

**UFRRJ**  
**INSTITUTO DE CIÊNCIAS EXATAS**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM**  
**MODELAGEM MATEMÁTICA E COMPUTACIONAL**

**DISSERTAÇÃO**

**Modelos de séries temporais para a previsão do  
consumo de energia elétrica da indústria de cimento  
no Brasil**

**Rodrigo Felipe da Silva Mendes**

**2023**



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
INSTITUTO DE CIÊNCIAS EXATAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM  
MATEMÁTICA E COMPUTACIONAL**

**MODELOS DE SÉRIES TEMPORAIS PARA A PREVISÃO DO  
CONSUMO DE ENERGIA ELÉTRICA DA INDÚSTRIA DE CIMENTO  
NO BRASIL**

**RODRIGO FELIPE DA SILVA MENDES**

*Sob orientação de*  
**Felipe Leite Coelho da Silva**

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre** no Programa de Pós-Graduação em Modelagem Matemática e Computacional, Área de Concentração em Modelagem Matemática e Computacional.

Seropédica, RJ, Brasil  
Dezembro de 2023

Universidade Federal Rural do Rio de Janeiro  
Biblioteca Central / Seção de Processamento Técnico

Ficha catalográfica elaborada  
com os dados fornecidos pelo(a) autor(a)

F534m

Felipe da Silva Mendes, Rodrigo , 09/02/1991-  
Modelos de séries temporais para a previsão do  
consumo de energia elétrica da indústria de cimento  
no Brasil / Rodrigo Felipe da Silva Mendes. - Duque  
de Caxias, 2023.  
66 f.

Orientador: Felipe Leite Coelho da Silva.  
Dissertação(Mestrado). -- Universidade Federal Rural  
do Rio de Janeiro, Programa de Pós-Graduação em  
Modelagem Matemática e Computacional, 2023.

1. Previsão . 2. Indústria do cimento. 3. Séries  
Temporais. 4. Consumo de energia elétrica. I. Leite  
Coelho da Silva, Felipe , 28/05/1981-, orient. II  
Universidade Federal Rural do Rio de Janeiro.  
Programa de Pós-Graduação em Modelagem Matemática e  
Computacional III. Título.



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
INSTITUTO DE CIÊNCIAS EXATAS



PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL

Seropédica-RJ, 22 de dezembro de 2023.

## **Rodrigo Felipe da Silva Mendes**

Dissertação submetida como requisito parcial para a obtenção de grau de **Mestre**, no Programa de Pós-Graduação em Modelagem Matemática e Computacional PPGMMC, área de Concentração em Modelagem Matemática e Computacional.

DISSERTAÇÃO APROVADA EM 22/12/2023

Felipe Leite Coelho da Silva Dr<sup>o</sup> UFRRJ (Orientador, Presidente da Banca)

Carlos Andres Reyna Vera Tudela Dr<sup>o</sup> UFRRJ (membro interno)

Igor Campos de Almeida Lima Dr<sup>o</sup> UERJ (Externo à Instituição)



*ATA Nº ata/2023 - ICE (12.28.01.23)*

*(Nº do Documento: 6727)*

*(Nº do Protocolo: NÃO PROTOCOLADO)*

*(Assinado digitalmente em 27/12/2023 12:06 )*

**CARLOS ANDRES REYNA VERA TUDELA**

PROFESSOR DO MAGISTERIO SUPERIOR

DeptM (12.28.01.00.00.00.63)

Matrícula: ###336#3

*(Assinado digitalmente em 27/12/2023 16:25 )*

**FELIPE LEITE COELHO DA SILVA**

PROFESSOR DO MAGISTERIO SUPERIOR

DeptM (12.28.01.00.00.00.63)

Matrícula: ###398#2

*(Assinado digitalmente em 16/01/2024 15:34 )*

**IGOR CAMPOS DE ALMEIDA LIMA**

ASSINANTE EXTERNO

CPF: ###.###.587-##

Visualize o documento original em <https://sipac.ufrrj.br/documentos/> informando seu número: **6727**, ano: **2023**,  
tipo: **ATA**, data de emissão: **27/12/2023** e o código de verificação: **e5b6e96f33**

## Agradecimentos

Gostaria de agradecer a todos que contribuíram para a elaboração desse trabalho, em particular ao Senhor Deus por sempre ter me abençoando e me dado força não só neste trabalho, mas em toda a minha vida.

Tudo o que conquistei foi graças ao Senhor meu Deus.

A minha esposa Priscilla e filha Ana Beatriz pelo apoio e ajuda nos momentos difíceis.

A minha mãe Adriana e meu pai Washington pelo esforço de sempre querer me dar a melhor educação possível e por tudo o que fizeram para eu me tornar o homem que sou hoje.

Aos meus amigos pelo apoio e pelo companheirismo em todos os momentos.

Ao professor Dr. Felipe Leite Coelho da Silva, que me ajudou desde o início desse projeto até a me orientar neste trabalho.

A todo o corpo docente do PPGMMC UFRRJ.

Todos os amigos e parentes que me ajudaram nesta caminhada.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

This work was carried out with the support of the Coordination for the Improvement of Higher Education Personnel - Brazil (CAPES) - Financing Code 001.

*"Ainda que a figueira não floresça,  
nem haja fruto na videira; ainda que a  
colheita da oliveira decepcione, e os  
campos não produzam mantimento;  
ainda que as ovelhas desapareçam do  
aprisco, e nos currais não haja mais  
gado, mesmo assim eu me alegro no  
Senhor, e exulto no Deus da minha  
salvação."Habacuque 3:17,18*

## RESUMO GERAL

FELIPE DA SILVA MENDES, Rodrigo. **Modelos de séries temporais para a previsão do consumo de energia elétrica da indústria de cimento do Brasil**. 2023. 66f. Dissertação (Mestrado em Modelagem Matemática e Computacional). Instituto de Ciências Exatas, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2023.

Este estudo tem a finalidade de apresentar uma análise e previsão do consumo de energia elétrica na indústria de cimento brasileira. Esse setor tem uma importância social, ambiental e econômica para o Brasil. Neste contexto, as projeções do consumo de energia elétrica são informações importantes para o planejamento energético e para eficiência energética do setor. Assim, foram utilizados os métodos de previsão como o de Holt-Winters, ARIMA Sazonal (SARIMA), redes neurais autorregressivas e os modelos de regressão dinâmica. Para avaliar a qualidade preditiva dos modelos foram utilizadas as métricas da raiz do erro quadrático médio (RMSE) e erro médio absoluto percentual (MAPE). Os resultados demonstraram que o modelo de regressão dinâmica apresentou o melhor desempenho preditivo nos três primeiros períodos dos quatro avaliados, e no quarto período em análise o modelo que apresentou os melhores resultados para previsão foi o modelo SARIMA.

**Palavras-chave:** Previsão; indústria do cimento, séries Temporais; consumo de energia elétrica.



## GENERAL ABSTRACT

FELIPE DA SILVA MENDES, Rodrigo. **Time series models for forecasting electricity consumption in the cement industry of Brazil**. 2023. 66p. Dissertation (Master in Mathematical and Computational Modeling). Instituto de Ciências Exatas, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2023.

This study aims to present an analysis and forecast of electricity consumption in the Brazilian cement industry. This sector has social, environmental, and economic importance for Brazil. In this context, the projections of electricity consumption are important information for energy planning and the sector's energy efficiency. Thus, forecasting methods such as Holt-Winters, Seasonal ARIMA (SARIMA), autoregressive neural networks, and dynamic regression models were used. To evaluate the predictive quality of the models, metrics such as the root mean square error (RMSE) and mean absolute percentage error (MAPE) were used. The results showed that the dynamic regression model had the best predictive performance in the first three of the four periods evaluated, and in the fourth period under analysis, the model that showed the best results for prediction was the SARIMA model.

**Keywords:** Forecast; cement Industry, times series; consumption electricity.

<b>1 INTRODUÇÃO .....</b>	<b>1</b>
<b>1.1 Considerações Gerais .....</b>	<b>1</b>
<b>1.2 Motivação .....</b>	<b>2</b>
<b>1.3 Objetivos .....</b>	<b>2</b>
1.3.1 Objetivo geral .....	2
1.3.2 Objetivos específicos .....	2
<b>1.4 Introdução .....</b>	<b>3</b>
<b>2 REVISÃO BIBLIOGRÁFICA .....</b>	<b>5</b>
<b>2.1 Revisão bibliográfica .....</b>	<b>5</b>
<b>3 INDÚSTRIA DE CIMENTO NO BRASIL .....</b>	<b>8</b>
<b>3.1 Indústria de cimento no Brasil .....</b>	<b>8</b>
3.1.1 A história da indústria do cimento no Brasil .....	9
3.1.2 Produção de cimento no Brasil .....	10
3.1.3 Mercado de cimento no Brasil .....	11
3.1.4 Impactos ambientais da indústria do cimento .....	12
3.1.4.1 Emissão de gases de efeito estufa .....	12
3.1.4.2 Uso de recursos naturais .....	13
3.1.5 Tecnologias mais eficientes e sustentáveis na produção de cimento .....	13
3.1.5.1 Produção de cimento de baixo carbono .....	13
3.1.5.2 Uso de fontes renováveis de energia .....	14
3.1.6 Regulamentação da indústria do cimento no Brasil .....	14
<b>4 REFERENCIAL TEÓRICO .....</b>	<b>16</b>
<b>4.1 Metodologia .....</b>	<b>16</b>
4.1.1 Identificação dos modelos .....	16
<b>4.2 A importância da construção civil para a economia brasileira .....</b>	<b>17</b>
<b>4.3 Séries temporais .....</b>	<b>18</b>
<b>4.4 Componentes de tendência .....</b>	<b>20</b>
<b>4.5 Componente sazonal .....</b>	<b>20</b>
<b>4.6 Métricas .....</b>	<b>21</b>

<b>4.7</b>	<b>Médias móveis simples</b>	<b>21</b>
<b>4.8</b>	<b>Amortecimento Exponencial Simples</b>	<b>21</b>
<b>4.9</b>	<b>Modelos de Holt-Winters</b>	<b>22</b>
<b>4.10</b>	<b>Modelos Box e Jenkins</b>	<b>24</b>
4.10.1	Função de Autocorrelação FAC	24
4.10.2	Função de Autocorrelação Parcial FACP	26
4.10.3	Aplicação do Teste de Ljung-Box para Autocorrelação Serial	26
4.10.4	Modelo autoregressivo AR	26
4.10.5	Modelo de médias móveis MA	27
4.10.6	Semelhanças comportamentais das FAC e FACP de AR e MA	28
4.10.7	Modelo autoregressivo e de médias móveis (ARMA (p,q))	29
4.10.8	Modelo ARIMA não sazonal	29
4.10.9	Modelo SARIMA	29
<b>4.11</b>	<b>Modelos de regressão dinâmica</b>	<b>30</b>
<b>4.12</b>	<b>Estimação de parâmetros</b>	<b>31</b>
<b>4.13</b>	<b>Redes Neurais artificiais</b>	<b>32</b>
4.13.1	Arquitetura das Redes Neurais artificiais	32
4.13.2	Modelos de redes neurais <i>feedforward</i>	32
4.13.3	Redes Neurais Autorregressivas NNAR	34
<b>5</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>35</b>
<b>5.1</b>	<b>Resultados e Discussões</b>	<b>35</b>
5.1.1	Análise Descritiva dos dados	35
5.1.2	Método de Holt-Winters	38
5.1.2.1	Modelo de Holt-Winters para previsão 12, 24, 36, 48 passos à frente	40
5.1.3	Modelo SARIMA	42
5.1.3.1	Modelo SARIMA para previsão 12, 24, 36 e 48 passos à frente	46
5.1.4	Redes Neurais Autorregressivas	48
5.1.4.1	Modelo de Redes Neurais para previsão 12, 24, 36 e 48 passos à frente	50
5.1.5	Modelo de Regressão Dinâmica	52
5.1.5.1	Modelo de Regressão Dinâmica para previsão 12, 24, 36 e 48 passos à frente	54
5.1.6	Métricas de Ajuste	56
5.1.7	Métricas de Previsão	56
<b>6</b>	<b>CONCLUSÕES</b>	<b>58</b>
<b>6.1</b>	<b>Conclusões</b>	<b>58</b>
<b>7</b>	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b>	<b>59</b>

## Lista de Figuras

Figura 4.1 – série temporal de consumo de energia elétrica em Gwh, dados de janeiro de 2001 a dezembro de 2021, da indústria de cimento do Brasil .....	19
Figura 4.2 – Fluxograma do ciclo iterativo de Box & Jenkins .....	25
Figura 4.3 – Função de autocorrelação .....	28
Figura 4.4 – Função de autocorrelação parcial .....	28
Figura 4.5 – Diagrama da Rede Neural .....	33
Figura 5.1 – Série temporal do consumo de energia elétrica da indústria de cimento no Brasil, entre 2001-2022. ....	37
Figura 5.2 – Consumo de energia elétrica acumulado anualmente e o gráfico de boxplot de cada mensal.....	37
Figura 5.3 – Consumo de energia elétrica acumulado anualmente e o gráfico de boxplot de cada mensal.....	38
Figura 5.4 – Ajuste (período de 2001-2017) e previsão (período de 2018-2019) para o método de Holt-Winters.....	39
Figura 5.5 – Ajuste (período de 2001-2019) e previsão (período de 2020-2021) para o método de Holt-Winters.....	39
Figura 5.6 – Ajuste (período de 01/2001-12/2017) e previsão (período de 01/2018-12/2021) para o método de Holt-Winters.....	41
Figura 5.7 – Série temporal (a), série temporal com diferença sazonal (b) e série temporal com dupla diferenciação (c).....	42
Figura 5.8 – Função de autocorrelação (a) e autocorrelação parcial (b). ....	43
Figura 5.9 – função de autocorrelação (a), função de autocorrelação parcial (b) e distribuição dos resíduos (c).....	44
Figura 5.10 – Ajuste (período de 2001-2017) e previsão (período de 2018-2019) para o modelo Sarima.....	45
Figura 5.11 – Ajuste (período de 2001-2019) e previsão (período de 2020-2021) para o modelo Sarima.....	45
Figura 5.12 – Ajuste (período de 01/2001-12/2017) e previsão (período de 01/2018-12/2021) para o modelo SARIMA $(1, 1, 2) \times (0, 1, 1)_{12}$ . ....	47
Figura 5.13 – Ajuste (período de 2001-2017) e previsão (período de 2018-2019) para o modelo Redes Neurais Autorregressivas.....	48
Figura 5.14 – Ajuste (período de 2001-2019) e previsão (período de 2020-2021) para o modelo Redes Neurais Autorregressivas.....	49

Figura 5.15 – Ajuste (período de 01/2001-12/2017) e previsão (período de 01/2018-12/2021) para o Modelo de Redes Neurais NNAR. ....	51
Figura 5.16 – Ajuste (período de 2001-2017) e previsão (período de 2018-2019) para o modelo Regressão Dinâmica. ....	52
Figura 5.17 – Ajuste (período de 2001-2019) e previsão (período de 2020-2021) para o modelo Regressão Dinâmica. ....	53
Figura 5.18 – Ajuste (período de 01/2001-12/2017) e previsão (período de 01/2018-12/2021) para o modelo de Regressão Dinâmica. ....	55

## Lista de Tabelas

Tabela 5.1 – Análise descritiva dos dados. ....	36
Tabela 5.2 – Métricas de ajuste valores RMSE. ....	40
Tabela 5.3 – Métricas de ajuste valores MAPE. ....	40
Tabela 5.4 – Métricas para previsão valores RMSE. ....	40
Tabela 5.5 – Métricas para previsão MAPE. ....	40
Tabela 5.6 – Métricas de previsão valores RMSE para 12, 24, 36, e 48 passos á frente. ....	41
Tabela 5.7 – Métricas de previsão valores MAPE para 12, 24, 36, e 48 passos á frente. ....	42
Tabela 5.8 – Métricas de ajuste valores RMSE. ....	46
Tabela 5.9 – Métricas de ajuste valores MAPE. ....	46
Tabela 5.10 – Métricas para previsão valores RMSE. ....	46
Tabela 5.11 – Métricas para previsão MAPE. ....	46
Tabela 5.12 – Métricas de previsão valores RMSE para 12, 24, 36, e 48 passos á frente. ....	47
Tabela 5.13 – Métricas de previsão valores MAPE para 12, 24, 36, e 48 passos á frente. ....	48
Tabela 5.14 – Métricas de ajuste valores RMSE. ....	49
Tabela 5.15 – Métricas de ajuste valores MAPE. ....	49
Tabela 5.16 – Métricas para previsão valores RMSE. ....	50
Tabela 5.17 – Métricas para previsão MAPE. ....	50
Tabela 5.18 – Métricas de previsão valores RMSE para 12, 24, 36, e 48 passos á frente. ....	51
Tabela 5.19 – Métricas de previsão valores MAPE para 12, 24, 36, e 48 passos á frente. ....	51
Tabela 5.20 – Métricas de ajuste valores RMSE. ....	53
Tabela 5.21 – Métricas de ajuste valores MAPE. ....	53
Tabela 5.22 – Métricas para previsão valores RMSE. ....	53
Tabela 5.23 – Métricas para previsão MAPE. ....	54
Tabela 5.24 – Métricas de previsão valores RMSE para 12, 24, 36, e 48 passos á frente. ....	55
Tabela 5.25 – Métricas de previsão valores MAPE para 12, 24, 36, e 48 passos á frente. ....	55
Tabela 5.26 – Métricas de comparação entre os ajustes dos modelos valores RMSE. ....	56
Tabela 5.27 – Métricas de comparação entre os ajustes dos modelos valores MAPE. ....	56
Tabela 5.28 – Métricas de comparação entre os modelos para previsão valores RMSE. ....	57
Tabela 5.29 – Métricas de comparação entre os modelos para previsão valores MAPE. ....	57

## 1.1 Considerações Gerais

O presente estudo teve como objetivo analisar e modelar as séries mensais de consumo de energia elétrica na indústria de cimento no Brasil ao longo do período de janeiro de 2001 a dezembro de 2021.[1] A relevância dessa pesquisa reside no contexto da priorização do planejamento e previsão do consumo de energia elétrica desde a crise de 2001, com foco no desenvolvimento do setor energético, eficiência energética e garantia de suprimento[2].

Para alcançar os objetivos propostos, foram aplicados diversos modelos de previsão, incluindo o método de Holt-Winters, modelos de Box e Jenkins, o modelo de redes neurais autorregressivas e o modelo de Regressão Dinâmica. A comparação entre esses modelos foi baseada em métricas de precisão, como a raiz quadrática do erro médio (RMSE) e o erro percentual absoluto médio (MAPE).

Os resultados obtidos demonstraram que o modelo de Regressão Dinâmica apresentou o melhor desempenho preditivo para a previsão do consumo futuro de energia elétrica na indústria de cimento brasileira. Essa conclusão é respaldada por estudos anteriores que enfatizam a eficácia do modelo SARIMA em séries temporais sazonais e a capacidade da metodologia Box e Jenkins em modelar dados complexos de consumo de energia.

Pesquisas recentes têm enfatizado a importância da análise do consumo de energia elétrica no setor industrial brasileiro, especialmente em segmentos como o da indústria de cimento. O setor energético tem sido constantemente investigado quanto à sua capacidade de atender à demanda crescente e garantir a segurança energética do país. Nesse sentido, a Empresa de Pesquisa Energética (EPE), responsável por publicar as previsões de consumo de energia, desempenha um papel fundamental no fornecimento de informações confiáveis para o planejamento energético nacional.

As informações obtidas neste estudo podem contribuir significativamente para aprimorar as previsões de consumo de energia elétrica não apenas na indústria de cimento, mas em todos os setores energéticos do país. A adoção da abordagem *top-down* no planejamento energético, aliada ao uso adequado de modelos de previsão como o SARIMA, oferece uma perspectiva mais precisa e abrangente do consumo de eletricidade, possibilitando uma gestão eficiente e sustentável do setor energético brasileiro.

Esse trabalho também pode fornecer direções valiosas para futuros estudos e pesquisas relacionadas à previsão e planejamento do consumo de energia elétrica. À medida que novas tecnologias e abordagens metodológicas emergem, é essencial continuar aprimorando as técnicas de previsão para atender às demandas em evolução do setor energético.

## **1.2 Motivação**

Nos últimos anos têm-se investigado as projeções do consumo de energia elétrica em setores da indústria no Brasil, seja a curto, médio ou longo prazo [3]. Esse interesse está relacionado com o desenvolvimento do setor, o planejamento energético e a eficiência energética. A energia elétrica tem uma importância econômica e social para um país ou região, fazendo com que as projeções sejam ferramentas importantes na tomada de decisão de órgãos e entidades que atuam no setor energético. A indústria cimenteira no Brasil apresenta grande demanda de consumo de energia, dentre elas a energia elétrica e de outros derivados para que se possa obter o seu produto final, ou seja, o cimento Portland [4]. E se tratando da indústria do cimento é imprescindível o planejamento adequado, considerando que a indústria de cimento desempenha papel relevante no desenvolvimento da infraestrutura econômica e social da economia brasileira. Representando cerca 60,8 milhões de toneladas de cimento produzido anualmente e ocupando o 5º lugar no ranking mundial de produção de cimento Portland [5]. Se tratando de um sistema de transmissão e produção de eletricidade exige a disponibilidade de projeções de demanda de curto, médio e longo prazo do consumo de eletricidade [6]. Nesse sentido, o consumo de energia elétrica, associado aos processos produtivos e de consumo passaram a ser investigado nos últimos anos devido sua alta necessidade para atender a demanda cada vez maior a níveis nacional e internacional. Cabe ressaltar que segundo [7] No ano de 2001, aproximadamente 10% do consumo energético da indústria cimenteira era representado pelo uso de eletricidade. A maior parte da eletricidade sendo utilizada no processo de moagem do clínquer (40%) e das matérias primas (25%) e na operação do forno e do resfriador (20%). Segundo dados da Empresa de Pesquisa Energética [2] sobre o consumo de energia desse setor industrial revela que cerca (15%) de toda energia consumida é elétrica, a partir daí, iniciamos nossa investigação sobre esse subsetor. Cabe ressaltar que na literatura pesquisada não foi encontrado nenhum trabalho para indústria de cimento do Brasil relacionado a um estudo comparativo com modelos de previsão e a abordagem bottom-up e top-down.

