figura 9 são demonstradas graficamente as previsões realizadas pelo modelo junto com os dados reais separados para teste.

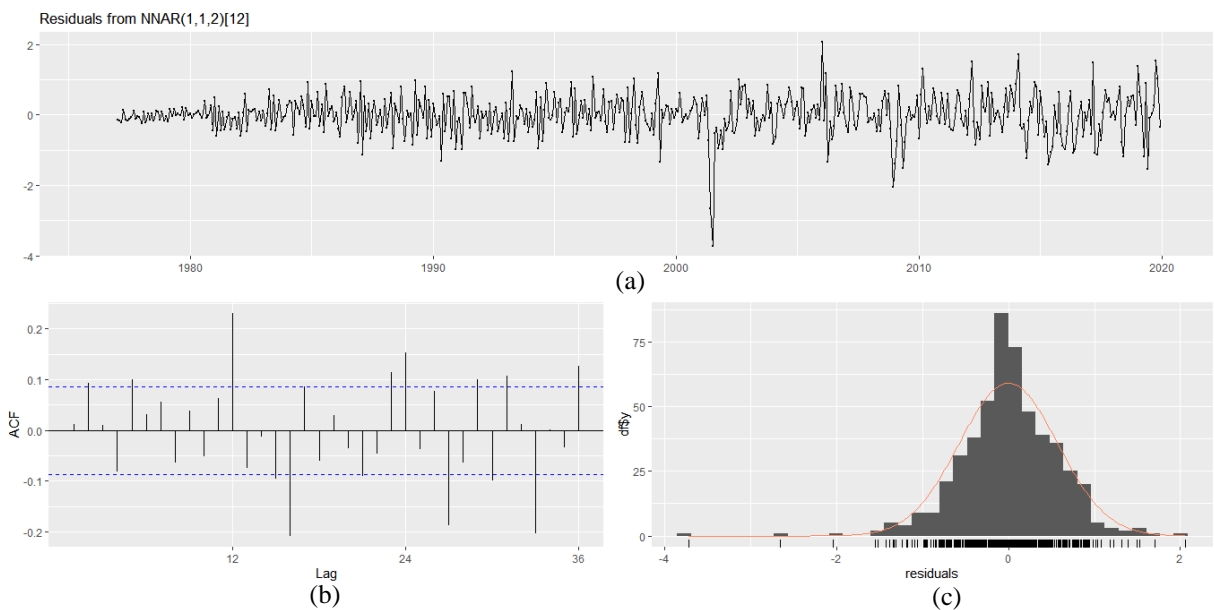
Figura 9 – Representação gráfica do modelo Autorregressão da Rede Neural com Intervalos de Previsão



Fonte: Autor (2021)

Analisando a Figura 9, verifica-se que a curva da previsão apresenta um comportamento suave devido ao modelo não prever valores com grandes variações, desta forma, o modelo demonstra falhas para casos em que a série temporal que possua tendência e sazonalidade. A Figura 10 apresenta a análise residual do modelo.

Figura 10 – (a) Variação residual, (b) Correlograma e (c) Histograma do modelo Autorregressão da Rede Neural com Intervalos de Previsão



Fonte: Autor (2021)

Conforme a Figura 10 percebe-se que os resíduos do modelo variam entre 2 e -4, apresentando a maior dispersão entre os modelos analisados. O seu correlograma também demonstra que várias *lag's* saíram dos limites, portanto, indicando que existe uma correlação significativa entre os dados. Por meio do histograma, verifica-se que os resíduos provavelmente seguem uma distribuição normal. Devido à existência de correlação na série o modelo pode ser ajustado para eliminar a estrutura de dependência e apresentar melhores resultados.

4.2.4. Método Naive

A Tabela 6 apresenta as previsões de demanda geradas através do Método Naive.

Tabela 6 – Resultados do Método Naive


Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Sup (90%)
2020	Janeiro	40,638	39,843	41,433	39,423	41,853
	Fevereiro	40,638	39,514	41,762	38,919	42,357
	Março	40,638	39,262	42,014	38,533	42,743
	Abril	40,638	39,049	42,227	38,207	43,069
	Mai	40,638	38,861	42,415	37,921	43,355
	Junho	40,638	38,692	42,584	37,661	43,615
	Julho	40,638	38,536	42,740	37,423	43,853
	Agosto	40,638	38,390	42,886	37,201	44,075
	Setembro	40,638	38,254	43,022	36,992	44,284
	Outubro	40,638	38,125	43,151	36,795	44,481
	Novembro	40,638	38,003	43,273	36,607	44,669
	Dezembro	40,638	37,885	43,391	36,428	44,848
2021	Janeiro	40,638	37,773	43,503	36,256	45,020
	Fevereiro	40,638	37,665	43,611	36,091	45,185
	Março	40,638	37,560	43,716	35,931	45,345
	Abril	40,638	37,459	43,817	35,777	45,499
	Mai	40,638	37,362	43,914	35,627	45,649
	Junho	40,638	37,267	44,009	35,482	45,794
	Julho	40,638	37,174	44,102	35,341	45,935

Fonte: Autor (2021)

O Método Naive em sua mecânica é bastante simples por isso indica, conforme a Tabela 6, que o valor previsto será igual ao último valor observado. Por isso, neste modelo além da avaliação das previsões e dos limites deve-se considerar a experiência de quem está analisando a demanda para tomar decisões. A Figura 11 traz a representação gráfica do modelo em

comparação com os dados da demanda real.

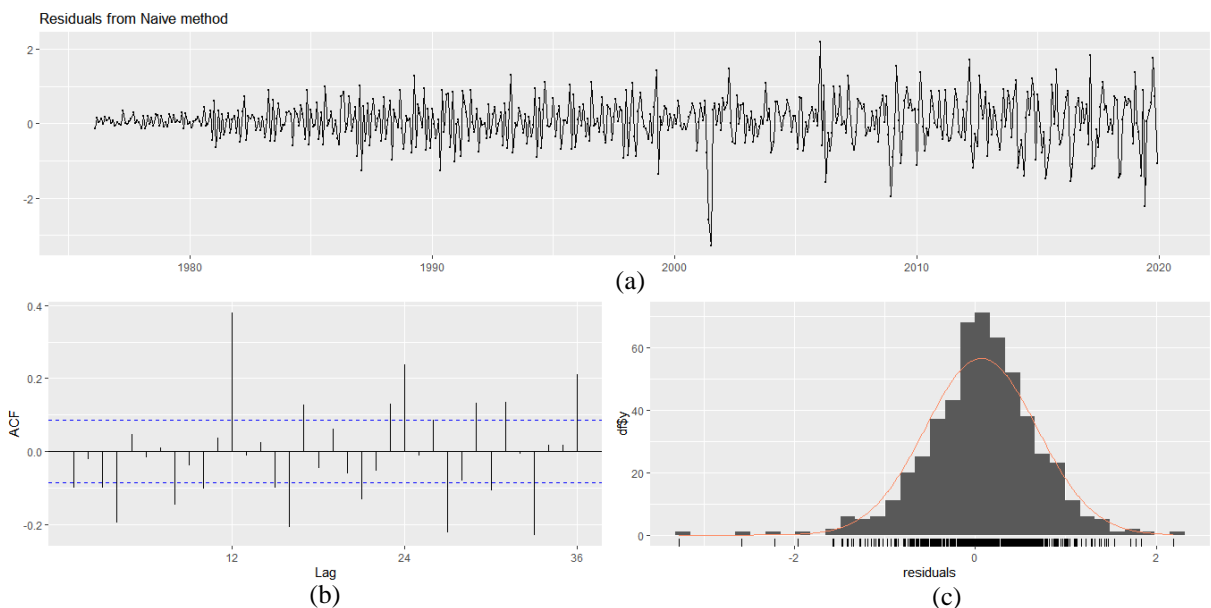
Figura 11 – Representação gráfica do Método Naive



Fonte: Autor (2021)

Avaliando a Figura 11 pode-se considerar a previsão aceitável, contudo, a mesma apresentou um comportamento linear não seguindo a variação demonstrada pelos dados de teste. De acordo com Krajewski et al. (2009), o modelo apresenta um melhor desempenho quando os padrões horizontal, tendencial ou sazonal são estáveis, e a variação aleatória é pequena. A demonstração gráfica dos seus resíduos é apresentada na Figura 12.

