

## **DISSERTAÇÃO DE MESTRADO**

Modelagem de um Sistema de Abastecimento de Água  
utilizando Séries Temporais

**NEILTON DE MIRANDA PINTO**

**BRASÍLIA, 15 DE OUTUBRO DE 2025**

**UNIVERSIDADE DE BRASILIA**  
Faculdade de Tecnologia  
DEPARTAMENTO DE ENGENHARIA MECÂNICA

UNIVERSIDADE DE BRASILIA  
Faculdade de Tecnologia

## **DISSERTAÇÃO DE MESTRADO**

Modelagem de um Sistema de Abastecimento de Água  
utilizando Séries Temporais

**NEILTON DE MIRANDA PINTO**

*Dissertação submetida ao Departamento de Engenharia Mecânica da Faculdade de  
Tecnologia da Universidade de Brasília, como requisito parcial para obtenção do grau de  
Mestre em Sistemas Mecatrônicos.*

### **Banca Examinadora**

Prof. Dr. Antônio Piratelli Filho, UnB/ ENM (Orientador)

---

Prof. Dr. Sadek Absi Alfaro (PPMEC), UnB/ ENM (Examinador Interno)

---

Prof. Dr. Rosenda Valdés Arencibia (UFU) (Examinador Externo)

---

Brasília, 15 de setembro de 2025.

## **Dedicatória,**

Ao Eterno, que me concedeu o intelecto e a racionalidade humana, minha fonte de sabedoria e conhecimento. Capacitou-me ao exercício da prudência, diligência e reflexão.

À minha mãe, Maria de Miranda Pinto (*in memoriam*), que dedicou a sua vida em prol da educação e bom cuidado com os filhos.

À minha digníssima esposa, Adriana Aparecida Teixeira de Oliveira, que me inspira a crescer e acredita em meu potencial.

Ao meu filho, Lucas Gabriel de Araújo Miranda, que é motivo de orgulho e satisfação em minha vida.

Ao corpo docente do Programa de Pós-graduação em Sistemas Mecatrônicos – PPMEC, que me acolheu de forma ética e profissional, motivando e direcionando em todos os momentos.

*“Aja apenas segundo uma máxima tal que possas, ao mesmo tempo, querer que ela se torne uma lei universal”*

*Immanuel Kant*

## **RESUMO**

Este estudo apresenta a modelagem de um Sistema Instrumentado de Abastecimento de Água – SIAA por meio de Séries Temporais. A modelagem foi feita para os seguintes parâmetros de desempenho: vazão mínima noturna, índices de perda na distribuição, consumo de energia elétrica, demandas horária, mensal e per capita. O conjunto de dados foi extraído do banco de dados de uma companhia de abastecimento de água, contemplando um período de 8 anos. O desenvolvimento dos algoritmos foi feito utilizando a linguagem de programação estatística R e o ambiente de desenvolvimento integrado RStudio, com o intuito de efetuar o ajuste dos dados aos modelos de séries temporais e previsão dos parâmetros. A revisão bibliográfica investigou, no âmbito da literatura técnica e acadêmica, as três vertentes que envolvem a questão de pesquisa: a eficácia de modelos estatísticos que trabalham com a análise de dados e o comportamento de variáveis no tempo; a importância do planejamento de demanda em sistemas de produção; e os aspectos de funcionamento e gerenciamento de sistemas de abastecimento de água – SAAs. Neste último tópico, estão incluídas tecnologias emergentes como Telemetria e Business Intelligence. Após todas as compilações necessárias, foi verificado que o modelo ARIMA com sazonalidade foi adequado para o consumo mensal, dada a assertividade das previsões elaboradas. O método de análise por séries temporais viabilizou a definição de características fundamentais e a promoção de ajustes e previsões operacionais no sistema. A parametrização proposta pela modelagem identificou variáveis importantes do processo, viabilizando a elaboração de planos de produção e operação de maior eficiência, eficácia e efetividade.

Palavras-chave: Instrumentação, Séries Temporais, Modelo ARIMA.

## **ABSTRACT**

This study presents the modeling of an Instrumented Water Supply System (IWSS) using Time Series. The modeling was performed for the following performance parameters: minimum night flow, distribution loss indices, electricity consumption, hourly, monthly, and per capita demands. The dataset was extracted from the database of a water supply company, covering a period of 8 years. The algorithms were developed using the R statistical programming language and the RStudio integrated development environment, with the aim of fitting the data to the time series models and forecasting the parameters. The literature review investigated, within the scope of technical and academic literature, the three aspects involved in the research question: the effectiveness of statistical models that work with data analysis and the behavior of variables over time; the importance of demand planning in production systems; and the operational and management aspects of water supply systems (WSSs). This last topic includes emerging technologies such as Telemetry and Business Intelligence. After all the necessary data compilations, it was verified that the ARIMA model with seasonality was suitable for monthly consumption, given the accuracy of the forecasts produced. The time series analysis method enabled the definition of fundamental characteristics and the promotion of operational adjustments and forecasts in the system. The parameterization proposed by the modeling identified important process variables, enabling the development of more efficient, effective, and impactful production and operation plans.

**Keywords:** Instrumentation, Time Series, ARIMA Model.

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>12</b>
1.1 Contextualização .....	12
1.2 Justificativa e Relevância do Tema .....	13
1.3 Questão de Pesquisa .....	15
1.4 Objetivos .....	15
1.4.1 Objetivo Geral .....	15
1.4.2 Objetivos Específicos .....	15
1.5 Organização da Dissertação .....	16
<b>2 REFERENCIAL TEÓRICO .....</b>	<b>16</b>
2.1 Previsão de Demanda .....	17
2.2 Gerenciamento de sistemas de abastecimento de água .....	20
2.2.1 Modelagem de Redes de Distribuição.....	20
2.2.2 Balanço Hídrico.....	22
2.2.3 Controle de perdas na distribuição: gerenciando vazão e pressão dinâmica em tubulações .....	24
2.2.4 Eficiência energética em Sistemas de Abastecimento .....	29
2.2.5 Tecnologias aplicadas na operação e gerenciamento de Sistemas de Abastecimento de Água .....	30
2.3 Modelagem de Séries Temporais.....	39
<b>3 MÉTODOLOGIA DE PESQUISA .....</b>	<b>44</b>
3.1 Instrumentação, Armazenamento e Coleta de Dados .....	45
3.2 Ferramentas computacionais .....	50
3.3 Percurso metodológico .....	51
3.4 Técnicas e recursos utilizados para ajuste dos modelos.....	52
<b>4 RESULTADOS E DISCUSSÕES .....</b>	<b>55</b>
4.1 Demanda per capita .....	55
4.2 Demanda mensal (m <sup>3</sup> ) .....	59
4.3 Índices de perdas na distribuição - IPD.....	63
4.4 Consumo de energia elétrica.....	68
4.5 Verificação da eficácia das previsões .....	73
4.6 Comportamento da vazão mínima noturna .....	75
4.7 Equações ajustadas para o modelo ARIMA.....	77
<b>5 CONCLUSÕES E SUGESTÃO DE TRABALHOS FUTUROS.....</b>	<b>79</b>
<b>REFERENCIAS BIBLIOGRAFICAS .....</b>	<b>81</b>
<b>APÊNDICES.....</b>	<b>84</b>

## **LISTA DE FIGURAS**

Figura 2.1: Métodos Quantitativos de Previsão .....	18
Figura 2.2: Exemplo de previsão de demanda .....	18
Figura 2.3: Padrões de Séries Temporais .....	20
Figura 2.4: Estrutura Padrão do Balanço Hídrico .....	23
Figura 2.5: Perfil de velocidades em um tubo.....	26
Figura 2.6: Tubo de corrente.....	26
Figura 2.7: Válvula Redutora de Pressão – VRP .....	27
Figura 2.8: Variação de vazão em uma UDA .....	28
Figura 2.9: Setorização de redes de abastecimento .....	29
Figura 2.10: Exemplo de um Centro de Controle e Operação .....	31
Figura 2.11: Evolução e características das revoluções industriais .....	32
Figura 2.12: Computação em Nuvem – Infraestrutura e Aplicações .....	33
Figura 2.13: Interação entre elementos ciber-físicos.....	35
Figura 2.14: Sistema Autônomo de Tratamento de Água .....	36
Figura 2.15: Arquitetura <i>Business Intelligence</i> .....	37
Figura 2.16: Painéis de monitoramento de SAA.....	38
Figura 2.17: Estação de Bombeamento Instrumentada .....	39
Figura 2.18: Padrões de séries temporais .....	40
Figura 3.1: <i>Dataloggers</i> .....	45
Figura 3.2: Instrumentação do Barrillete de Recalque .....	46
Figura 3.3: Instrumentação na Linha de Distribuição .....	46
Figura 3.4: Reservatórios de Abastecimento.....	47
Figura 3.5: Sistema Supervisório de Automação.....	47
Figura 3.6: Dados tabulados por sistema de telemetria .....	47
Figura 3.7: Tempos de operação de conjuntos motobombas .....	48
Figura 3.8: Painel de extração de dados e informações .....	49
Figura 3.9: Painel de extração de dados e informações - SAA.....	50
Figura 3.10: Processamento stepwise (auto.arima) .....	53
Figura 4.1 Data frame demanda per capita .....	55
Figura 4.2 Série Temporal – demanda per capita .....	55
Figura 4.3 Parâmetros do modelo.....	56

Figura 4.4 Análise de Resíduos – consumo per capita .....	56
Figura 4.5 Analise de Autocorrelação .....	57
Figura 4.6 Teste de estacionariedade .....	57
Figura 4.7 Projeção demanda per capita .....	58
Figura 4.8 Projeção per capita (gráfica).....	58
Figura 4.9 Vetor de dados consumo mensal .....	59
Figura 4.10 Série Temporal .....	60
Figura 4.11 Parâmetros de otimização .....	60
Figura 4.12 Análise de resíduos (teste) .....	61
Figura 4.13 Análise de resíduos (gráfico) .....	61
Figura 4.14 Teste de estacionariedade .....	62
Figura 4.15 Previsão de demanda mensal .....	62
Figura 4.16 Previsão gráfica de demanda mensal .....	63
Figura 4.17 Vetor - IPD .....	63
Figura 4.18 Série Temporal - IPD .....	64
Figura 4.19 Parâmetro do modelo .....	65
Figura 4.20 Teste de resíduos .....	65
Figura 4.21 Projeção - gráfico.....	66
Figura 4.22 Teste de estacionariedade .....	66
Figura 4.23 Série Temporal Energia – gráfico .....	67
Figura 4.24 Previsão – vetor (IPD).....	67
Figura 4.25 Previsão IPD - gráfico .....	68
Figura 4.26 Vetor de dados - energia .....	69
Figura 4.27 Série histórica - energia .....	69
Figura 4.28 Parâmetro ARIMA.....	69
Figura 4.29 Análise de resíduos .....	70
Figura 4.30 Análise de resíduos .....	71
Figura 4.31 Teste de estacionariedade vetor de dados históricos .....	71
Figura 4.32 Teste de estacionariedade .....	72
Figura 4.33 Análise gráfica - previsão.....	72
Figura 4.34 Série Temporal – vazão mínima noturna .....	75
Figura 4.35 Valores médios da mínima noturna (horários) .....	75
Figura 4.36 Valores médios da mínima noturna (horários) .....	76

Figura 4.37 Valores médios da mínima noturna (horários) .....	76
Figura 4.38 Valores médios da mínima noturna (horários) .....	77

## **LISTA DE TABELAS**

Tabela 2.1: Faixa de populações e consumo per capita .....	19
Tabela 3.1: Modelagem das Séries Temporais: .....	54
Tabela 4.1: Nível de eficácia do modelo – Demanda mensal .....	73
Tabela 4.2: Nível de eficácia do modelo – Energia .....	74
Tabela 4.3: Nível de eficácia do modelo – IPD .....	74

## **LISTA DE SIGLAS E ABREVIATURAS**

ANA – AGÊNCIA NACIONAL DE ÁGUA

SAA – SISTEMA DE ABASTECIMENTO DE ÁGUA

SNIS - SISTEMA NACIONAL DE INFORMAÇÕES SOBRE O SANEAMENTO

DMC - DISTRITO DE MEDAÇÃO E CONTROLE

ETA - ESTAÇÃO DE TRATAMENTO DE ÁGUA

BI - BUSINESS INTELLIGENCE

VRP - VÁLVULA REDUTORA DE PRESSÃO

MCA - METRO DE COLUNA D'ÁGUA

UDA - UNIDADE DE DISTRIBUIÇÃO DE ÁGUA

ARIMA - MODELO AUTOREGRESSIVO INTEGRADO DE MÉDIA MÓVEL

IPD - ÍNDICE DE PERDA NA DISTRIBUIÇÃO

## **1. INTRODUÇÃO**

Este capítulo apresenta os elementos norteadores da pesquisa e um panorama do tema no segmento industrial a que pertence: sistemas automatizados por meio de instrumentos e telemetria. Foram definidas bases metodológicas, justificativa e objetivos consistentes com a relevância da questão a ser investigada.

### **1.1 CONTEXTUALIZAÇÃO**

Diante dos desafios impostos pelo ambiente regulatório, a automação de processos de produção, controle e distribuição de água potável tem sido adotada como instrumento de otimização de recursos e elevação da eficiência energética. A redução dos níveis de perda na operação dos sistemas de abastecimento está diretamente relacionada a implantação de projetos de monitoramento, estudos e diagnósticos que subsidiam o planejamento operacional. Para os fins desta pesquisa, a atenção será concentrada nos Sistemas de Abastecimento de Água – SAAs operados com auxílio de instrumentação, com análise específica de uma Unidade de Distribuição - UDA pressurizada por um conjunto de bombeamento e monitorada por dispositivos de telemetria.

Dados retirados do Diagnóstico SNIS 2022 (Ministério das Cidades) nos informam que no Brasil há 808,2 mil quilômetros de extensão de redes de abastecimento; 64,4 milhões de ligações; consumo per capita médio de 148,2 l/hab/dia; e um índice de perda médio de 37,8%. Todavia, as companhias estaduais ainda buscam avançar nos projetos de automação, visando a maior eficiência de suas operações.

Diante do cenário apresentado, e tendo em vista que aplicações tecnológicas elevam a eficiência dos meios de produção, a evolução de sistemas mecânicos controlados por recursos computacionais tem se apresentado como opção bastante viável para o monitoramento de dados operacionais e maior disponibilidade de recursos.