## **1.3 Objetivos**

### **1.3.1 Objetivo geral**

O objetivo deste estudo é analisar e prever as séries temporais mensais do consumo de energia elétrica na indústria de cimento no Brasil.

### **1.3.2 Objetivos específicos**

- Investigar a indústria de cimento no Brasil;
- Análise exploratória da série temporal (média de consumo, variabilidade mensal e anual);
- Ajustar os modelos clássicos de séries temporais;
- Ajustar o modelo de redes neurais autoregressivas;
- Avaliar a capacidade preditiva dos modelos de séries temporais.



## 1.4 Introdução

Ao longo da história da construção civil vários estudos foram desenvolvidos em busca de alcançarem um produto que fosse capaz de oferecer segurança e durabilidade para as construções civis e as edificações, essa busca conduziu o homem à diversos experimentos com materiais aglomerantes. Mas, somente o inglês Joseph Aspdin, em 1824, pode patentear tal descoberta, batizando sua descoberta como cimento Portland, fazendo referência à Portlandstone, tipo de pedra arenosa muito usada em construções na região de Portland, Inglaterra[8].

O cimento Portland em suas primeiras utilizações foi produzido a partir de um tipo de pedra arenosa utilizada em inúmeras construções na região de Portland, Inglaterra. Para que o produto fosse patenteado, em sua descrição havia as seguintes especificações: calcário moído com argila, em meio úmido, até se transformar-se em um pó fino e de cor acinzentada. Nesse processo de produção a água era evaporada a partir da exposição do sol ou ainda por erradicação do calor através de canos com vapor. Após o processo de secagem eram calcinados em fornos e depois passavam por uma moenda que os tornavam um pó bem finos.

O cimento Portland é considerado um dos materiais mais utilizados no ramo da construção civil, seja no Brasil e também no cenário internacional. O mesmo é considerado um componente indispensável para a produção do concreto, componente básico e fundamental em sua preparação.

Desde a crise energética dos anos 70 [9], inúmeras pesquisas foram implementadas em prol de alcançar um meio que pudesse auxiliar nos processos produtivos de cimento [5], e nos últimos anos têm-se investigado as projeções do consumo de energia elétrica em setores da indústria no Brasil, seja a curto ou longo prazo [3]. Esse interesse está relacionado com o desenvolvimento do setor, o planejamento energético e a eficiência energética. Além disso, a energia elétrica tem uma importância econômica e social para um país ou região, fazendo com que as projeções sejam ferramentas importantes na tomada de decisão de órgãos e entidades que atuam no setor energético [10].

Neste contexto, vários modelos de séries temporais têm sido utilizados para obter as projeções de eletricidade, tais como os modelos de regressão [11, 12], os modelos de Box e Jenkins, e de amortecimento exponencial [11], os modelos de redes neurais [13], modelo linear dinâmico Bayesiano [14], os modelos semi-paramétricos aditivos [15], e estocástica [6]. O ajuste de modelo espaço-temporal para dados de consumo de energia elétrica é de fundamental importância para a pesquisa, uma vez que existem inúmeros fatores que podem interferir em uma análise dos setores econômicos, por exemplo, com restrições de financiamento e crédito, como mostraram [16].

De acordo com [17], um dos principais critérios mais utilizados em uma avaliação sobre o consumo de energia de um determinado material, é a energia embutida nele, e que por sua vez consiste no total de energia consumida na extração da matéria prima, nas etapas de transformação e transporte. Nesse sentido, a indústria cimenteira no Brasil apresenta grande demanda de consumo de energia, dentre elas a energia elétrica e de outros derivados, para que se possa obter o seu produto final, ou seja, o cimento Portland.

O Portland é um dos principais itens utilizados pelo ser humano e sua composição segue o seguinte processo, são empregados, além de outros componentes como: areia, minério de ferro, entre outros. Tais matérias-primas são necessárias para o fornecimento dos compostos que são essenciais para a produção de cimento [7], uma vez que é delas que se origina o clínquer (o principal componente do cimento Portland) [18]. A partir de sua produção ele recebe uma adição do carbonato de cálcio (gesso), entre outras adições, de acordo com o tipo de cimento que se deseja produzir.

Segundo dados do Sindicato Nacional da Indústria do Cimento[4], o cimento é um dos principais materiais utilizados na construção civil. Esse setor que já chegou a representar cerca de 6% da economia brasileira segundo dados de 2014. O setor exerce papel importante para o desenvolvimento do Brasil uma vez que o setor é responsável por aproximadamente 70 mil empregos, sendo um propulsor na geração de renda que, em cenários anteriores a pandemia do Covid-19, alcançou valores próximos aos R\$ 27 bilhões de reais ao ano e uma arrecadação líquida que se aproxima de R\$ 3 bilhões em tributos anuais.

A finalidade deste trabalho é comparar diferentes abordagens de modelos de previsão de séries temporais (clássica, bayesiana e de redes neurais) aplicados ao consumo de energia elétrica na indústria de cimento no Brasil. Para abordagem clássica, foram considerados o método de Holt-Winters aditivo [19, 20] e o modelo SARIMA [21]. Em seguida, foi utilizado o modelo de redes neurais autorregressivas [22]. Por último, foi aplicado o modelo Regressão Dinâmica [22] que nos permite analisar estruturas de séries temporais flexíveis, tais como um crescimento linear ou sazonalidade, que se aplicam a série temporal deste estudo, entre outras.

O trabalho está organizado da seguinte forma: na seção 2 apresentamos uma breve revisão bibliográfica; na seção 3 realizamos uma abordagem sobre a indústria de cimento no Brasil; na seção 4 uma breve descrição teórica dos modelos e métodos de previsão utilizados. Na seção 5 são apresentados os resultados e discussões, na seção 6 são apresentados as conclusões. E, por fim, na seção 7 são expostas as principais referências.

## Revisão bibliográfica

### 2.1 Revisão bibliográfica

Neste capítulo será apresentado diferentes metodologias adotadas para previsões no horizonte de curto, médio e longo prazo.

De acordo com [23, 24, 25, 26, 6, 27] as abordagens *bottom-up* e *top-down* são utilizadas em análises em que os dados apresentam uma variável que segue um padrão hierárquico. De modo geral, os modelos de consumo de energia do setor industrial podem ser reunidos em conjuntos de acordo com as abordagens *top-down* e *bottom-up*. Já na abordagem *top-down* trabalhos com características similares a esse possam avaliar as variáveis de interesse num todo, ou seja de cima para baixo, e assim viabilize uma análise que seja capaz de nos apresentar a demanda energética sem distinção; ou seja, sem separar os processos tecnológicos embutidos e o comportamento de uso da indústria ou de um determinado setor.

Desse modo, os setores consumidores são considerados e podem ser classificados como componentes de um grupo homogêneo que deve ser avaliado em sua totalidade, ou seja, como setores representativos. Uma outra característica desta abordagem é que a quantidade de dados analisados é menor se comparado ao modelo *bottom-up*, uma vez que sua abordagem não toma como ponto de partida todo o processo, ou seja desde o momento inicial ao final, analisando setor por setor; assim sua representação dos dados apresenta resultados menos expressivos. Em contrapartida, a abordagem *bottom-up* parte do consumo setorial individualizado. Logo, são consideradas as variáveis de interesse e efetuamos um processo de separação em componentes que são agrupados para que possamos avaliar as variáveis de interesse. de acordo com Swan, Ugursal, Fleiter et al., Yun et al. e Maçaira [28, 25, 26, 29].

Os trabalhos desenvolvidos por [23, 24, 30, 31, 3] apresentaram uma revisão em que analisam a combinação entre as abordagens *bottom-up*, *top-down*, essa análise teve como objetivo produzir previsões que apresentassem resultados de curto prazo de séries temporais hierárquicas; ou seja, seguindo uma ordem de prioridade entre os elementos de um determinado conjunto de dados.

Os trabalhos de [32, 33, 34, 35] abordam que a previsão desenvolvida a partir da abordagem *bottom-up* apresenta resultados mais precisos do que os alcançados com a abordagem *top-down*, o principal motivo é a estrutura de detalhamento dos dados. Fliedner [36] realizou um detalhamento em que apresentou as informações essenciais para realização de uma previsão hierárquica. Esse procedimento teve como objetivo melhorar o desempenho apresentado pela previsão.

A abordagem *bottom-up* é utilizada para refinar as possibilidades de avaliação do modelo. Segundo [37, 38]. Essa é utilizada na avaliação dos impactos de entrada ou melhoria de

uma determinada tecnologia ou de um determinado sistema. O principal objetivo dessa análise é estabelecer um modelo descritivo e quantitativo e que possibilita avaliarmos a eficiência de conservação de energia elétrica e a sua forma de uso. De acordo com (Muratori et al. [39]) o modelo *bottom-up* inicia o procedimento pela estimativa do setor energético demandado, e a partir daí, encontra o equilíbrio térmico, assim é possível descrevermos cenários futuros utilizando diferentes combinações de tecnologias ou fontes de energia que possam suprir esse setor; no presente trabalho o que se espera é que ele seja capaz de suprir a necessidade de energia elétrica. Essa análise só é possível devido a desagregação dos dados e detalhada de consumo de energia elétrica.

Koopmans e Veld [40] desenvolveram um estudo sobre o consumo de energia na Holanda utilizando as abordagens *bottom-up* e *top-down* e uma combinação entre as abordagens. Swan e Ugursal [28] apresentaram uma revisão de várias técnicas de modelagem utilizadas para obter o consumo de energia do setor residencial. Eles reforçaram a ideia de que os modelos *bottom-up* e *top-down* são mais apropriados para integrar tecnologias. Chen et al. [41] representou o consumo de energia industrial de ferro e aço da China utilizando a abordagem *bottom-up*. Esse estudo mostra que essa abordagem é capaz de prever os períodos de pico do consumo de energia para produção do ferro e do aço. Mariane et al. [42] modelaram o consumo de energia elétrica de curto prazo do setor residencial na Região Sul do Brasil utilizando a abordagem *top-down* para previsão da demanda de consumo de energia elétrica, esse trabalho apresentou que a importância do método depende dos tipos de abordagens a serem aplicados e do ajuste dos modelos de suavização exponencial aplicados. O estudo ressalta a importância da abordagem *top-down* para estratégia econômica no Brasil; destacando a necessidade de um balanceamento adequado em sua distribuição.

Oy et al. [43] apresentou um estudo comparando as projeções de demanda de energia industrial e emissões de gases de efeito estufa em modelos de energia de curto e longo prazo a partir dos dados fornecidos pela *International Energy Agency (IEA)*. O trabalho aponta que na aplicação das abordagens *bottom-up* e *top-down* existem uma divergência relacionada as projeções de longo prazo; já na aplicação de curto prazo fica explícito que os modelos projetam um crescimento constante da demanda de energia industrial, o mesmo ressalta que o detalhamento do subsetor industrial pode melhorar a compreensão desse potencial energético.

Georgiou [44] apresentou um modelo de otimização utilizando a abordagem *bottom-up* para o planejamento e fornecimento de energia de longo prazo da Grécia, onde integra-se sistemas elétricos continentais e insulares. Yi et al. [45] construíram um planejamento de rede elétrica inter-regional até 2030 na China aplicando a abordagem *bottom-up*. Lee e Huh [46] utilizaram a abordagem *bottom-up* para previsão de longo prazo de fornecimento de energia nova e renovável da Coreia do Sul em que espera-se um aumento de 11% até 2035. O modelo proposto utiliza a abordagem *bottom-up* para refletir as características de cada fonte nova e renovável.

Tanaka [47] apresentou uma revisão das políticas e medidas de eficiência energética no setor industrial, abordando cerca de 570 medidas que foram implementadas pelos países que compõem IEA, ou seja, China, Índia, México, Rússia e África do Sul. Rao [48] apresentou um modelo de eficiência energética no setor industrial, onde a eficiência energética tem se tornado o principal motor do desenvolvimento sustentável em muitas economias em todo mundo.

Wagner et al. [49] apresentaram uma metodologia para a avaliação dos múltiplos benefícios das medidas de eficiência energética industrial da Suíça considerando uma aplicação de curto prazo em que suas medidas de eficiência se mostram viáveis aos setores financeiros e que por conta disso resultam em benefícios das medidas de eficiência energética em um contexto industrial. Já Massimo et al. [50] modelaram os impactos na produtividade de programas de

eficiência energética em países em desenvolvimento: evidências de empresas de ferro e aço na China a partir de uma função de custo aplicada a produtividade e aos impactos; os estudos comprovam que os programas de eficiência energética foram capazes de aumentar o crescimento e a produtividade das empresas siderúrgicas do país, e que os resultados foram satisfatórios apresentando um ganho de 148,7 milhões de RMB/ano (Renminbi por ano).

Gokan et al. [51] apresentaram uma revisão de literatura sobre a gestão de energia na manufatura: da revisão da literatura a uma estrutura conceitual em que analisou-se e investigou-se cerca de 300 artigos publicados entre os anos de 1995 a 2015, em que visam descrever o processo dinâmico de gerenciamento de energia em manufatura abrangendo os seguintes pontos: drivers e barreiras, tecnologias de informação e comunicação, paradigmas estratégicos, ferramentas e métodos de apoio, manufatura paradigmas de processo, e desempenhos de fabricação. Assim, o trabalho apresenta uma análise abrangente e sistemática das literaturas. Abdelaziz et al. [52] apresentam uma revisão de literatura sobre estratégias de economia de energia no setor industrial. neste trabalho foram reunidos inúmeros trabalhos com uma abordagem sobre economia de energia industrial por meio de gerenciamento, tecnologias e políticas.

Os trabalhos dos seguintes autores [53, 54, 55, 56, 26] utilizaram a abordagem *bottom-up* para avaliar os potenciais econômicos de energia em inúmeros setores da indústria e em diferentes países. Cabe ainda, ressaltar que esses estudos não levaram em consideração o quanto de energia seria poupado ao longo do tempo.

Silva et al. [1] apresentaram um processo de modelagem para o consumo de eletricidade de longo prazo para o subsetor da indústria de papel e celulose no Brasil, a partir de uma aplicação da abordagem *bottom-up*. Os resultados obtidos colaboram com uma das ideias centrais que são abordadas ao longo desse trabalho em que o consumo de eletricidade pode ser reduzido após o aprimoramento das medidas de eficiência energética. Essas medidas de eficiência podem ser aplicadas nos processos e nas tecnologias transversais deste subsetor.

Brunke e Blesl [57] apresentaram um modelo utilizando a abordagem *bottom-up* para avaliar o potencial econômico da conservação de energia e sua capacidade de compensar o aumento dos custos relacionados à energia na indústria alemã de ferro e aço. Brunke e Blesl [58] utilizaram o modelo *bottom-up* para avaliarem as medidas de conservação de energia para a indústria de cimento alemã e sua capacidade de compensar o aumento dos custos de produção relacionados à energia, entre os anos de 2012 a 2035 com uma projeção até 2050, onde haverá uma redução de 25% do consumo de energia elétrica e que tal avanço só será alcançado através das medidas de eficiência energética. Huang et al. [59] apresentaram uma abordagem *bottom-up* para avaliar o consumo de energia de longo prazo da indústria de cimento em Taiwan. Os resultados obtidos a partir dessa modelagem mostraram o quanto o método se mostrou eficaz para redução no consumo de energia através da utilização de medidas de eficiência energética.

## Indústria de cimento no Brasil

### 3.1 Indústria de cimento no Brasil

A indústria do cimento é um setor importante para a economia brasileira, responsável pela produção de um dos principais insumos para a construção civil. No entanto, essa atividade também gera impactos ambientais significativos, o que tem motivado as empresas do setor a investirem em tecnologias mais eficientes e sustentáveis. Ao longo deste trabalho, será discutida a indústria do cimento no Brasil, abordando sua história, produção, mercado, impactos ambientais e regulamentação.

A produção de cimento no Brasil teve início no final do século XIX, com a instalação da primeira fábrica no estado de São Paulo [5]. Desde então, a indústria do cimento vem se desenvolvendo e se modernizando, acompanhando o crescimento da construção civil no país. Atualmente, o Brasil é um dos maiores produtores de cimento do mundo, com uma produção anual de cerca de 70 milhões de toneladas [60]. A maior parte dessa produção é destinada ao mercado interno, mas uma parcela significativa é exportada para outros países.

O mercado de cimento no Brasil é altamente competitivo, com diversas empresas atuando no setor. As principais empresas são a Votorantim Cimentos, a Holcim Lafarge, a Cimento Itambé e a InterCement, que juntas detêm a maior parte do mercado [60].

Porém, a produção de cimento é uma atividade que gera impactos ambientais significativos, principalmente em relação à emissão de gases de efeito estufa e à utilização de recursos naturais, como água e energia. De acordo com o Relatório de Sustentabilidade da Votorantim Cimentos[61], a indústria do cimento é responsável por cerca de 7% das emissões globais de CO<sub>2</sub>, sendo considerada uma das principais fontes de emissão de gases de efeito estufa. Além disso, a produção de cimento consome grandes quantidades de energia e água, recursos naturais cada vez mais escassos.

Para reduzir esses impactos ambientais, a indústria do cimento tem investido em tecnologias mais eficientes e sustentáveis, como a produção de cimento de baixo carbono e o uso de fontes renováveis de energia. A produção de cimento de baixo carbono utiliza processos mais eficientes e materiais alternativos, como resíduos de outras indústrias, para reduzir as emissões de CO<sub>2</sub> [5]. Já o uso de fontes renováveis de energia, como a energia eólica e solar, contribui para reduzir a dependência da indústria do cimento em relação aos combustíveis fósseis [5].

A regulamentação da indústria do cimento no Brasil também tem um papel importante na redução dos impactos ambientais. A Lei nº 12.305/2010 instituiu a Política Nacional de Resíduos Sólidos, que estabelece diretrizes e instrumentos para a gestão de resíduos sólidos, incluindo os resíduos gerados pela indústria do cimento [62]. Além disso, a Resolução CONAMA nº 307/2002 estabelece as diretrizes, critérios e procedimentos para a gestão dos resíduos da



construção civil, que incluem os resíduos gerados na produção de cimento [63].

Diante desses desafios e oportunidades, nesta etapa desse trabalho tem-se como objetivo analisar a indústria do cimento no Brasil, destacando seus aspectos históricos, econômicos e ambientais. Para isso, serão realizadas pesquisas bibliográficas em fontes confiáveis e atualizadas, como relatórios de empresas do setor, publicações científicas e regulamentações governamentais. Será também apresentado um panorama das tecnologias mais eficientes e sustentáveis na produção de cimento, bem como da regulamentação ambiental aplicável ao setor.

Ao final desta etapa, espera-se contribuir para a discussão sobre a importância da indústria do cimento para a economia brasileira, bem como sobre os desafios e oportunidades para a produção sustentável de cimento no país.

### **3.1.1 A história da indústria do cimento no Brasil**

A indústria do cimento no Brasil teve início no final do século XIX, com a realização das primeiras experiências para produção do material em larga escala [64]. O primeiro cimento produzido no país foi em 1892, pela Companhia Brasileira de Cimento Portland, na cidade de São Paulo [5]. Porém, foi somente a partir da década de 1930 que a indústria do cimento passou a se desenvolver de forma significativa no Brasil, com a construção de diversas fábricas em todo o país.

Nos anos 1950, houve uma grande expansão da indústria do cimento no Brasil, impulsionada pelo crescimento da construção civil e das obras de infraestrutura no país [5]. Com o aumento da demanda, novas empresas foram criadas e novas tecnologias foram desenvolvidas para melhorar a produção e a qualidade do cimento.

Durante as décadas seguintes, a indústria do cimento continuou a crescer e se modernizar no Brasil. A partir dos anos 1990, a privatização das empresas estatais do setor e a entrada de investidores estrangeiros contribuíram para uma maior competitividade e modernização da indústria [5].

Atualmente, a indústria do cimento é uma das mais importantes para a economia brasileira, com uma produção anual de cerca de 60 milhões de toneladas em 2021, segundo dados do Sindicato Nacional da Indústria do Cimento [60]. Além disso, o setor é responsável por gerar empregos e por contribuir para a construção de moradias, infraestrutura e desenvolvimento do país.

No entanto, a indústria do cimento também enfrentou desafios ao longo da sua história no Brasil. Durante a década de 1980, a crise econômica e a alta inflação prejudicaram a indústria, resultando em queda na produção e no fechamento de diversas fábricas [64]. Além disso, a produção de cimento é uma atividade que gera impactos ambientais, como a emissão de gases de efeito estufa, a geração de resíduos sólidos e a utilização de recursos naturais, como a água e a energia elétrica. Por isso, a indústria do cimento no Brasil tem buscado implementar práticas sustentáveis em sua produção, como a utilização de combustíveis alternativos, a reciclagem de resíduos e o monitoramento ambiental [5].

Outro desafio enfrentado pela indústria do cimento no Brasil é a concorrência de materiais alternativos, como o concreto celular e os blocos de concreto, que possuem características similares ao cimento e podem ser produzidos de forma mais sustentável e econômica [5]. Apesar dos desafios, a indústria do cimento continua a ser um setor importante para a economia brasileira, contribuindo para a geração de empregos e para o desenvolvimento do país. Com a adoção de práticas sustentáveis e a busca por inovações tecnológicas, a indústria do cimento poderá continuar a crescer e a se desenvolver de forma sustentável no Brasil.

O trabalho de Guimarães et. al. [64] apresenta uma revisão histórica da indústria do

cimento no Brasil, desde a sua origem até os dias atuais. Segundo os autores, a primeira fábrica de cimento do país foi inaugurada em 1926, no município de Perus, em São Paulo. Nessa época, a produção de cimento ainda era incipiente e limitada, com apenas três fábricas em todo o país.

Com o tempo, a produção de cimento foi se expandindo no Brasil, impulsionada pela demanda crescente por materiais de construção e pelo desenvolvimento da infraestrutura do país. Na década de 1950, a indústria do cimento começou a se consolidar no Brasil, com a criação de novas fábricas e a modernização dos processos de produção. Na década de 1970, a produção de cimento no Brasil atingiu seu auge, com a inauguração de diversas fábricas em todo o país. No entanto, esse período também foi marcado pela falta de planejamento e pela falta de investimentos em infraestrutura, o que acabou gerando problemas para a indústria do cimento e para o país como um todo.

A partir da década de 1980, a indústria do cimento começou a enfrentar desafios, como a crise econômica e a alta inflação, que resultaram em queda na produção e no fechamento de diversas fábricas. No entanto, nos anos 90, a indústria do cimento começou a se recuperar, com a retomada dos investimentos e a modernização dos processos de produção.