Figura 12 – (a) Variação residual, (b) Correlograma e (c) Histograma do Método Naive



Fonte: Autor (2021)

Assim como nos outros modelos, percebe-se que a variação residual permanece praticamente constante ao longo do tempo, entretanto, tonando-se mais dispersa nos últimos anos. Analisando o correlograma verifica-se que existe uma correlação significativa entre os dados, pois grande parte das *lag*'s ultrapassam os limites. O histograma sugere que os resíduos podem seguir uma distribuição normal. Esses resultados indicam que modelo pode ser ajustado e apresentar resultados com maior confiabilidade para o caso em análise.

4.3 Definição do Modelo Mais Adequado

Com o objetivo de identificar qual o modelo mais adequado para o estudo, os dados foram submetidos aos testes de Shapiro-Wilk e de Wilcoxon, tendo a finalidade de observar a diferença estatística presente nos resultados. A Tabela 7 mostra o valor da estatística dos testes aplicados.

Tabela 7 – Resultados dos testes de normalidade e testes para amostras dependentes

Dados	Shapiro-Wilk (<i>p-value</i>)	Dados	Wilcoxon (<i>p-value</i>)
Demanda Real	0,1081	-	-
NNAR1	0,0080	Real x NNAR1	0,1227
ARIMA	0,0266	Real x ARIMA	0,1157
NNAR2	0,0292	Real x NNAR2	0,2343
NAIVE	-	Real x NAIVE	0,7788

Fonte: Autor (2021)

Diante dos resultados expostos, observou-se através do teste de Shapiro-Wilk que os valores do *p-value* de todos os modelos estão abaixo de 0,05, o que significa que nenhum dos casos segue uma distribuição normal. Por isso, foi necessário utilizar o teste de Wilcoxon, teste não-paramétrico para variáveis quantitativas que não seguem distribuição normal. Analisando os resultados deste, verificou-se que todos os valores do *p-value* foram maiores que 0,05, indicando que o conjunto dos dados reais e o conjunto dos dados estimados pelos modelos não possuem diferença significativa. Logo após, na Tabela 8, foram mensurados os erros percentuais, considerado todas as previsões do período de teste dos quatro melhores modelos comparadas com a demanda real e com a demanda acumulada.

Tabela 8 – Comparação dos erros entre a demanda real e a demanda prevista

Período	Demanda real	NNAR1	Erro (%)	ARIMA	Erro (%)	NNAR2	Erro (%)	NAIVE	Erro (%)
01.2020	41,144	40,221	2,2%	41,237	-0,2%	40,652	1,2%	40,638	1,2%
02.2020	40,697	40,369	0,8%	41,280	-1,4%	40,664	0,1%	40,638	0,1%
03.2020	40,946	40,170	1,9%	41,224	-0,7%	40,624	0,8%	40,638	0,8%
04.2020	37,116	40,174	-8,2%	40,682	-9,6%	40,287	-8,5%	40,638	-9,5%
05.2020	36,051	40,185	-11,5%	41,090	-14,0%	40,284	-11,7%	40,638	-12,7%
06.2020	35,630	38,898	-9,2%	40,212	-12,9%	39,771	-11,6%	40,638	-14,1%
07.2020	37,715	38,321	-1,6%	40,272	-6,8%	39,466	-4,6%	40,638	-7,8%
08.2020	39,122	38,282	2,1%	40,453	-3,4%	39,355	-0,6%	40,638	-3,9%
09.2020	40,227	39,139	2,7%	40,726	-1,2%	39,417	2,0%	40,638	-1,0%
10.2020	42,426	40,541	4,4%	41,496	2,2%	39,849	6,1%	40,638	4,2%
11.2020	40,986	40,738	0,6%	41,839	-2,1%	40,278	1,7%	40,638	0,8%
12.2020	41,884	40,360	3,6%	41,441	1,1%	40,323	3,7%	40,638	3,0%
01.2021	42,531	39,934	6,1%	41,726	1,9%	40,354	5,1%	40,638	4,5%
02.2021	41,254	40,002	3,0%	41,782	-1,3%	40,375	2,1%	40,638	1,5%
03.2021	43,416	40,364	7,0%	41,798	3,7%	40,379	7,0%	40,638	6,4%
04.2021	42,432	40,686	4,1%	41,614	1,9%	40,308	5,0%	40,638	4,2%
05.2021	40,351	40,416	-0,2%	41,821	-3,6%	40,263	0,2%	40,638	-0,7%
06.2021	40,182	39,525	1,6%	41,499	-3,3%	40,121	0,2%	40,638	-1,1%
07.2021	39,950	38,765	3,0%	41,562	-4,0%	39,964	0,0%	40,638	-1,7%
Total	764,060	757,090	0,9%	783,751	-2,6%	762,734	0,2%	772,122	-1,1%

Fonte: Autor (2021)

De acordo com as informações apresentadas, é possível perceber que todos os modelos selecionados desempenharam ótimos resultados, obtendo previsões muito próximas da realidade e com medidas de erro muito baixas. No entanto, devido ao fato das previsões terem sido estatisticamente semelhantes, cabe ao gestor continuar utilizando todos os modelos com um intervalo de tempo maior e poder tomar uma decisão sobre qual o modelo se mantém como o mais apropriado e preciso. Contudo, especificamente para o período em análise o modelo de Autorregressão da Rede Neural com Intervalos de Previsão, comprovou-se como o mais adequado a ser utilizado, pois, apresentou a maior precisão com um percentual de erro de 0,2%.

Pode-se verificar que os modelos que utilizam RNAs apresentaram resultados mais precisos e com menores erros se comparados aos outros métodos. Estudos constaram resultados similares, como em uma pesquisa realizada por Pianucci et al. (2019), que comparou o desempenho de modelos lineares com modelos que utilizam RNAs, obtendo valores bem similares e compatíveis, entretanto, os resultados foram sutilmente melhores para as RNAs. Devido às redes neurais artificiais possuírem uma grande capacidade de generalização e mapeamento, estas ajustam bem seus dados previstos aos valores reais (SILVA et al., 2018).

Entretanto, os modelos lineares também demonstraram uma alta eficiência, sendo o método Naive com um percentual de erro de -1,1% e o ARIMA com -2,6%. Weyll et al. (2018), encontram resultados semelhantes ao comparar o modelo NNAR com o Naive, sendo que neste a RNA registrou erros menores do que o modelo Naive em todos os conjuntos de teste.

Corroborando, Borsato e Corso (2019) propuseram a comparação do modelo ARIMA com o modelo de Redes Neurais Artificiais, observou-se que o modelo RNA otimizado apresentou menor percentual de erro e se adaptou melhor a estocasticidade dos dados, todavia, o modelo ARIMA também apresentou previsões satisfatórias. O estudo de Nunes et al. (2021) retrata sobre a previsão do consumo de energia elétrica no Rio Grande do Sul, o mesmo constatou que modelos ARIMA apresentaram menores valores para as medidas que quantificam os erros de previsão em comparação com outros modelos, forneceram intervalos de confiança que contemplam todos os valores observados, além de precisarem de menos informações para ser gerado, pois, é univariado, sendo mais facilmente implementado.