Tendo em vista que determinados problemas demandam soluções bem elaboradas, a pesquisa acadêmica e científica possibilita elevar o nível de eficácia na gestão de sistemas de abastecimento pública de água tratada. Para Alain Biahmou

(2015), a Engenharia de Sistemas é uma metodologia para dominar a complexidade, o que na verdade significa aplicar pensamento sistêmico para enfrentar os desafios da criação de produtos complexos. O ferramental matemático e estatístico melhora os resultados de avaliação e decisões importantes em matéria de operações industriais.

O tratamento estatístico de bases de dados robustas requer um trabalho criterioso de análise devido à multidisciplinaridade de conhecimentos que, muitas vezes, ali se encontram. Para Alain Biahmou (2015), um sistema RDB – Requirements Data Base – é composto das seguintes áreas de conhecimento:

- *Electric/Electronics*
- *Mechanics*
- *Software*
- *Systems Engineering*

Esse modelo simboliza a união de áreas da tecnologia envolvidas em soluções complexas, bem como os requisitos envolvidos e a estruturação.

## 1.2 JUSTIFICATIVA E RELEVÂNCIA DO TEMA

A automação e controle de processos na indústria de saneamento têm promovido resultados satisfatórios na busca de modernização do setor. O monitoramento do consumo médio de água em sistemas de abastecimento viabiliza o planejamento e controle operacional pelas companhias públicas e privadas do país; eleva a eficiência no dimensionamento de novos projetos e a eficácia na implementação de medidas de racionamento do consumo em regiões com escassez hídrica.

Dado o potencial da automação em viabilizar o monitoramento de sistemas e a produção de dados em massa, a proposta deste trabalho é utilizar o recurso estatístico de séries temporais para elaborar previsões que sejam mais assertivas e que elevem o nível de gestão operacional.

Para BLEIDORN et al. (2023), “A análise de séries temporais é uma ferramenta útil para muitas aplicações práticas de gestão de recursos hídricos, como planejamento e antecipação de conflitos em torno do uso da água”. A utilização de

métodos estatísticos para previsão de demanda por abastecimento em sistemas públicos proporciona os seguintes benefícios:

- Antecipação do perfil de consumo nas regiões de abastecimento;
- Auxílio na elaboração de planos de otimização de recursos de produção;
- Estabelecimento de diretrizes para utilização racional das vazões disponíveis em corpos hídricos.

Como um dos componentes do Saneamento Ambiental, a água tratada possui relevante importância tanto por ser um bem essencial à vida como pela escassez de suas fontes naturais. O ambiente legislativo e regulatório brasileiro tem estabelecido normas e diretrizes que visam à expansão e modernização dos sistemas de abastecimento público com a nobre intenção de proporcionar a cobertura integral desse serviço no território nacional.

De acordo com o Sistema Nacional de Informações sobre Saneamento no Brasil, a medição de grandes volumes de água aportados é conhecida como macromedição. Essa é feita por meio de equipamentos na saída das ETAs e em diferentes pontos da rede de distribuição. Dados do SNIS-AE 2022 informam que o índice de macromedição (IN011) alcança 72,3%. Numa comparação simples, significa que, de cada 100 litros de água disponibilizados para consumo, 72,3 litros foram efetivamente medidos. (Diagnóstico Temático – Serviços de Água e Esgoto / 2022).

Para (SOBRINHO, Renavan Andrade; BORJA, Patrícia Campos; 2016):

A universalização do acesso à água em condições de potabilidade, com implantação e manutenção de uma infraestrutura capaz de atender de maneira adequada e otimizada à demanda dos grandes centros urbanos, é o grande desafio dos prestadores de serviço público de abastecimento de água para as próximas décadas. Destarte, o controle das perdas nos sistemas de abastecimento de água, somado a projetos apropriados e ao uso racional da água pela população, é um instrumento fundamental para a sustentabilidade dos recursos hídricos. (SOBRINHO, Renavan Andrade; BORJA, Patrícia Campos. **Management of water and energy losses in Embasa water supply systems: a study of factors involved in RMS**. Salvador – BA, 2016.

Dessa forma é possível compreender que o controle estatístico dos processos de distribuição e demanda de água tratada são de fundamental importância para o

alcance de metas e objetivos relacionados à Sustentabilidade em seu tripé: Econômico, Social e Ambiental.

### **1.3 QUESTÃO DE PESQUISA**

A automação e controle de processos são ferramentas largamente utilizadas no segmento industrial. A modelagem de demanda de água potável em regiões geográficas atendidas por sistemas de abastecimento automatizados possui como fim a otimização do desempenho operacional e o subsídio ao planejamento e gestão operacional. Razão esta que impõe ao setor necessidade de estudo e pesquisa.

### **1.4 OBJETIVOS**

Esta pesquisa possui o intuito de avaliar parâmetros funcionais em um Distrito de Medição e Controle – DMC que possui operação automatizada; responsável pelo abastecimento de 3025 unidades de consumo residencial, 63 comerciais, 5 unidades de instituições públicas e 1 industrial na cidade de Brazlândia/DF. Visa ainda ao estabelecimento de um modelo operacional de desempenho referente ao controle de vazão, consumo energético do processo produtivo, demanda per capita, consumo mensal e perdas na distribuição.

#### **1.4.1 Objetivo Geral**

Implementar modelos preditivos de consumo em um sistema instrumentado de distribuição de água potável, com ênfase nos parâmetros de vazão horária e volumes de consumo mensal e per capita. Por meio da modelagem de séries temporais estabelecer parâmetros que possam definir características fundamentais e contribuir para previsões e ajustes nas operações do sistema.

#### **1.4.2 Objetivos Específicos**

- Identificar parâmetros que subsidiem planos de produção e distribuição de água potável;
- Avaliar os atuais índices de perda na distribuição e contribuir com a melhoria da gestão operacional do sistema;

- Avaliar o perfil de consumo energético da Unidade de Distribuição - UDA;
- Localizar possíveis falhas no processo de distribuição;
- Modelar séries temporais para os principais parâmetros de desempenho e identificar erros na previsão de demanda.

## **1.5 ORGANIZAÇÃO DA DISSERTAÇÃO**

A presente Dissertação foi organizada a partir de Introdução, Referencial Teórico, Materiais e Método, Resultados, Conclusões e sugestão de trabalhos futuros, Referências Bibliográficas e Apêndice. No capítulo 1, o texto é introduzido a partir de uma contextualização do tema e do cenário em que se encontra, seguido de elementos que justifiquem a pesquisa e relevância das questões abordadas. A elaboração da questão de pesquisa, definição dos objetivos e formação de hipótese a ser investigada aparecem na sequência. O capítulo 2 discorre sobre as referências bibliográficas encontradas na literatura técnica e acadêmica, especificamente livros, artigos científicos, relatórios de acesso público e sites de empresas privadas que atuam no segmento. Está dividido em três subtópicos que se interrelacionam na compreensão global da proposta e de seus resultados. No capítulo 3 são apresentados o percurso metodológico e o ferramental utilizado na coleta e processamento dos dados históricos do sistema estudado. Já os capítulos 4 e 5 apresentam os resultados obtidos com as análises e suas devidas conclusões, respectivamente. Por fim são listadas todas as referências bibliográficas utilizadas e um apêndice contendo materiais importantes, como os scripts da linguagem R desenvolvidos na modelagem das séries temporais.

## **2. REFERENCIAL TEÓRICO**

Nesta seção são abordados conhecimentos consolidados pela literatura no que diz respeito ao embasamento teórico e científico do que se propõe a investigar com os estudos. Isto valendo para as características operacionais e tecnológicas do sistema, seu gerenciamento e as ferramentas metodológicas adotadas para análise dos dados referentes aos objetivos específicos já mencionados.

## 2.1 PREVISÃO DE DEMANDA

Os sistemas de produção de água tratada abastecem reservatórios que por sua vez alimentam redes de distribuição e demais dispositivos operacionais. Normalmente a demanda de consumidores varia em função do perfil da unidade (residencial, comercial, industrial e público) e de períodos sazonais, basicamente. Um bom planejamento de produção e operações industriais passa pela previsão de demanda.

Por meio das definições de SILVA (2003), é possível compreender que:

demandas podem incluir as necessidades do mercado (clientes finais), as necessidades de distribuição, as necessidades de reabastecimento (armazéns na indústria em geral; reservatórios em um sistema de abastecimento de água) e a necessidade entre processos (plantas industriais ou ETA's em sistemas de saneamento). As necessidades da empresa envolvem as demandas por produtos acabados, pedidos nos postos de abastecimento e as demandas a serem previstas, fazendo assim uma antecipação.

Prever demanda por produtos e serviços é uma das mais importantes tarefas no gerenciamento de empresas. A previsão de demanda significa apoiar a gerência a decidir, onde, quando e quanto produzir ou realizar serviços. (SILVA, Carla Silva da. **Tese Doutoral: Previsão multivariada da demanda horária de água em sistemas urbanos de abastecimento**. Campinas – SP, 2003).

A autora complementa que “Toda a hierarquia de decisão da cadeia de suprimentos é afetada pela previsão da demanda, incluindo etapas tais como” (Adaptado de SILVA, Carla Silva da; Campinas – SP, 2003).

- Planejamento de Capacidade;
- Plano Mestre de Produção;
- Planejamento de estoque;
- Sequenciamento e alocação de recursos.

A figura 2.1 apresenta elementos fundamentais para da elaboração de previsões quantitativas, incluindo a modelagem de séries temporais.

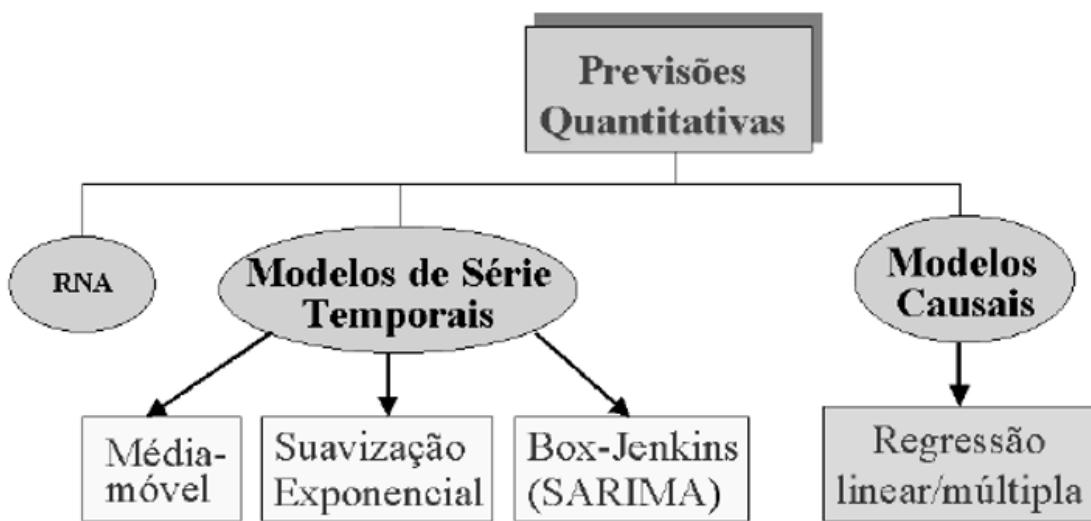


Figura 2.1 - Métodos Quantitativos de Previsão. Fonte: SILVA (2003)

Em matéria de sistemas de abastecimento urbano, conhecer a demanda horária por vazões nas linhas principais proporciona o melhor direcionamento em manobras de válvulas de abertura e fechamento, controle de pressão e equipamentos de elevação. Outro parâmetro importante, nessa mesma linha, é a sazonalidade. Em períodos diurnos ocorrem horários de pico e menor consumo; assim como em períodos semanais e anuais, de acordo com os meses do ano. A figura 2.2 exemplifica uma curva de previsão de demanda por um produto com alta sazonalidade.



Figura 2.2 - exemplo de previsão de demanda. Fonte: KUSTERS (2023).

ROCHA E SILVA et al. (1999) apud (FEIL, Alexandre André; HAETINGER, Claus; 2013) discorrem em artigo publicado que no âmbito do Brasil, “o método de

previsão não está sendo usado em larga escala. Geralmente o SAA é planejado a partir da previsão e projeção do consumo per capita de água". Fundamentalmente, outros fatores têm de ser levados em conta quando do dimensionamento de sistemas de abastecimento. Dado que o consumo de água envolve outras variáveis relacionadas a clima, sazonalidade, população e classes socioeconômicas das regiões atendidas.

Em se tratando de número de habitantes, Magalhães et al. (2001) apud (FEIL, Alexandre André; HAETINGER, Claus; 2013) estudaram 83 sistemas de abastecimento de água rurais e urbanos em São Paulo, com população de até 113 mil habitantes, concluindo que "há fraca influência da relação entre o porte da cidade e o consumo per capita de água".

A tabela 2.1 contém as faixas de população e seus respectivos consumos per capita, evidenciando baixa influência entre a quantidade de habitantes e o consumo per capita de água na cidade.

<b>Faixa de população (habitantes)</b>	<b>Consumo per capita L/hab/dia</b>
<2.000	130
2000 - 10000	125
10000 - 50000	133
50000 - 120000	128

Tabela 2.1 - Faixa de população e consumo per capita. Fonte: (FEIL, Alexandre André; HAETINGER, Claus; 2013)

Um componente importante no estudo das séries temporais é o gráfico de decomposição, plotado na figura 2.3. Trata-se de um instrumento de avaliação de parâmetros separadamente, porém em figuras paralelas que facilitam a visualização e contextualização.

Segundo Barros (2021) et al, a primeira janela da figura representa a série temporal, enquanto a segunda, terceira e quarta janelas representam, respectivamente, as componentes de tendência, sazonalidade e erro.