Atualmente, a indústria do cimento é um setor importante da economia brasileira, com a produção de cerca de 70 milhões de toneladas por ano e a geração de mais de 10 mil empregos diretos[60]. No entanto, a indústria do cimento também enfrenta desafios, como a concorrência de materiais alternativos e a necessidade de implementar práticas sustentáveis em sua produção.

Apesar dos desafios enfrentados pela indústria do cimento no Brasil, a produção continua crescendo, impulsionada principalmente pelo desenvolvimento da construção civil e da infraestrutura do país. De acordo com a Associação Brasileira de Cimento Portland [5], o setor de construção civil tem um papel fundamental na economia brasileira, contribuindo com cerca de 5% do PIB e gerando milhares de empregos diretos e indiretos em todo o país.

Além disso, a indústria do cimento tem um papel importante na sustentabilidade da construção civil, já que o cimento é um dos principais materiais utilizados na produção de concreto, que por sua vez é utilizado em diversas obras de infraestrutura e construção civil. No entanto, é importante ressaltar que a produção de cimento também pode gerar impactos ambientais significativos, como a emissão de gases de efeito estufa e o consumo de recursos naturais.

Diante desses desafios, a indústria do cimento no Brasil tem buscado implementar práticas sustentáveis em sua produção, como a utilização de fontes renováveis de energia e a reciclagem de resíduos. Além disso, a indústria tem investido em pesquisa e desenvolvimento de novos materiais e tecnologias que possam contribuir para a sustentabilidade da construção civil.

### **3.1.2 Produção de cimento no Brasil**

A produção de cimento no Brasil tem uma longa história de desenvolvimento e crescimento. A produção de cimento no país teve início em 1926, com a instalação da primeira fábrica em Perus, São Paulo. Desde então, a produção de cimento no Brasil tem crescido significativamente, com a instalação de diversas fábricas em todo o país. Atualmente, o Brasil é o terceiro maior produtor de cimento do mundo, atrás apenas da China e da Índia. Em 2020, a produção brasileira de cimento atingiu cerca de 60 milhões de toneladas, um aumento de 3,7% em relação ao ano anterior[5].

Esse crescimento da produção de cimento no Brasil está relacionado principalmente ao desenvolvimento da construção civil e da infraestrutura do país. De acordo com a [5], o setor de construção civil contribui com cerca de 5% do PIB brasileiro e gera mais de 2 milhões de empregos diretos e indiretos em todo o país.



No entanto, a produção de cimento também pode gerar impactos ambientais significativos. Segundo a Agência Nacional de Mineração (ANM)[65], a indústria do cimento é responsável por cerca de 5% das emissões de dióxido de carbono (CO<sub>2</sub>) no Brasil. A produção de cimento consome grandes quantidades de recursos naturais, como calcário e argila.

Diante desses desafios, a indústria do cimento no Brasil tem buscado implementar práticas sustentáveis em sua produção, como a utilização de fontes renováveis de energia e a reciclagem de resíduos. A indústria tem investido em pesquisa e desenvolvimento de novos materiais e tecnologias que possam contribuir para a sustentabilidade da construção civil.

Além disso, a produção de cimento no Brasil também tem enfrentado desafios relacionados à competitividade e à inovação. Segundo dados da [5], a indústria brasileira do cimento tem sido pressionada pela concorrência de cimentos importados, que muitas vezes são comercializados a preços mais baixos. A indústria tem enfrentado dificuldades para inovar e modernizar seus processos produtivos, o que pode comprometer sua competitividade no longo prazo.

Diante desses desafios, a indústria do cimento no Brasil tem buscado implementar medidas para aumentar sua competitividade e inovação. Entre essas medidas, destacam-se a modernização das fábricas, a adoção de novas tecnologias e processos produtivos, e a busca por parcerias e alianças estratégicas.

Outro aspecto importante da produção de cimento no Brasil é a sua distribuição geográfica. De acordo com dados da ABCP [5], a produção de cimento está concentrada nas regiões Sudeste e Nordeste do país, que juntas respondem por mais de 80% da produção nacional. Isso se deve principalmente à existência de grandes jazidas de matérias-primas nessas regiões, como calcário e argila.

No entanto, a concentração geográfica da produção de cimento também pode gerar desafios relacionados ao transporte e logística, o que pode encarecer o produto final e comprometer sua competitividade. Por isso, a indústria do cimento tem buscado investir em infraestrutura de transporte e logística, visando reduzir os custos e aumentar a eficiência da cadeia produtiva.

### **3.1.3 Mercado de cimento no Brasil**

O mercado de cimento no Brasil é influenciado por diversos fatores, como a demanda da construção civil, a oferta de matérias-primas, a concorrência de cimentos importados e as políticas governamentais relacionadas ao setor. De acordo com a Associação Brasileira de Cimento Portland [5], o consumo de cimento no país tem apresentado uma recuperação gradual nos últimos anos, impulsionado pela retomada de investimentos em infraestrutura e pelo aquecimento do mercado imobiliário.

No entanto, apesar dessa recuperação, a indústria do cimento ainda enfrenta desafios relacionados à volatilidade do mercado e às oscilações da economia brasileira. Além disso, a concorrência de cimentos importados, principalmente da Ásia, tem pressionado os preços do produto no mercado nacional [66].

Outro fator importante que afeta o mercado de cimento no Brasil é a sustentabilidade ambiental. A produção de cimento é responsável por significativas emissões de gases de efeito estufa, além de gerar resíduos sólidos e líquidos. Por isso, a indústria do cimento tem investido em práticas sustentáveis, como a utilização de fontes renováveis de energia, a reciclagem de resíduos e a redução das emissões de gases de efeito estufa [5].

Além disso, a sustentabilidade tem se tornado um fator cada vez mais importante na decisão de compra dos consumidores, o que pode impactar a demanda por cimento. Segundo a consultoria Nielsen, mais de 70% dos consumidores brasileiros preferem marcas que se preocupam com o meio ambiente e adotam práticas sustentáveis [67].

Diante desses desafios e oportunidades, a indústria do cimento no Brasil tem buscado implementar medidas para aumentar sua competitividade e sua sustentabilidade ambiental. Entre essas medidas, destacam-se a modernização das fábricas, a adoção de novas tecnologias e processos produtivos sustentáveis, e a busca por parcerias e alianças estratégicas. Outro aspecto importante a ser considerado no mercado de cimento no Brasil é a concentração da produção nas mãos de poucas empresas. Segundo dados da ABCP[5], as cinco maiores produtoras de cimento do país detêm cerca de 80% do mercado nacional. Isso pode limitar a concorrência e aumentar os preços do produto para os consumidores finais.

No entanto, também existem oportunidades para a indústria do cimento no Brasil, especialmente em relação ao mercado externo. A exportação de cimento brasileiro tem crescido nos últimos anos, impulsionada pela alta qualidade do produto e pela proximidade geográfica com alguns mercados consumidores, como a América Latina e a África [5]. Além disso, o Brasil possui um grande potencial para a produção de cimento sustentável, o que pode se tornar um diferencial competitivo no mercado global.

No cenário da produção de cimento no Brasil, alguns estados se destacam como os maiores produtores do país. De acordo com dados da ABCP[5], em 2020, os três estados que mais produziram cimento foram Minas Gerais, São Paulo e Paraná, responsáveis por mais de 60% da produção nacional. Minas Gerais é o maior produtor de cimento do país, com mais de 25% da produção total em 2020. Esse estado tem uma forte tradição na mineração, o que explica a sua liderança na produção de cimento. Além disso, o estado possui uma grande quantidade de calcário, principal matéria-prima para a produção de cimento, o que contribui para a sua posição de destaque no setor.

São Paulo é o segundo maior produtor de cimento do Brasil, com cerca de 20% da produção nacional em 2020. Esse estado possui uma infraestrutura mais desenvolvida e uma forte presença da indústria da construção civil, o que explica a sua posição de destaque na produção de cimento. O Paraná ocupa o terceiro lugar na produção de cimento, com cerca de 16% da produção total em 2020. Esse estado tem uma localização estratégica, próximo aos principais mercados consumidores do Sul e Sudeste do país, o que favorece o escoamento da produção.

A representatividade desses estados na produção de cimento reflete a importância desse setor na economia brasileira. Além de gerar empregos e renda para a população, a produção de cimento é fundamental para o desenvolvimento da construção civil, um setor que tem grande impacto em diversos outros setores da economia, como o de serviços e o imobiliário.

### **3.1.4 Impactos ambientais da indústria do cimento**

A indústria do cimento é uma atividade que pode gerar impactos ambientais significativos. Alguns dos principais impactos estão relacionados à emissão de gases de efeito estufa (GEE) e ao uso de recursos naturais.

#### **3.1.4.1 Emissão de gases de efeito estufa**

A produção de cimento é uma atividade que demanda um grande consumo de energia e emite uma quantidade significativa de gases de efeito estufa (GEE), principalmente dióxido de carbono (CO<sub>2</sub>). Segundo a Agência Internacional de Energia (AIE), o setor cimenteiro é responsável por cerca de 7% das emissões globais de CO<sub>2</sub> [68].

No Brasil, a indústria do cimento é responsável por cerca de 1,5% das emissões nacio-

nais de GEE, de acordo com o Inventário Nacional de Emissões de Gases de Efeito Estufa [69]. Essa emissão ocorre principalmente durante a produção do clínquer, principal componente do cimento, que é obtido pela calcinação de calcário e argila em altas temperaturas. Além disso, a produção de energia para o funcionamento das fábricas também contribui para as emissões de GEE.

#### **3.1.4.2 Uso de recursos naturais**

A produção de cimento também tem um grande impacto no uso de recursos naturais, como água e minerais. A produção de uma tonelada de cimento consome cerca de 1,6 toneladas de matéria-prima, sendo que a maior parte dessa matéria-prima é composta por calcário e argila [5]. Além disso, a produção de cimento requer grandes quantidades de água para resfriar os equipamentos e para a produção do concreto.

Essa grande demanda por recursos naturais pode ter impactos negativos na biodiversidade e no equilíbrio hidrológico local, especialmente em áreas onde há escassez de água. Além disso, a extração de matéria-prima pode levar à degradação ambiental e à perda de habitats naturais.

#### **3.1.5 Tecnologias mais eficientes e sustentáveis na produção de cimento**

A indústria do cimento tem buscado cada vez mais tecnologias mais eficientes e sustentáveis na produção de cimento. Algumas das tecnologias mais promissoras são aquelas que visam a redução das emissões de gases de efeito estufa (GEE) e a utilização de fontes renováveis de energia.

##### **3.1.5.1 Produção de cimento de baixo carbono**

A produção de cimento de baixo carbono é uma das tecnologias mais promissoras para a redução das emissões de GEE na indústria do cimento. Uma das formas de produzir cimento de baixo carbono é através da substituição parcial do clínquer por materiais alternativos, como cinzas volantes, escórias de alto-forno, pozolanas naturais e artificiais, entre outros. Essa substituição pode reduzir a quantidade de calcário necessária para a produção do clínquer, o que por sua vez reduz as emissões de CO<sub>2</sub> durante a produção de cimento (ABCP, 2021)[5].

Outra forma de produzir cimento de baixo carbono é através da utilização de combustíveis alternativos, como biomassa e resíduos sólidos urbanos. Essa tecnologia permite a substituição parcial ou total do combustível fóssil utilizado na produção de cimento, o que reduz as emissões de CO<sub>2</sub> durante a produção de energia para as fábricas de cimento [5].

A produção de cimento de baixo carbono é uma das formas mais promissoras de reduzir as emissões de gases de efeito estufa na indústria do cimento. Essa tecnologia permite a substituição do clínquer por materiais alternativos na produção de cimento, que possuem menor conteúdo de carbono. Esses materiais podem ser pozolanas, como a cinza volante e as escórias de alto-forno, entre outros [70].

Além disso, a produção de cimento de baixo carbono também pode ser alcançada através da utilização de tecnologias que permitem a captura e armazenamento de carbono (CCS, na sigla em inglês). Essa tecnologia consiste em capturar o dióxido de carbono (CO<sub>2</sub>) emitido durante a produção de cimento e armazená-lo em locais apropriados, como em reservatórios subterrâneos [71].

### **3.1.5.2 Uso de fontes renováveis de energia**

O uso de fontes renováveis de energia, como a solar e a eólica, tem se mostrado uma alternativa promissora para reduzir as emissões de GEE na indústria do cimento. Essa tecnologia pode ser utilizada tanto para a produção de energia elétrica para o funcionamento das fábricas de cimento, como para a produção de energia térmica necessária na produção de cimento [5].

A energia eólica é utilizada principalmente para a produção de energia elétrica para as fábricas de cimento. Já a energia solar pode ser utilizada para a produção de energia elétrica e térmica na produção de cimento. A utilização da energia solar pode ser feita através da instalação de painéis solares nas fábricas de cimento ou através da construção de usinas solares próximas às fábricas [70].

Além disso, a utilização de fontes renováveis de energia pode trazer benefícios econômicos e sociais para as comunidades locais, como a geração de empregos e a redução da dependência de combustíveis fósseis importados. No entanto, a implantação dessas tecnologias requer investimentos significativos e mudanças na estrutura atual da indústria do cimento [71].

### **3.1.6 Regulamentação da indústria do cimento no Brasil**

A indústria do cimento no Brasil é regulamentada por diversas leis e resoluções, com o objetivo de garantir a sua sustentabilidade e minimizar os impactos ambientais. Uma das principais leis é a Política Nacional de Resíduos Sólidos, instituída pela Lei nº 12.305/2010. Essa lei estabelece diretrizes para a gestão integrada e o gerenciamento ambientalmente adequado dos resíduos sólidos, incluindo os gerados pela indústria do cimento.

Além disso, a Resolução CONAMA nº 307/2002 dispõe sobre a gestão de resíduos da construção civil, incluindo os resíduos gerados pela produção de cimento. Essa resolução estabelece diretrizes para a gestão dos resíduos da construção civil, desde a geração até a disposição final, visando a sua redução, reutilização e reciclagem [63].

Outra regulamentação importante é a Resolução CONAMA nº 436/2011, que estabelece limites máximos de emissão de poluentes atmosféricos para a indústria do cimento. Essa resolução estabelece limites para a emissão de material particulado, dióxido de enxofre, óxidos de nitrogênio e dióxido de carbono, entre outros poluentes [72].

É importante ressaltar que a indústria do cimento no Brasil vem adotando tecnologias mais limpas e sustentáveis, buscando reduzir os impactos ambientais e atender às regulamentações em vigor. Dessa forma, é possível conciliar o desenvolvimento econômico com a preservação do meio ambiente.

A indústria do cimento tem uma longa história no Brasil e é uma das principais atividades econômicas do país. A produção de cimento tem um impacto significativo no meio ambiente, em especial na emissão de gases de efeito estufa e no uso de recursos naturais. No entanto, a indústria tem trabalhado para implementar tecnologias mais eficientes e sustentáveis, como a produção de cimento de baixo carbono e o uso de fontes renováveis de energia.

Além disso, existem regulamentações importantes, como a Lei nº 12.305/2010 - Política Nacional de Resíduos Sólidos e a Resolução CONAMA nº 307/2002 - Gestão de resíduos da construção civil, que visam mitigar os impactos ambientais da indústria do cimento [62, 63].

É importante que a indústria do cimento continue a buscar soluções mais sustentáveis para sua produção e a cumprir as regulamentações ambientais, garantindo assim um desenvolvimento econômico que respeite os limites do meio ambiente. A busca por tecnologias mais eficientes e sustentáveis pode ser uma oportunidade para a indústria do cimento se destacar e contribuir para a transição para uma economia mais verde e sustentável.

Portanto, é necessário que haja uma maior conscientização e colaboração entre os diversos setores da sociedade para garantir um desenvolvimento econômico sustentável e a preservação do meio ambiente.

## Referencial teórico

### 4.1 Metodologia

Com o objetivo de realizarmos previsões da demanda de consumo de energia elétrica, inicialmente, foram coletados os dados de consumo no sítio eletrônico da Empresa de Pesquisa Energética (EPE) [2] e no Sindicato Nacional da Indústria do Cimento (SINC) [4], no período entre janeiro de 2001 e dezembro de 2021. O período escolhido, de janeiro de 2001 a dezembro de 2019, é significativo por compor uma série histórica extensa e fornecer um volume robusto de dados, facilitando a análise estratégica em diversos cenários. Esses dados mensais foram utilizados para ajustar o conjunto de treinamento. Para o horizonte de previsão dos modelos, foram considerados os dados de janeiro de 2020 a dezembro de 2021. No entanto, isso não compromete a pesquisa, cujo o intuito é apresentar e discutir a importância dessa abordagem para previsão de curto, médio e longo prazo.

Inúmeras são as formas e modelos existentes na literatura para estimar o consumo industrial de energia e são definidos a partir do comportamento dos dados em análise. O modelo proposto visa, de forma objetiva, analisar as questões de variação de demanda de consumo de energia elétrica da indústria de cimento no Brasil.

O desempenho dos modelos foi medido através das métricas de precisão raiz do erro quadrático médio (RMSE - root mean squared error), e o erro médio absoluto percentual (MAPE - Mean Absolute Percentage Error).

As análises estatísticas foram realizadas através do programa R 4.0.5 (The R foundation for Statistical Computing, Vienna, Austria; <http://www.r-project.org>).

#### 4.1.1 Identificação dos modelos

Para que possamos identificar os modelos apropriados, nosso primeiro passo deve ser analisar os dados coletados ao longo do tempo da série temporal investigada. A análise desses dados pode ser representada a partir de um gráfico que pode nos indicar a presença de tendência (crescente, decrescente ou estacionária) ou alteração na variância, o que nos indicará o comportamento apresentado pela série. Ou seja, o comportamento dos dados de consumo mensal de energia elétrica para produção de cimento no Brasil.

O passo seguinte é analisar as funções de autocorrelações (ACF - autocorrelation function) e de autocorrelações parciais (PACF - partial autocorrelation function). A partir do comportamento dessas funções será possível indicarmos quais os modelos que serão utilizados, assim como nos auxiliará na tomada de decisão e nos testes aplicados aos modelos aplicados. Em seguida pode-se observar que a (ACF) irá apresentar o decaimento da série, chegando a

zero nas primeiras defasagens ou não, o que indicará o seu comportamento, e que será indicado a partir de um modelo AR(1).

Já a (PACF) apresenta as autocorrelações parciais, as quais medem a correlação entre o valor de  $Z_t$  e  $Z_{t-k}$ , em que são descontados a influência dos valores de  $Z_{t-1}$  até obtermos uma  $Z_{t-k+1}$ , e são obtidas pelas equações de Yule-Walker. Observa-se que apenas a autocorrelação de defasagem 1 que é significativa, o que reforça a ideia da aplicação do modelo AR(1). Visto que a série em análise pode ser considerada não estacionária, a ordem de integração será maior que zero, isto é,  $d > 0$ .

## **4.2 A importância da construção civil para a economia brasileira**

Um dos princípios fundamentais da economia postula que o Estado deve ajustar seus gastos públicos de acordo com os ciclos econômicos favoráveis ou desfavoráveis [73]. Durante fases de crescimento econômico acima do potencial, é aconselhável para o governo reduzir os gastos públicos, permitindo a desaceleração da economia e o aumento de suas reservas por meio do incremento da receita tributária gerada pela expansão econômica.

Simultaneamente, durante períodos de recessão econômica, a teoria sugere que o governo deve aumentar os gastos, principalmente por meio de despesas de capital, dada sua capacidade de gerar efeitos multiplicadores mais significativos em comparação com as despesas correntes. Esse princípio, conhecido como política anticíclica, seja contracionista ou expansionista, foi amplamente desenvolvido pelo economista inglês John Maynard Keynes, fundador da Macroeconomia.

As políticas anticíclicas, também conhecidas como políticas keynesianas, são implementadas de maneira sistemática por economias avançadas, como indicado em [74], destacando-se os Estados Unidos como líder na aplicação dessas políticas entre 1980 e 2016. Em contraste, muitos países em desenvolvimento adotaram uma abordagem pró-cíclica em sua política fiscal, cometendo erros ao gastar ou economizar no momento inadequado.

Para analisar a situação fiscal recente da economia nacional, podemos dividir em quatro períodos distintos:

- (i) consolidação fiscal, 1999-2004;
- (ii) flexibilização fiscal por meio de investimentos públicos, 2005-2010;
- (iii) flexibilização fiscal com subsídios e desonerações, 2011-2014; e
- (iv) a hipótese de austeridade fiscal expansionista, a partir de 2015 [75].

Cada período apresenta características específicas, destacando a importância de uma abordagem cuidadosa e adaptável às circunstâncias econômicas.

Destaca-se o papel da indústria do cimento nesse contexto econômico, uma vez que esta desempenha um papel fundamental em projetos de infraestrutura e investimentos públicos. A produção e o consumo de cimento são indicadores-chave do desenvolvimento econômico, refletindo diretamente a atividade na construção civil e em setores correlatos. Durante períodos de flexibilização fiscal via investimentos públicos (como no período marcado pela expansão nos investimentos públicos de 2005-2010), a demanda por materiais de construção, incluindo cimento, tende a aumentar. Isso não apenas impulsiona a indústria do cimento, mas também gera efeitos multiplicadores na economia, criando empregos e estimulando o crescimento em cadeias produtivas relacionadas. Projetos como PAC 1 demonstram capacidade do Estado em gerar crescimento através de investimentos em infraestrutura.

Por outro lado, estratégias de flexibilização fiscal via subsídios e desonerações (como observado no período 2011-2014) podem ter impactos diferenciados na indústria do cimento. A dependência de subsídios diretos ou a redução de tributos sobre a produção de cimento pode



não ser tão eficaz quanto investimentos diretos em infraestrutura para impulsionar a demanda por cimento. Nesse período o Brasil passou por obras de infraestrutura com impacto reduzido na economia, como a Copa do Mundo de 2014.

No contexto da política fiscal conduzida pela hipótese de "austeridade expansionista" após 2015, a indústria do cimento foi afetada negativamente devido ao congelamento real dos gastos públicos. Mesmo com eventos localizados, como as Olimpíadas de 2016, não houve grandes investimentos em infraestrutura ou projetos de desenvolvimento que tivesse como foco o setor da construção civil. A redução nos investimentos em infraestrutura pode resultar em uma diminuição na demanda por cimento, impactando não apenas a indústria em si, mas também setores relacionados e a economia como um todo. Portanto, ao analisar as políticas fiscais, é essencial considerar a interconexão entre as decisões governamentais e setores-chave, como a indústria do cimento, reconhecendo seu papel vital na promoção do crescimento econômico sustentável.