Diante disso, importante mencionar que ambos os modelos, são ferramentas simples, assertivas e rápidas para serem implementadas e executadas, podendo resultar em informações eficientes para o planejamento e a tomada de decisões, além de apresentarem baixo custo.

5. CONSIDERAÇÕES FINAIS

A previsão de demanda do consumo de energia elétrica é uma etapa importante para o planejamento energético de um país. É importante que se tenha um planejamento adequado para que não ocorram desperdícios ou escassez desse recurso. O estudo teve objetivo de analisar e comparar a aplicação de diversos modelos de previsão de demanda, a fim de determinar qual terá o maior êxito ao medir o consumo de energia elétrica.

Após o desenvolvimento dos modelos e da estimação das previsões, foi possível determinar, através das medidas de acurácia, os quatro modelos mais adequados para os dados em análise, estes foram: o de Autorregressão da Rede Neural, o ARIMA de Box-Jenkins, o de Autorregressão da Rede Neural com Intervalos de Previsão e o Método Naive. Além das medidas de erros, os modelos foram validados através do comportamento gráfico da previsão e da análise residual, dessa forma, comprovando o bom desempenho dos métodos e pontos de melhoria.

Com o propósito de verificar o comportamento estatístico dos resultados, utilizou-se através do teste Shapiro-Wilk que nenhum dos modelos seguem distribuição normal, entretanto, por meio do teste de Wilcoxon comprovou-se que não existem diferenças significativas, ou seja, os dados reais e os dados previstos são muito semelhantes. Demonstrado que as previsões possuem uma precisão muito boa.

A análise dos erros percentuais de cada modelo indicou que todos os modelos se mostraram eficientes e muito semelhantes, o que comprova que todos podem ser utilizados no período em questão, cabendo ao gestor uma possível análise futura para decidir qual se mantém como o mais apropriado. Contudo, o modelo de Autorregressão da Rede Neural com Intervalos de Previsão apresentou a melhor adequação ao estudo, devido a sua previsão ser a mais próxima da realidade e obter o menor percentual de erro.

Embora os resultados indiquem que os modelos de previsão de demanda são satisfatórios ao estimar o consumo de energia elétrica. Fica evidente que nenhum método de previsão foi preponderante diante os demais, os métodos tradicionais e intuitivamente simples são capazes de superar métodos mais robustos em determinada quantidade de séries. Portanto, aconselha-se utilizar um conjunto de métodos de previsão ao invés de apenas um, especialmente quando o conjunto de dados a ser previsto apresenta os mais diversos comportamentos de demanda.

Mediante ao exposto, conclui-se que a previsão de demanda é fundamental no desenvolvimento de ações estratégicas, pois fornece informações com alto grau de relevância

para o planejamento e controle de diversas áreas e cenários, além de ser um método rápido, assertivo e de baixo custo.

O presente estudo foi caracterizado como univariado, ou seja, limita-se a estimação de apenas uma variável por vez, neste caso, o consumo, se indicadores econômicos, políticos e sociais fossem inseridos aos modelos de previsão, a precisão aumentaria, especialmente quando ocorrem grandes sazonalidades e tendências, tornando o modelo mais robusto.

Por fim, para análises futuras podem ser desenvolvidos modelos mais complexos que envolvam multivariáveis como regressões múltiplas ou modelos com redes neurais recorrentes, além da aplicação de métodos híbridos que integrem a abordagem qualitativa com a quantitativa.

REFERÊNCIAS

- ABERTOS, P. B. D. D. **O que são dados abertos?** Disponível em: <<https://dados.gov.br/pagina/dados-abertos>>. Acessado em: 6 de Setembro de 2021.
- ALADAG, C. H.; EGRIOGLU, E.; KADILAR, C. Forecasting nonlinear time series with a hybrid methodology. **Applied Mathematics Letters**, v. 22, n. 9, p. 1467–1470, 2009.
- ALVES, D. B. M.; MENEGUETTE JR., M.; MONICO, J. F. G. Utilizando Splines Cúbicas Naturais para Atenuação de Erros no Posicionamento GPS. **TEMA - Tendências em Matemática Aplicada e Computacional**, v. 6, n. 2, p. 197–205, 2005.
- ANACE. **Qual o futuro do mercado de energia elétrica?** Disponível em: <<http://www.anacebrasil.org.br/noticias/qual-o-futuro-do-mercado-de-energia-eletrica/>>. Acessado em: 14 de Junho de 2021.
- BALLOU, R. H. **Gerenciamento da Cadeia de Suprimentos/Logística Empresarial**. 5. ed. ed. Porto Alegre: Bookman, 2006.
- BAZIEWICZ, C. M. **Análise de uma metodologia de classificação de séries temporais para definição dos métodos de previsão**. Universidade Federal do Paraná, 2019.
- BORSATO, R.; CORSO, L. L. Aplicação de Inteligência Artificial ARIMA na Previsão de Demanda no setor metal mecânico. **Scientia cum Industria** , 2019.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. **Times Series Analysis – Forecasting and Control**. 5. ed. ed. New Jersey: Wiley, 2016.
- BOYLAN, J. E.; SYNTETOS, A. A. Forecasting for Inventory Management of Service Parts. Complex System Maintenance Handbook. **SpringerCincinnati: Springer**, v. 1, p. 479– 508, 2008.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2 ed. ed. Rio de Janeiro: LTC Editora, 2007.
- BRUNI, A. L. **Estatística Aplicada à Gestão Empresarial**. São Paulo: Atlas, 2007.

CHEN, R. J. C.; BLOOMFIELD, P.; CUBBAGE, F. W. COMPARING FORECASTING MODELS IN TOURISM. v. 32, n. 1, p. 3–21, 2008.

CHOPRA, S.; MEINDL, P. **Gestão da cadeia de suprimentos: estratégia, planejamento e operações**. 6. ed. ed. São Paulo: Pearson Education do Brasil, 2016.

CIA, C. I. A. **Eletricidade, mapa de consumo mundial. USA: CIA World Factbook**. Disponível em: <<https://www.cia.gov/library/publications/the-world-factbook/>>. Acessado em: 14 de Junho de 2021.

CORRÊA, H. L.; CORRÊA, C. A. **Administração da Produção e Operações**. 2. ed. ed. São Paulo: Atlas, 2007.

CORREIA-SILVA, D. C. et al. Relação entre Desempenho Econômico e Consumo de Eletricidade no Brasil. **Reflexões Econômicas**, v. 2, n. 2, p. 98–118, 2017.

CROSTON, J. D. Forecasting and stock control for intermittent demands. **Operational Research Quarterly**, v. 3, n. 23, p. 289–303, 1972.

DEMIR, Í.; KIRIŞCI, M. Forecasting COVID-19 disease cases using the SARIMA-NNAR hybrid model. **medRxiv**, p. 2021.04.26.21256108, 2021.

DIAS, D. S.; SILVA, M. F. **Como Escrever uma Monografia**. Rio de Janeiro: UFRJ/COPPEAD, 2009. 72 p.

EPE, E. DE P. E. –. **Balanco Energético Nacional**. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dadosabertos/publicacoes/PublicacoesArquivos/publicacao-377/topico-494/BEN_2019_Completo_WEB.pdf>. Acessado em: 16 de Junho de 2021.