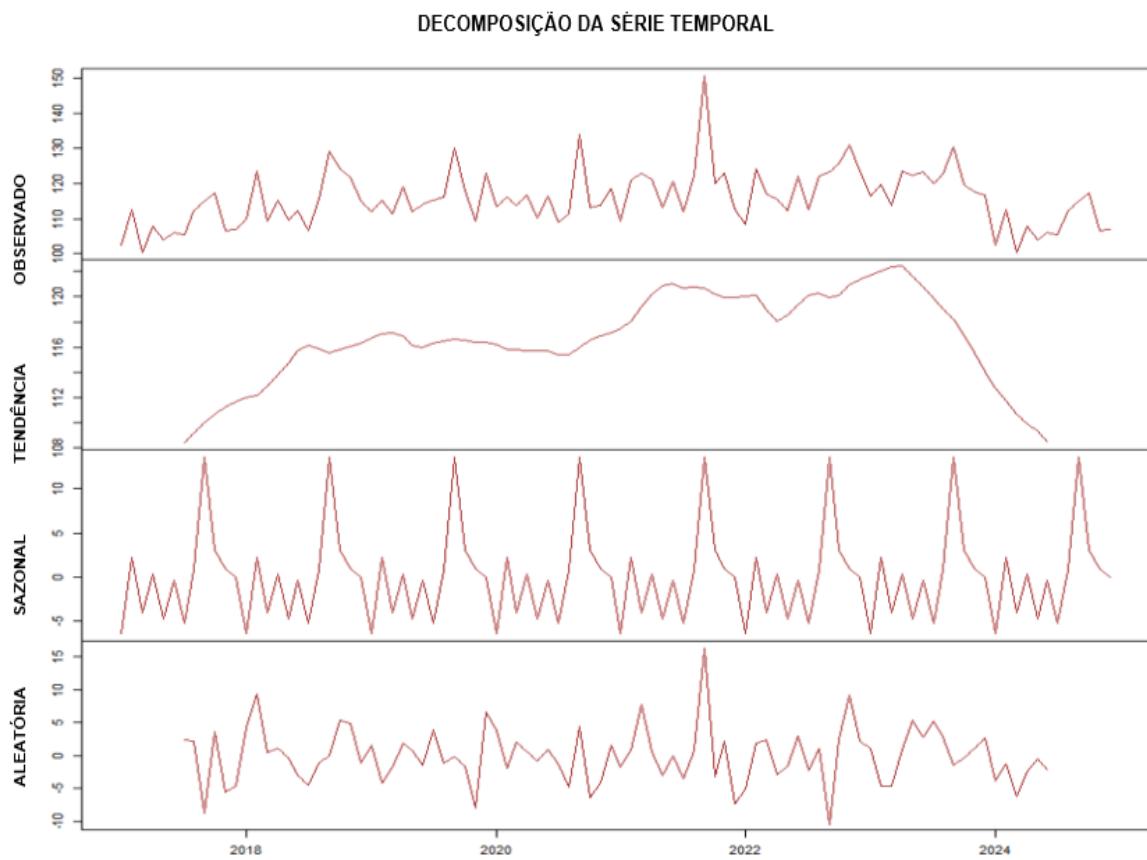


Figura 2.3 - Decomposição da série temporal – consumo per capita. Eixo y – consumo per capita em l/s; eixo x – tempo em anos. Fonte: Autoria própria.

O gráfico de decomposição exibido revela um comportamento de sazonalidade, típico em sistemas de abastecimento de água, porém objeto de investigação e validação para consolidar as características do sistema em estudo. As componentes da referida decomposição são: série temporal, tendência sazonalidade e erro, respectivamente.

## 2.2 GERENCIAMENTO DE SISTEMAS DE ABASTECIMENTO DE ÁGUA

Os sistemas de abastecimento de água desempenham um papel fundamental no planeamento urbano, não só para garantir que os cidadãos possam ter acesso a bens essenciais, mas também por razões de segurança pública (GRAYMAN et al., 2009).

### 2.2.1 Modelagem de Redes

A modelagem de redes é uma ferramenta bastante útil no estudo do comportamento hidráulico de um sistema. Por meio dela é possível diagnosticar o

funcionamento operacional de componentes fundamentais no fluxo de distribuição de água em um setor. Segundo Itonaga (2005) o cadastramento de tais elementos técnicos dever assegurar confiabilidade em um modelo proposto:

É fundamental que haja um processo sistemático de atualização e revisão do cadastro de modo a dar confiabilidade para o modelo a ser gerado, nos aspectos topológicos de operação (trechos conectados, registros, válvulas redutoras de pressão, reservatórios, boosters, etc). O modelo deve apresentar as características necessárias à correta representação funcional desses elementos. (Itonaga, 2005, p. 6)

A partir da correta configuração de cada dispositivo em uma malha de redes (tubulações, válvulas, medidores, motobombas etc.) é possível implementar o gerenciamento otimizado de variáveis importantes como vazão, pressão dinâmica distribuída no setor controlado e consumo autorizado. A divisão em distritos menores facilita o diagnóstico de anomalias e a elevação do desempenho operacional.

Para Novarini et al (2019):

Os critérios topológicos de um sistema de abastecimento de água, como a demanda máxima de água, a diferença máxima na elevação do nó e o comprimento total do tubo, definem o comportamento hidráulico da rede. Identificar tais critérios no processo de clusterização pode favorecer o gerenciamento de pressão nos distritos. (Bernardo Novarini; Bruno Melo Brentan; Gustavo Meirelles and Edevar Luvizotto Junior - 2019)

A Engenharia Hidráulica possibilitou enormes avanços na organização da vida civil e militar; isto desde os primórdios da sociedade humana. Aplicar conhecimentos especializados aumenta as chances de projetos e operações bem-sucedidas.

Para CHAVES (2023):

a modelagem hidráulica é uma ferramenta essencial na simulação do comportamento hidráulico de um sistema de abastecimento de água (SAA), a qual tem como objetivo verificar as condições hidráulicas da rede, tais como: vazão, velocidade de escoamento, perdas de carga, pressões estáticas. Com isso, pode-se identificar os pontos críticos do sistema, para assim simular cenários de intervenções que promovam melhoria operacional, tais como reforços na rede,

instalação de Válvulas Redutoras de Pressão (VRPs), boosters ou a realização de projetos de setorização.

Pelo exposto até aqui, concluímos pela importância de estudos e elaboração de modelos de redes que refletem as condições reais de operação de um sistema. Isto facilitará o controle das perdas físicas e a elevação de eficiência em suas operações. (Ver apêndices A e B – modelagem e simulação)

## 2.2.2 Balanço Hídrico

O Balanço Hídrico é um instrumento de gestão que permite a construção de indicadores importantes no gerenciamento das perdas e consumo de água em um sistema. A IWA - International Water Association desenvolveu sua estrutura básica contendo os fluxos e componentes principais; permitindo melhor controle dos dados e promoção de ações táticas e operacionais para melhor gerenciamento das redes de abastecimento. Segundo diretrizes do segmento, as companhias estaduais calculam os balanços hídricos seguindo uma periodicidade de 12 meses.

A seguir são apresentados os elementos que compõe o Balanço Hídrico (Adaptado de Ministério das Cidades e International Water Association):

**Volume de água fornecido ao sistema:** volume anual de água introduzido na parte do sistema de abastecimento que é objeto do cálculo do balanço hídrico.

**Consumo autorizado:** volume anual medido e/ou não medido fornecido a consumidores cadastrados, à própria companhia de saneamento (usos administrativos ou operacionais) e a outros que estejam implícitos ou explicitamente autorizados a fazê-lo, para usos domésticos, comerciais ou industriais.

**Perdas de água:** volume referente à diferença entre a água que entra no sistema e o consumo autorizado.

**Consumo autorizado faturado:** volume que gera receita potencial para a companhia de saneamento, correspondente à somatória dos volumes constantes nas contas emitidas aos consumidores. É composto pelos volumes medidos nos hidrômetros e volumes estimados nos locais onde não há hidrômetros instalados e volumes previstos, segundo critérios da política de cobrança.

**Consumo autorizado não faturado:** volume que não gera receita para a companhia de saneamento, oriundo de usos legítimos da água no sistema de

distribuição. É composto de volumes medidos (como uso administrativo da própria companhia) e volumes não medidos, a estimar, tais como a água utilizada no combate a incêndios, lavagem de ruas, rega de espaços públicos e a água empregada em algumas atividades operacionais da companhia de saneamento (lavagem de redes e de reservatórios, por exemplo).

**Perdas aparentes:** correspondem aos volumes consumidos, porém não contabilizados, associados aos erros de medição, fraudes e falhas no cadastro comercial da companhia de saneamento.

**Perdas reais:** correspondem aos volumes que escoam através de vazamentos nas tubulações ou reservatórios e extravasamentos nos reservatórios.

**Águas faturadas:** representam a parcela de água comercializada, traduzida no faturamento.

**Águas não faturadas:** representam a diferença entre o total anual da água que entra no sistema e o consumo autorizado faturado. Esses volumes incorporam as perdas reais e aparentes, bem como o consumo autorizado não faturado.

Volume Fornecido ao Sistema Compensado para imprecisões conhecidas)	Consumo Autorizado	Consumo Autorizado Faturado	Consumo Médio Faturado	Água Faturada
		Consumo Não Medido Faturado	Consumo Medido Não Faturado	
Perdas de Água	Consumo Autorizado Não Faturado	Consumo Não Medido Não Faturado	Consumo Não Autorizado	Água Não Faturada (ANF)
	Perdas Aparentes	Imprecisão nos Hidrômetros e Erro no Manuseio de Dados	Vazamento nas Redes	
	Perdas Reais	Vazamentos e Extravasamentos em Reservatórios	Vazamentos em Ligações até o Hidrômetro	

Figura 2.4 - Estrutura Padrão do Balanço Hídrico  
Fonte: (Ministério das Cidades / IWA)

Para um estudo e controle sistemático de demanda em um setor de abastecimento, é fundamental a implementação de setores de manobra nas redes. Variáveis importantes como pressão e vazão poder ser dinamicamente distribuídas de acordo com a topologia do sistema e características específicas da região geográfica abrangida. Em sede de Tese Doutoral, estudando previsão de demanda em tempo

real para sistemas de abastecimento público de água, BRETAN, Bruno Melo; 2012 conceitua:

Em um sistema de abastecimento setorizado, isto é, um sistema cujos consumidores estão agrupados em zonas de abastecimento, há algumas possibilidades de arranjo de distribuição. Num arranjo mais simples, a vazão de entrada pode ir direto aos consumidores, alimentando as ligações individuais faturadas, o que é caracterizado como o volume consumido, as ligações individuais não faturadas, alimentando parte das perdas aparentes e ainda as fugas e vazamentos. Também há a possibilidade de passagem por um reservatório que será responsável por estabilizar as oscilações do fornecimento e ainda regularizar a pressão de abastecimento ou, finalmente num esquema misto, alimentar consumidores e ainda ser responsável pelo enchimento de reservatórios. (BRETAN, Bruno Melo. **Tese Doutoral: Sistemas de Abastecimento de Água inteligentes: Previsão de demanda e controle ótimo em tempo real.** Campinas – SP, 2017).

### **2.2.3 Controle de Perdas na Distribuição: gerenciando a vazão e pressão dinâmica nas tubulações.**

A eficiência de um sistema de abastecimento público de água potável guarda relação direta com parâmetros de vazão e distribuição de pressão nas redes. Nesse sentido, conhecer a natureza dos escoamentos dos fluidos facilita a compreensão de detalhes importantes.

Gomes et al (2012) afirmam que “os escoamentos se classificam em vários aspectos, cujo conhecimento é indispensável para o estudo da Mecânica dos fluidos e da Hidráulica”. Basicamente a literatura apresenta dois tipos de escoamentos: laminar e turbulento. Sendo o escoamento turbulento bastante presente em sistemas de saneamento, vejamos uma definição clássica desse movimento:

O escoamento turbulento é o mais frequente na engenharia. Neste as partículas movem-se segundo trajetórias erráticas, causando transferência de quantidade de movimento entre estas, inclusive na direção normal ao escoamento, causando flutuações de velocidades em torno de uma média que só podem ser percebidas com instrumentação de alta precisão e baixo tempo de resposta. Em tubos, os dois regimes podem ser identificados através do parâmetro

adimensional conhecido como número de Reynolds. (Pimentel Gomes, Heber; Sampaio Gomes, Airton; Andrade Filho, Luis Simão; Menezes Salvino, Moisés; Cramer de Otero, Osvaldo Luiz; Oliveira de Carvalho, Paulo Sérgio; Soares de Alencar, Ronildo Inácio; Marques Bezerra, Saulo de Tarso; De Paula Coura, Sebastião; Arnaud da Silva, Simplício. Sistemas de Bombeamento: Eficiência Energética (Abastecimento de Água Livro 4) - 2012 (Portuguese Edition) (p. 22). Edição do Kindle.

Fórmula do número de Reynolds:

$$R_e = \frac{VD\rho}{\mu} = \frac{VD}{\vartheta} \quad (01)$$

Onde:

V = Velocidade Média

D = Diâmetro da tubulação

$\rho$  = Densidade

$\mu$  = Viscosidade

$\vartheta$  = Viscosidade cinemática

A velocidade média em um escoamento possui atuação direta na vazão volumétrica e pode ser representada gráfica e matematicamente pela ilustração da figura 2.5:

$$V = \frac{Q}{A} = \frac{1}{A} \int_A v \cdot dA$$

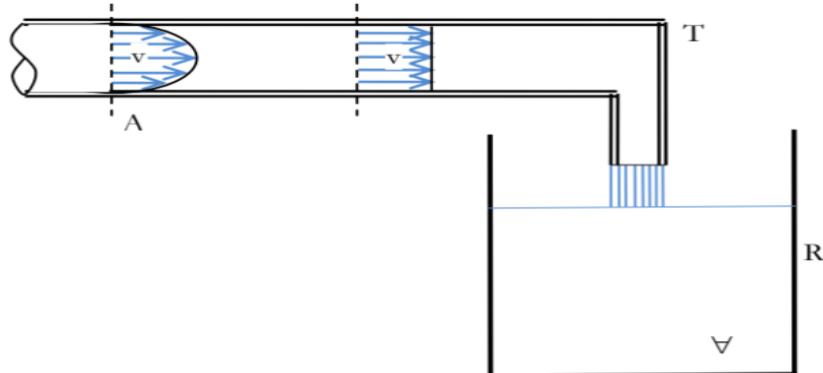


Figura 2.5 - Perfil de velocidades em um tubo e velocidade média correspondente. Fonte: Gomes et al (2012)

Princípio importante em hidrodinâmica, é o da conservação de massa e energia. Segundo as definições de Gomes et al (2012), um feixe de linhas de corrente que passa através de uma seção transversal dá origem ao chamado tubo de corrente, em que a parede lateral é paralela às linhas de corrente adjacentes, não havendo fluxo através dela. Neste caso a vazão volumétrica se conserva, conforme a fórmula:  $Q = V_1 A_1 = V_2 A_2$ . A figura 2.6 apresenta a ilustração deste processo

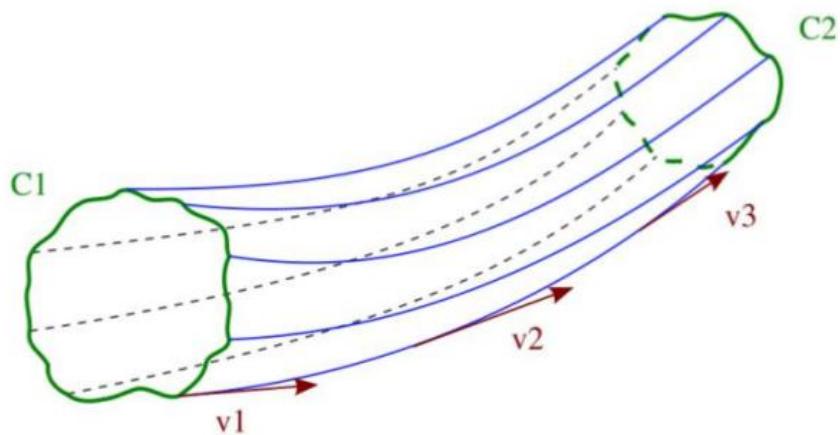


Figura 2.6 - Tubo de corrente. Fonte: Gomes et al (2012)

No que diz respeito às pressões distribuídas nas redes, um elemento importante é a válvula redutora de pressão – VRP. O ajuste de pressão à montante e jusante faz parte de um gerenciamento operacional e contribui para proteção das tubulações contra eventos indesejados, como vazamentos de grande intensidade e transientes hidráulicos. Vejamos o conceito de um dos grandes fabricantes desses equipamentos:

A Válvula Sustentadora e Redutora de Pressão Modelo 723 é uma válvula de controle operada hidraulicamente e acionada por diafragma com duas funções independentes. Ela mantém uma pressão mínima predefinida a montante, independentemente da demanda flutuante ou da variação de pressão de montante ou de variações da pressão de jusante, e evita que a pressão de jusante aumente acima do máximo predefinido, independentemente de flutuações na vazão ou pressão excessiva a jusante. (<https://www.bermad.com/> - acesso em 24/09/2024)

A figura 2.7 representa uma válvula redutora de pressão em uma versão bastante comercializada.