### 4.3 Séries temporais

Uma série temporal é conhecida como um conjunto de valores a partir de uma variável, que são representados ao longo do tempo. No estudo de estatística, podemos observar que esta análise se distingue das demais realizadas pelo fato de as observações em análise serem registradas em períodos distintos e ao mesmo tempo sucessivos; logo, é possível analisarmos a dependência entre os dados passados e presentes entre si.

Para Morettin et al. [76], os modelos utilizados para descrever séries temporais são processos estocásticos, ou seja, processos que são controlados ao longo de um determinado período por leis probabilísticas.

Com base nessas informações, faz-se necessário conhecermos alguns pontos antes de iniciarmos uma análise de séries temporais que são os dados e os componentes da série, para tal, são utilizados com frequência os seguintes passos:

- Tendência (T): É comum encontrarmos essa componente em uma série temporal quando esta apresenta crescimento ou decrescimento, é preciso ressaltar que os dados não necessariamente precisam apresentar linearidade.

- Sazonalidade (S): É comum encontrarmos essa componente em uma série temporal em que os dados se repetem em uma mesma semana, mês, trimestre, semestre, anos, entre outros.

- Ciclo (C): Diferente da sazonalidade, no ciclo temos um padrão de repetição que apresenta certa regularidade. No entanto, não segue um mesmo modelo dentro de um período estimado.

Em que  $Z_t$  é uma série temporal representada pelas combinações das componentes de tendência, sazonalidade e componente aleatória. Onde o modelo aditivo pode ser descrito da seguinte maneira:

$$Z_t = T_t + S_t + a_t \quad (4.1)$$

No modelo multiplicativo utilizamos as mesmas componentes e aplicamos o produto entre elas:

$$Z_t = T_t \times S_t \times a_t \quad (4.2)$$

Onde  $Z_t$  é considerado uma variável dependente,  $T_t$  uma componente de tendência,  $S_t$  é a componente de sazonalidade e  $a_t$  é a componente aleatória.

Ao removermos as componentes  $T_t$  e  $S_t$ , o que teremos será apenas a componente aleatória residual ou ainda irregular,  $a_t$ . Assim,  $a_t$  é um ruído branco, ou seja, trata-se de um



processo estocástico com distribuição normal, média zero e variância constante. Para [24] em séries com ruído branco, esperamos que cada autocorrelação seja próxima de zero. Claro, eles não serão exatamente iguais a zero, pois há alguma variação aleatória.

O modelo aditivo é considerado mais adequado quando os dados em análise apresentam as seguintes características: sazonalidade e comportamento aleatório, ou seja, não depende de outras componentes, como por exemplo a tendência. Contudo, é preciso observarmos se as amplitudes sazonais apresentam variações em sua tendência, caso isso ocorra o modelo mais adequado será o multiplicativo.

Os processos de transformação das séries temporais são utilizados para que se estabeleça a variância e a partir desse passo tornar o efeito sazonal aditivo. Em determinadas séries em que temos a presença de tendência, pode ser necessário um acréscimo da variância, e para determinarmos esta necessidade é fundamental que observemos os dados ao longo do tempo. Em casos como esse há utilização de uma transformação logarítmica torna-se adequada.

A análise das séries temporais tem a finalidade de interpretar e isolar tais componentes. Nesse sentido, o isolamento busca identificar os componentes e adquirir informações relevantes ao estudo e as previsões de valores futuros. Contudo, é preciso observar que quando analisamos várias componentes, elas podem agir de modo isolado ou interligados e só é possível fazermos previsões com base nos dados, se as propriedades de suas componentes permanecerem ou se apresentarem estáveis durante o tempo em análise.

Na figura 4.1 abaixo temos um exemplo clássico de uma série temporal que apresenta uma frequência mensal. Nesta figura é possível observarmos a série temporal de consumo de energia elétrica em Gwh, apresentando dados de janeiro de 2001 a dezembro de 2021, da indústria de cimento do Brasil.

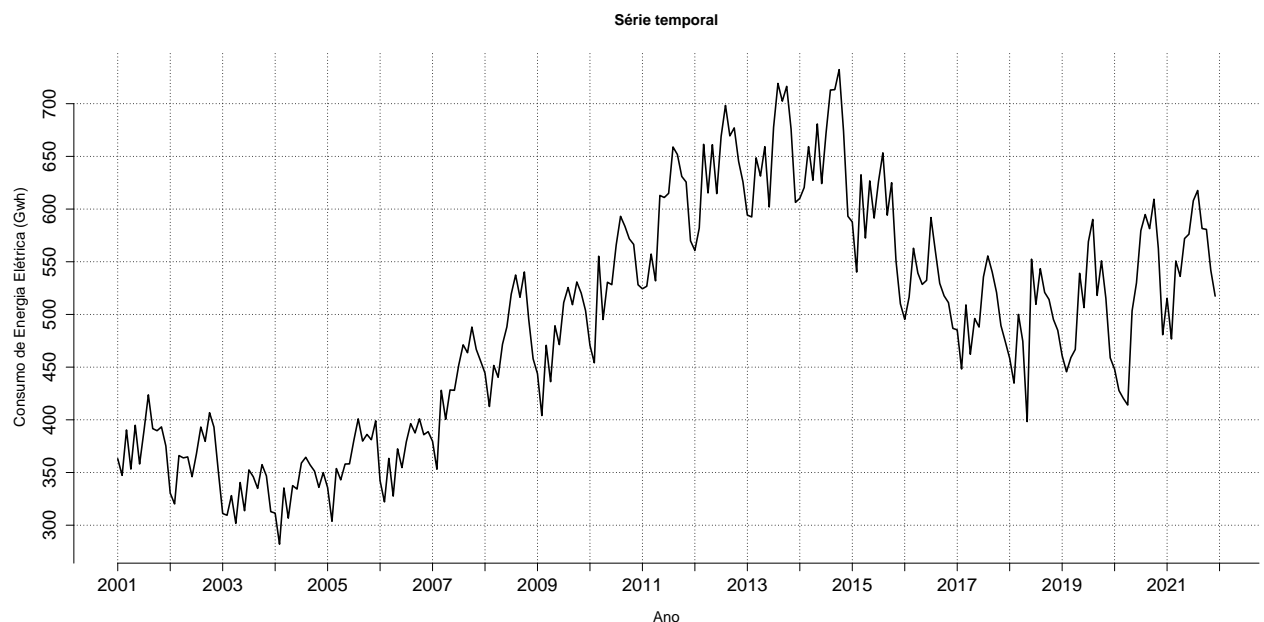


Figura 4.1 – série temporal de consumo de energia elétrica em Gwh, dados de janeiro de 2001 a dezembro de 2021, da indústria de cimento do Brasil

#### 4.4 Componentes de tendência

A tendência de uma série possui o objetivo de indicar o seu comportamento ao longo do tempo; ou seja, se ela pode ser classificada por apresentar aumento ou redução gradual das observações ao longo de um determinado período. Em outras palavras, a partir desse método é possível descrevermos se ela cresce, decresce ou permanece estável, e ainda identificar em que velocidade essas mudanças ocorrem.

Os métodos utilizados com frequência para estimar  $T_t$  são tendência polinomial, suavização e o método das diferenças.

Os testes frequentemente utilizados para identificar a componente de tendência apresentada em uma série temporal são os de sequências (Wald-Wolfowitz) e o de sinais (Cox-Stuart). Podemos encontrar mais. Com relação a cada um dos testes citados podemos afirmar que o de Wald-Wolfowitz, também conhecido como run test, tem o objetivo de verificar se os dados de uma série temporal se comportam de forma aleatória; já o teste de sinais (Cox-Stuart) é um dos mais recomendados para análises em que o objetivo é de verificar a presença ou existência de tendências monótonas, ou seja, se os dados são crescentes ou decrescentes [76].

#### 4.5 Componente sazonal

A componente de sazonalidade reflete as variações periódicas que ocorrem em subperíodos, podendo ser identificadas em escalas mensais, trimestrais, diárias, entre outras. Para estimar a componente de sazonalidade  $S_t$ , primeiramente, obtemos as estimativas  $\hat{S}_t$  de  $S_t$  e, em seguida, subtraímos esta série estimada de  $Z_t$ . A série temporal ajustada sazonalmente, para um modelo aditivo, é expressa por:

$$Z_t^{SA} = Z_t - \hat{S}_t \quad (4.3)$$

No caso de um modelo multiplicativo, representado por:

$$Z_t = T_t \cdot S_t \cdot \epsilon_t \quad (4.4)$$

a transformação para um modelo aditivo é realizada através da aplicação do logaritmo, resultando na série ajustada sazonalmente como:

$$Z_t^{SA} = \log(Z_t) - \log(\hat{S}_t) \quad (4.5)$$

ou equivalentemente, se  $Z_t$  e  $\hat{S}_t$  estiverem em escala logarítmica:

$$Z_t^{SA} = Z_t - \hat{S}_t \quad (4.6)$$

Ao estimar  $S_t$ , introduzimos o erro de ajuste sazonal  $\delta_t$ , que é a diferença entre a componente de sazonalidade real  $S_t$  e a estimada  $\hat{S}_t$ :

$$\delta_t = S_t - \hat{S}_t \quad (4.7)$$

O termo  $\delta_t$  é essencial na análise de séries temporais para avaliar a precisão da estimativa sazonal. A minimização do erro de ajuste sazonal, frequentemente representada pela minimização de  $E(\delta_t^2)$ , é um objetivo comum em processos de ajuste sazonal, visando melhorar a precisão do modelo.

Existem diversos métodos para estimar  $S_t$ , sendo os mais comuns o método de regressão e o método de médias móveis [76], é um excelente meio para séries que apresentam sazonalidade e características determinísticas, ou seja, que podem ser previstas a partir de meses anteriores. No que tange ao método de médias móveis é mais adequado quando temos uma série temporal cuja o componente de sazonalidade apresenta variação ao longo do tempo, ou seja, para séries cuja sazonalidade é estocástica.

#### 4.6 Métricas

O desempenho dos modelos foi medido através das métricas de precisão raiz do erro quadrático médio (RMSE) e o erro médio absoluto percentual (MAPE).

(a) A raiz quadrática média dos erros entre valores observados (reais) e predições (hipóteses).

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (4.8)$$

(b) O erro médio absoluto percentual (MAPE) É definido por

$$MAPE = 100 \times \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4.9)$$

As duas métricas RMSE e MAPE são baseadas apenas no ajuste do modelo comparando se os valores previstos médios com os observados.

#### 4.7 Médias móveis simples

No método das Médias Móveis Simples (MMS), o estimador  $\hat{\mu}_t(N)$ , também denotado por  $M_t$ , corresponde à média aritmética dos últimos  $N$  valores da série  $Z_t$ . E pode ser representado da seguinte forma:

$$\hat{\mu}_t(N) = M_t = \frac{1}{N} \sum_{i=0}^{N-1} Z_{t-i} \quad (4.10)$$

A previsão  $h$  passos à frente,  $\hat{Z}_t(h)$ , é igualmente representada por  $M_t$ . Este método atualiza continuamente os valores na série, onde o dado mais antigo é substituído pelo mais recente, caracterizando o processo como "médias móveis". A eficácia do método reside na sua simplicidade e na capacidade de incorporar novos dados de forma dinâmica na série [76].

#### 4.8 Amortecimento Exponencial Simples

O método das médias móveis possui uma desvantagem evidente: todos os elementos que participam da estimativa da previsão possuem o mesmo peso,  $\frac{1}{N}$ . Isso pode ser inadequado, considerando que, frequentemente, espera-se que os elementos mais recentes da série histórica tenham maior relevância para a previsão.

Para superar essa limitação, introduzimos o conceito de amortecimento exponencial. A partir da equação recursiva das médias móveis:

$$M_t = M_{t-1} + \frac{Z_t - Z_{t-N}}{N} \quad (4.11)$$

podemos adaptá-la considerando  $M_{t-1}$  como um estimador de  $Z_{t-N}$ , resultando em:

$$M_t = \frac{1}{N}Z_t + \left(1 - \frac{1}{N}\right)M_{t-1} \quad (4.12)$$

Substituindo  $\frac{1}{N}$  por  $\alpha$ , obtemos a fórmula do amortecimento exponencial simples:

$$\hat{\mu}_t(N) = M_t = \alpha Z_t + (1 - \alpha)M_{t-1} \quad (ii) \quad (4.13)$$

A equação (ii) representa o amortecimento exponencial simples, onde  $\alpha$ , a constante de amortecimento, varia entre 0 e 1. Através de substituições sucessivas, define-se o estimador  $M_t$ :

$$\hat{\mu}_t(N) = M_t = \alpha Z_t + \alpha(1 - \alpha)Z_{t-1} + \alpha(1 - \alpha)^2 Z_{t-2} + \dots + \alpha(1 - \alpha)^{t-1} M_1 \quad (4.14)$$

Nessa abordagem, cada elemento da série histórica recebe um peso diferenciado, com os dados mais recentes tendo um peso maior e decrescendo exponencialmente para os dados mais antigos. O valor inicial,  $M_1$ , é geralmente escolhido como a média aritmética das primeiras observações ou igual a  $M_0 = Z_1$  [76].

#### 4.9 Modelos de Holt-Winters

O Método sazonal Holt-Winters foi desenvolvido por Charles Holt e Peter Winters em 1960 (Holt Winters, 1960) [76] e tem sido amplamente utilizado em diversos campos, como finanças, marketing e previsão de demanda.

A abordagem aditiva do método Holt-Winters assume que a série temporal é composta por três componentes principais: nível, tendência e sazonalidade. O nível representa a média da série temporal, a tendência representa a direção geral da série ao longo do tempo e a sazonalidade representa a variação regular que ocorre em períodos fixos, como dias da semana, semanas ou meses. A mesma pode ser representada da seguinte forma:

$$Z_t = a_1 + b_1 t + S_t + e_t \quad (4.15)$$

Em que  $e_t$  é o ruído e,  $a_1, b_1 e S_t$  são, respectivamente, os parâmetros de nível, tendência e sazonalidade. Já a previsão dos valores futuros e dada pela série no método aditivo, representado abaixo:

$$\hat{Z}_t(h) = L_t + hT_t + S_{t+h-s}, \quad h = 1, 2, \dots, s \quad (4.16)$$

onde  $h$  é o horizonte de previsão e  $s$  é uma estação completa de sazonalidade ou o chamado período sazonal.

A componente de nível  $L_t$  é representada por:

$$L_t = \alpha(Z_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1}), \quad 0 < \alpha < 1 \quad (4.17)$$

onde  $\alpha$  é a constante de suavização da componente de nível.

A componente de tendência é representada por:

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}, \quad 0 < \beta < 1 \quad (4.18)$$

onde  $\beta$  é a constante de suavização da componente de nível.

A componente de sazonalidade é representada por:

$$S_t = \gamma(Z_t - L_t) + (1 - \gamma)S_{t-s}, \quad 0 < \gamma < 1 \quad (4.19)$$

onde  $\gamma$  é a constante de suavização da componente de sazonalidade.

Por outro lado, a série temporal descrita pelo modelo de Holt-Winters multiplicativo pode ser expressa por

$$Z_t = (a_t + b_t)S_t + \varepsilon_t \quad (4.20)$$

onde  $\varepsilon_t$  é o ruído e,  $a_t$ ,  $b_t$  e  $S_t$  são, respectivamente, os parâmetros de nível, tendência e sazonalidade.

A previsão dos valores futuros da série no método multiplicativo é dado por

$$\hat{Z}_t(h) = (L_t + hT_t)S_{t-s+h}, \quad h = 1, 2, \dots, s \quad (4.21)$$

onde  $h$  é o horizonte de previsão e  $s$  é uma estação completa de sazonalidade.

A componente de nível  $L_t$  é representada por:

$$L_t = \alpha \left( \frac{Z_t}{S_{t-s}} \right) + (1 - \alpha)(L_{t-1} + T_{t-1}), \quad 0 < \alpha < 1 \quad (4.22)$$

onde  $\alpha$  representa a constante de suavização da componente de nível.

A componente de tendência  $T_t$  é expressa como:

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}, \quad 0 < \beta < 1 \quad (4.23)$$

onde  $\beta$  é a constante de suavização da componente de tendência.

A componente de sazonalidade  $S_t$  é descrita por:

$$S_t = \gamma \left( \frac{Z_t}{L_t} \right) + (1 - \gamma)S_{t-s}, \quad 0 < \gamma < 1 \quad (4.24)$$

onde  $\gamma$  é a constante de suavização da componente de sazonalidade.

Os métodos de Holt-Winters, tanto aditivos quanto multiplicativos, podem incluir um amortecimento na tendência. Isso resulta em uma versão do método conhecida como Holt-Winters com tendência amortecida. Este método frequentemente proporciona previsões precisas e robustas para dados com padrões sazonais.

A previsão dos valores futuros da série no método de Holt-Winters com tendência amortecida é fornecida pela fórmula:

$$\hat{Z}_t(h) = (L_t + (\phi + \phi^2 + \dots + \phi^h)T_t)S_{t-s+h_m^+}, \quad h = 1, 2, \dots, s \quad (4.25)$$

onde  $\phi$  é a taxa de crescimento local.

Onde  $h$  é o horizonte de previsão,  $s$  é uma estação completa de sazonalidade e  $\phi$  é a taxa de crescimento local.

A componente de nível  $L_t$  é representada por:

$$L_t = \alpha \left( \frac{Z_t}{S_{t-s}} \right) + (1 - \alpha)(L_{t-1} + \phi T_{t-1}), \quad 0 < \alpha < 1 \quad (4.26)$$

onde  $\alpha$  é a constante de suavização da componente de nível.

A componente de tendência é representada por:

$$T_t = \beta^* (L_t - L_{t-1}) + (1 - \beta^*) \phi T_{t-1}, \quad 0 < \beta^* < 1 \quad (4.27)$$

onde  $\beta^*$  é a constante de suavização da componente de nível.

A componente de sazonalidade é representada por:

$$S_t = \gamma^* \left( \frac{Z_t}{L_{t-1} + \phi T_{t-1}} \right) + (1 - \gamma^*) S_{t-s}, \quad 0 < \gamma^* < 1 \quad (4.28)$$

Onde  $\gamma^*$  é a constante de suavização da componente de sazonalidade.

A determinação dos parâmetros  $\alpha$ ,  $\beta^*$ , e  $\gamma^*$  é uma etapa crucial na modelagem de séries temporais. Estes parâmetros são comumente obtidos por meio da minimização da soma dos erros quadráticos de previsão.

#### 4.10 Modelos Box e Jenkins

A metodologia proposta por Box e Jenkins (1970) [21] representa um marco na análise e modelagem de séries temporais. Este método sistemático visa ajustar modelos Autoregressivos Integrados de Médias Móveis (ARIMA), comumente representados pela notação ARIMA(p, d, q). Nesta formulação,  $p$  denota a ordem dos componentes autorregressivos AR(p),  $d$  o grau de diferenciação requerido para alcançar a estacionariedade da série e  $q$  a ordem dos componentes de médias móveis MA(q).

O processo de Box-Jenkins pode ser descrito em três etapas principais: identificação, estimação e verificação. Na fase de identificação, ferramentas como a Função de Autocorrelação (ACF) e a Função de Autocorrelação Parcial (PACF) são empregadas para determinar os parâmetros iniciais  $p$ ,  $d$ , e  $q$ . A ACF é útil para identificar a ordem potencial de um modelo MA(q), enquanto a PACF é frequentemente usada para determinar a ordem de um modelo AR(p). O parâmetro  $d$  é estimado pela observação do número de diferenças necessárias para que a série temporal se torne estacionária.

Após a identificação dos parâmetros, a etapa de estimação utiliza métodos de otimização numérica para ajustar os coeficientes do modelo ARIMA aos dados. Tradicionalmente, o método de máxima verossimilhança é aplicado para estimar os parâmetros do modelo.

A etapa de verificação, ou diagnóstico, envolve o exame dos resíduos do modelo ajustado para assegurar que eles se comportem como ruído branco, isto é, sejam independentes e identicamente distribuídos com média zero e variância constante.

A estratégia utilizada para a construção de modelos, pela metodologia Box & Jenkins, é baseada no ciclo iterativo, Figura 4.2, no qual a estrutura do modelo é formada pelos próprios elementos da série.

Nas subseções a seguir detalharemos as definições e usos da ACF e da PACF, bem como as técnicas envolvidas na estimação e diagnóstico do modelo ARIMA, fornecendo assim uma base sólida para a análise de séries temporais conforme proposto por Box e Jenkins.

##### 4.10.1 Função de Autocorrelação FAC

A função de autocorrelação (FAC) mostra a dependência entre os inúmeros termos da série temporal[76]. Seu gráfico é chamado de correlograma e mostra a autocorrelação de lag  $k$ , entre  $Z_t$  e  $Z_t - k$ , para diferentes valores da defasagem  $k$  no tempo.




Figura 4.2 – Fluxograma do ciclo iterativo de Box & Jenkins

Seja um processo estacionário  $Z(t)$  com média  $\mu$  e variância  $\sigma^2$ , então a função de autocorrelação pode ser expressa [77] por:

$$\rho_j = \frac{\gamma_j}{\gamma_0} = \frac{\gamma_j}{\sigma^2} \quad (4.29)$$

onde  $\gamma_j$  é a função de autocovariância.

Ao Consideramos as observações  $Z_1, Z_2, \dots, Z_N$ , a função de autocorrelação (FAC)  $\rho_j$  é estimado por:

$$\hat{\rho}_j = r_j, \quad (4.30)$$

onde  $r_j$  é definido por:

$$r_j = \frac{c_j}{c_0}, \quad j = 0, 1, \dots, N-1, \quad (4.31)$$

onde  $c_j$  é a estimativa da função de autocovariância  $\gamma_j$  definido por:

$$c_j = \frac{1}{N} \sum_{i=1}^{N-j} (Z_{i+j} - \bar{Z})(Z_i - \bar{Z}) = \text{Cov}(Z_i, Z_{i+j}), \quad (4.32)$$

para  $j = 0, 1, \dots, N-1$ , e  $\bar{Z}$  é a média amostral, representada por:

$$\bar{Z} = \frac{1}{N} \sum_{i=1}^N Z_i. \quad (4.33)$$

#### 4.10.2 Função de Autocorrelação Parcial FACP

A correlação entre  $Z_t$  e  $Z_{t-k}$ , removendo o efeito das variáveis  $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$  para séries estacionárias, é chamada de autocorrelação parcial na posição  $k$  e será denotada por  $\phi_{kk}$ . Assumindo que  $Z_t$  seja normalmente distribuído, temos:

$$\phi_{kk} = \text{Cor}(Z_t, Z_{t-k} | Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}) \quad (4.34)$$

onde  $\phi_{kk}$  é o coeficiente de correlação da distribuição de  $Z_t$  condicional a  $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$ .