FINE, B.; LEOPOLD, E. **The World of Consumption**. 1^a ed. ed. Londres.

FORUM, W. E. **World Economic Forum Annual Meeting**. Disponível em: <<https://www.weforum.org/events/world-economic-forum-annual-meeting-2016>>. Acessado em: 12 de Junho de 2021.

GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. ed. São Paulo: Atlas, 2008.

GODINHO FILHO, M.; FERNANDES, F. C. F. **Planejamento e controle da produção: dos fundamentos ao essencial**. São Paulo: Atlas, 2010.

GUERRINI, F. M.; BELHOT, R. V.; JUNIOR, W. A. **Planejamento e controle da produção**. 1. ed. ed. Rio de Janeiro: Elsevier, 2014. v. 23

GUJARATTI, D. N.; PORTER, D. C. **Econometria Básica**. 5. ed. ed. São Paulo: AMGH, 2011.

HAYKIN, S. **Neural Networks and Learning Machines**. 3 rd. ed. New York: Prentice Hall, 2008.

HILL, R. CARTER; GRIFFITHS, WILLIAM E.; JUDGE, G. G. **Econometria**. 2. ed. ed. São Paulo: Saraiva, 2003.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. 2. ed. ed. Monash University, Australia: OTexts, 2018.

HYNDMAN, R. et al. **Forecasting with exponential smoothing: the state space approach**. Springer-Verlag Berlin Heidelberg, 2008.

HYNDMAN, R. J. et al. Rob J. Hyndman 1*, Maxwell L. King 1, Ivet Pitrun 1 and Baki Billah 1. v. 47, n. 1, p. 87–99, 2005.

HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. **International Journal of Forecasting**, v. 22, n. 4, p. 679–688, 2006.

IEA, A. I. DE E. **Estatísticas de eletricidade**. Disponível em: <<https://www.iea.org/statistics/electricity/>>. Acessado em: 22 de Junho de 2021.

IPEADATA, I. D. P. E. A. –. **Dados macroeconômicos e regionais**. Disponível em: <<http://www.ipeadata.gov.br/Default.aspx>>. Acessado em: 15 de Maio de 2021.

KIM, N. The limit distribution of a modified Shapiro-Wilk statistic for normality to Type II censored data. **Journal of the Korean Statistical Society**, v. 40, n. 3, p. 257–266, 2011.

KLASSEN, R. D.; FLORES, B. E. Forecasting practices of Canadian Firms: Survey Results

and comparisons. **International Journal of Production Economics**, v. 70, n. 2, p. 163–174, 2001.

KOEHLER, A. B.; SNYDER, R. D.; ORD, J. K. Forecasting Models and Prediction Intervals for the Multiplicative Holt-Winters Method. **International Journal of Forecasting**, v. 17, n. 2, p. 269–286, 2001.

KOTLER, P. **Administração de Marketing: Análise, Planejamento, Implementação e Controle**. 5. ed. ed. São Paulo: Atlas, 1998.

KRAJEWSKI, L.; RITZMAN, L.; MALHOTRA, M. **Administração da produção e operações**. 8. ed. ed. São Paulo: Pearson Prentice Hall, 2009.

LEE, C.; KO, C. Expert Systems with Applications Short-term load forecasting using lifting scheme and ARIMA models. **Expert Systems With Applications**, v. 38, n. 5, p. 5902–5911, 2011.

LEITE, A. D. **A energia do Brasil**. 2.ed ed. Rio de Janeiro: Elsevier, 2007.

LEONARDO LUSTOSA, MARCO A. MESQUITA, OSVALDO QUELHAS, R. O. **Planejamento e controle da produção**. 4. ed. ed. Rio de Janeiro: Elsevier, 2008. v. 9.

MAKRIDAKIS, S. G.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting: Methods and Applications**. 3. ed. ed. New York: John Wiley & Sons, 1998.

MANCUSO, A. C. B. WERNER, L. Review of combining forecasts approaches. **Independent Journal of Management & Production (IJM&P)**, v. 4, n. 1, 2013.

MARCONI, M. DE A., LAKATOS, E. M. **Fundamentos de Metodologia Científica**. 6. ed. ed. São Paulo: Atlas, 2009.

MARCUZZO, F.; ANDRADE, L.; MELO, D. Métodos de Interpolação Matemática no Mapeamento de Chuvas do Estado do Mato Grosso (Interpolation Methods in Mathematics of Rainfall Mapping of the State of Mato Grosso). **Revista Brasileira de Geografia Física**, v. 4, n. 4, p. 793, 2012.

MARTIN, A. C. et al. Análise de séries temporais para previsão da evolução do número de

automóveis no município de Joinville. **Espacios**, v. 37, n. 6, p. 1–15, 2016.

MARTINS, PETRÔNIO GARCIA; LAUGENI, F. P. **Administração da Produção**. 2. ed. ed. São Paulo: Saraiva, 2005.

MARTINS, A. R. et al. Consumo de energia elétrica do estado do Tocantins nos últimos 5 anos. **VII JICE - Jornada de Iniciação Científica e Extensão**, p. 1–6, 2017.

MIRANDA, R. G. et al. Método estruturado para o processo de planejamento da demanda nas organizações. **Revista ADMpg Gestão Estratégica**, v. 4, n. 1, p. 45–53, 2011.

MME, M. DE M. E E. **Estatísticas do setor energético brasileiro**. Acessado em: 22 de Junho de 2021.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to Time Series Analysis and Forecasting**. New Jersey: John Wiley & Sons, 2008.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística Aplicada e Probabilidade para Engenheiros**. 4. Ed. ed. Rio de Janeiro: LTC Editora, 2009.

MOREIRA, D. A. **Administração da Produção e Operações**. 2 ed. ed. São Paulo: Cengage Learning, 2009.

MOREIRA, L.; JUNIOR, C. Previsão do consumo de eletricidade no nordeste brasileiro. **Engevista**, v. 20, n. 3, p. 408–423, 2018.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. 2. ed. ed. São Paulo: Edgar Blucher Ltda., 2006.

NELSON, C. R. Applied Time Series Analysis for Managerial Forecasting. **Operations Research**, v. 23, n. 1, p. 181–182, 1975.

NIGEL SLACK, STUART CHAMBERS, R. J. **Administração da Produção**. São Paulo: Atlas, 2009.

NUNES, G. DOS S. et al. Avaliação da capacidade preditiva de modelos ARIMA e VAR-VEC : o caso da demanda por energia elétrica no Rio Grande do Sul Evaluation of the predictive capacity of ARIMA and VAR-VEC models : the case of electricity demand in Rio Grande do

Sul O presente e. **Exacta**, n. 2000, 2021.

ONU. **Nosso Futuro Comum (Our Common Future)**, 1987. Disponível em: <<https://ambiente.files.wordpress.com/2011/03/brundtland-report-our-common-future.pdf>> Acessado em: 12 de Junho de 2021.

ONU. **17 Goals to Transform Our World**. Disponível em: <<https://www.un.org/sustainabledevelopment/>>. Acessado em: 12 de Junho de 2021.

PEINADO, J.; GRAEML, A. R. **Administração da Produção (Operações Industriais e de Serviços)**. Curitiba: UnicenP, 2007.

PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para Implantação de Sistemas de Previsão de Demanda- Técnicas e Estudo de Caso. **Produção**, v. 11, n. 1, p. 43–64, 2001.

PIANUCCI, M. N. et al. Previsão da demanda por viagens domiciliares através de método sequencial baseado em população sintética e redes neurais artificiais. **Transportes**, v. 27, n. 4, p. 1–23, 2019.