Figura 2.7 - Válvula Redutora de Pressão – VRP. Fonte: <https://www.bermad.com/>

Dados do SNIS-AE 2022 apontam **índice de perdas na distribuição de água** (IN049) de **37,8%**; este percentual representa uma média do território nacional brasileiro. Segundo o referido sistema de informação, em relação a 2021 houve redução de 2,9 pontos percentuais no índice de perdas, que apresentava aumento contínuo desde 2015. O percentual em estudo significa a fração do volume de água disponibilizado que não foi faturado, não contabilizado como volume utilizado pelos consumidores, seja por vazamentos, falhas nos sistemas de medição ou ligações clandestinas. Ou seja, 62,2 a cada 100 litros de água distribuída são de fato

contabilizados como consumo regular pelos habitantes da região. (Sistema Nacional de Informações sobre o Saneamento – Relatório 2022; Ministério das Cidades).

O controle de vazão nos diversos pontos de um sistema de abastecimento consiste em fator estratégico no gerenciamento e otimização do processo. Gonçalves (1998) apud Itonaga (2015) afirma que “a vazão noturna é o principal indicador do nível de perdas em um setor, principalmente em áreas residenciais, onde o consumo é baixo”. A figura 2.8 apresenta a dinâmica de comportamento deste parâmetro em um intervalo de 24 horas.

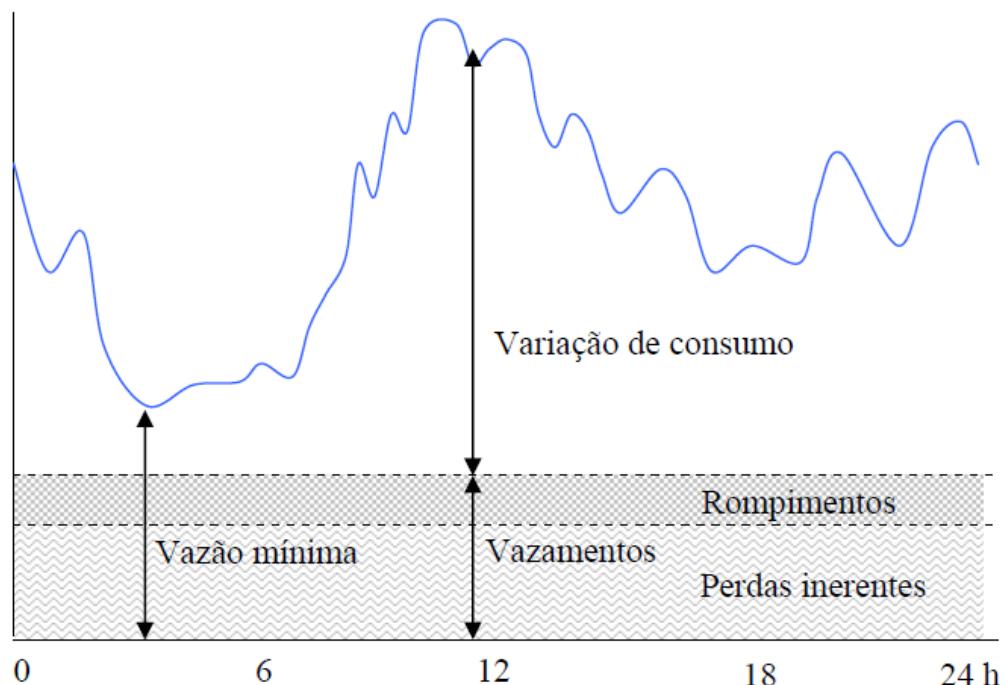


Figura 2.8 - Variação de vazão em uma UDA em um dia típico. Fonte: (Itonaga, 2015)

### **Inteligência Geográfica na setorização de redes de abastecimento**

As tecnologias de geoprocessamento têm propiciado diagnósticos e decisões inteligentes no setor de saneamento. A partir do cadastro técnico georreferenciado de redes, equipamentos e unidades consumidoras, é possível fazer uma conexão com bancos de dados operacionais e promover um gerenciamento espacial de todas as demandas de operação e manutenção. A figura 2.9 representa uma imagem retirada de boletins informativos de Geoprocessamento e serve de base para uma explanação dos benefícios alcançados na gestão operacional dos sistemas por meio da setorização.



Figura 2.9 - Setorização de redes. Fonte: Base de Geoprocessamento, 2020

É possível segmentar as áreas abastecidas por cada válvula e, posteriormente, estabelecer controles e gerenciamento remoto – por telemetria. As cores simbolizam zonas de pressão e abastecimento que pertencem a cada Distrito de Medição e Controle – DMC.

#### **2.2.4 Eficiência Energética em Sistemas de Saneamento**

Para Marques (2016), a energia elétrica é fundamental para a produção nos Sistemas de Abastecimento de Água e está presente em todas as fases, pois é necessária para a captação, adução, transporte, tratamento e distribuição da água através das redes.

Segundo as definições de CARMO (2023), a relação entre eficiência energética e proteção do meio ambiente é indissociável e de extrema importância para a busca de um futuro mais sustentável. Isto porque a eficiência energética desempenha um papel fundamental na mitigação de impactos ambientais negativos e na redução das emissões de gases de efeito estufa, por exemplo. Ao reduzir perdas na distribuição de água, indiretamente é influenciada a economia de energia elétrica utilizada tanto na produção como na distribuição, nos perfis de consumo residencial, industrial ou comercial.

No tópico anterior foi abordada a questão das perdas de sistemas de abastecimento de água. São elementos inerentes ao processo produtivo e que devem

ser gerenciados com o objetivo de mantê-los nos menores índices possíveis. A energia elétrica é um insumo fundamental tanto na produção como na distribuição da água tratada, participando do acionamento de toda infraestrutura eletromecânica responsável pela captação, adução, armazenamento e distribuição.

O relatório SNIS-AE 2022 aponta o **índice de consumo de energia elétrica em sistemas de abastecimento de água** (IN058) de **0,67 kWh/m<sup>3</sup>**. O **consumo total** em sistemas de abastecimento de água é de **12,6 TWh**, que corresponde a 88,3% dos 14,3 TWh utilizados pelos serviços de água e esgoto apurados na amostra. Ainda de acordo com o relatório, “a energia elétrica é um dos principais custos operacionais dos serviços de água e esgoto. O SNIS-AE identifica crescimento constante das despesas com energia elétrica”. (Sistema Nacional de Informações sobre o Saneamento – Relatório 2022; Ministério das Cidades).

ITONAGA (2005) apud (SOBRINHO, Renavan Andrade; BORJA, Patrícia Campos; 2016) afirmam que:

Apesar das experiências para o controle das perdas de água e eficiência energética, os prestadores de serviços de abastecimento de água e de esgotamento sanitário no Brasil, o que inclui a Empresa Baiana de Águas e Saneamento (Embasa), ainda demonstram níveis elevados de perdas em relação aos padrões internacionais de países desenvolvidos, onde esse indicador atinge patamares da ordem de 10%, como Japão e Alemanha, por exemplo (ITONAGA, 2005).

## **2.2.5 Tecnologias Aplicadas na Operação e Gerenciamento do Sistema**

O Sistema de Abastecimento de Água estudado nesta pesquisa dispõe de um monitoramento por telemetria e construção de Balanço Hídrico em painel de Business Intelligence. Sendo assim, a revisão de conceitos e tecnologias presentes em seu funcionamento faz necessária para a melhor compreensão de seus resultados.

Conforme artigo publicado por empresa de desenvolvimento de automação industrial, a importância de sistemas automatizados e telemetria em saneamento visa, dentre outros, a (Adaptado de GRACHTEN (2015)):

- Garantir o abastecimento da população;
- Monitorar em tempo real o funcionamento de estações elevatórias, reservatórios, medidores de vazão e demais dispositivos elétricos e hidráulicos do sistema;

- Armazenar e apresentar dados históricos sobre a qualidade do abastecimento;
- Alarmar vazamentos, falhas de operação, falhas de equipamentos, intrusões, valores anormais de níveis, pressões e vazões;
- Prevenir e minimizar perdas;
- Garantir a qualidade dos serviços prestados.

Um centro de controle de operações e manutenção gerencia a distribuição de pressão e vazão na UDA estabelecida para esta pesquisa. Conceitualmente consiste no agrupamento de dispositivos e recursos tecnológicos que facilitam o gerenciamento operacional, conforme ilustrado na figura 2.10.

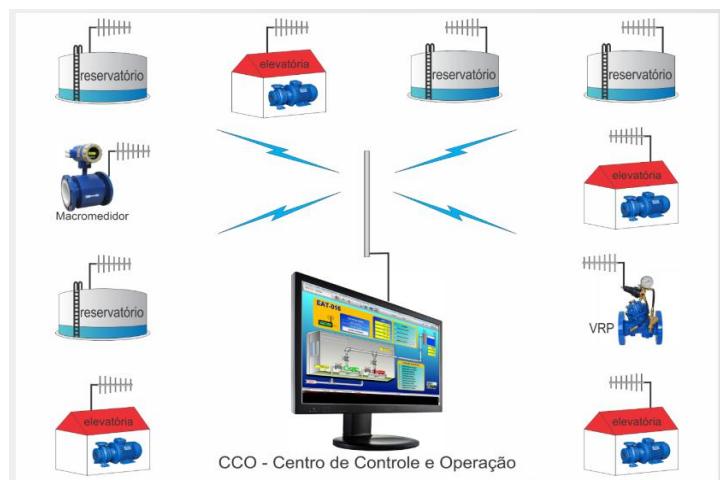


Figura 2.10 - Exemplo de um Centro de Controle e Operação. Fonte: GRACHTEN, Eduardo. **A contribuição dos sistemas de automação na melhoria do desempenho de empresas de saneamento.** Publicação na web, 2015.

## Os avanços tecnológicos e industriais

Segundo Vermulm (2018), a Indústria 4.0 - ou Manufatura Avançada – é um novo estágio de desenvolvimento da produção industrial. O mesmo autor nos informa que “Estados Unidos, Alemanha e China se destacam em matéria de investimento e modernização; estando, pois, a caminho da liderança mundial”. (Vermulm, 2018, p. 4).

O engenheiro e economista Klaus Schwab, fundador do Fórum Econômico Mundial, conceituou com muita propriedade o termo revolução:

A palavra “revolução” denota mudança abrupta e radical.

Em nossa história, as revoluções têm ocorrido quando novas tecnologias e novas formas de perceber o mundo

desencadeiam uma alteração profunda nas estruturas sociais e nos sistemas econômicos. Já que história é usada como referência, as alterações podem levar anos para se desdobrarem. (Schwab, 2017, p. 15)

Para este autor, o momento é de fusão dos mundos físicos, digitais e biológicos; mudanças de modelos operacionais e reconfiguração de sistemas de produção, distribuição e consumo relacionados. Isto, de fato, vai ao encontro das necessidades atuais dos governos e sociedades ao redor do mundo; ou seja, é possível trazer a Tecnologia como grande aliada das inovações que tanto almejamos.

É nítida a percepção de que estamos vivenciando uma profunda transformação digital; que por conseguinte alavanca cada vez mais possibilidades e ganhos de eficiência. Para Leme, Santos e Stevan Jr. (2018), a Quarta Revolução Industrial é impulsionada pelas tendências de conectividade, materiais avançados que permitem o desenvolvimento de novos sensores e tecnologias de processamento. A figura 2.11 ilustra as fases e principais tecnologias presentes nas revoluções industriais.

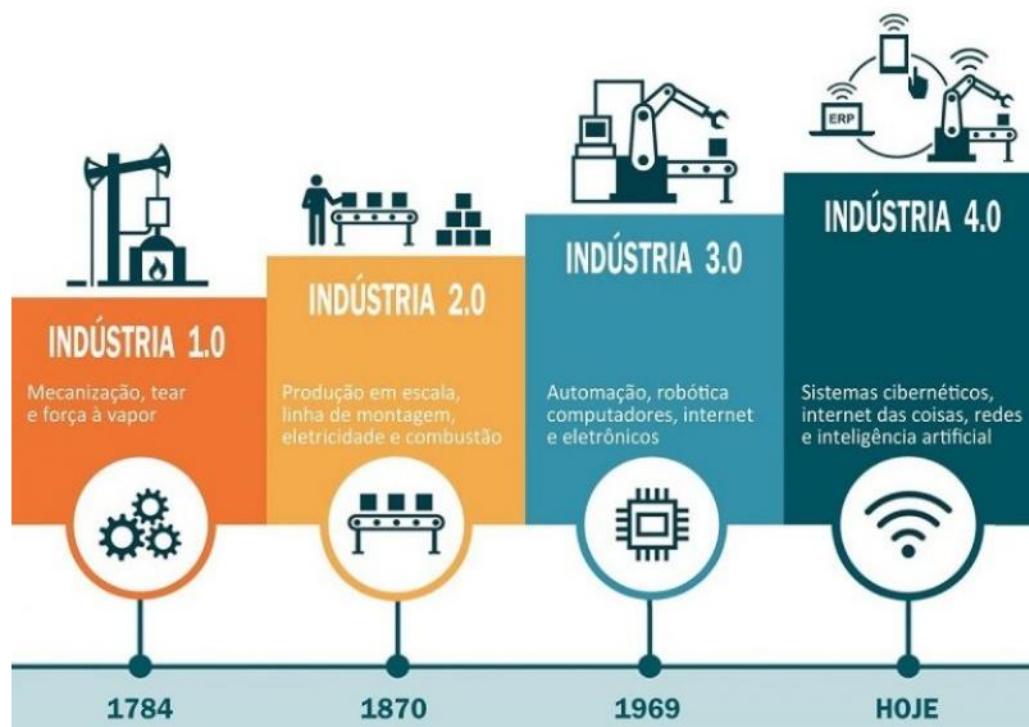


Figura 2.11 - Evolução e características das revoluções industriais  
Fonte: (Leme; Santos; Stevan Júnior., 2018, p. 81)

## **Elementos impulsionadores**

Observa-se que a Quarta Revolução Industrial faz uma concatenação de ideias, conhecimentos, tecnologias e inovações; tudo convergindo em uma estrutura de comunicação que gera Sistemas Inteligentes. Os resultados são altas performances e níveis de produção em vários segmentos. Nesse sentido, conceituemos alguns componentes de destaque: Computação em Nuvem; Big-Data; Internet das Coisas (IoT); Inteligência Artificial e Sistemas Ciber-Físicos.