Seja um processo estacionário com FAC  $\rho_k$ , um método para obter a FACP  $\phi_{kk}$  para um dado  $k$  pode ser baseado nas equações de Yule-Walker[78], expressas por:

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kj}\rho_{j-k}, \quad j = 1, 2, \dots, k \quad (4.35)$$

Portanto, para uma série temporal observada, a função de autocorrelação parcial  $\phi_{kk}$  será estimada por:

$$\phi_{kk} = \rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j} / \left( 1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j \right), \quad j = 1, 2, \dots, k-1 \quad (4.36)$$

onde  $\phi_{kj}$  é derivado de  $\phi_{k-1,j}$  e  $\phi_{k-1,k-j}$  para  $j = 1, 2, \dots, k-1$ .

#### 4.10.3 Aplicação do Teste de Ljung-Box para Autocorrelação Serial

O Teste de Ljung-Box [79] é uma método utilizado com frequência para identificar a presença de autocorrelação serial em séries temporais. O teste tem como base a soma acumulada das autocorrelações estimadas, usando a fórmula:

$$Q = n(n+2) \sum_{j=1}^k \frac{\hat{\rho}_j^2}{n-j}, \quad (4.37)$$

onde  $n$  representa o tamanho da amostra,  $k$  o número de defasagens, e  $\hat{\rho}_j$  a autocorrelação estimada. A hipótese nula do teste é a independência dos dados. Valores-p baixos indicam autocorrelação significativa, sugerindo a rejeição da hipótese nula. Este teste é crucial na modelagem de séries temporais para verificar a adequação do modelo, especialmente em modelos ARIMA. Contudo, deve-se atentar para suas limitações em dados com tendências fortes ou sazonalidade e na escolha do número de defasagens.

#### 4.10.4 Modelo autoregressivo AR

Segundo Morettin e Toloi (2018) [76], um modelo autorregressivo de ordem  $p$ , denotado por  $\text{AR}(p)$ , é tal que:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t, \quad (4.38)$$

onde  $a_t$  é um ruído branco;

Esse modelo pressupõe que o valor atual da série é uma combinação linear dos  $p$  valores passados da série e de um ruído branco  $a_t$ . A função de autocorrelação de um processo autorregressivo é constituída de uma mistura de polinômios, exponenciais e senoides amortecidas e é infinita em extensão. Já a função de autocorrelação parcial não é nula somente para defasagens menores que  $p$  [78].



#### 4.10.5 Modelo de médias móveis MA

Em um processo de médias móveis MA( $q$ ), cada observação  $Z_t$  é gerada por uma média ponderada dos erros aleatórios  $q$  períodos no passado, cuja equação é representada por:

$$Z_t = \theta(B) a_t \quad (4.39)$$

Em que:

$$Z_t = c + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q} \quad (4.40)$$

em que  $a_t$  é ruído branco. Fazendo  $\tilde{Z}_t = Z_t - c$ , assim teremos:

$$\tilde{Z}_t = (1 - \theta_1 B - \theta_2 B^2 - \cdots - \theta_q B^q) \varepsilon_t = \theta(B) \varepsilon_t \quad (4.41)$$

em que  $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \cdots - \theta_q B^q$  é o operador de médias móveis de ordem  $q$ .

em que  $\theta(B) a_t = 1 - \theta_1 B - \theta_2 B^2 - \cdots - \theta_q B^q$  é o operador de médias móveis de ordem  $q$ .

Assume-se que os erros aleatórios são gerados por um processo de ruído branco, ou seja,  $a_t \sim N(0, \sigma_a^2)$  e covariância  $\gamma_k = 0$  para defasagens  $k \neq 0$ .

Os modelos autorregressivos e de médias móveis ARMA( $p, q$ ) irão modelar o grau de autocorrelação e de observações defasadas. Em sua forma geral, se escrevem

$$\phi(B) Z_t = \theta(B) a_t \quad (4.42)$$

Para aplicarmos os modelos a série temporal, é necessário que as variáveis sejam estacionárias. Uma série temporal é estacionária quando se desenvolve no tempo, aleatoriamente, ao redor de uma média constante, refletindo uma forma de equilíbrio estável.

Para tornar a série temporal estacionária é necessário transformar os dados originais, e o procedimento mais comum consiste em tomar diferenças sucessivas da série original.

A primeira diferença de  $Z_1$  é definida por:

$$\Delta Z_t = Z_t - Z_{t-1} \quad (4.43)$$

a segunda diferença:

$$\Delta^2 Z_t = \Delta[\Delta Z_t] = \Delta[Z_t - Z_{t-1}] \quad (4.44)$$

ou seja,

$$\Delta^2 Z_t = Z_t - 2Z_{t-1} + Z_{t-2} \quad (4.45)$$

logo, a  $n$ -ésima diferença de  $\underline{Z_1}$  é:

$$\Delta^n Z_t = \Delta[\Delta^{n-1} Z_t] \quad (4.46)$$

Normalmente, será necessário tomar uma ou duas diferenças para que a série se torne estacionária.

Portanto, o modelo para a série diferenciada ARIMA( $p, d, q$ ) é:

$$\phi(B)(1-B)^d Z_t = \theta(B) a_t \quad (4.47)$$

em que  $\phi(B)$  e  $\theta(B)$  são operadores autorregressivos e de médias móveis descritos anteriormente;  $(1-B)$  é o operador diferença e  $d$  é o número de diferenças.

#### 4.10.6 Semelhanças comportamentais das FAC e FACP de AR e MA

Em suma, a FAC dos processos  $AR(p)$  comporta-se como a FACP dos processos  $MA(q)$ . Nesse sentido, tipicamente decai gradualmente para zero (exponenciais amortecidas e/ou senoide amortecida) e a função de autocorrelação parcial (FACP) é zero para  $k > p$ ; a FACP dos processos  $AR(p)$  comporta-se como a FAC dos processos  $MA(q)$ , decaindo bruscamente para zero.

As Figuras 4.3 e 4.4 ilustram, respectivamente, o comportamento das FAC e FACP para um modelo  $AR(1)$  onde  $0 < \phi < 1$ . Na Figura 4.3, a FAC exibe um decaimento exponencial, refletindo a característica de que as autocorrelações em modelos  $AR(1)$  diminuem de forma contínua à medida que o número de defasagens aumenta. Este decaimento é consistente com a presença de um único termo autorregressivo significativo. Em contraste, a Figura 4.4 mostra que a FACP é significativa apenas no primeiro lag e praticamente zero nos lags subsequentes, o que é esperado para um processo  $AR(1)$ , confirmando que a autocorrelação parcial após o primeiro lag não é mais influenciada por correlações indiretas através de lags intermediários.




Figura 4.3 – Função de autocorrelação




Figura 4.4 – Função de autocorrelação parcial

#### 4.10.7 Modelo autoregressivo e de médias móveis (ARMA (p,q))

O modelo conhecido como ARMA, é a junção de de dois modelos: o autorregressivo (AR) e o de médias móveis (MA). Assim, sua representação será dada por  $ARMA(p,q)$ ; onde, temos a representação de um processo autorregressivo e de médias móveis de ordem  $(p,q)$  é dado por:

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (4.48)$$

em que  $a_t$  é ruído branco.

#### 4.10.8 Modelo ARIMA não sazonal

No momento em que a série temporal não apresenta um comportamento estacionário é necessário utilizarmos algumas transformações para torná-las estacionárias. Assim, dada uma série temporal  $Z_t$  não estacionária, a transformação de diferenças sucessivas pode ser aplicada com intuito de obter a série temporal estacionária transformada  $W_t$ , isto é,

$$W_t = \Delta^d Z_t \quad (4.49)$$

onde  $\Delta^d$  é o operador de diferenças sucessivas.

Assim pode-se escrever  $W_t$  por um modelo ARMA(p,q), isto é,

$$\phi(B)W_t = \theta(B)a_t \quad (4.50)$$

onde  $\phi(B)$  é o operador autorregressivo,  $\theta(B)$  é o operador de médias móveis e  $a_t$  é um ruído branco.

O processo autorregressivo integrado de médias móveis [22] denotado ARIMA(p; d; q) é dado por

$$W_t = c + \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} + a_t \quad (4.51)$$

Podendo ser reescrita por

$$(1 - \phi_1 B - \dots - \phi_p B^p) Z_t = c + (1 + \theta_1 B + \dots + \theta_q B^q) a_t \quad (4.52)$$

em que  $p$  e  $q$  são as ordens de  $\phi(B)$  e  $\theta(B)$ , respectivamente.

Ou ainda

$$\phi(B)\Delta^d Z_t = c + \theta(B)a_t \quad (4.53)$$

#### 4.10.9 Modelo SARIMA

Séries temporais, especialmente aquelas relacionadas ao consumo e à demanda de energia, frequentemente exibem comportamentos periódicos. Mesmo após a remoção da sazonalidade determinística, ainda pode haver autocorrelação significativa em lags de baixa ordem ou em lags sazonais, que são múltiplos do período  $s$ .

Portanto, é necessário considerar uma sazonalidade estocástica, ajustando um modelo SARIMA à série original. Um modelo SARIMA  $(p,d,q)(P,D,Q)$  pode ser descrito pela seguinte equação:

$$\phi(B)\Phi(B^s)(1-B)^d(1-B^s)^D Z_t = \theta(B)\Theta(B^s)a_t \quad (4.54)$$

onde  $s$  é o período sazonal;  $\phi(B)$  é o operador autorregressivo de ordem  $p$ ;

$$\Phi(B^s) = 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{ps} \quad (4.55)$$

é o operador autorregressivo sazonal de ordem  $P$ ;

$$\theta(B)\Theta(B^s) = 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs} \quad (4.56)$$

é o operador de médias móveis sazonal de ordem  $Q$ ; e

$$(1 - B^s)^D \quad (4.57)$$

é o operador de diferenças sazonais, com  $D$  indicando o número de diferenças sazonais a serem aplicadas.

#### 4.11 Modelos de regressão dinâmica

Os modelos de séries temporais das seções anteriores permitem a inclusão de informações de observações anteriores de uma série, mas não a introdução de outras informações que também podem ser relevantes [22]. Por exemplo, efeitos de feriados, atividade do comércio, mudanças na lei, contextos externos ou outras variáveis externas que podem explicar algumas das variações históricas e, conseqüentemente, que possam prever preços mais precisos. Por outro lado, os modelos de regressão permitem a inclusão de muitas informações relevantes de variáveis preditoras, mas não permitem a dinâmica da série temporal que pode ser modelada com modelos ARIMA. Nesta seção, será considerado como modelo os modelos ARIMA para permitir que outras informações sejam incluídas nos modelos.

A regressão dinâmica é uma técnica estatística que tem como objetivo modelar e prever dados com estrutura temporal, considerando as variáveis explicativas e a estrutura temporal dos dados. Segundo [80], a regressão dinâmica é particularmente útil para lidar com dados que possuem tendências e sazonalidades.

Para aplicar a regressão dinâmica, é necessário entender a estrutura temporal dos dados e identificar as variáveis que influenciam o comportamento temporal observado. Em seguida, é possível construir um modelo que leve em consideração tanto as variáveis explicativas quanto a estrutura temporal dos dados [81].

A regressão dinâmica oferece uma série de vantagens em relação a outros modelos estatísticos, como a capacidade de fazer previsões mais precisas e a análise de causalidade temporal. Além disso, a regressão dinâmica é uma ferramenta fundamental em diversas áreas do conhecimento, incluindo finanças, economia, ciências sociais e biologia.

Os passos para construir um modelo de regressão dinâmica incluem a escolha das variáveis explicativas, a identificação da estrutura temporal dos dados, a construção do modelo estatístico e a avaliação da qualidade do modelo. Para isso, é necessário ter conhecimentos sólidos em teoria estatística e habilidades em programação e análise de dados.

A autocorrelação dos resíduos ocorre quando há uma correlação entre os erros do modelo de regressão em diferentes momentos no tempo. Isso pode comprometer a validade das inferências feitas a partir do modelo estimado, levando a intervalos de confiança estreitos, prejudicando a previsão de valores futuros e resultando em inferências incorretas sobre a significância

estatística dos coeficientes do modelo. Para evitar esse problema, é importante que os modelos de regressão considerem a possibilidade de autocorrelação nos dados e que sejam aplicados testes adequados para identificar e lidar com esse problema.

Considere o modelo regressivo dado por:

$$y_t = \beta_0 + \beta_1 x_{1t} + \cdots + \beta_k x_{kt} + n_t \quad (4.58)$$

em que  $y_t$  sendo uma variável resposta e que é uma função linear de  $k$  variáveis preditoras  $x_{1t}, x_{2t}, \dots, x_{kt}$  e  $n_t$  geralmente é considerado um termo de erro (ou residual) e  $n_t = \phi_1 n_{t-1} + \cdots + \phi_p n_{t-p} + \epsilon_t$ .

Nesta seção, será permitido que os erros de uma regressão contenham autocorrelação. Para especificar essa mudança de perspectiva, supomos  $e_t = n_t + c$ . Assume-se que a série de erros  $n$  segue um modelo ARIMA. Por exemplo, se  $n$  segue um modelo ARIMA (1, 1, 1), então temos:

$$n_t = \phi n_{t-1} + (1 - \phi)(1 - B)n_{t-1} + \theta \epsilon_t \quad (4.59)$$

É possível observarmos que o modelo tem dois termos de erro, sendo  $n$  o erro do modelo de regressão e  $\epsilon$  o erro do modelo ARIMA. Apenas os erros do modelo ARIMA são considerados ruído branco.

#### 4.12 Estimação de parâmetros

Para estimar os parâmetros do modelo  $(y_t, \dots)$ , deve-se minimizar a soma dos quadrados dos valores de  $e_t$ . Se  $e_t$  vem disso, minimizar a soma dos quadrados dos valores de  $e_t$  que é o que aconteceria se estimássemos o modelo de regressão ignorando as autocorrelações nos erros, vários problemas surgem. Como, os coeficientes estimados não são mais as melhores estimativas, pois algumas informações foram ignoradas no cálculo; os testes estatísticos associados aos modelo (por exemplo, testes  $t$  nos coeficientes) estariam incorretos; e mais do cálculo, os valores previstos seriam afetados por não terem em conta o padrão, algumas variáveis preditoras afirmam-se portanto quando não são. Isso é conhecido como "regressão espúria". Minimizar a soma dos quadrados dos valores de  $e_t$  evita esses problemas. Alternativamente, a estimativa máxima da verossimilhança pode ser usada; isso daria estimativas semelhantes para os coeficientes.

É crucial reconhecer que, ao estimar uma regressão com erros ARMA, todas as variáveis incluídas no modelo devem ser inicialmente estacionárias. Isto implica que, para uma variável  $y_t$ , tanto os termos originais quanto os valores previstos devem ser estacionários. Caso o modelo seja estimado com a presença de termos não estacionários, os coeficientes estimados poderão não ser consistentes, comprometendo a significância dos resultados. Uma exceção notável ocorre quando as variáveis não estacionárias estão cointegradas. Mesmo se uma longa série econômica for não estacionária, se os preditores forem todos cointegrados, a modelagem ainda pode ser realizada com validade.

Se todas as variáveis no modelo forem estacionárias, então só precisamos considerar os erros ARMA separadamente. É fácil agora um modelo de regressão com erros ARMA a partir do ARIMA estimado. Tudo depende de diferenças como erros ARIMA.

### 4.13 Redes Neurais artificiais

As redes neurais foram propostas pela primeira vez por Warren McCulloch e Walter Pitts [82]. Uma Rede Neural Artificial (ANN) modela a relação entre um conjunto de sinais de entrada e um sinal de saída usando um modelo derivado da nossa compreensão de como o cérebro biológico responde a estímulos de entradas sensoriais. Assim como o cérebro usa uma rede de células interconectadas chamadas neurônios para criar um processador paralelo massivo, uma ANN é construída a partir de uma rede de neurônios ou nós artificiais para resolver problemas de aprendizagem. Por exemplo, o cérebro humano é composto por cerca de 85 bilhões de neurônios, e um rato tem cerca de 70 milhões de neurônios.

#### 4.13.1 Arquitetura das Redes Neurais artificiais

Na concepção das redes neurais artificiais, a "arquitetura" alude à disposição estrutural dos neurônios e suas interconexões.[83] De forma resumida, uma rede neural é composta por três segmentos principais: a camada de entrada, as camadas ocultas e a camada de saída. A camada de entrada atua como o ponto de recebimento de dados do ambiente externo, iniciando o processo de computação neural. As camadas ocultas, por sua vez, abrigam neurônios que processam as informações, desempenhando a crucial função de extrair e interpretar características relevantes ao sistema ou processo em análise[84].

O processamento substancial da rede ocorre nas camadas ocultas, onde os neurônios trabalham para decifrar e transformar os dados de entrada em uma representação mais abstrata[85]. Finalmente, a camada de saída, composta também por neurônios, é encarregada de entregar os resultados finais. Esta camada sintetiza e projeta a saída da rede, que é o culminar dos cálculos realizados pelas camadas antecedentes.

Dentre as diversas arquiteturas de redes neurais, as mais proeminentes são: as redes feedforward de camada única, que direcionam dados em um único sentido, da entrada para a saída; as redes feedforward de múltiplas camadas, que possuem uma ou mais camadas ocultas entre a entrada e a saída, permitindo o processamento em níveis mais complexos; as redes recorrentes, que se caracterizam pela presença de laços de feedback, permitindo que a informação circule em um ciclo; e as redes reticuladas, onde as conexões formam uma malha, sem um sentido único de fluxo para o processamento dos dados. Essas arquiteturas são escolhidas com base no tipo de tarefa a ser executada e na natureza dos dados a serem processados, determinando o comportamento e a eficiência da rede neural em tarefas específicas[85].

#### 4.13.2 Modelos de redes neurais *feedforward*

Com os dados da série temporal, os valores defasados da série temporal podem ser usados como entradas para uma rede neural, assim como usamos os valores defasados em um modelo de autorregressão linear. Na Figura 4.5 apresentamos uma rede *feedforward* com três entradas, uma camada oculta com (quatro neurônios) e uma camada de saída com (dois neurônios). A partir desse arranjo o sinal será propagado para frente, ou seja, o fluxo de dados será da entrada para a saída, sem a realimentação dos neurônios. Chamamos isso de autorregressão de rede neural ou modelo NNAR.




Figura 4.5 – Diagrama da Rede Neural  
Autor, 2023.

Segundo Zanetti et al. [86], o modelo apresentado na Figura 4.5 pode ser descrito por:

$$z_j = f(a_0 + a^\top x_j), \quad j = 1, 2, \dots, 4; \quad (4.60)$$

$$y_k = g(b_0 + b^\top z_k), \quad k = 1, 2. \quad (4.61)$$

Em que  $f$  é conhecida como função de ativação,  $a_0$  denota o intercepto do neurônio de saída,  $a_0$  representa o intercepto do  $j$ -ésimo neurônio oculto,  $x = (x_1, x_2, x_3)$  são as observações (covariáveis ou neurônios) da camada de entrada,  $z' = (z_1, z_2, z_3, z_4)$  são os neurônios da camada oculta,  $y' = (y_1, y_2)$  são os neurônios da camada de saída;  $a = (a_1, a_2, a_3, a_4)$  são os pesos atribuídos à conexão entre a entrada e a camada oculta,  $b = (b_1, b_2)$  são os pesos entre a camada oculta e a camada de saída e  $g$  é uma função de integração incluída para permitir uma transformação final da saída.

Os parâmetros de uma rede neural são os pesos. Os pesos usados em um modelo de rede neural são estimados a partir dos dados do conjunto de treinamento por mínimos quadrados, por exemplo, para a rede descrita acima, minimizando-os, podemos representá-los por:

$$R(a, b) = \sum_k (y_k - \hat{y}_k)^2 \quad (4.62)$$

um critério que não é linear nos parâmetros. Muitas das vezes não é fácil minimizar  $R$  uma vez que pode ter mínimos locais e o monte de redes neurais são super-parametrizadas, muitas delas vezes com mais parâmetros do que observações. Na literatura de rede neural, este estágio de estimativa é frequentemente descrito como "treinamento" da rede.

A função  $f$  de ativação pode ser escolhida dentre as seguintes funções:

- identidade:  $f(z) = z$ ;
- logística:  $f(z) = \frac{1}{1+e^{-z}}$ ;
- tangente hiperbólica:  $f(z) = \tanh(z)$ .

#### 4.13.3 Redes Neurais Autorregressivas NNAR

As redes neurais artificiais consistem em um tipo de modelagem que se assemelha ao funcionamento do cérebro humano.[87] Logo, esses modelos de redes neurais artificiais busca modelar a relação entre um conjunto de sinais de entrada e um sinal de saída. Uma rede neural *feedforward* pode ser representada através de uma camada oculta e uma camada de entradas defasadas; as camadas ocultas trabalham com um número previamente determinado de “neurônios” que recebem as informações, ou seja, os dados de entrada, filtram as informações e nos fornecem os resultados para a camada oculta seguinte ou para a camada que apresenta os resultados[88].

Assim, é possível observarmos que esse método é considerado como uma abordagem útil para a previsão de séries temporais univariadas. Ao utilizar-se os valores defasados da série temporal como entradas para uma rede neural *feedforward*, esse processo é chamado de autorregressão de redes neurais ou modelo NNAR [24]. Neste trabalho estamos utilizando um modelo NNAR que considera sazonalidade.