PINDYCK, R. S.; RUBINFELD, D. L. **Econometria: Modelos & Previsões**. 1 ed. ed. Rio de Janeiro: Elsevier, 2004.

PINTO JR, H. Q. **Economia da energia: fundamentos econômicos, evolução histórica e organização industrial**. 1. ed. ed. Rio de Janeiro: Elsevier, 2007.

SAMOHYL, R. W.; SOUZA, G. P.; MIRANDA, R. G. **Métodos simplificados de previsão empresarial**. 1. ed. Ciência Moderna, 2008.

SCALCO, P. R. Relações de causalidade entre energia e crescimento econômico no brasil. **Revista Brasileira de Energia**, v. 19, n. 18, p. 355–374, 2013.

SIEGEL, S.; CASTELLAN JR, N. . **Estatística não-paramétrica para ciências do comportamento**. 2ª Ed. ed. New York: Artmed, 2006.

SIFFERT FILHO, N. F.; ALONSO, L. A.; CHAGAS, E. B.; SZUSTER, F. R.; SUSSEKIND, C. S. O papel do BNDES na expansão do setor elétrico nacional e o mecanismo de project finance. In: **BNDES Setorial**. Rio de Janeiro, p. 3–36.

SILVA, E. L. DA; MENEZES, E. M. **Metodologia da Pesquisa e Elaboração de Dissertação**. 4. ed. rev ed. Florianópolis: UFSC, 2005.

SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas: Fundamentos Teóricos e Aspectos Práticos**. 2ª ed. ed. São Paulo: Artliber, 2016.

SILVA, N. et al. Neural Networks for Predicting Prices of Sugarcane Derivatives. **Sugar Tech**, v. 21, n. 3, p. 514–523, 2018.

SIPPER, D.; BULFIN, R. L. **Production : planning, control, and integration**. New York: McGraw-Hill Education, 1997.

STEVENSON, W. J. **Production / Operations Management**. 5. ed. ed. São Paulo: Atlas, 2007.

TEAM, R. D. C. **R: A Language and Environment for Statistical Computing**. Disponível em: <<http://www.r-project.org>>. Acessado em: 02 de Outubro de 2021.

TOLMASQUIM, M. T.; GUERREIRO, A.; GORINI, R. Matriz energética Brasileira: Uma perspectiva. **Novos Estudos CEBRAP**, n. 79, p. 47–69, 2007.

TUBINO, D. F. **Planejamento e controle da produção: teoria e prática**. São Paulo: Atlas, 2007.

TUTUN, S.; CHOU, C.; CAN, E. A new forecasting framework for volatile behavior in net electricity consumption : A case study in Turkey *. **Energy**, v. 93, p. 2406–2422, 2015.

VERÍSSIMO, A. J. et al. Métodos Estatísticos de Suavização Exponencial Holt-Winters para Previsão de Damanda em uma Empresa do Setor Metal Mecânico. **Revista Gestão Industrial**, v. 8, n. 4, p. 154–171, 2012.

VILAR, J. M.; CAO, R.; ANEIROS, G. Forecasting next-day electricity demand and price using nonparametric functional methods. **International Journal of Electrical Power & Energy Systems**, v. 39, n. 1, p. 48–55, 2012.

WALTER, O. M. F. C. et al. Aplicação de um modelo SARIMA na previsão de vendas de motocicletas. **Exacta**, v. 11, n. 1, p. 77–88, 2013.

WANKE, P. F. **Gestão de Estoques na Cadeia de Suprimentos: Decisões e Modelos Quantitativos**. 3. ed. ed. São Paulo: Atlas, 2011.

WEYLL, A.; CRUZ, F.; SIMAS FILHO, E. Previsão de Demanda de Curta Duração Utilizando Modelo NAR de Redes Neurais e Naive. **ENECOM**, 2018.

WERNER, L.; RIBEIRO, J. L. D. Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais. **Gestão e Produção**, v. 10, n. 1, p. 47–67, 2003.

WINTERS, P. R. Forecasting Sales by Exponentially Weighted Moving Averages. **Management Science**, v. 6, n. 3, p. 324–342, 1960.

WU, L. et al. Using a novel multi-variable grey model to forecast the electricity consumption of Shandong Province in China. **Energy**, v. 157, n. 2018, p. 327–335, 2018.

ZANELLA, L. C. H. **Metodologia de pesquisa**. 2. ed. rei ed. Florianópolis: Departamento de Ciências da Administração/UFSC, 2013.

ZHANG, G.; EDDY PATUWO, B.; Y. HU, M. Forecasting with artificial neural networks: The state of the art. **International Journal of Forecasting**, v. 14, n. 1, p. 35–62, 1998.

ZHANG, G. P. Time series forecasting using a hybrid ARIMA and neural network model. v. 50, p. 159–175, 2003.

APÊNDICES

APÊNDICE A – Resultados do Método Splinéf

Tabela Apêndice A – Resultados do Método Splinéf

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Sup (90%)
2020	Janeiro	41,474	40,520	42,427	40,015	42,932
	Fevereiro	41,917	40,756	43,077	40,142	43,692
	Março	42,360	40,931	43,789	40,175	44,545
	Abril	42,803	41,054	44,553	40,127	45,480
	Mai	43,247	41,135	45,358	40,018	46,476
	Junho	43,690	41,183	46,197	39,856	47,524
	Julho	44,133	41,197	47,070	39,642	48,625
	Agosto	44,577	41,184	47,970	39,388	49,766
	Setembro	45,020	41,144	48,896	39,092	50,948
	Outubro	45,463	41,081	49,846	38,761	52,166
	Novembro	45,907	40,993	50,820	38,393	53,420
	Dezembro	46,350	40,886	51,814	37,993	54,706
2021	Janeiro	46,793	40,756	52,830	37,561	56,025
	Fevereiro	47,236	40,608	53,865	37,099	57,373
	Março	47,680	40,440	54,919	36,608	58,751
	Abril	48,123	40,254	55,992	36,088	60,158
	Mai	48,566	40,050	57,083	35,542	61,591
	Junho	49,010	39,828	58,191	34,968	63,051
	Julho	49,453	39,590	59,316	34,369	64,537