### **Computação em Nuvem**

Para Leme, Santos e Stevan Júnior. (2018), associado ao grande volume de dados gerados pela Indústria 4.0, a computação em nuvem vem facilitar todo o processamento de informações e, ao mesmo tempo, disponibilizá-las para qualquer ambiente; a figura 2.12 ilustra o conceito. A oportunidade é de parceria e redução de custos, tendo em vista a possibilidade de reduzir o porte da infraestrutura de informação e comunicação.



Figura 2.12 - Computação em Nuvem – Infraestrutura e Aplicações. Fonte: (Leme; Santos; Stevan Júnior., 2018, p. 74)

## **Big Data**

O aumento de produtividade e eficiência do ambiente industrial necessita de tomada de decisão e informações apropriadas. Leme, Santos e Stevan Jr. (2018), apresentam uma abordagem apropriada sobre *big data*:

As grandes estruturas de comunicação geram um volume de dados que nenhum banco de dados convencional ou sistema de processamento é capaz de tratar. *Big Data* corresponde a grandes estruturas, normalmente instaladas em ambientes especializados, construídas para tratar dados estruturados e não estruturados de uma variedade de fontes, como texto, formulários, *blogs* da *web*, comentários, vídeos, fotografias, telemetria, GPS, *chat* de mensagens instantâneas, notícias e, ainda as estruturas de produção industrial como rastreamento logístico RFID, entre outros. (Leme; Santos; Stevan Júnior., 2018, p. 75)

Vários dispositivos e tecnologias no ambiente interconectado se tornam fonte de dados; assim, em plena era e sociedade da informação, é preciso – cada vez mais – aprimorar as capacidades e os métodos de análises para extrair informações válidas e relevantes para a tomada de decisões.

## **Inteligência Artificial**

Para Klaus Schwab (2017), a inteligência artificial viabiliza a correspondência de padrões e a automação de processos, o que torna a tecnologia interessante para muitas funções em grandes organizações. Redução de custos e ganhos de eficiência são reflexos em toda a cadeia produtiva.

Segundo pesquisas da Oxford Martin School, algumas funções são suscetíveis de serem substituídas por máquinas automatizadas. Nessa linha, o trabalho humano se concentrará na análise de dados, informações e tomada de decisão.

## **Sistemas Ciber-Físicos**

Segundo o artigo publicado pela empresa E-aware Technologies, “em ciber-física, dispositivos eletrônicos com elementos de computação inteligente e comunicação estão integrados a componentes físicos da natureza”. A integração de dispositivos computacionais, sensores e comunicação estruturam a plataforma sensorial que controlará as variáveis de um processo – por exemplo.

Como podemos compreender, a Cibernética potencializa o nível de interação entre máquinas e sistemas de produção permitindo a correção de falhas e o aumento de desempenho em diversos segmentos. Contudo, o grande desafio da Sociedade moderna é interpretar o grande volume de informações no intuito de validar e obter os benefícios almejados. A figura 2.13 ilustra os principais elementos.

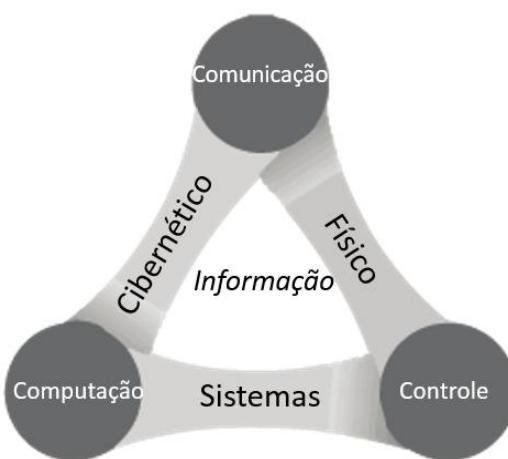


Figura 2.13 - Interação entre os principais elementos ciber-físicos

Fonte: <<https://www.eaware.com.br/sistemas-ciber-fisicos-a-nova-revolucao/>> - acesso em 21 nov. 2019

### **Internet das Coisas (IoT)**

Na concepção de Indústria 4.0, um termo relevante a ser explorado é Internet das Coisas; Leme, Santos e Stevan Júnior. (2018, p. 77) apontam que “toda a integração e convergência de tecnologias de comunicação, associadas a uma grande quantidade de novos sensores, nos leva a um novo conceito de fábrica inteligente”. Essa troca de informações e interação entre processos permitem uma comunicação mais efetiva em toda a cadeia produtiva.

### **Telemetria de dados e Telecomando de máquinas e processos (Aplicação na Indústria do Saneamento)**

Vissotto Junior (2004) – citado por Salles, Hermosilla e Silva (2016) – em artigo publicado pela Associação Brasileira de Engenharia de Produção – ABEPRO informam que “a origem da palavra telemetria vem de termos gregos como tele, que significa longe ou remoto, e metron, que se relaciona à medida, e de forma sucinta pode ser definida como uma técnica de obtenção de dados à distância”. Assim, viabiliza a coleta de dados em pontos remotos e sua posterior transferência para controle e monitoramento de processos.

Tomy Moreira dos Santos (2018), por sua vez, nos possibilita entender os componentes principais de um sistema de telemetria: hardware embarcado local –

para coleta de dados nos pontos de medição; Sistemas de transmissão de dados; e software para supervisão. Nesta linha de raciocínio podemos compreender a telemetria e telecomando como sistemas que utilizam recursos físicos e lógicos para captura de dados, controle e acionamento remoto; tais recursos, de ordem computacional, têm apresentado significativos avanços nos últimos anos.

Na figura 2.14 observa-se um exemplo de unidade de produção de água operando com dispositivos de automatização dos processos. O supervisório do sistema de automação informa dados como estado das bombas (ligado ou desligado), níveis dos reservatórios de contato, condicionamento das válvulas e frequência dos motores.

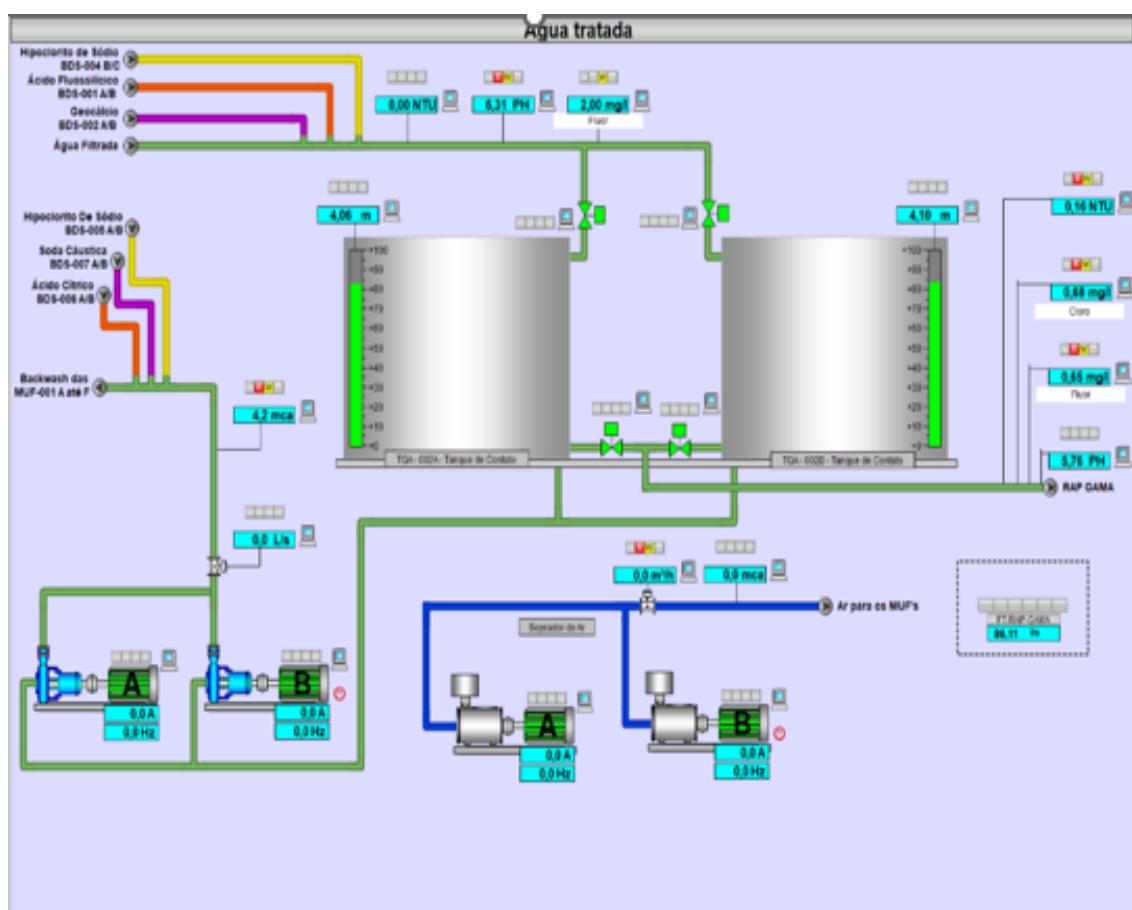


Figura 2.14 - Sistema de Tratamento de Água monitorado por computador. Fonte: Projetos de Automação Industrial.

No âmbito do saneamento ambiental, a telemetria tem dado contribuições no sentido de coletar dados de forma remota agilizando processos de tomada de decisão. Em estudos e diagnósticos de redes de abastecimento, é possível monitorar vazão, pressão de montante e pressão de jusante; permitindo assim calcular alguns indicadores e direcionar as ações de operação e manutenção do Sistema. Nos

apêndices C e D é possível visualizar gráficos extraídos de um sistema de monitoramento remoto.

### ***Business Intelligence***

Chaudhuri et al. (2011) apud Freitas Neto (2014) apresenta uma ilustração muito eficiente dos elementos principais de um sistema de *business intelligence*; como exibido na figura 2.15.

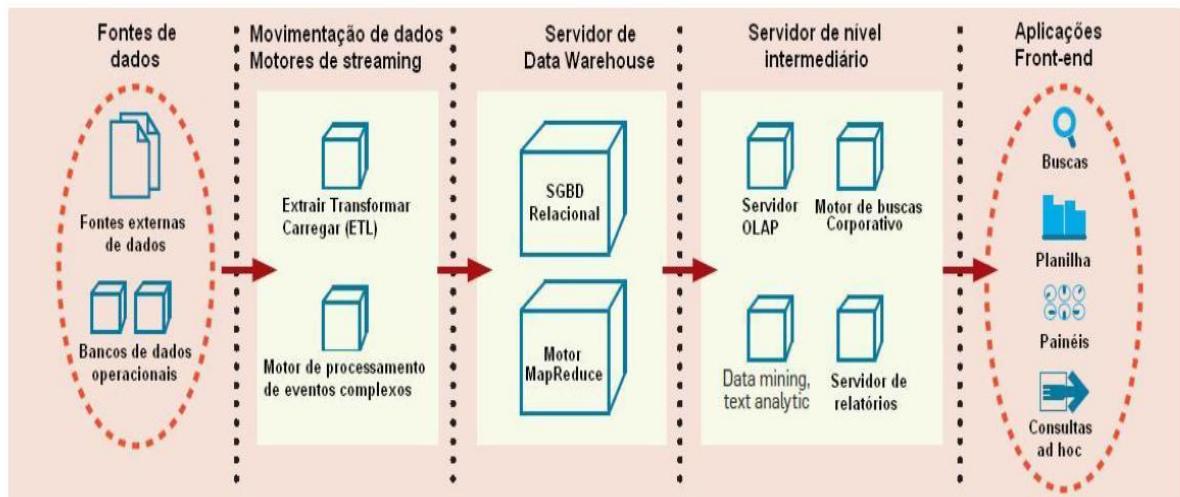


Figura 2.15 - Arquitetura típica de um sistema baseado em *Business Intelligence*  
Fonte: Chaudhuri et al. (2011) apud Freitas Neto (2014)

Este recurso computacional é um grande elemento estratégico no processo de tomada de decisão. Na figura 2.16 são exibidos alguns painéis de monitoramento de sistemas de abastecimento a partir de dados oriundos de telemetria. Conhecer o perfil de consumo, dados de vazão e índices de perdas é de fundamental importância para o gerenciamento eficaz e otimização dos processos.



Figura 2.16 - Painéis de monitoramento de sistemas de abastecimento  
Fonte: Sistemas de Automação e Telemetria.

Citados os diversos elementos de alto nível computacional, podemos também mencionar os sensores de base industrial, aqueles que farão a coleta direta dos dados operacionais que definem o comportamento de um sistema hidráulico. A figura 2.17 exibe uma estação de bombeamento instrumentada, com dados sendo transmitidos para computadores e centrais de processamento.

Como vantagens da utilização desses recursos informacionais podemos citar:

- Agilidade na identificação de falhas técnicas e operacionais nos sistemas de abastecimento (reservatórios, estações elevatórias, boosters, válvulas, etc);
- Viabilidade de controle centralizado e tomada de decisão;
- Dados e informações atualizados em tempo real;
- Interface e comunicação com outras aplicações.