O modelo de rede neural descrito apresenta característica autorregressiva (NNAR) em seu funcionamento; ou seja, podemos observar que ela possui um processo similar ao modelo ARIMA. Na literatura ela classificada por possuir o seguinte formato para o modelo NNAR  $(p, P, k)_m$ , em que:  $p$  é o número de observações utilizadas;  $P$  é considerado a quantidade de observações semelhantes dos períodos anteriores utilizados, em séries que apresentam sazonalidade como o caso que estamos tratando;  $k$  é considerado o número de nós ou “neurônios” que a camada oculta possui; e  $m$  é descrito como o número de observações por ano, a camada de entrada é escrita como:

$$(y_{t-1}, y_{t-2}, \dots, y_{tp}, y_{tm}, y_{t-2m}, y_{t-Pm}) \quad (4.63)$$



## Resultados e Discussões

### 5.1 Resultados e Discussões

Nesta seção serão apresentados os resultados encontrados através da aplicação das análises descritivas e das seguintes técnicas de séries temporais: método de Holt-Winters, dos modelos de Box&Jenkins, Modelo de regressão dinâmica e o modelo de redes neurais autorregressivas.

Assim, uma vez recolhido os dados e feito a escolha dos modelos adequados para serem aplicados na amostra selecionada, após aplicação dos métodos estatísticos, é possível analisarmos os principais resultados, iremos proceder com a organização, sistematização e análise dos dados, onde serão apresentados e interpretados através da representação gráfica e, também, das métricas de precisão utilizadas para comparar os conjuntos de treino e teste.

A análise pela estatística descritiva foi desenvolvida com o intuito de sintetizar os dados obtidos e para permitir uma leitura clara e objetiva dos mesmos, a níveis nacionais, regionais e estaduais. De modo, a analisá-los, e para tal utilizamos a estatística inferencial para estabelecer as relações entre as variáveis dependentes e independentes. Considerando o nível de significância estatística para os testes de 5%, ou seja, o valor de "p" estabelecido entre 0,05 ou inferior, para que os respectivos resultados obtidos sejam considerados estatisticamente significativos.

#### 5.1.1 Análise Descritiva dos dados

Na tabela 5.1 será apresentado a análise descritiva dos dados de consumo de energia elétrica para produção de cimento no período de janeiro de 2001 a dezembro de 2022. Nesta tabela será apresentado a média, variância, desvio padrão e a amplitude para os dados de consumo de energia elétrica em (GWh) que compõem a série temporal da indústria de cimento no Brasil.

Tabela 5.1 – Análise descritiva dos dados.

	Média	Desvio padrão	Amplitude	Mínimo	Máximo
2001	380,83	21,96	76,41	347,29	423,69
2002	365,25	25,76	86,56	320,19	406,75
2003	329,58	19,23	55,70	301,77	357,47
2004	335,42	24,48	82,46	281,99	364,45
2005	365,00	28,50	97,22	303,72	400,94
2006	368,42	26,58	78,83	322,13	400,96
2007	434,59	40,20	134,88	353,14	488,02
2008	481,29	41,37	127,68	412,64	540,32
2009	484,67	40,06	126,78	404,05	530,83
2010	536,92	44,50	139,00	454,13	593,13
2011	593,02	48,76	134,59	524,33	658,92
2012	640,00	41,03	137,62	560,75	698,36
2013	652,17	47,08	126,71	592,52	719,23
2014	660,00	45,24	139,17	593,16	732,32
2015	592,58	43,00	143,21	510,15	653,36
2016	531,00	29,64	105,18	486,77	591,95
2017	500,42	32,68	107,30	448,23	555,53
2018	490,58	44,22	154,09	398,35	552,43
2019	506,67	48,66	144,56	445,60	590,16
2020	512,67	73,14	195,29	414,05	609,34
2021	556,20	40,98	140,92	476,74	617,66
2022	591,50	44,91	140,98	506,58	647,56

Fonte: Autor, 2023

Analizando os dados apresentados na tabela 5.1, o ano que apresentou maior consumo de energia elétrica no período em estudo foi em 2014, o ano que apresentou o menor consumo foi o de 2003. Em relação a variabilidade dos dados, o ano de 2020 apresentou a maior variabilidade, devido possivelmente ocasionado pela pandemia do COVID-19, e o setor com a menor variabilidade foi o ano de 2003.

A figura 5.1 mostra a trajetória do consumo mensal de energia elétrica da indústria de cimento no Brasil. Essa figura apresenta períodos de crescimento e queda no consumo ao longo da série temporal. Pode-se observar a presença de sazonalidade com repetições de padrões na série temporal. A figura 5.2 mostra o consumo de energia elétrica acumulado por ano ao longo do tempo e o gráfico de boxplot para cada mês da série temporal. A figura 5.2(a) apresenta a componente de tendência da série temporal. Na figura 5.2(b), pode-se observar que o meses de agosto e setembro apresentam os maiores valores mensais de consumo de energia elétrica. Essa figura mostra que a partir do período da pandemia de COVID-19 uma retomada no crescimento do consumo de energia elétrica.




Figura 5.1 – Série temporal do consumo de energia elétrica da indústria de cimento no Brasil, entre 2001-2022.

Fonte: Autor, 2023




Figura 5.2 – Consumo de energia elétrica acumulado anualmente e o gráfico de boxplot de cada mensal.

Fonte: Autor, 2023

Figura 5.3 apresenta a decomposição da série temporal através do método STL. Essa figura mostra cada componente da série temporal do consumo de energia elétrica, como a sazonalidade, tendência e ruído.




Figura 5.3 – Consumo de energia elétrica acumulado anualmente e o gráfico de boxplot de cada mensal.

Fonte: Autor, 2023

### 5.1.2 Método de Holt-Winters

A Figura 5.4 mostra o ajuste e previsão através do método aditivo de Holt-Winters aplicado ao consumo de energia elétrica da indústria do cimento do Brasil. Os resultados mostram que o modelo foi capaz de se ajustar de maneira razoável aos dados do conjunto de treino (período de ajuste). E as previsões geradas pelo modelo também se mostram razoáveis, isto é, conseguiram capturar a trajetória dos valores observados. Nesta figura, o período de ajuste e previsão foram desenvolvidos para a série temporal antes do período da pandemia do COVID-19. Por outro lado, a figura 5.5 mostra a previsão considerando o período da pandemia do COVID-19. Essa figura mostra que o modelo de amortecimento exponencial conseguiu capturar razoavelmente os valores observados da série temporal. Pode-se verificar também que os valores observados pertencem ao intervalo de confiança.




Figura 5.4 – Ajuste (período de 2001-2017) e previsão (período de 2018-2019) para o método de Holt-Winters.

Fonte: Autor, 2023

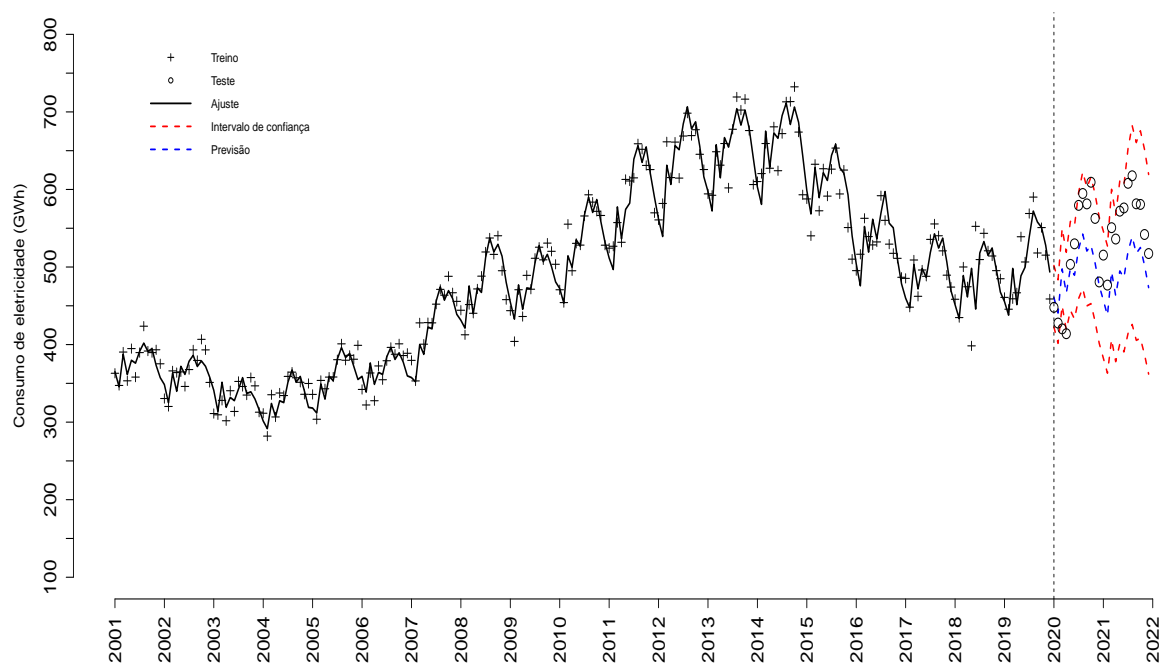


Figura 5.5 – Ajuste (período de 2001-2019) e previsão (período de 2020-2021) para o método de Holt-Winters.

Fonte: Autor, 2023

Nas tabelas 5.2, 5.3, 5.4 e 5.5 serão apresentados os respectivos valores e as médias entre os quatro períodos abordados acima tendo início em janeiro de 2001, considerando como horizonte de ajuste 12 passos a frente para cada período e para previsão 24 passos a frente, verificou-se que o modelo de Holt-Winters apresentou resultados razoáveis para as métricas RMSE e MAPE considerando a previsão. Assim, conclui-se que, dentre os modelos considerados, o modelo Holt-Winters não obteve a melhor capacidade de previsão aos dados de consumo de energia elétrica para a indústria de cimento no Brasil.

Tabela 5.2 – Métricas de ajuste valores RMSE.

Modelo	2001-2017	2001-2018	2001-2019	2001-2020	Média
Holt-Winters	17,276	19,946	20,311	21,876	19,852

Fonte: Autor, 2023

Tabela 5.3 – Métricas de ajuste valores MAPE.

Modelo	2001-2017	2001-2018	2001-2019	2001-2020	Média
Holt-Winters	2,814	2,980	3,035	3,200	3,010

Fonte: Autor, 2023

Tabela 5.4 – Métricas para previsão valores RMSE.

Modelo	2018-2019	2019-2020	2020-2021	2021-2022	Média
Holt-Winters	44,784	45,147	58,565	129,671	69,541

Fonte: Autor, 2023

Tabela 5.5 – Métricas para previsão MAPE.

Modelo	2018-2019	2019-2020	2020-2021	2021-2022	Média
Holt-Winters	7,033	6,843	9,795	6,628	7,570

Fonte: Autor, 2023

#### 5.1.2.1 Modelo de Holt-Winters para previsão 12, 24, 36, 48 passos à frente

Nessa subseção serão apresentados 4 períodos onde são realizados os ajustes e as previsões para o modelo de Holt-Winters para previsão 12, 24, 36, 48 passos à frente. Com o objetivo de analisar o desempenho do modelo em diferentes períodos, e assim; verificar sua capacidade de previsão em diferentes momentos e a partir dessa análise percebermos ou não os possíveis impactos causados no período de análise pré-pandemia, o período da pandemia e por último o período pós-pandemia.

A Figura 5.6 mostra o ajuste e previsão através do método aditivo de Holt-Winters aplicado ao consumo de energia elétrica da indústria do cimento do Brasil para 48 passos a frente. Os resultados mostram que o modelo foi capaz de se ajustar de maneira razoável aos dados do conjunto de treino (período de ajuste). E as previsões geradas pelo modelo também se mostram razoáveis, isto é, conseguiram capturar a trajetória dos valores observados. Nesta figura, o período de ajuste e previsão foram desenvolvidos para contemplar toda a série temporal, onde podemos avaliar o período antes, durante e após a pandemia do COVID-19. Outro detalhe, é

que essa figura mostra que o modelo de amortecimento exponencial conseguiu capturar razoavelmente os valores observados da série temporal. Pode-se verificar também que os valores observados pertencem ao intervalo de confiança.




Figura 5.6 – Ajuste (período de 01/2001-12/2017) e previsão (período de 01/2018-12/2021) para o método de Holt-Winters.

Fonte: Autor, 2023

Nas tabelas 5.6 e 5.7 serão apresentados os respectivos valores e as médias entre os quatro períodos abordados acima tendo início em janeiro de 2001, verificou-se que o modelo de Holt-Winters apresentou resultados razoáveis para as métricas RMSE e MAPE considerando a previsão. Assim, conclui-se que, dentre os modelos considerados, o modelo Holt-Winters não obteve a melhor capacidade de previsão aos dados de consumo de energia elétrica para a indústria de cimento no Brasil.

Tabela 5.6 – Métricas de previsão valores RMSE para 12, 24, 36, e 48 passos á frente.

Modelo Holt-Winters	Período 01	Período 02	Período 03	Período 04	Média
12	44,784	31,740	50,181	30,144	39,212
24	44,784	45,147	58,565	—	49,498
36	57,231	56,238	—	—	56,734
48	54,534	—	—	—	54,534

Fonte: Autor, 2023

Modelo Holt-Winters	Período 01	Período 02	Período 03	Período 04	Média
12	7,033	4,772	8,250	4,430	6,121
24	7,033	6,843	9,795	—	7,890
36	8,743	8,782	—	—	8,762
48	11,312	—	—	—	11,312

Fonte: Autor, 2023

### 5.1.3 Modelo SARIMA

Para que se possa identificar o modelo SARIMA mais adequado é necessário verificar o comportamento da série temporal, da função de autocorrelação (FAC) e da função de autocorrelação parcial (FACP).

A série temporal do consumo de eletricidade é claramente não estacionária (Figura 5.7(a)), com alguma sazonalidade, portanto, primeiramente será necessário uma diferença sazonal. Pode-se observar que os dados sazonalmente diferenciados também não são estacionários (Figura 5.7(b)). Assim, será necessário uma primeira diferença adicional (Figura 5.7(c)).




Figura 5.7 – Série temporal (a), série temporal com diferença sazonal (b) e série temporal com dupla diferenciação (c).

Fonte: Autor, 2023



Na figura 5.8(a), a FAC mostra um pico significativo no lag 1 sugerindo uma componente de médias móveis (MA(1)) não sazonal, e o aumento significativo no lag 12 que sugere uma componente de médias móveis sazonal. Pela FACP, pode-se observar um pico significativo no lag 3 sugerindo uma componente autorregressiva (AR(1)) não sazonal e um pico acentuado no lag 12 sugerindo uma componente autorregressiva sazonal. Consequentemente, será considerado inicialmente com base nas funções de autocorrelação um modelo SARIMA(1,1,1)  $\times$  (0,1,1)<sub>12</sub>. Através do teste de sobrefixação para verificar a possibilidade da existência de um modelo de ordem mais elevada, foi encontrado o modelo SARIMA(1,1,2)  $\times$  (0,1,1)<sub>12</sub>.




Figura 5.8 – Função de autocorrelação (a) e autocorrelação parcial (b).

Fonte: Autor, 2023

A Figura 5.9(a) mostra os resíduos gerados a partir do ajuste do modelo SARIMA (1,1,2)  $\times$  (0,1,1)<sub>12</sub>. Pode-se observar que todos os picos estão dentro dos limites da significância da FAC 5.9(b), então o processo gerou ruído branco. Além disso, usando o teste Ljung-Box, o p-valor obtido foi igual a 0,2854, o que indicou que os resíduos são não correlacionados. O histograma dos resíduos mostra que a suposição de normalidade é razoável, com exceção de possíveis outliers 5.9(c).




Figura 5.9 – função de autocorrelação (a), função de autocorrelação parcial (b) e distribuição dos resíduos (c).

Fonte: Autor, 2023

A Figura 5.10 mostra o ajuste e previsão através do modelo ARIMA-Sazonal  $(1, 1, 2) \times (0, 1, 1)_{12}$  aplicado ao consumo de energia elétrica da indústria do cimento do Brasil. Os resultados mostram que o modelo foi capaz de se ajustar de maneira razoável aos dados do conjunto de treino (período de ajuste). E as previsões geradas pelo modelo também se mostram razoáveis, isto é, conseguiram capturar a trajetória dos valores observados. Nesta figura, o período de ajuste e previsão foram desenvolvidos para a série temporal antes do período da pandemia do COVID-19. Por outro lado, a figura 5.11 mostra a previsão considerando o período da pandemia do COVID-19. Essa figura mostra que o modelo ARIMA-Sazonal  $(1, 1, 2) \times (0, 1, 1)_{12}$  conseguiu capturar razoavelmente os valores observados da série temporal. Pode-se verificar também que os valores observados pertencem ao intervalo de confiança.

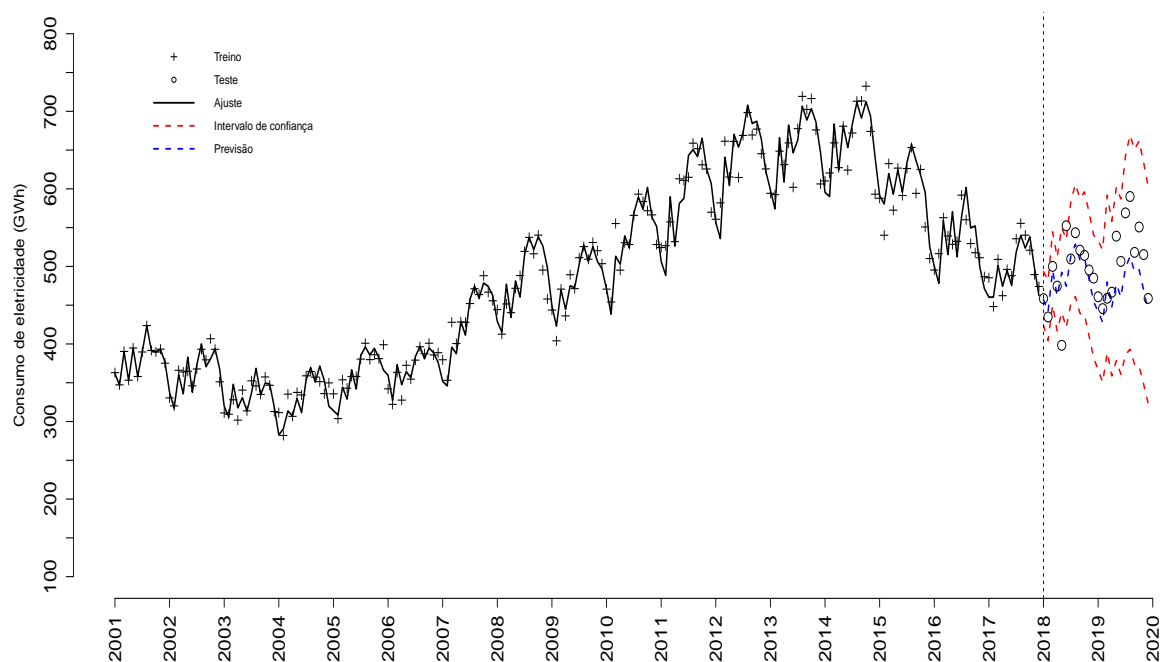


Figura 5.10 – Ajuste (período de 2001-2017) e previsão (período de 2018-2019) para o modelo Sarima.

Fonte: Autor, 2023




Figura 5.11 – Ajuste (período de 2001-2019) e previsão (período de 2020-2021) para o modelo Sarima.

Fonte: Autor, 2023

Nas tabelas 5.8, 5.9, 5.16 e 5.17 serão apresentados os respectivos valores e as médias entre os quatro períodos abordados acima tendo início em janeiro de 2001, considerando como horizonte de ajuste 12 passos a frente para cada período e para previsão 24 passos a frente, verificou-se que o modelo SARIMA  $(1, 1, 2) \times (0, 1, 1)_{12}$  apresentou resultados razoáveis para as métricas RMSE e MAPE considerando a previsão. Assim, conclui-se que, dentre os modelos considerados, o modelo SARIMA não obteve a melhor capacidade de previsão aos dados de consumo de energia elétrica para a indústria de cimento no Brasil. Contudo, apresentou resultados mais significativos do que o modelo exponencial.

Tabela 5.8 – Métricas de ajuste valores RMSE.

Modelo	2001-2017	2001-2018	2001-2019	2001-2020	Média
SARIMA	17,991	20,742	21,320	22,785	20,709

Fonte: Autor, 2023

Tabela 5.9 – Métricas de ajuste valores MAPE.

Modelo	2001-2017	2001-2018	2001-2019	2001-2020	Média
SARIMA	2,799	2,979	3,018	3,218	3,000

Fonte: Autor, 2023

Tabela 5.10 – Métricas para previsão valores RMSE.

Modelo	2018-2019	2019-2020	2020-2021	2021-2022	Média
SARIMA	41,352	42,176	52,334	114,249	62,527

Fonte: Autor, 2023

Tabela 5.11 – Métricas para previsão MAPE.

Modelo	2018-2019	2019-2020	2020-2021	2021-2022	Média
SARIMA	6,192	6,521	8,900	4,306	6,480

Fonte: Autor, 2023

### 5.1.3.1 Modelo SARIMA para previsão 12, 24, 36 e 48 passos à frente

Nessa subseção serão apresentados 4 períodos onde são realizados os ajustes e as previsões para o Modelo SARIMA  $(1, 1, 2) \times (0, 1, 1)_{12}$  para previsão 12, 24, 36 e 48 passos à frente. Com o objetivo de analisar o desempenho do modelo em diferentes períodos, e assim; verificar sua capacidade de previsão em diferentes momentos e a partir dessa análise percebermos ou não os possíveis impactos causados no período de análise pré-pandemia, o período da pandemia e por último o período pós-pandemia.

A Figura 5.12 mostra o ajuste e previsão através do modelo SARIMA  $(1, 1, 2) \times (0, 1, 1)_{12}$  aplicado ao consumo de energia elétrica da indústria do cimento do Brasil para 48 passos a frente. Os resultados mostram que o modelo foi capaz de se ajustar de maneira razoável aos dados do conjunto de treino (período de ajuste). E as previsões geradas pelo modelo também se mostram razoáveis, isto é, conseguiram capturar a trajetória dos valores observados. Nesta figura, o período de ajuste e previsão foram desenvolvidos para contemplar toda a série temporal, onde podemos avaliar o período antes, durante e após a pandemia do COVID-19. Outro

detalhe, é que essa figura mostra que o modelo SARIMA  $(1, 1, 2) \times (0, 1, 1)_{12}$  conseguiu capturar razoavelmente os valores observados da série temporal. Pode-se verificar também que os valores observados pertencem ao intervalo de confiança.