Figura Apêndice A – Representação gráfica do Método Splinéf

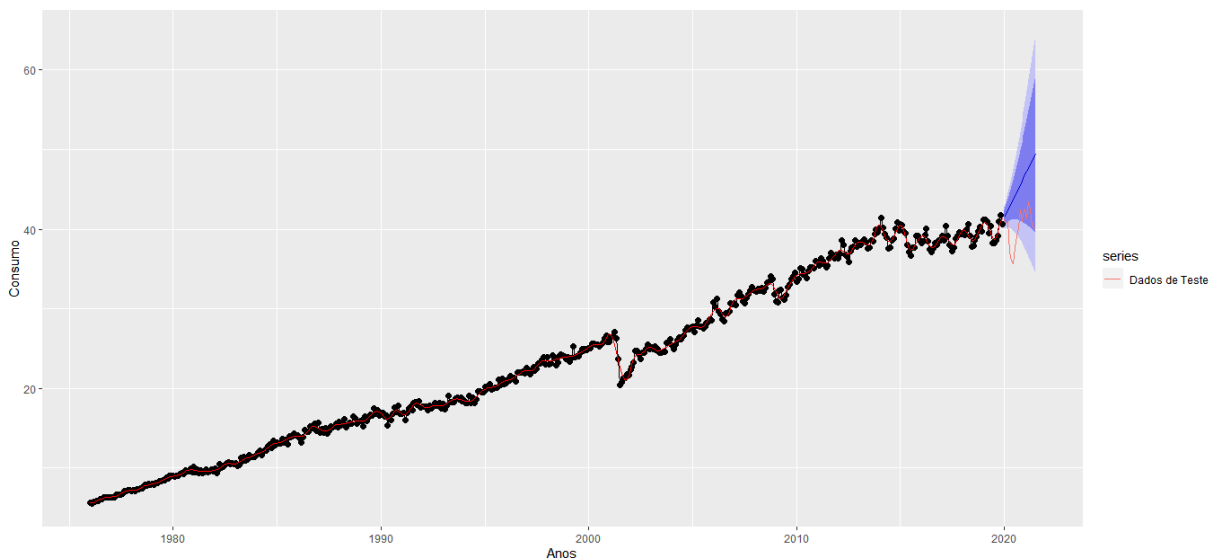
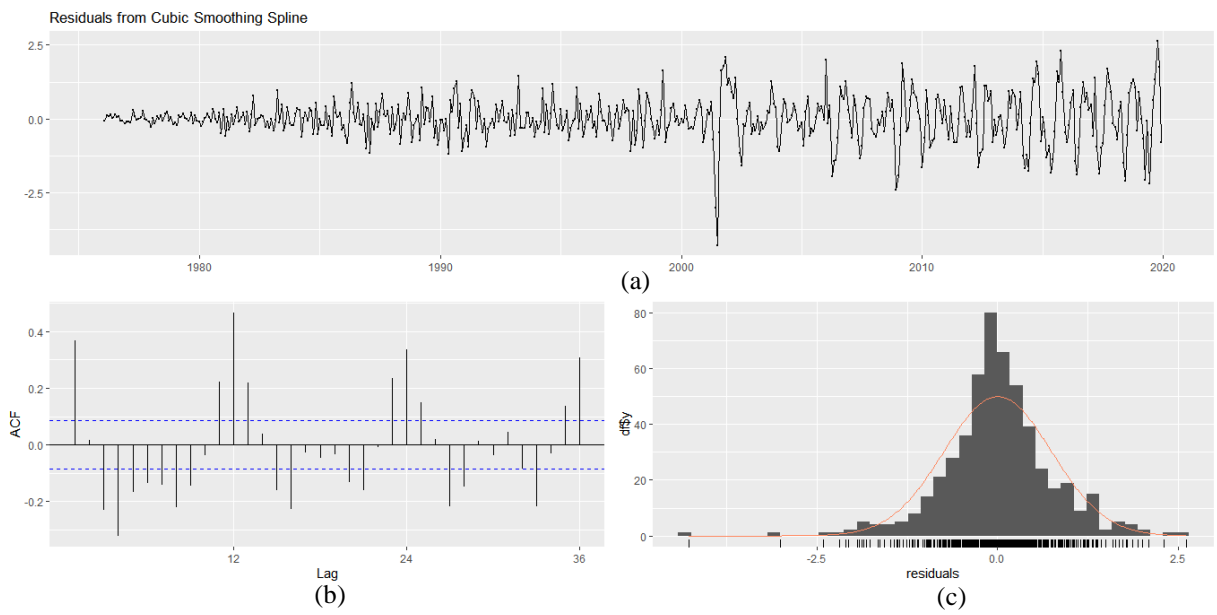


Figura Apêndice A – (a) Variação residual, (b) Correlograma e (c) Histograma do Método Splines



APÊNDICE B – Resultados do Método Naive Sazonal

Tabela Apêndice B – Resultados do Método Naive Sazonal

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Sup (90%)
2020	Janeiro	41,142	39,393	42,891	38,468	43,816
	Fevereiro	41,162	39,413	42,911	38,488	43,836
	Março	40,938	39,189	42,687	38,264	43,612
	Abril	39,534	37,785	41,283	36,860	42,208
	Mai	40,435	38,686	42,184	37,761	43,109
	Junho	38,213	36,464	39,962	35,539	40,887
	Julho	38,265	36,516	40,014	35,591	40,939
	Agosto	38,613	36,864	40,362	35,939	41,287
	Setembro	39,183	37,434	40,932	36,509	41,857
	Outubro	40,959	39,210	42,708	38,285	43,633
	Novembro	41,700	39,951	43,449	39,026	44,374
	Dezembro	40,638	38,889	42,387	37,964	43,312
2021	Janeiro	41,142	38,669	43,615	37,360	44,924
	Fevereiro	41,162	38,689	43,635	37,380	44,944
	Março	40,938	38,465	43,411	37,156	44,720
	Abril	39,534	37,061	42,007	35,752	43,316
	Mai	40,435	37,962	42,908	36,653	44,217
	Junho	38,213	35,740	40,686	34,431	41,995
	Julho	38,265	35,792	40,738	34,483	42,047

Figura Apêndice B – Representação gráfica do Método Naive Sazonal


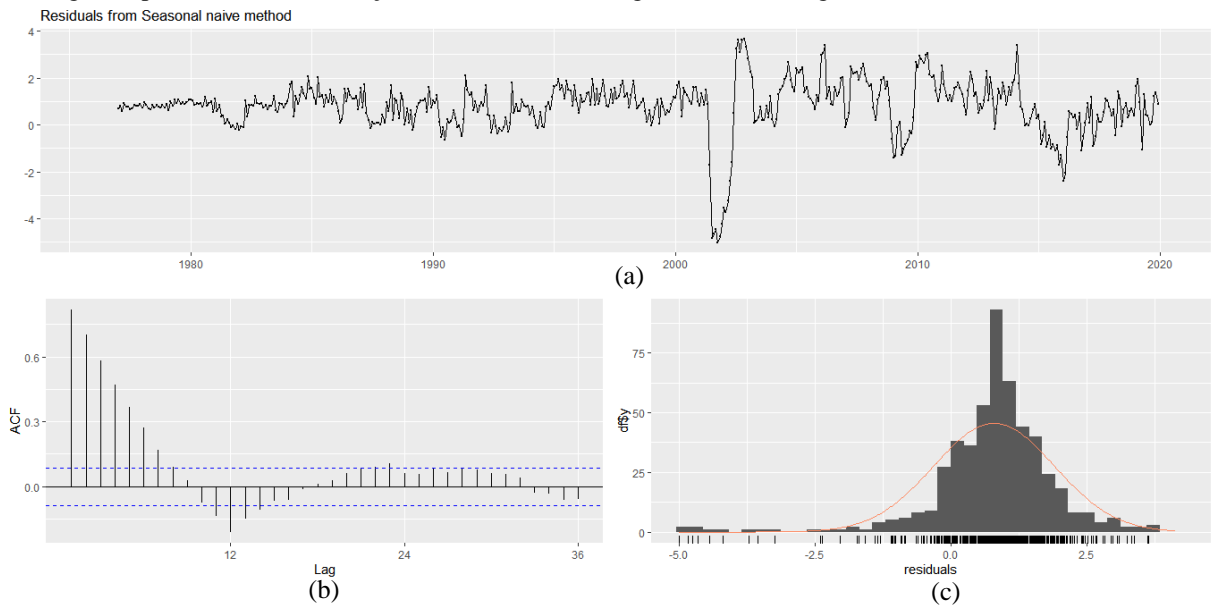


Figura Apêndice B – (a) Variação residual, (b) Correlograma e (c) Histograma do Método Naive Sazonal