Figura 2.17 - Estação de bombeamento instrumentada. Fonte:  
<https://www.abstelemetria.com/saneamento>

### 2.3 MODELAGEM DE SÉRIES TEMPORAIS

Para Illukkumbura (2021), a análise de dados de série temporal é importante para identificar forças e estruturas subjacentes em uma variável de série no tempo e para identificar um modelo adequado para fins de previsão. Neste sentido, ao planejar um modelo operacional baseado em métodos preditivos, faz-se uso de um recurso com potencialidade para alcance de bons resultados.

Séries temporais são coleções de observações feitas em intervalos de tempo iguais. Uma série temporal é uma coleção de observações ou dados obtidos para uma variável específica durante intervalos de tempo específicos, definidos e sequenciais. Em um modelo de série temporal, observações de uma variável são registradas em intervalos de tempo iguais. Em estatística, dois tipos de modelos são usados para analisar séries de dados. Eles são modelos causais e modelos de séries temporais. (Illukkumbura, Anusha. **Introduction to Time Series Analysis** (Easy Statistics) (p. 8). anushabooks.com. Edição do Kindle.)

No estudo das séries temporais, o pesquisador se depara com flutuações no comportamento dos dados que advém de fenômenos ocorridos de forma variada. A

literatura consolida quatro componentes de uma série temporal que podem descrever tais variações:

1. Tendência de longo prazo
2. Variação Sazonal
3. Variação Cíclica
4. Variações Irregulares

Ilustrativamente, alguns padrões de séries temporais são apresentados na figura 2.18, com a presença das características de Tendência e movimento aleatório; Cíclico; Padrão Sazonal; e Tendência com padrão sazonal.

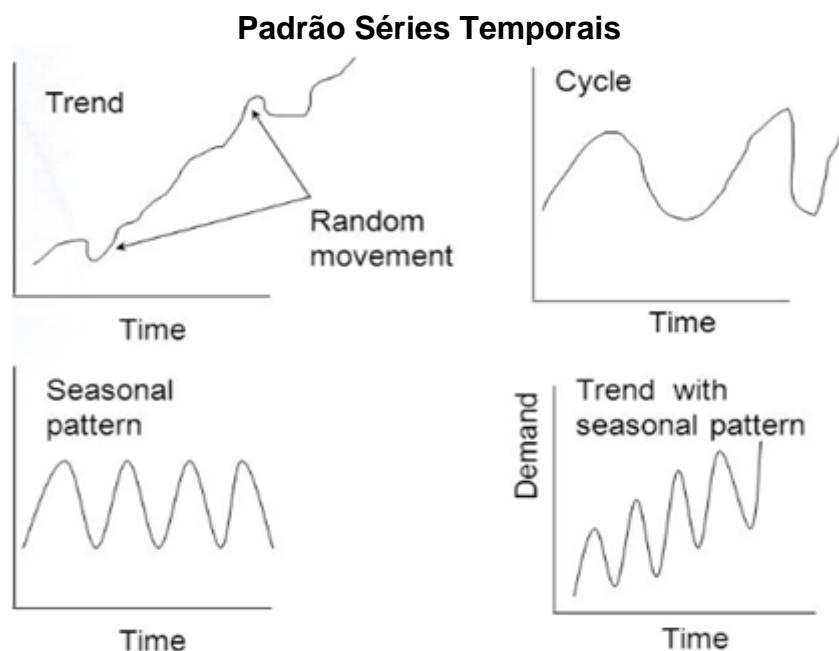


Figura 2.18 - Padrões de Séries Temporais. Fonte: (Illukkumbura, Anusha. *Introduction to Time Series Analysis* (Easy Statistics), p. 11)

No estudo inicial das séries temporais, dois conceitos importantes são o ruído branco e filtro linear, já que objetivamente se decompõe a massa de dados em partes a serem avaliadas. Para MARGARIDO (2020),

ao se trabalhar com modelos de séries de tempo, o objetivo básico consiste em decompor a série em diversos componentes utilizando-se para tal tarefa os denominados filtros lineares. Essa decomposição se baseia no Teorema da Decomposição de Wold, o qual afirma que todo processo estocástico ( $Y_t - \mu$ ), pode ser escrito como uma combinação linear de uma sequência não correlacionada de variáveis aleatórias.

O termo ruído branco (white noise) caracteriza uma série de tempo que é identicamente e independentemente distribuída (IID), com média zero. A função de Autocorrelação (ACF) da série é igual a zero para todas as defasagens (lags) exceto para a defasagem zero. Pressupõe-se que uma série ruído branco seja completamente aleatória e seu comportamento não pode ser previsto por qualquer processo de estimação. Sendo assim, uma série temporal pode ser representada a partir de uma soma ponderada de observações presentes e passadas do ruído branco. (Margarido, Mario Antônio. MODELOS DE SÉRIES TEMPORAIS: Uma introdução com aplicações práticas (LIVROS DE ECONOMETRIA E MODELOS DE SÉRIES TEMPORAIS - APLICADOS) (Portuguese Edition) (pp. 31-32). Mario Antônio Margarido. Edição do Kindle.)

### **Ruído Branco (*White Noise Process*)**

Estudando o comportamento de séries temporais interrompidas, McDOWALL et al. (2019) conceituam o processo estacionário mais simples possível como ruído branco, assemelhando-se a uma estática de rádio ou luz branca de um tubo fluorescente, em casos de som e imagem, respectivamente. Sendo o ruído branco resultado de um processo aleatório, ocorrências de tempo passado não possuem informações sobre o tempo futuro. As equações 02 e 03 apresentam a formulação matemática do processo e dos choques aleatórios, distribuídos com média zero e variância constante. (Adaptado de McDOWALL, David; McCLEARY, Richard; BARTOS, Bradley J. Interrupted Time Series Analysis. Oxford University Press, 2019).

$$a = \infty, \dots a - 1, a0, [a1, a2, \dots aN], aN + 1, aN + 2, \dots a + \infty \quad (02)$$

$$\mu a = E(at) = 0 \text{ and } \gamma 0 = E(a^2 t) = \sigma^2 a \quad (03)$$

### **Modelos ARIMA e SARIMA**

Segundo as definições de Illukkumbura (2021), a modelagem ARIMA Sazonal é representada por (p, d, q) (P, D, Q) em que P = SAR ou termo autorregressivo sazonal; D = número de diferenças sazonais; Q = termo SMA ou termo de média móvel sazonal. Os dados sazonais podem ser identificados quando a assinatura MA pura ou AR pura ocorre em períodos de tempos iguais. Em suma, temos que p, d, q são as

ordens e diferença do modelo não sazonal e P, D, Q seus pares para o modelo sazonal.

A variação sazonal mostra padrões repetitivos semelhantes durante períodos de tempos semelhantes (equivalentes) e sequenciais. Nos padrões sazonais, as séries de dados são influenciadas por dados com flutuações sazonais. A temperatura sazonal de um país durante alguns anos mostra padrões sazonais. Os padrões cíclicos são os movimentos alternativos para cima e para baixo em um gráfico de série temporal. Isto também pode ser identificado como sequências recorrentes de pontos acima e abaixo da linha de tendência que duram pelo menos mais de um ano. (Adaptado de (Illukkumbura, Anusha. Introduction to Time Series Analysis (Easy Statistics).

Para Margarido (2020), apud Macaúbas (2022),

O modelo ARIMA é um modelo univariado, ou seja, possui uma única variável. Nesse caso, procura-se explicar o comportamento presente e futuro de uma variável com base nos seus próprios valores passados, também denominados de parâmetros autorregressivos (AR) e seu próprio erro presente e passados, chamados de parâmetros de médias móveis (MA).

Sazonalidade em séries temporais são padrões regulares que se repetem ao longo do tempo, onde S define o número de períodos até que o padrão volte a se repetir. A presença de sazonalidade pode fazer com que a série não seja estacionária. (MACAÚBAS, Flávio; 2022).

Equações matemáticas referentes aos indicadores de desempenho do modelo SARIMA

$$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^N (xi - \tilde{x}_i)^2} \quad (04)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \left( \frac{xi - \tilde{x}_i}{xi} \right) \right| \quad (05)$$

Fonte: (Adaptado de Bleidorn et al, 2024)

Colischonn et al. (2005) apud CHECI, Leonardo & BAYER, Fábio M (2012), em pesquisa de investigação climatológica, avaliaram a importância de modelos estocásticos como o ARIMA na previsão de parâmetros concluindo que “Os resultados desses modelos podem ser usados como insumo (*input*) em modelos complexos hidrológicos determinísticos para simulação de chuva e vazão”. Em relação aos aspectos hidrológicos a modelagem e a previsão da disponibilidade hídrica também são importantes para outros usos, como integridade, abastecimento e navegação. (CHECI, Leonardo & BAYER, Fábio M; 2012)

Com o objetivo de avaliar o comportamento de séries temporais para previsão da incidência de leishmaniose visceral, PIMENTEL et al. (2021) conceituam que “o modelo SARIMA sazonal (p,d,q)(P,D,Q)s permite uma descrição da variabilidade dos processos relacionados ao tempo, linear, estacionário ( $d = D = 0$ ) ou não estacionário”.

A formulação matemática segue o seguinte padrão - SARIMA (p,d,q)(P,D,Q)s:

$$\Delta(B^S) \varphi(B)(1 - B)^d(1 - B^S)^D T(X_t) = \Psi(B^S)\Theta(B) Z_t \quad (06)$$

Fonte: PIMENTEL et al. (2021)

Cada termo equacionado representa:

- $\Delta(B^S)$ : Operador de variação e defasagem do componente sazonal;
- $\varphi(B)$ : Polinômio operador de retrocesso B – componente autorregressivo;
- $B)^d$ : Diferenciação/estacionariedade;
- $(1-Bs)$ : Diferenciação sazonal;
- $DT(X_t)$ : Transformação/tendência determinística;
- $\Psi(BS)$ : Polinômio operador de retrocesso – média móvel;
- $\Theta(B)$ : Polinômio operador de retrocesso;
- $Z_t$ : Ruído branco.

Em sequência temos respectivamente (Adaptado de PIMENTEL et al (2021)):

- Polinômios autorregressivos;
- Polinômios de média móvel da parte sazonal do período S;
- T – (transformação Box Cox) utilizada para estabilização da variância (quando este for o caso);

- $Z_t$  – processo de ruído branco – processo não corrigido com média zero e variância constante;
- No caso de  $p$  e  $q$ , são parâmetros autorregressivos e partes de média móvel com sazonalidade  $S$ ;
- $P$  e  $Q$  representam números equivalentes a esses parâmetros entre períodos sazonais;
- No caso dos parâmetros representados pelas letras  $d$  e  $D$ , são elementos que representam, respectivamente, graus de diferenciação simples e a diferenciação.

### **Critério de Informação de Akaike (AIC)**

“O Critério de Informação (AIC) é um estimador assintótico que utiliza a minimização da distância de Kullback-Leibler ( $K - L$ ) como base para seleção do modelo. Ele mede o modelo que perde menos informação entre a realidade e o modelo candidato”. (IMAMURA, Célia Sayuri; GOMES, Fabrício Maciel; 2018). Avaliando características como viés e variância das funções consegue prever a irregularidade em uma base de dados estudada; sendo o melhor modelo aquele que reflete um equilíbrio entre as duas variáveis.

$$AIC = -2\ln(L) + 2K. \quad (07)$$

Na fórmula o elemento  $k$  se refere ao número de parâmetros do modelo, e  $\ln(L)$  o seu logaritmo de verossimilhança.

### **3. METODOLOGIA DE PESQUISA**

Para alcançar os objetivos propostos, foi realizada uma análise das variáveis importantes no processo estudado e características tecnológicas do sistema. Os dados brutos foram extraídos de sistemas informatizados que contêm o Balanço Hídrico e o armazenamento da Telemetria.

A produção, armazenamento e manipulação dos dados históricos utilizados neste estudo foi viabilizada pelas tecnologias de instrumentação e automação de sistemas presentes no ambiente industrial analisado. Conforme discorrido na Revisão Bibliográfica e na seção de Metodologia, a união de controle e automação em

sistemas hidráulicos e mecânicos destaca-se como elemento impulsionador de inovação, produtividade e eficiência operacional.

### **3.1 INSTRUMENTAÇÃO, ARMAZENAMENTO E COLETA DOS DADOS**

#### **Sensoriamento, registro e transmissão de dados**

A medição dos parâmetros de vazão e pressão dinâmica na linha de distribuição principal é realizada a partir de instrumentos (sensores) instalados para esta finalidade. O registro e transmissão dos dados para central computadorizada (tecnologias GPRS/3G) ocorre com auxílio de equipamentos eletrônicos denominados “*Dataloggers*” (figura 3.1). Esses componentes auxiliam no monitoramento contínuo de transientes hidráulicos relacionados à operação dos boosters de abastecimento e aos fechamentos e aberturas de válvulas de controle. Os intervalos de medição podem ser regulados por comando remoto.



Figura 3.1 – *Dataloggers*. Fonte: Vectora/ABStelemetria

O sistema em estudo possui dispositivos instalados na tubulação e no sistema de bombeamento, conforme apresentado nas figuras 3.2 e 3.3.



Figura 3.2 – Instrumentação no barrilete de recalque. Fonte: Relatório de visita técnica ao sistema.



Figura 3.3 - Instrumentação na linha de distribuição. Fonte Relatório de visita técnica ao sistema.

A linha de distribuição sensoriada é abastecida por reservatórios apoiados que, por sua vez, recebem carga de adutora ligada ao sistema de produção. Isto viabiliza um bom nível de segurança operacional, dado que a função do bombeamento automatizado é garantir os parâmetros de pressão e vazão adequados para o abastecimento público na região.



Figura 3.4 – Reservatórios de Abastecimento da Linha. Fonte: Relatório de visita técnica ao sistema.

## Telemetria e gerenciamento da automação

Os sistemas de automação e a telemetria são gerenciados a partir de telas supervisórias e bancos de dados historiadores (figuras 3.5 e 3.6). Esses recursos possibilitam um monitoramento contínuo das operações, o tratamento de alarmes e a manipulação e tratamento dos registros históricos, viabilizando relatórios de análise estatísticas e planejamento operacional.