Figura 5.12 – Ajuste (período de 01/2001-12/2017) e previsão (período de 01/2018-12/2021) para o modelo SARIMA  $(1, 1, 2) \times (0, 1, 1)_{12}$ .

Fonte: Autor, 2023

Nas tabelas 5.12 e 5.13 serão apresentados os respectivos valores e as médias entre os quatro períodos abordados acima tendo início em janeiro de 2001, verificou-se que o modelo de SARIMA apresentou resultados razoáveis para as métricas RMSE e MAPE considerando a previsão. Assim, conclui-se que, dentre os modelos considerados, o modelo SARIMA  $(1, 1, 2) \times (0, 1, 1)_{12}$  não obteve a melhor capacidade de previsão aos dados de consumo de energia elétrica para a indústria de cimento no Brasil.

Tabela 5.12 – Métricas de previsão valores RMSE para 12, 24, 36, e 48 passos á frente.

Modelo SARIMA	Período 01	Período 02	Período 03	Período 04	Média
12	41,352	30,248	47,139	23,092	35,457
24	41,352	42,176	52,334	—	45,287
36	55,517	49,553	—	—	52,535
48	73,938	—	—	—	73,938

Fonte: Autor, 2023

Tabela 5.13 – Métricas de previsão valores MAPE para 12, 24, 36, e 48 passos á frente.					
Modelo SARIMA	Período 01	Período 02	Período 03	Período 04	Média
12	6,192	4,280	7,970	3,309	5,437
24	6,192	6,521	8,900	–	7,204
36	8,205	7,845	–	–	8,025
48	11,103	–	–	–	11,103

Fonte: Autor, 2023

#### 5.1.4 Redes Neurais Autorregressivas

A Figura 5.13 apresenta o ajuste e a previsão do consumo de energia elétrica na indústria do cimento do Brasil, empregando o modelo de Redes Neurais Autorregressivas (NNAR). Este modelo, que se baseia em técnicas de aprendizado de máquina, é particularmente eficaz em captar padrões não-lineares e complexos nas séries temporais. Os resultados indicam que o NNAR se ajustou satisfatoriamente aos dados do conjunto de treino, abrangendo o período pré-pandemia do COVID-19. As previsões geradas refletem uma boa capacidade do modelo em seguir a trajetória observada dos dados.

A análise se estende a dois momentos distintos: antes e durante a pandemia do COVID-19. Conforme ilustrado na Figura 5.14, o modelo NNAR se mostrou adaptável às mudanças significativas trazidas pela pandemia no setor industrial. A capacidade do modelo de Redes Neurais Autorregressivas de integrar e aprender com essas variações é evidenciada pela precisão das previsões, com os valores reais consistentemente dentro do intervalo de confiança estipulado pelo modelo, destacando sua aplicabilidade robusta em cenários dinâmicos

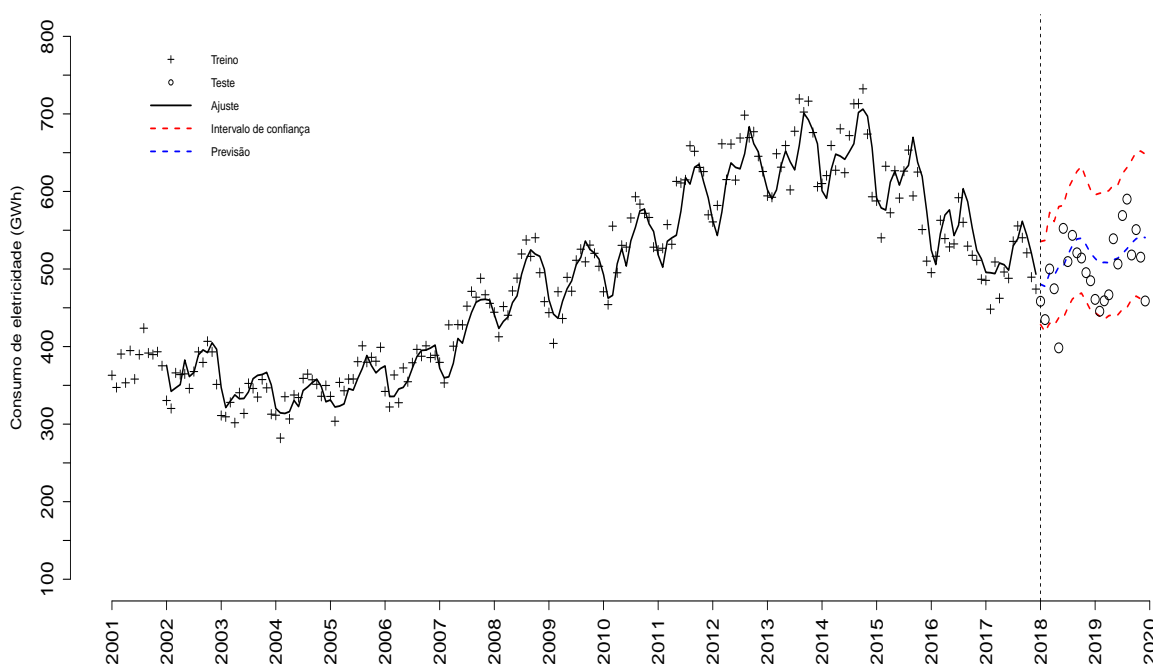


Figura 5.13 – Ajuste (período de 2001-2017) e previsão (período de 2018-2019) para o modelo Redes Neurais Autorregressivas.

Fonte: Autor, 2023




Figura 5.14 – Ajuste (período de 2001-2019) e previsão (período de 2020-2021) para o modelo Redes Neurais Autorregressivas.

Fonte: Autor, 2023

Nas tabelas 5.20, 5.21, 5.22 e 5.23 serão apresentados os respectivos valores e as médias entre os quatro períodos abordados acima tendo início em janeiro de 2001, considerando como horizonte de ajuste 12 passos a frente para cada período e para previsão 24 passos a frente, verificou-se que o Modelo de Redes Neurais NNAR apresentou resultados razoáveis para as métricas RMSE e MAPE considerando a previsão. Assim, conclui-se que, dentre os modelos considerados, o Modelo de Redes Neurais NNAR não obteve a melhor capacidade de previsão aos dados de consumo de energia elétrica para a indústria de cimento no Brasil. Os valores das métricas de previsão MAPE em três dos quatro períodos apresentaram valores bem relevantes, ficando abaixo dos 10% para a série temporal em estudo.

Tabela 5.14 – Métricas de ajuste valores RMSE.

Modelo	2001-2017	2001-2018	2001-2019	2001-2020	Média
NNAR	27,333	28,509	29,451	29,389	28,670

Fonte: Autor, 2023

Tabela 5.15 – Métricas de ajuste valores MAPE.

Modelo	2001-2017	2001-2018	2001-2019	2001-2020	Média
NNAR	4,399	4,584	4,660	4,669	4,580

Fonte: Autor, 2023

Tabela 5.16 – Métricas para previsão valores RMSE.

Modelo	2018-2019	2019-2020	2020-2021	2021-2022	Média
NNAR	42,513	57,338	60,317	102,983	65,742

Fonte: Autor, 2023

Tabela 5.17 – Métricas para previsão MAPE.

Modelo	2018-2019	2019-2020	2020-2021	2021-2022	Média
NNAR	7,278	9,331	8,940	12,261	9,450

Fonte: Autor, 2023

#### 5.1.4.1 Modelo de Redes Neurais para previsão 12, 24, 36 e 48 passos à frente

Nessa subseção serão apresentados 4 períodos onde são realizados os ajustes e as previsões para o Modelo de Redes Neurais NNAR para previsão 12, 24, 36 e 48 passos à frente. Com o objetivo de analisar o desempenho do modelo em diferentes períodos, e assim; verificar sua capacidade de previsão em diferentes momentos e a partir dessa análise percebermos ou não os possíveis impactos causados no período de análise pré-pandemia, o período da pandemia e por último o período pós-pandemia.

A Figura 5.15 mostra o ajuste e previsão através do Modelo de Redes Neurais NNAR aplicado ao consumo de energia elétrica da indústria do cimento do Brasil para 48 passos a frente. Os resultados mostram que o modelo foi capaz de se ajustar de maneira razoável aos dados do conjunto de treino (período de ajuste). E as previsões geradas pelo modelo também se mostram razoáveis, isto é, conseguiram capturar a trajetória dos valores observados. Nesta figura, o período de ajuste e previsão foram desenvolvidos para contemplar toda a série temporal, onde podemos avaliar o período antes, durante e após a pandemia do COVID-19. Outro detalhe, é que essa figura mostra que o modelo Modelo de Redes Neurais NNAR conseguiu capturar razoavelmente os valores observados da série temporal. Pode-se verificar também que os valores observados pertencem ao intervalo de confiança.






Figura 5.15 – Ajuste (período de 01/2001-12/2017) e previsão (período de 01/2018-12/2021) para o Modelo de Redes Neurais NNAR.

Fonte: Autor, 2023

Nas tabelas 5.18 e 5.19 serão apresentados os respectivos valores e as médias entre os quatro períodos abordados acima tendo início em janeiro de 2001, verificou-se que o Modelo de Redes Neurais NNAR apresentou resultados razoáveis para as métricas RMSE e MAPE considerando a previsão. Assim, conclui-se que, dentre os modelos considerados, o Modelo de Redes Neurais NNAR não obteve a melhor capacidade de previsão aos dados de consumo de energia elétrica para a indústria de cimento no Brasil.

Tabela 5.18 – Métricas de previsão valores RMSE para 12, 24, 36, e 48 passos á frente.

Modelo NNAR	Período 01	Período 02	Período 03	Período 04	Média
12	43,422	42,707	47,670	64,492	49,572
24	42,815	55,902	60,277	—	52,998
36	54,576	63,320	—	—	58,948
48	51,923	—	—	—	51,923

Fonte: Autor, 2023

Tabela 5.19 – Métricas de previsão valores MAPE para 12, 24, 36, e 48 passos á frente.

Modelo NNAR	Período 01	Período 02	Período 03	Período 04	Média
12	7,327	6,418	8,500	9,934	8,044
24	7,179	9,245	9,442	—	8,622
36	9,339	10,007	—	—	9,673
48	8,604	—	—	—	8,604

Fonte: Autor, 2023

### 5.1.5 Modelo de Regressão Dinâmica

A Figura 5.16 ilustra o ajuste e previsão do consumo de energia elétrica na indústria do cimento do Brasil utilizando um modelo de Regressão Dinâmica, onde a produção de cimento é considerada como uma variável regressora chave. Esta abordagem é significativa, pois a produção de cimento está intrinsecamente ligada ao consumo de energia elétrica na indústria, refletindo processos industriais intensivos em energia. Os resultados indicam que o modelo se ajustou de maneira satisfatória aos dados do conjunto de treino, abrangendo o período anterior à pandemia do COVID-19. As previsões geradas pelo modelo também apresentaram um desempenho razoável, demonstrando capacidade de capturar a tendência dos valores observados na série temporal.

Importante destacar que a análise cobre dois períodos distintos: o período pré-pandêmico e o período durante a pandemia do COVID-19. A Figura 5.17 evidencia que, mesmo considerando o impacto da pandemia, que trouxe mudanças significativas na dinâmica industrial, o modelo de Regressão Dinâmica foi eficaz em acompanhar as variações observadas no consumo de energia elétrica na indústria do cimento. Além disso, os valores observados se mantiveram consistentemente dentro do intervalo de confiança estabelecido pelo modelo, reforçando a sua adequação para a análise proposta. Pode-se verificar também que os valores observados pertencem ao intervalo de confiança.




Figura 5.16 – Ajuste (período de 2001-2017) e previsão (período de 2018-2019) para o modelo Regressão Dinâmica.

Fonte: Autor, 2023




Figura 5.17 – Ajuste (período de 2001-2019) e previsão (período de 2020-2021) para o modelo Regressão Dinâmica.

Fonte: Autor, 2023

Nas tabelas 5.20, 5.21, 5.22 e 5.23 serão apresentados os respectivos valores e as médias entre os quatro períodos abordados acima tendo início em janeiro de 2001, considerando como horizonte de ajuste 12 passos a frente para cada período e para previsão 24 passos a frente, verificou-se que o Modelo de Regressão Dinâmica apresentou os melhores resultados para as métricas RMSE e MAPE considerando a previsão. Assim, conclui-se que, dentre os modelos considerados, o Modelo de Regressão Dinâmica obteve a melhor capacidade de previsão aos dados de consumo de energia elétrica para a indústria de cimento no Brasil. Apresentando resultados significativos e com uma margem de previsão para a métrica MAPE abaixo dos 10%.

Tabela 5.20 – Métricas de ajuste valores RMSE.

Modelo	2001-2017	2001-2018	2001-2019	2001-2020	Média
SARIMA	17,991	20,742	21,320	22,785	20,709

Fonte: Autor, 2023

Tabela 5.21 – Métricas de ajuste valores MAPE.

Modelo	2001-2017	2001-2018	2001-2019	2001-2020	Média
SARIMA	2,799	2,979	3,018	3,218	3,000

Fonte: Autor, 2023

Tabela 5.22 – Métricas para previsão valores RMSE.

Modelo	2018-2019	2019-2020	2020-2021	2021-2022	Média
SARIMA	41,352	42,176	52,334	114,249	62,527

Fonte: Autor, 2023

Tabela 5.23 – Métricas para previsão MAPE.

Modelo	2018-2019	2019-2020	2020-2021	2021-2022	Média
SARIMA	6,192	6,521	8,900	4,306	6,480

Fonte: Autor, 2023

#### 5.1.5.1 Modelo de Regressão Dinâmica para previsão 12, 24, 36 e 48 passos à frente

Nessa subseção serão apresentados 4 períodos onde são realizados os ajustes e as previsões para o modelo de Regressão Dinâmica para previsão 12, 24, 36 e 48 passos à frente. Com o objetivo de analisar o desempenho do modelo em diferentes períodos, e assim; verificar sua capacidade de previsão em diferentes momentos e a partir dessa análise percebermos ou não os possíveis impactos causados no período de análise pré-pandemia, o período da pandemia e por último o período pós-pandemia.

A Figura 5.18 mostra o ajuste e previsão através do Modelo de Regressão Dinâmica aplicado ao consumo de energia elétrica da indústria do cimento do Brasil para 48 passos a frente. Os resultados mostram que o modelo foi capaz de se ajustar de maneira razoável aos dados do conjunto de treino (período de ajuste). E as previsões geradas pelo modelo também se mostram satisfatórias, isto é, conseguiram capturar a trajetória dos valores observados. Nesta figura, o período de ajuste e previsão foram desenvolvidos para contemplar toda a série temporal, onde podemos avaliar o período antes, durante e após a pandemia do COVID-19. Outro detalhe, é que essa figura mostra que o Modelo de Regressão Dinâmica conseguiu capturar de forma satisfatória os valores observados da série temporal. Pode-se verificar também que os valores observados pertencem ao intervalo de confiança.




Figura 5.18 – Ajuste (período de 01/2001-12/2017) e previsão (período de 01/2018-12/2021) para o modelo de Regressão Dinâmica.

Fonte: Autor, 2023

Nas tabelas 5.24 e 5.25 serão apresentados os respectivos valores e as médias entre os quatro períodos abordados acima tendo início em janeiro de 2001, verificou-se que Modelo de Regressão dinâmica apresentou resultados razoáveis para as métricas RMSE e MAPE considerando a previsão. Assim, conclui-se que, dentre os modelos considerados, o Modelo de Regressão Dinâmica obteve a melhor capacidade de previsão em três dos quatro períodos analisados para os dados de consumo de energia elétrica para a indústria de cimento no Brasil.

Tabela 5.24 – Métricas de previsão valores RMSE para 12, 24, 36, e 48 passos á frente.

Modelo de Regressão Dinâmica	Período 01	Período 02	Período 03	Período 04	Média
12	5,359	12,564	36,898	2,895	14,429
24	14,186	34,931	0,189	–	16,372
36	34,484	39,902	–	–	37,193
48	41,831	–	–	–	41,831

Fonte: Autor, 2023

Tabela 5.25 – Métricas de previsão valores MAPE para 12, 24, 36, e 48 passos á frente.

Modelo de Regressão Dinâmica	Período 01	Período 02	Período 03	Período 04	Média
12	1,069	2,462	7,155	0,520	2,671
24	2,429	5,842	6,644	–	4,971
36	5,236	6,783	–	–	6,009
48	6,552	–	–	–	6,552

Fonte: Autor, 2023

### 5.1.6 Métricas de Ajuste

Analisando os valores apresentados pelas métricas na Tabela 5.26 e 5.27 e a média entre os quatro períodos apresentados, verificou-se que o modelo de Regressão Dinâmica possui os menores valores para as métricas RMSE e MAPE consideradas no ajuste. Assim, conclui-se que, dentre os modelos considerados, o modelo Regressão Dinâmica foi o que obteve a melhor capacidade de ajuste aos dados de consumo de energia elétrica para a indústria de cimento no Brasil.

Tabela 5.26 – Métricas de comparação entre os ajustes dos modelos valores RMSE.

Modelo	2001-2017	2001-2018	2001-2019	2001-2020	Média
Holt-Winters	17,276	19,946	20,311	21,876	19,852
SARIMA	17,991	20,742	21,320	22,785	20,709
NNAR	27,333	28,509	29,451	29,389	28,670
Regressão dinâmica	<b>2,700</b>	<b>2,588</b>	<b>2,585</b>	<b>3,273</b>	<b>2,768</b>

Fonte: Autor, 2023

Tabela 5.27 – Métricas de comparação entre os ajustes dos modelos valores MAPE.

Modelo	2001-2017	2001-2018	2001-2019	2001-2020	Média
Holt-Winters	2,814	2,980	3,035	3,200	3,010
SARIMA	2,799	2,979	3,018	3,218	3,000
NNAR	4,399	4,584	4,660	4,669	4,580
Regressão dinâmica	<b>0,188</b>	<b>0,156</b>	<b>0,189</b>	<b>0,166</b>	<b>0,170</b>

Fonte: Autor, 2023

### 5.1.7 Métricas de Previsão

Analisando os valores apresentados pelas métricas na Tabela 5.28 e 5.29 e a média entre os quatro períodos apresentados, verificou-se que o modelo de Regressão Dinâmica possui os menores valores para a métrica RMSE e para a métrica MAPE o modelo apresentou os melhores resultados nos três primeiros períodos, no quarto período o melhor resultado foi apresentado pelo modelo Sarima consideradas na análise de previsão dos modelos. Assim, conclui-se que, dentre os modelos considerados, o modelo Regressão Dinâmica foi o que obteve a melhor capacidade de previsão aos dados de consumo de energia elétrica para a indústria de cimento no Brasil, por apresentar uma maior quantidade de vezes uma excelente capacidade preditiva.

Tabela 5.28 – Métricas de comparação entre os modelos para previsão valores RMSE.

Modelo	2001-2017	2001-2018	2001-2019	2001-2020	Média
Holt-Winters	44,784	45,147	58,565	129,671	69,541
SARIMA	41,352	42,176	52,334	114,249	62,527
NNAR	42,513	57,338	60,317	102,983	65,742
Regressão dinâmica	<b>14,186</b>	<b>34,931</b>	<b>35,566</b>	<b>38,285</b>	<b>30,742</b>

Fonte: Autor, 2023

Tabela 5.29 – Métricas de comparação entre os modelos para previsão valores MAPE.

Modelo	2018-2019	2019-2020	2020-2021	2021-2022	Média
Holt-Winters	7,033	6,843	9,795	6,628	7,570
SARIMA	6,192	6,521	8,900	<b>4,306</b>	6,480
NNAR	7,278	9,331	8,940	12,261	9,450
Regressão dinâmica	<b>2,429</b>	<b>5,842</b>	<b>6,644</b>	5,150	<b>5,020</b>

Fonte: Autor, 2023

### 6.1 Conclusões

Este trabalho apresenta uma análise detalhada e comparativa de diferentes modelos de séries temporais, sendo os modelos de Holt-Winters, SARIMA, NNAR (Redes Neurais Auto-regressivas) e Regressão Dinâmica, com o objetivo de prever o consumo de energia elétrica na indústria de cimento do Brasil. Esta análise é importante, visto que a indústria de cimento é um termômetro econômico, refletindo o crescimento do setor de construção civil, ou seja, um motor significativo da economia.

A pesquisa abrangeu o período de janeiro de 2001 a dezembro de 2022, envolvendo um grande volume de dados. Estes foram obtidos de fontes confiáveis, incluindo o Sindicato Nacional da Indústria do Cimento (SINC) e a Empresa de Pesquisa Energética (EPE). A abrangência e a qualidade dos dados fornecem uma base sólida para a análise, garantindo que os resultados sejam representativos e confiáveis.

A avaliação dos modelos foi conduzida utilizando as métricas de precisão do RMSE e MAPE. Essas métricas são cruciais para avaliar não apenas a precisão das previsões, mas também a robustez e a confiabilidade dos modelos em diferentes cenários e períodos.

Entre os modelos analisados, o modelo de Regressão Dinâmica destacou-se como o mais eficiente. Sua superioridade foi evidenciada tanto na capacidade de ajuste aos dados históricos quanto na precisão das previsões futuras. Este modelo, demonstrou ser particularmente adequado para lidar com a natureza variável e muitas vezes imprevisível do consumo de energia elétrica na indústria de cimento.

Embora o modelo de Regressão Dinâmica tenha apresentado o melhor desempenho geral, os outros modelos também apresentaram uma boa capacidade preditiva. O modelo de Holt-Winters, por exemplo, mostrou-se bastante eficaz na previsão de curto prazo, enquanto o SARIMA foi notável na captura de padrões sazonais.

A indústria de cimento, por estar intimamente ligada ao desenvolvimento infraestrutural, serve como um indicador da atividade econômica. Assim, as projeções do consumo de energia elétrica nesta indústria é importante para o planejamento e decisão estratégica. As projeções contribuem para legisladores, planejadores e agentes econômicos, facilitando decisões informadas que podem impactar a sustentabilidade econômica e ambiental.

Em vista dos resultados promissores, sugere-se a exploração de modelos híbridos ou a combinação dos modelos existentes com técnicas de aprendizado de máquina em estudos futuros. Outro trabalho interessante, seria introduzir a abordagem *bottom-up* para incorporar o comportamento regional e estadual do consumo de energia elétrica no Brasil.