APÊNDICE C – Resultados do Método Croston

Tabela Apêndice C – Resultados do Método Croston

Ano	Mês	Previsão
2020	Janeiro	39,820
	Fevereiro	39,820
	Março	39,820
	Abril	39,820
	Maio	39,820
	Junho	39,820
	Julho	39,820
	Agosto	39,820
	Setembro	39,820
	Outubro	39,820
	Novembro	39,820
	Dezembro	39,820
2021	Janeiro	39,820
	Fevereiro	39,820
	Março	39,820
	Abril	39,820
	Maio	39,820
	Junho	39,820
	Julho	39,820

Figura Apêndice C – Representação gráfica do Método Croston

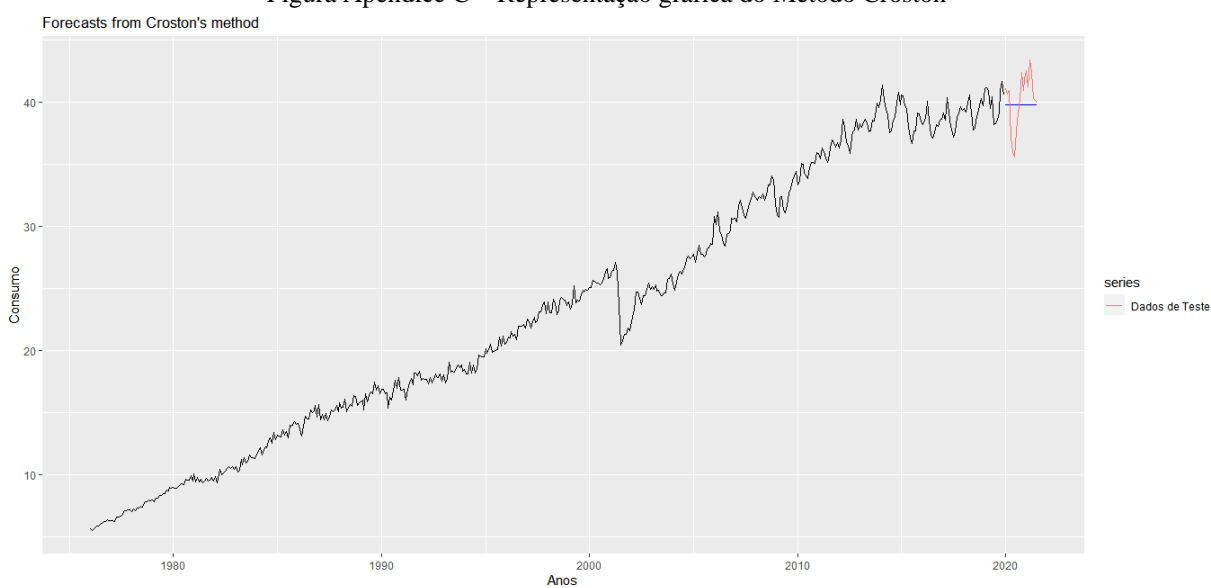
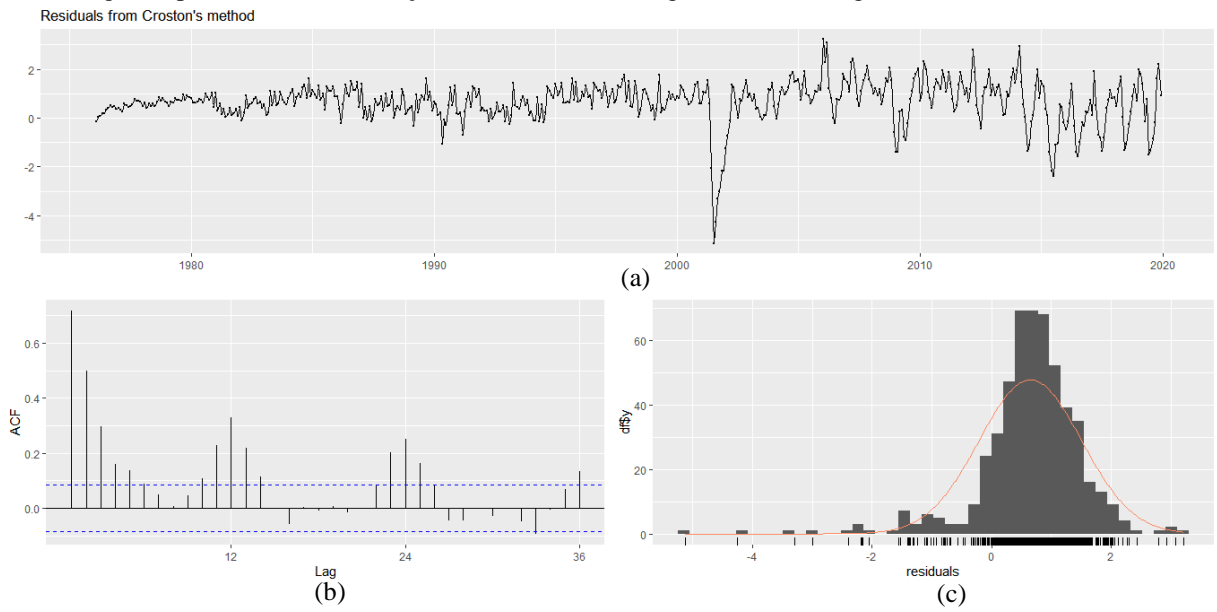


Figura Apêndice C – (a) Variação residual, (b) Correlograma e (c) Histograma do Método Croston



APÊNDICE D – Resultados do Modelo da Média Móvel

Tabela Apêndice D – Resultados do Modelo da Média Móvel

Ano	Mês	Previsão	Limite Inf (80%)	Limite Sup (80%)	Limite Inf (90%)	Limite Sup (90%)
2020	Janeiro	23,157	9,517	36,796	2,275	44,039
	Fevereiro	23,157	9,517	36,796	2,275	44,039
	Março	23,157	9,517	36,796	2,275	44,039
	Abril	23,157	9,517	36,796	2,275	44,039
	Mai	23,157	9,517	36,796	2,275	44,039
	Junho	23,157	9,517	36,796	2,275	44,039
	Julho	23,157	9,517	36,796	2,275	44,039
	Agosto	23,157	9,517	36,796	2,275	44,039
	Setembro	23,157	9,517	36,796	2,275	44,039
	Outubro	23,157	9,517	36,796	2,275	44,039
	Novembro	23,157	9,517	36,796	2,275	44,039
	Dezembro	23,157	9,517	36,796	2,275	44,039
2021	Janeiro	23,157	9,517	36,796	2,275	44,039
	Fevereiro	23,157	9,517	36,796	2,275	44,039
	Março	23,157	9,517	36,796	2,275	44,039
	Abril	23,157	9,517	36,796	2,275	44,039
	Mai	23,157	9,517	36,796	2,275	44,039
	Junho	23,157	9,517	36,796	2,275	44,039
	Julho	23,157	9,517	36,796	2,275	44,039