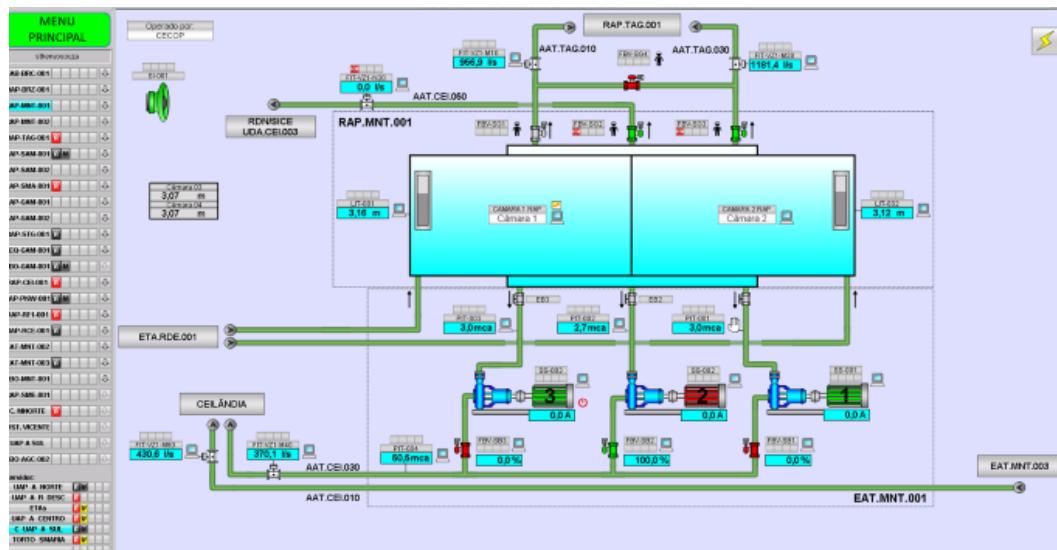


Figura 3.5 – Sistema Supervisório de Automação. Fonte: Sistemas de Automação e Controle.

Na imagem que representa o supervisório da automação temos a representação de dois conjuntos motor-bomba em operação (cor verde) e um em estado de reserva (cor vermelha).

hora	Data_Hora	VZL_AAB_ERC.010	VZL_AAB_BRI.010	VZL_AAB_CCH.010	VZL_AAB_CNT.010	VZL_AAB_CON.010	VZL_AAB_CDZ.010	VZL_AAB_CRG.010	VZL_AAB_CVD.010	VZL_AAB_FUM.010	VZL_AAB_MDR.030	VZL_AAB_PIP.030	VZL_AAB_PRZ.010	VZL_AAB_RDE.030	VZL_AAB_SMR.010	VZL_AAB_SMR.030	VZL_AAB_TOR.010	VZL_AAB_TOR.010	VZL_AAT_AUG.010	VZL_AAT_AUG.010		
14:25	21/10/2022 14:25	16,1	32,9	Bad	55,2	0	20,4	46,8	2,46	0,04	120	90,6	0	305	22,7	2756	2509	1552	1176	1176	Bad	574
14:35	21/10/2022 14:35	91,4	32,7	Bad	55	0	35,7	46,9	2,37	0,04	120	90,9	0	305	22,5	2760	2530	1554	1176	1176	Bad	666
14:45	21/10/2022 14:45	94,2	32,9	Bad	55	0	35	47	2,31	0,04	120	90,1	0	305	22,7	2761	2529	1553	1176	1176	Bad	660
14:55	21/10/2022 14:55	94,5	33,4	Bad	55,2	0	34,9	47,1	23,4	0,04	121	90,2	0	305	22,8	2766	2480	1549	1176	1176	Bad	649
15:05	21/10/2022 15:05	94,8	32,8	Bad	55	0	34,7	47,2	61,3	0,04	120	90,1	0	305	22,7	2767	2511	1555	1176	1176	Bad	646
15:15	21/10/2022 15:15	95,1	33	Bad	54,9	0	34,4	47,4	54,5	0,04	120	90,1	0	305	22,7	2763	2553	1554	1176	1176	Bad	644
15:25	21/10/2022 15:25	76,5	32,9	Bad	55,2	0	33,9	47,3	3,06	0,04	120	90,1	0	305	22,6	2766	2521	1546	1176	1176	Bad	641
15:35	21/10/2022 15:35	62,8	32,9	Bad	55,1	0	34,2	47,5	3,19	0,03	121	90,1	1,77	305	22,5	2765	2531	1569	1176	1176	Bad	637
15:45	21/10/2022 15:45	63,1	32,8	Bad	55,2	0	34,2	47,3	3,7	0,03	120	90	0,12	305	22,5	2769	2530	1556	1176	1176	Bad	622
15:55	21/10/2022 15:55	0,44	33,1	Bad	55,3	0	13,9	47,6	3,23	0,03	120	90,1	0,26	305	22,6	2771	2522	1570	1176	1176	Bad	607
16:05	21/10/2022 16:05	45,7	33	Bad	55	0	34,2	47,4	2,98	0,05	120	89,9	0,2	305	22,8	2765	2538	1569	1176	1176	Bad	597
16:15	21/10/2022 16:15	65,4	33	Bad	55,3	0	34	47,3	2,94	0,04	120	89,7	0,04	305	22,5	2766	2542	1562	1176	1176	Bad	591
16:25	21/10/2022 16:25	39,5	33,2	Bad	55,2	0	20,7	47,4	3	0,03	120	89,7	0,08	305	22,6	2761	2487	1554	1176	1176	Bad	600
16:35	21/10/2022 16:35	0,03	32,9	Bad	55	0	8,17	47,5	2,94	0,03	120	89,6	0,13	305	22,7	2769	2512	1525	1176	1176	Bad	594
16:45	21/10/2022 16:45	0,01	33	Bad	55,1	0	34,9	47,4	2,92	0,03	121	89,6	0,08	305	22,6	2760	2508	1539	1176	1176	Bad	593
16:55	21/10/2022 16:55	0,01	32,9	Bad	55	0	35,1	47,6	2,8	0,03	120	89,5	0,03	305	22,6	2769	2498	1529	1176	1176	Bad	582
17:05	21/10/2022 17:05	0	33,2	Bad	55,2	0	34	47,6	2,66	0,17	120	89,8	0,1	305	22,6	2769	2528	1549	1176	1176	Bad	578
17:15	21/10/2022 17:15	0	33,2	Bad	55,1	0	34,3	47,7	2,59	0,03	120	89,6	0,01	305	22,7	2768	2505	1549	1176	1176	Bad	568
17:25	21/10/2022 17:25	0,01	33,1	Bad	55,2	0	34,3	47,6	2,63	0,03	120	89,4	0,02	305	22,7	2766	2497	1527	1176	1176	Bad	555

Figura 3.6 – Dados tabulados por sistema de telemetria. Fonte: Sistemas de Automação.

Os dados de vazão podem ser visualizados na figura 3.6 referente ao dia 21/10/2022, especificados por equipamento instalado.

O sistema de automação armazena o histórico de operação dos conjuntos moto-bombas (cmbs) – figura 3.7. Esses dados são tabulados em formato de relatórios operacionais e servem de fonte para planos de manutenção preventiva dos componentes eletromecânicos do Sistema de Abastecimento de Água – SAA).

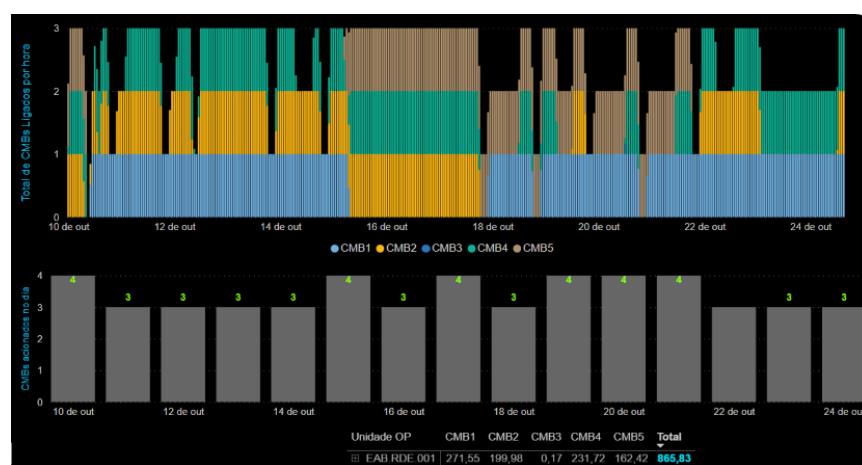


Figura 3.7 – Tempos de operação de conjuntos motobombas (cmbs). Fonte: Sistemas de Automação.

## Coleta e tratamento preliminar dos dados experimentais

A Companhia de Saneamento Ambiental do Distrito Federal utiliza de sistemas de informação e automação para armazenamento e manipulação de dados operacionais que são responsáveis pelo processo de telemetria e de desenvolvimento de dashboards de inteligência de negócio e tomada de decisão. (figura 3.8)

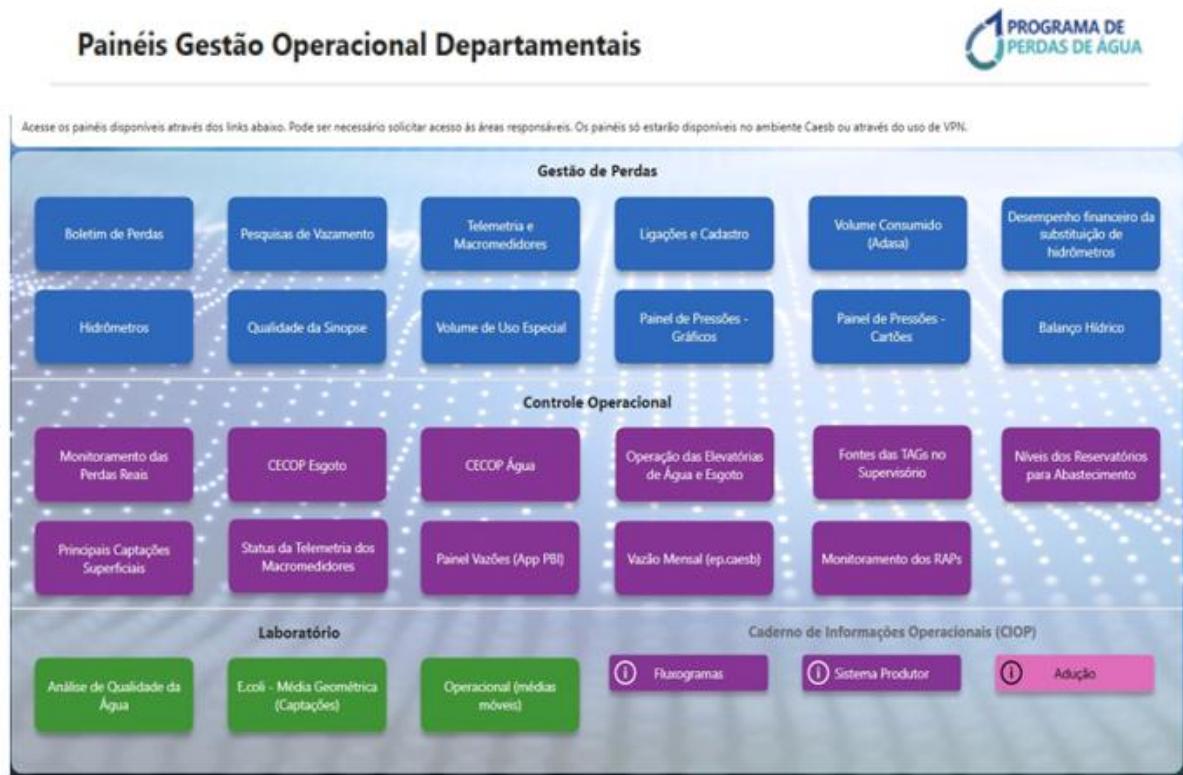


Figura 3.8 – Painel de extração de dados e informações. Fonte: Sistemas de Automação.

O painel de gestão operacional exibido na figura 3.9 representa as diversas interfaces gráficas para análise de dados. Anomalias e intervenções nos sistemas de abastecimento também podem ser gerenciadas por esta ferramenta. Os dados de vazão e consumo de energia analisados neste projeto de pesquisa foram extraídos dessas plataformas. Dentre os painéis está o que contém o balanço hídrico do sistema de bombeamento automatizado, objeto de análise deste projeto.



Figura 3.9 – Painel de extração de dados e informações (SAA). Fonte: Sistemas de Automação.

O conteúdo dos *dashboards* são importância fundamental para tomadas de decisão e representam falhas de automação, ocorrências em sistemas rurais, limpeza de reservatórios, entre outros.

### 3.2 FERRAMENTAS COMPUTACIONAIS

O processamento, análise, modelagem e visualização dos dados de vazão, pressão dinâmica, índices de perdas, consumo de energia e volume distribuído foram realizados com o auxílio dos seguintes recursos computacionais: Linguagem de Programação R; Ambiente de Desenvolvimento Integrado - RStudio; Microsoft Power BI. Scripts e detalhes importantes estão contidos na seção de apêndice deste trabalho.

A sequência lógica e computacional para execução do modelo ARIMA foi a seguinte:

- Instalação dos pacotes da linguagem R: `install.packages (library('readxl'))`
- Leitura dos dados de análise: `Dados_de análise <- read`
- Plotagem dos dados: `- > print(Dados_Consumo)`
- Criar o vetor: `str(Dados_Análise)`
- Chamar o vetor: `Dados <- as.vector`
- Modelagem da Série Temporal: `> Serie <- ts`
- Plotagem da Série Temporal: `print(Serie)`

- Análise dos parâmetros conforme explanado no item 4.4

De igual importância, seguem as formulações matemática dos parâmetros estatísticos avaliados na linguagem R de séries temporais:

$$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^N (xi - \tilde{x}_i)^2} \quad (08)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \left( \frac{xi - \tilde{x}_i}{xi} \right) \right| \quad (09)$$

$$AIC = -2\ln(L) + 2K. \quad (10)$$

### 3.3 PERCURSO METODOLÓGICO

As etapas seguintes foram implementadas:

- Avaliar o modelo hidráulico do sistema – poligonal de estudo e as características operacionais do sistema;
- Realizar a coleta de dados operacionais (vazão, consumo per capita, pressão de montante, pressão de jusante, índices de perda e demanda mensal);
- Promover a análise preliminar de dados e informações; processo de preparação;
- Desenvolver *scripts* em linguagem de programação apropriada para análise, tratamento e modelagem estatística dos dados referentes ao sistema de abastecimento;
- Identificar características de sazonalidade e tendência no volume consumido dentro da zona de controle;
- Mapear registros de vazão mínima noturna e pressões dinâmicas; sendo estes parâmetros importantes para o monitoramento de perdas físicas na distribuição;
- Modelar séries temporais para os parâmetros de demanda mensal ( $m^3$ ), consumo per capita (l/hab/dia), vazão horária e índices de perda no contexto histórico das redes de abastecimento.