## Referências bibliográficas

- 1 SILVA, F. L. C. e. a. Forecast of long-term electricity consumption of the industrial sub-sector of pulp and paper in brazil using a bottom-up approach. *Procedia Computer Science*, v. 55, p. 9, 2015.
- 2 Empresa de Pesquisa Energética. *Séries Estudos de Energia, Anuário Estatístico de Energia Elétrica*. 2021. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/anuario-estatistico-de-energia-eletrica>.
- 3 SILVA, F. L. C. et al. "a bottom-up methodology for long term electricity consumption forecasting of an industrial sector - Application to pulp and paper sector in Brazil". *Energy*, 2018.
- 4 Sindicato Nacional da Indústria do Cimento. *Relatórios anuais de 2001 a 2020*. 2021. Disponível em: <http://snic.org.br/numeros-relatorio-anual.php>.
- 5 ABCP. Associação brasileira de cimento portland. a indústria do cimento. 2023. Disponível em: <http://abcp.org.br/industria-do-cimento>.
- 6 Silva, F. L.; Cyrino Oliveira, F. L.; SOUZA, R. C. A bottom-up bayesian extension for long term electricity consumption forecasting. *Energy*, v. 167, p. 198–210, 2019. ISSN 0360-5442. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0360544218321984>.
- 7 MARÍNGOLO, V. *Clínquer Coprocessado: Produto de Tecnologia Integrada para Sustentabilidade e Competitividade da Indústria de Cimento*. Dissertação (Mestrado), 2001.
- 8 BATTAGIN A. F.; BATTAGIN, I. L. S. A evolução da normalização e de algumas propriedades dos cimentos portland brasileiros. 2010. Disponível em: [http://ibracon.org.br/publicacoes/revistas\\_ibracon/rev\\_construcao/pdf/Revista\\_Concreto\\_52.pdf](http://ibracon.org.br/publicacoes/revistas_ibracon/rev_construcao/pdf/Revista_Concreto_52.pdf).
- 9 LIMA, M. et al. On the brazilian energetic situation 1970 - 2030. *Ciência e Natura*, v. 37, n. 0, p. 06–16, 2015. ISSN 2179-460X. Disponível em: <https://periodicos.ufsm.br/cienciaenatura/article/view/18492>.
- 10 ARDAKANI, F. J.; ARDEHALI, M. M. Novel effects of demand side management data on accuracy of electrical energy consumption modeling and long-term forecasting. *Energy Conversion and Management*, v. 78, p. 745–752, 2014.

- 11 TAYLOR, J. W.; BUIZZA, R. Using weather ensemble predictions in electricity demand forecasting. *International Journal of Forecasting*, v. 19, p. 57–70, 2003.
- 12 BIANCO, V.; MANCA, O.; NARDINI, S. Electricity consumption forecasting in Italy using linear regression models. *Energy*, v. 34, n. 9, p. 1413–1421, 2009. ISSN 0360-5442. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0360544209002539>.
- 13 SANTANA, A. L. et al. Predict decision support system for load forecasting and inference: A new undertaking for Brazilian power suppliers. *Electrical Power and Energy Systems*, v. 38, p. 33–45, 2012.
- 14 SADOWNIK, R.; BARBOSA, E. P. Short-term forecasting of industrial electricity consumption in Brazil. *Journal of Forecasting*, v. 18, p. 215–224, 1999.
- 15 FAN, S.; HYNDMAN, R. J. Short-term load forecasting based on a semi-parametric additive model. *IEEE Transactions on Power Systems*, v. 27, p. 134–141, 2012.
- 16 CARGNELUTTI A.; MALUF, J. R. T. M. R. Geographic coordinates in the ten-day maximum and mean air temperature estimation in the state of Rio Grande do Sul, Brazil. v. 38, p. 2448–2456, 2008. Disponível em: <https://www.scielo.br/j/cr/a/qJzxkQmr9WB9nNYM5W5S5vP/?lang=pt#ModalTutors>.
- 17 KIBERT TITLE=Sustainable Construction: Green Building Design and Delivery, p. y. a. C. J. [S.l.: s.n.].
- 18 KIHARA, Y.; CENTURIONE, S. L. O cimento Portland. *CONCRETO: Ensino, pesquisa e realizações*. São Paulo: IBRACON, p. 295–322, 2005.
- 19 GRANGER, C. W. J.; NEWBOLD, P. *Forecasting Economic Time Series*. [S.l.]: Academic Press, New York., 1977.
- 20 WINTERS, P. R. Forecasting sales by exponentially weighted moving averages. *Management Science*, v. 6, n. 3, p. 324–342, 1960. Disponível em: <https://EconPapers.repec.org/RePEc:inm:ormnsc:v:6:y:1960:i:3:p:324-342>.
- 21 BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. *Time Series Analysis: Forecasting and Control*. [S.l.]: Prentice-Hall, 2015.
- 22 HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: principles and practice*. [S.l.]: OTexts, 2018.
- 23 ATHANASOPOULOS G.; AHMED, R. A. H. R. J. Hierarchical forecasts for Australian domestic tourism. *Journal of Forecasting*, v. 25., 2009. Disponível em: <https://robjhyndman.com/publications/hierarchical-tourism/>.
- 24 HYNDMAN R.JJ., . A. G. *Forecasting: principles and practice*. OTexts: Melbourne, Australia: 2nd edition, 2018.
- 25 FLEITER, T. e. a. Energy efficiency in the German pulp and paper industry – a model-based assessment of saving potentials. 2012. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S036054421200120X?via=I>.

- 26 HUANG, J.-H. W. Y.-H. Bottom-up analysis of energy efficiency improvement and co2 emission reduction potentials in the cement industry for energy transition: An application of extended marginal abatement cost curves. *Journal of Cleaner Production*, v. 296, n. 126619, p. 11, 2021. Disponível em: <[\(https://doi.org/10.1016/j.jclepro.2021.126619\)](https://doi.org/10.1016/j.jclepro.2021.126619)>(<<https://www.sciencedirect.com/science/article/pii/S0959652621008398>)>.
- 27 COSTA, K. V. S.; SILVA, F. L. C. Modelos de previsão de séries temporais aplicados ao produto interno bruto do brasil entre 1996 e 2019. In: . [s.n.], 2020. (Anais do XXVII Simpósio de Engenharia de Produção). Disponível em: <[https://www.researchgate.net/publication/346049627\\_Modelos\\_de\\_Previsao\\_de\\_Series\\_Temporais\\_Aplicados\\_ao\\_Produto\\_Interno\\_Bruto\\_do\\_Brasil\\_entre\\_1996\\_E\\_2019](https://www.researchgate.net/publication/346049627_Modelos_de_Previsao_de_Series_Temporais_Aplicados_ao_Produto_Interno_Bruto_do_Brasil_entre_1996_E_2019)>.
- 28 SWAN, L. G.; UGURSAL, V. I. Modeling of end-use energy consumption in the residential sector: A review of modeling techniques. *Renewable and Sustainable Energy Reviews*, v. 13, n. 8, p. 1819–1835, 2009. Disponível em: <<https://EconPapers.repec.org/RePEc:eee:rensus:v:13:y:2009:i:8:p:1819-1835>>.
- 29 MAÇAIRA, P. *Modelagem e previsão das séries de consumo de energia elétrica no Brasil com métodos de suavização exponencial de Pegels e abordagem bottom up por uso final*. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro – RJ, Brasil, 2015.
- 30 HYNDMAN R. J.; LEE, A. J. W. E. Fast computation of reconciled forecasts in hierarchical and grouped time series. v.55,. 2014.
- 31 HYNDMAN R. J.; LEE, A. J. W. E. Fast computation of reconciled forecasts for hierarchical and grouped time series. 2016.
- 32 COLLINS, D. W. Predicting earnings with sub-entity data: some further evidence. 1976.
- 33 DUNN D. M.; WILLIAMS, W. H. D. T. L. Aggregate versus sub aggregate models in local area forecasting. 1976.
- 34 ZELLNER A.; TOBIAS, J. A note on aggregation, disaggregation and forecasting performance. 2000.
- 35 DANGERFIELD B. J.; MORRIS, J. S. Top-down or bottom-up: aggregate versus disaggregate extrapolations. 1992.
- 36 FLIEDNER, G. Hierarchical forecasting: issues and use guidelines. 2001.
- 37 CHATEAU B.; LAPILLONNE, B. The medee models for long term energy demand forecasting. 1981.
- 38 GEROSKI, P. A. Models of technology diffusion. 2000.
- 39 MURATORI M.; ROBERTS, M. C. S. R. M. V. R. G. A highly resolved modeling technique to simulate residential power demand. 2013. Disponível em: <<<http://dx.doi.org/10.1016/j.apenergy.2013.02.057>>>.
- 40 KOOPMANS, C.; VELDE, D. W. te. Bridging the energy efficiency gap: using bottom-up information in a top-down energy demand model. *Energy Economics*, v. 23, n. 1, p. 57–75, 2001. Disponível em: <<https://EconPapers.repec.org/RePEc:eee:eneeco:v:23:y:2001:i:1:p:57-75>>.

- 41 CHEN W., Y. X. . M. D. A bottom-up analysis of china's iron and steel industrial energy consumption and co 2 emissions. *Applied Energy*, v. 136, n. 10, p. 1174–1183, 2014. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0306261914005765>>.
- 42 AMARAL MARIANE; SILVEIRA, A. M. V. B. E. Previsão da demanda de energia elétrica a curto prazo para região sul do brasil utilizando o modelo arima e o modelo de suavização exponencial de holt (seh). 2020. Disponível em: <<https://doi.org/10.5753/eniac.2020.12154>>.
- 43 EDELENBOSCH, O. Y. et al. Comparing projections of industrial energy demand and greenhouse gas emissions in long-term energy models. *Energy*, v. 122, n. 10, p. 701–710, 2017. Disponível em: <<https://doi.org/10.1016/j.energy.2017.01.017>>.
- 44 GEORGIOU, P. N. A bottom-up optimization model for the long-term energy planning of the greek power supply sector integrating mainland and insular electric systems. *Comput. Oper. Res.*, Elsevier Science Ltd., GBR, v. 66, n. C, p. 292–312, fev. 2016. ISSN 0305-0548. Disponível em: <<https://doi.org/10.1016/j.cor.2015.02.015>>.
- 45 YI, B.-W.; XU, J.-H.; FAN, Y. Inter-regional power grid planning up to 2030 in China considering renewable energy development and regional pollutant control: A multi-region bottom-up optimization model. *Applied Energy*, v. 184, n. C, p. 641–658, 2016. Disponível em: <<https://ideas.repec.org/a/eee/appene/v184y2016icp641-658.html>>.
- 46 LEE, C.-Y.; HUH, S.-Y. Forecasting new and renewable energy supply through a bottom-up approach: The case of South Korea. *Renewable and Sustainable Energy Reviews*, v. 69, n. C, p. 207–217, 2017. Disponível em: <<https://ideas.repec.org/a/eee/rensus/v69y2017icp207-217.html>>.
- 47 TANAKA, K. Review of policies and measures for energy efficiency in industry sector. *Energy Policy*, v. 39, p. 6532–6550, 10 2011.
- 48 RAO, R. Energy efficiency in industrial sector. *ieema*, 10 2012.
- 49 WAGNER C., O. M. . L. R.
- 50 FILIPPINI THOMAS GEISSMANN, V. J. K. D. Z. M. The productivity impacts of energy efficiency programs in developing countries: Evidence from iron and steel firms in china. *China Economic Review*, v. 59.
- 51 MAY BOJAN STAHL, M. T. D. K. G. Energy management in manufacturing: From literature review to a conceptual framework. *Journal of Cleaner Production*, v. 167.
- 52 ABDELAZIZ, E.; SAIDUR, R.; MEKHILEF, S. A review on energy saving strategies in industrial sector. *Renewable and Sustainable Energy Reviews*, v. 15, n. 1, p. 150–168, 2011. Disponível em: <<https://EconPapers.repec.org/RePEc:eee:rensus:v:15:y:2011:i:1:p:150-168>>.
- 53 LU, S.-M. et al. Energy-saving potential of the industrial sector of taiwan. *Renewable and Sustainable Energy Reviews*, v. 21, p. 674–683, 05 2013.
- 54 XU, J.-H. et al. CO2 emissions reduction potential in China's cement industry compared to IEA's Cement Technology Roadmap up to 2050. *Applied Energy*, v. 130, n. C, p. 592–602, 2014. Disponível em: <<https://ideas.repec.org/a/eee/appene/v130y2014icp592-602.html>>.

- 55 FLUES, F.; RÜBBELKE, D.; VÖGELE, S. An analysis of the economic determinants of energy efficiency in the european iron and steel industry. *Journal of Cleaner Production*, v. 104, n. C, p. 250–263, 2015.
- 56 BRUGGER WOLFGANG EICHHAMMER, N. M. E. D. H. Energy efficiency vision 2050: How will new societal trends influence future energy demand in the european countries? *Energy Policy*, v. 152, n. 11216, p. 15, 2021. Disponível em: <https://doi.org/10.1016/j.enpol.2021.112216>.(<https://www.sciencedirect.com/science/article/pii/S0301421521000859>)>.
- 57 BRUNKE, J.-C.; BLES, M. A plant-specific bottom-up approach for assessing the cost-effective energy conservation potential and its ability to compensate rising energy-related costs in the German iron and steel industry. *Energy Policy*, v. 67, n. C, p. 431–446, 2014. Disponível em: <https://ideas.repec.org/a/eee/enepol/v67y2014icp431-446.html>>.
- 58 BRUNKE, J.-C.; BLES, M. Energy conservation measures for the german cement industry and their ability to compensate for rising energy-related production costs. *Journal of Cleaner Production*, 06 2014.
- 59 HUANG, Y.-H.; CHANG, Y.-L.; FLEITER, T. A critical analysis of energy efficiency improvement potentials in Taiwan's cement industry. *Energy Policy*, v. 96, n. C, p. 14–26, 2016. Disponível em: <https://ideas.repec.org/a/eee/enepol/v96y2016icp14-26.html>>.
- 60 SNIC. Sindicato nacional da indústria do cimento. dados estatísticos. 2023. Disponível em: <https://www.snic.org.br/estatisticas/>.
- 61 RSVC. Relatório de sustentabilidade votorantim cimentos 2020. 2020. Disponível em: <https://www.votorantimcimentos.com.br/content/dam/vcbr/files/publicacoes/relatorios-sustentabilidade/vc-relatorio-sustentabilidade-2020.pdf>>.
- 62 BRASIL. *Lei No 12.305, de 2 de agosto de 2010*. 2010. Política Nacional de Resíduos Sólidos. Disponível em: [https://www.planalto.gov.br/ccivil\\_03/\\_ato2007-2010/2010/lei/l12305.htm](https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2010/lei/l12305.htm)>.
- 63 RENOVÁVEIS, I. B. do Meio Ambiente e dos R. N. *Instrução Normativa IBAMA No 6, de 15 de fevereiro de 2021*. 2021. Dispõe sobre os procedimentos para a apresentação e a análise do Relatório de Controle Ambiental (RCA) e do Plano de Controle Ambiental (PCA). Disponível em: <https://www.ibama.gov.br/component/legislacao/?view=legislacao&legislacao=108894>>.
- 64 GUIMARÃES A. C.; CHAGAS, A. P. A história da produção de cimento no brasil. 2014. Disponível em: <http://www.scielo.br/pdf/mc/v64n334/v64n334a14.pdf>>.
- 65 MINERAÇÃO, A. N. de. Emissões de gases do efeito estufa no setor mineral brasileiro. 2021. Disponível em: <https://www.gov.br/anm/pt-br/assuntos/sustentabilidade-em-pauta/emissoes-de-gases-do-efeito-estufa-no-setor-mineral-brasileiro.pdf>>.
- 66 ECONÔMICO, V. Importação de cimento põe pressão sobre preço no brasil. 2022. Disponível em: <https://valor.globo.com/empresas/noticia/2022/01/25/importacao-de-cimento-poe-pressao-sobre-preco-no-brasil.ghml>>.
- 67 NIELSEN. Sustentabilidade como fator de compra. 2022. Disponível em: <https://www.nielsen.com/br/pt/insights/article/2022/sustentabilidade-como-fator-de-compra/>>.

- 68 ENERGIA, A. I. de. Cement. 2021. Disponível em: <<https://www.iea.org/reports/cement>>.
- 69 CIÊNCIA, T. e. I. Ministério da. Inventário nacional de emissões atmosféricas por fontes e remoções por sumidouros de gases de efeito estufa. 2021. Disponível em: <[https://www.mctic.gov.br/mctic/opencms/clima/inventario\\_emissoes/2020.html](https://www.mctic.gov.br/mctic/opencms/clima/inventario_emissoes/2020.html)>.
- 70 SILVA, R. M.; GRACIOSO, L. A.; MELO, D. M. C. Tendências tecnológicas da indústria de cimento visando a sustentabilidade ambiental. *Revista Brasileira de Engenharia e Sustentabilidade*, v. 3, n. 2, p. 96–109, 2017. Disponível em: <<https://revistas.uepg.br/index.php/ret/article/view/21138>>.
- 71 NUNES, R. A. O uso do gás natural na produção de cimento e as alternativas energéticas renováveis. 2019. Disponível em: <<https://www.meioambientepocos.com.br/anais2019.html>>.
- 72 RENOVÁVEIS, I. B. do Meio Ambiente e dos R. N. *Portaria IBAMA No 19, de 27 de janeiro de 2022*. 2022. Estabelece procedimentos para o licenciamento ambiental federal de empreendimentos de geração de energia elétrica a partir de fonte eólica offshore. Disponível em: <<https://www.ibama.gov.br/component/legislacao/?view=legislacao&legislacao=125982>>.
- 73 UNIÃO, C.-G. da. *Manual de Responsabilização de Entes Privados*. 2022. PDF disponível no repositório da Controladoria-Geral da União. Acessado através da extensão do Chrome. Disponível em: <[chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/https://repositorio.cgu.gov.br/bitstream/1/68182/5/Manual\\_de\\_Responsabiliza%C3%A7%C3%A3o\\_de\\_Entes\\_Privados\\_abril\\_2022\\_Corrigido.pdf](chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/https://repositorio.cgu.gov.br/bitstream/1/68182/5/Manual_de_Responsabiliza%C3%A7%C3%A3o_de_Entes_Privados_abril_2022_Corrigido.pdf)>.
- 74 DESENVOLVIMENTO, B. I. de. *Melhores Gastos para Melhores Vidas: Como a América Latina e o Caribe podem fazer mais com menos*. 2018. Publicação online. Disponível em: <<https://publications.iadb.org/pt/melhores-gastos-para-melhores-vidas-como-america-latina-e-o-caribe-podem-fazer-mais-com-menos>>.
- 75 ORAIR, R. O. *Política fiscal no Brasil contemporâneo: investimento público e ciclos econômicos*. 2018. Trabalho acadêmico.
- 76 MORETTIN, P. A.; TOLOI, C. M. C. *Análise de Séries Temporais*. [S.l.]: Edgard Blucher, 2018.
- 77 TRUTNEVYTE, E. Does cost optimization approximate the real-world energy transition? *Energy*, v. 106, p. 182–193, 2016. ISSN 0360-5442. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360544216302821>>.
- 78 BOX, G.; JENKINS, G. *Time Series Analysis: Forecasting and Control*. Holden-Day, 1976. (Holden-Day series in time series analysis and digital processing). ISBN 9780816211043. Disponível em: <<https://books.google.com.br/books?id=1WVHAAAAMAAJ>>.
- 79 BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. *Time Series Analysis: Forecasting and Control*. 5. ed. [S.l.]: John Wiley & Sons, 2016. 100-105 p.
- 80 ENDERS, W. *Applied Econometric Time Series*. [S.l.]: John Wiley & Sons, 2014.
- 81 CHATFIELD, C. *The Analysis of Time Series: An Introduction*. [S.l.]: CRC Press, 2016.
- 82 MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, v. 5, n. 4, p. 115–133, 12 1943. ISSN 1522-9602. Disponível em: <<https://doi.org/10.1007/BF02478259>>.



- 83 Deep Learning Book - Em Português, BR. *Capítulos 10*. Acessado em 2023. Disponível em: <https://www.deeplearningbook.com.br/capitulos/>.
- 84 GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. <http://www.deeplearningbook.org>.
- 85 HAYKIN, S. *Neural Networks and Learning Machines*. 3. ed. [S.l.]: Pearson, 2009. ISBN 0131471392.
- 86 ZANETTI, S. S. et al. Estimação da evapotranspiração de referência no estado do rio de janeiro usando redes neurais artificiais. *Revista Brasileira de Engenharia Agrícola e Ambiental*, Departamento de Engenharia Agrícola - UFCG, v. 12, n. 2, p. 174–180, Mar 2008. ISSN 1415-4366. Disponível em: <https://doi.org/10.1590/S1415-43662008000200010>.
- 87 BERNTSEN, P.; TRUTNEVYTE, E. Ensuring diversity of national energy scenarios: Bottom-up energy system model with modeling to generate alternatives. *Energy*, v. 126, p. 886–898, 03 2017.
- 88 CHAGAS, C. S. et al. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. *Revista Brasileira de Engenharia Agrícola e Ambiental*, Departamento de Engenharia Agrícola - UFCG, v. 13, n. 3, p. 319–327, May 2009. ISSN 1415-4366. Disponível em: <https://doi.org/10.1590/S1415-43662009000300014>.

Neste presente trabalho, as análises estatísticas foram realizadas usando o software R versão 4.0.5 (The R Foundation for Statistical Computing, localizada em Viena, Áustria; disponível em <http://www.r-project.org>). Foram empregadas as seguintes bibliotecas para os modelos específicos de séries temporais:

### **Modelo Holt-Winters Aditivo**

Biblioteca: forecast.

Função: No Modelo Holt-Winters foi implementada a função `hw()` da biblioteca forecast.

### **Modelo SARIMA**

Biblioteca: forecast.

Função: `Arima()` ou `auto.arima()` para modelos SARIMA.

### **Modelo de Redes Neurais(NNAR)**

Biblioteca: forecast ou nnfor.

Função: `nnetar()` para implementação de modelos de redes neurais autorregressivas para séries temporais.

### **Modelo de Regressão Dinâmica**

Biblioteca: forecast.

Função: A função `auto.arima()` juntamente com variáveis exógenas ou a função `Arima()` pode ser utilizada para ajustar modelos de regressão dinâmica.

As bibliotecas adicionais foram: `fpp2`, `readxl`, `astsa`, e `ggplot2` também foram utilizadas para suportar a análise e visualização de dados.