Figura Apêndice D – Representação gráfica do Modelo da Média Móvel


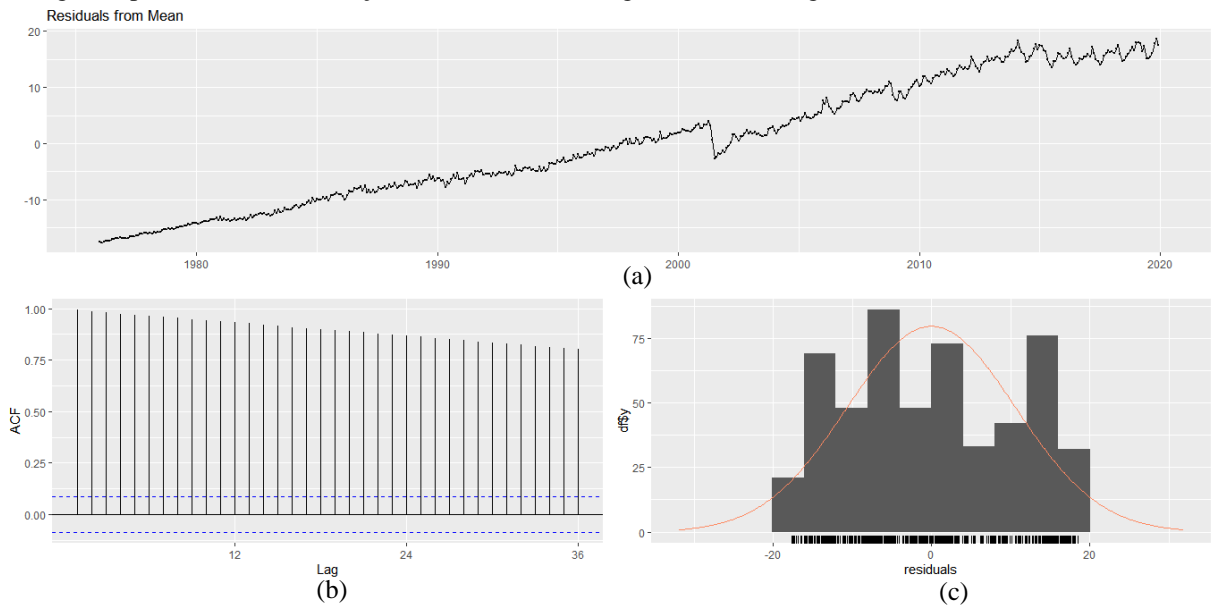


Figura Apêndice D – (a) Variação residual, (b) Correlograma e (c) Histograma do Modelo da Média Móvel



ANEXOS

ANEXO A – Dados do Consumo de Energia no Brasil em GWh

Ano	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1976	5,661	5,530	5,685	5,717	5,854	5,849	6,037	6,115	6,264	6,275	6,352	6,296
1977	6,339	6,318	6,279	6,618	6,629	6,608	6,677	6,796	7,093	7,093	7,166	7,191
1978	7,056	7,261	7,121	7,318	7,295	7,445	7,387	7,628	7,857	7,803	7,997	7,904
1979	7,947	7,859	8,108	8,138	8,355	8,379	8,455	8,496	8,805	8,682	8,963	8,959
1980	9,003	8,891	8,956	9,066	9,251	9,298	9,234	9,679	9,614	9,608	9,954	9,501
1981	10,102	9,468	9,804	9,405	9,656	9,360	9,470	9,752	9,486	9,589	9,781	9,529
1982	9,885	9,393	9,712	10,447	9,999	10,193	10,325	10,541	10,698	10,515	10,644	10,453
1983	10,630	10,253	10,36	11,266	10,788	11,411	10,945	11,077	11,608	11,402	11,366	11,332
1984	11,642	11,968	12,207	11,626	12,031	12,277	12,210	12,698	12,953	12,520	13,420	12,845
1985	13,204	13,114	13,079	13,651	13,224	13,528	12,965	13,969	13,918	14,002	14,320	14,041
1986	14,120	13,709	13,152	13,894	14,756	14,514	14,502	15,227	15,028	15,124	15,559	14,685
1987	15,698	14,422	14,885	14,412	14,940	14,357	14,618	15,267	15,093	15,220	15,568	15,092
1988	15,798	15,379	15,466	16,087	15,117	15,482	15,649	15,529	16,418	16,286	15,592	15,794
1989	15,882	16,006	15,232	16,510	15,872	16,383	16,669	16,566	17,513	16,810	17,208	16,534
1990	16,919	16,907	16,513	16,626	15,357	16,266	16,025	16,800	17,602	16,974	17,837	16,813
1991	16,795	16,892	16,010	16,876	17,439	17,744	17,276	18,179	18,214	17,986	18,373	17,624
1992	17,750	17,706	17,710	17,306	17,810	17,424	17,665	18,107	17,827	17,821	18,111	17,520
1993	18,070	17,416	17,781	19,100	18,312	18,316	18,259	18,673	18,881	18,630	18,879	18,331
1994	18,513	18,164	18,130	19,073	18,179	18,851	18,177	18,558	19,666	19,597	19,519	19,498
1995	20,175	19,829	20,085	20,548	19,866	19,954	20,041	20,062	21,108	20,415	21,199	20,554
1996	20,662	21,093	21,027	21,546	21,206	21,345	20,882	22,006	21,953	21,946	22,087	21,858
1997	22,566	22,332	21,818	22,306	22,698	22,255	22,442	23,110	23,161	23,614	23,954	23,025
1998	23,920	23,065	23,083	24,178	23,830	22,952	23,265	24,082	24,266	24,181	24,058	23,645
1999	23,901	23,370	23,815	25,247	23,882	24,065	24,028	24,490	24,886	24,705	24,958	24,843
2000	25,060	25,057	25,662	25,598	25,448	25,445	25,287	25,470	25,777	26,313	26,579	25,834
2001	25,878	26,410	26,487	27,097	26,311	23,723	20,447	20,809	21,338	21,305	21,824	21,630
2002	22,324	22,695	23,251	24,719	24,728	24,234	23,695	24,442	24,438	24,924	25,468	24,949
2003	25,152	24,965	25,281	24,787	24,889	24,535	24,443	24,629	24,621	25,715	25,786	26,189
2004	25,393	24,906	25,499	26,085	26,373	26,189	26,389	26,674	27,305	27,626	27,399	27,590
2005	27,803	27,117	27,827	28,511	27,766	27,788	27,564	27,784	28,216	28,280	28,662	28,599
2006	30,786	30,185	31,206	29,635	29,375	28,651	28,406	29,400	29,421	29,660	30,645	30,604
2007	30,670	30,415	31,708	32,101	31,567	30,862	30,641	31,312	31,842	32,244	32,765	32,427
2008	32,325	32,121	32,441	32,280	32,631	32,129	32,559	33,326	33,353	34,082	33,781	31,816
2009	30,919	30,777	32,316	32,401	31,326	31,103	31,713	32,678	33,099	33,723	34,077	34,479
2010	33,362	33,731	35,118	35,027	34,298	34,171	33,851	34,715	35,184	35,190	35,079	35,958
2011	35,875	35,446	36,352	36,050	35,567	35,161	35,419	36,337	36,967	36,745	36,370	36,744
2012	36,303	36,899	38,621	37,994	36,809	36,527	35,916	37,205	37,661	37,794	38,642	37,763
2013	38,311	38,004	38,44	38,652	38,343	37,626	37,696	38,612	38,523	39,387	39,919	39,555
2014	40,211	41,383	40,198	39,428	38,989	37,575	37,724	38,567	38,805	40,025	40,814	39,838

2015	40,629	40,545	39,757	39,533	38,059	37,131	36,684	37,725	37,716	39,168	39,114	38,539
2016	38,225	38,504	39,218	40,091	38,526	37,422	37,108	37,539	38,232	38,058	38,609	38,624
2017	39,138	38,576	40,408	39,188	38,034	37,864	37,223	37,658	38,773	39,152	39,629	39,396
2018	39,509	39,225	39,968	40,606	39,143	37,791	37,894	38,596	39,08	39,742	40,318	39,771
2019	41,142	41,162	40,938	39,534	40,435	38,213	38,265	38,613	39,183	40,959	41,7	40,638
2020	41,144	40,697	40,946	37,116	36,051	35,63	37,715	39,122	40,227	42,426	40,986	41,884
2021	42,531	41,254	43,416	42,432	40,351	40,182	39,950					