### **3.4 TÉCNICA E RECURSOS UTILIZADOS PARA AJUSTE DOS MODELOS**

Em princípio, segue as etapas iniciais do método computacional:

- Importação da base de dados;
- criação do vetor;
- criação da série temporal.

O modelo ARIMA com parâmetro de sazonalidade possui o formato  $(p, d, q) (P, D, Q)$  em que [adaptado de Barros (2021) et al]:

- P é a ordem do polinômio autorregressivo não sazonal;
- p é a ordem do polinômio autorregressivo sazonal;
- q é a ordem do polinômio de médias móveis não sazonal;
- Q é a ordem do polinômio de médias móveis sazonal
- d é a ordem de diferença não sazonal;
- D é a ordem de diferença sazonal.

Visando à otimização do processo de busca, a modelagem ótima das séries temporais foi realizada utilizando o recurso de automatização na busca do “melhor modelo”, através do comando “auto.arima” (pacote *forecast*) da linguagem R. Este comando executa um processo exaustivo e por etapas (*stepwise*), até que se atinja os coeficientes ideais, ajustados para os dados do modelo.

Com poder de processamento computacional, a linguagem R realiza inúmeros testes até que se atinja as melhores combinações para os coeficientes. A figura 3.10 destaca um trecho da operação do comando.

```

> Modelo_AUTO <- auto.arima(Serie, trace = T, stepwise = F, approximation = F,
+                               max.p = 5, max.q = 5, max.P = 2, max.Q = 2)

ARIMA(0,1,0) : 686.6786
ARIMA(0,1,0) with drift : 688.7632
ARIMA(0,1,0)(0,0,1)[12] : 663.3622
ARIMA(0,1,0)(0,0,1)[12] with drift : 665.4928
ARIMA(0,1,0)(0,0,2)[12] : 657.0695
ARIMA(0,1,0)(0,0,2)[12] with drift : 659.2501
ARIMA(0,1,0)(1,0,0)[12] : 651.3324
ARIMA(0,1,0)(1,0,0)[12] with drift : 653.4657
ARIMA(0,1,0)(1,0,1)[12] : 651.9199
ARIMA(0,1,0)(1,0,1)[12] with drift : 654.1006
ARIMA(0,1,0)(1,0,2)[12] : Inf
ARIMA(0,1,0)(1,0,2)[12] with drift : Inf
ARIMA(0,1,0)(2,0,0)[12] : 652.0602
ARIMA(0,1,0)(2,0,0)[12] with drift : 654.2409
ARIMA(0,1,0)(2,0,1)[12] : Inf
ARIMA(0,1,0)(2,0,1)[12] with drift : Inf
ARIMA(0,1,0)(2,0,2)[12] : Inf
ARIMA(0,1,0)(2,0,2)[12] with drift : Inf

```

Figura 3.10 - Trecho do processamento auto.arima com stepwise. Fonte: Elaborado pelo autor.

É possível observar a alternância dos coeficientes ( $p, d, q$ ) ( $P, D, Q$ ) até que se alcance a melhor versão para o modelo ARIMA da série temporal. A escolha se baseia nos melhores valores para os parâmetros: Erro Percentual Médio Absoluto - MAPE; Erro Quadrático Médio Raíz - RMSE; Erro Médio Absoluto - MAE; e Critério de Informação de Akaike – AIC.

Para avaliação da qualidade dos modelos, serão utilizados os critérios de independência dos resíduos a caracterização da série como distribuição normal, *Ljung-Box test* e *Shapiro.wilk normaly test*, concentrando a atenção nos parâmetros numéricos retornados e na avaliação gráfica produzida pelas saídas dos comandos.

As variáveis do sistema que foram avaliadas e modeladas são:

- Demanda per capita
- Demanda mensal
- Índice de perdas
- Demanda de energia elétrica
- vazão mínima noturna (Verificação da estabilidade)

A tabela 3.1 exibe a modelagem final encontrada após todo o processamento computacional dos dados via comandos R. pode-se verificar os valores e as combinações para os coeficientes ARIMA ( $p, d, q$ ) ( $P, D, Q$ ).

<b>VARIÁVEL ESTUDADA</b>	<b>MODELO DEFINIDO</b>
Demandas Per Capita	ARIMA (0,1,1) (2,0,0)
Demandas Mensais	ARIMA (0,1,2) (1,0,0)
Índice de Perdas	ARIMA (0,1,1) (1,0,0)
Consumo de Energia Elétrica	ARIMA (0,1,2) (1,0,0)

Tabela 3.1 – modelagem definida. Fonte: Elaborado pelo autor.

## 4. RESULTADOS E DISCUSSÕES

Nesta seção são apresentados os resultados do processamento estatístico dos dados históricos do sistema de abastecimento; promovidas as discussões pertinentes e necessárias ao estudo e avaliação da sua performance operacional; e a utilização de informações produzidas para o planejamento, modelagem e previsão de cada variável estudada.

### 4.1 DEMANDA PER CAPITA – (L/HAB/DIA)

O consumo per capita representa a quantidade de água que cada habitante utiliza em um dia. Dado que sofre influência de fatores econômicos e sociais presentes em cada região geográfica a ser estudada. A seguir é apresentado um fragmento do script R, “data frame” e a série temporal do período de 8 anos, figuras 4.1 e 4.2, respectivamente. Como decisão na análise de dados, os valores ausentes (setembro a dezembro) foram atribuídos a partir da média de anos anteriores, para os respectivos meses.

```
> Serie <- ts(ConsumoPerCapita, start = c(2017,1), end = c(2024,12), frequency=12)
> print(Serie)
   Jan    Feb    Mar    Apr    May    Jun    Jul    Aug    Sep    Oct    Nov    Dec
2017 102.5121 112.6058 100.4636 107.9152 104.0604 106.0424 105.5131 112.1586 114.8955 117.3345 106.5941 107.0501
2018 109.8011 123.6716 109.3402 115.3339 109.5622 112.3897 106.5556 115.5052 129.0999 124.2245 121.8844 115.0416
2019 111.9282 115.2049 111.3016 119.2305 112.0687 114.1318 115.0950 116.0616 129.9942 117.9836 109.3148 123.0443
2020 113.5804 116.1616 113.7574 116.7276 110.1663 116.2863 108.9131 111.3999 134.0447 113.2488 113.6353 118.6214
2021 109.3121 120.9619 122.9010 121.2485 113.0662 120.6446 112.0743 122.3896 150.6620 120.0545 123.0894 112.6841
2022 108.5141 124.0978 117.1547 115.5488 112.2541 121.9948 112.7009 122.1957 123.1446 125.6575 131.0221 123.5051
2023 116.4934 119.7235 113.6392 123.6670 122.2158 123.2738 119.9212 122.5627 130.3100 119.7500 117.5900 116.6600
2024 102.5121 112.6058 100.4636 107.9152 104.0604 106.0424 105.5131 112.1586 114.8955 117.3345 106.5941 107.0501
> plot(Serie)
```

Figura 4.1 – Data frame – demanda per capita. Fonte: Processamento Rstudio.

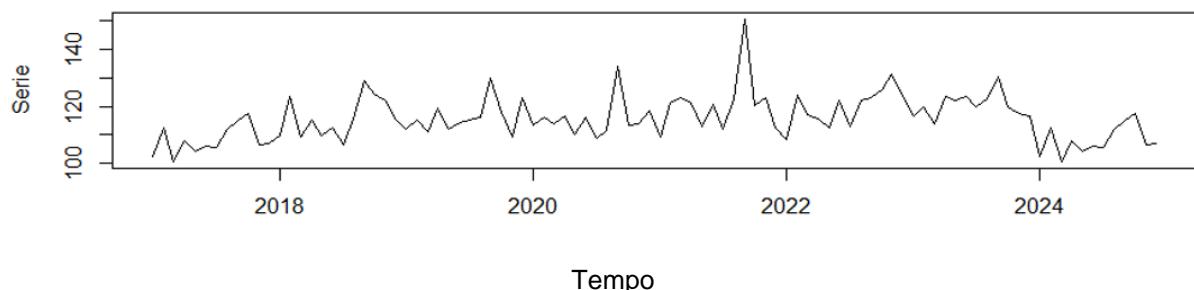


Figura 4.2 – Série temporal – consumo per capita. Eixo y – consumo per capita em l/hab/dia; eixo x – tempo em anos. Fonte: Elaborado pelo autor.

Na plotagem inicial dos dados históricos é possível observar o pico de consumo em novembro de 2022, fato que também aparece quando da avaliação da demanda mensal do booster (sistema de bombeamento automatizado). Como visto na revisão de literatura, o padrão médio para consumo per capita em sistemas de abastecimento

é de 140 l/hab/dia. Todavia, por se tratar de uma região com redes de distribuição bem monitoradas, e de acordo com o perfil populacional da região abastecida, os valores médios se comportam entre 102 e 112 l/hab/dia.

Dando sequência na apresentação de resultados, como estabelecido no capítulo 3 – Metodologia, os parâmetros retornados pelo algoritmo R de otimização computacional estão destacados na figura 4.3. Ressaltando que a melhor versão foi ARIMA (0,1,1)(2,0,0) [12].

```
> ### Best model: ARIMA(0,1,1)(2,0,0)[12]
> summary(Modelo_AUTO)
Series: Serie
ARIMA(0,1,1)(2,0,0)[12]

Coefficients:
      ma1     sar1     sar2
-0.6986  0.4145  0.2305
s.e.   0.0824  0.1006  0.1074

sigma^2 = 36.46: log likelihood = -307.14
AIC=622.28   AICC=622.73   BIC=632.5

Training set error measures:
          ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set -0.2610253 5.911352 4.606094 -0.4327713 3.927791 0.6778592 0.04907313
```

Fig. 4.3 Parâmetros no melhor modelo encontrado. Fonte: Elaborado pelo autor.

Desta forma, o modelo (p, d, q) (P, D, Q) ajustado retornou os parâmetros em nível ótimo, referentes ao Erro Percentual Médio Absoluto; Erro Quadrático Médio Raiz; Erro Médio Absoluto; e Critério de Informação de Akaike. Segue o próximo passo de aferição do modelo que será a análise dos resíduos.

A figura 4.4 exibe a saída do comando R utilizado para a análise de resíduos do modelo, já em sua versão otimizada pelo algoritmo computacional. Destaca-se a confirmação da hipótese H<sub>0</sub> de normalidade dos dados.

```
> # H0 = distribuição normal : p > 0.05
> # Ha = distribuição != normal : p <= 0.05
> shapiro.test(resid(Modelo_AUTO))

Shapiro-Wilk normality test

data: resid(Modelo_AUTO)
W = 0.98624, p-value = 0.4178
```

Fig. 4.4 Análise de Resíduos: Teste de normalidade Shapiro-Wilk. Fonte: Elaborado pelo autor.

A análise gráfica, por sua vez, denota a independência dos resíduos e o comportamento da função de autocorrelação - ACF, dado que as linhas paralelas estão em sua quase totalidade dentro dos limites estabelecidos pelas faixas azuis.

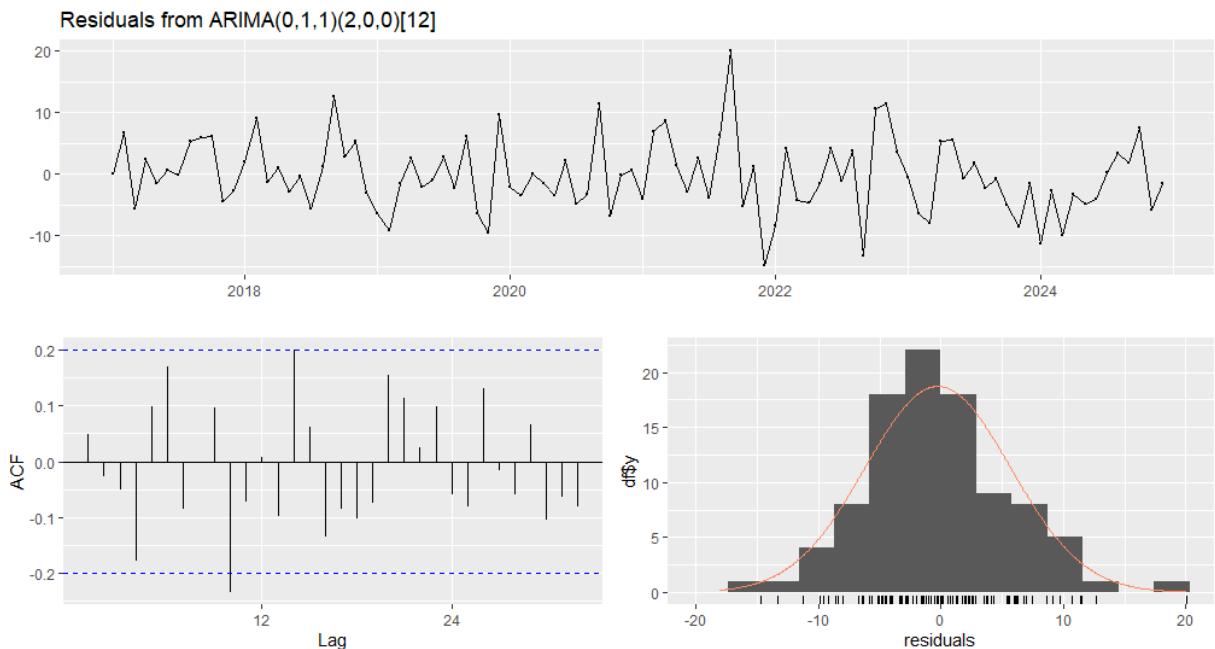


Fig. 4.5 Análise de Autocorrelação e Resíduos: informações gráficas. Fonte: Elaborado pelo autor.

O teste de estacionariedade para a série temporal restou comprovado após análise dentro do ambiente Rstudio, conforme a figura 4.6.

```

> library("urca")
> # Teste pp (Philips-Perron)
> # H0 = é estacionária: p > 0.05
> # Ha = não é estacionária: p <= 0.05
> estacionariedade <- ur.kpss(Serie)
> summary(estacionariedade)

#####
# KPSS Unit Root Test #
#####

Test is of type: mu with 3 lags.

value of test-statistic is: 0.4042

critical value for a significance level of:
      10pct  5pct  2.5pct  1pct
critical values 0.347 0.463  0.574 0.739

```

Fig. 4.6 Teste de Estacionariedade. Fonte: Processamento Rstudio.

Tendo a modelagem na versão ótima sido validada, as figuras 4.7 e 4.8 refletem as projeções realizadas para um horizonte de 12 meses, nas versões numéricas e gráficas, respectivamente.

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2025	100.63717	92.89853	108.3758	88.80194	112.4724
Feb 2025	105.56589	97.48334	113.6484	93.20470	117.9271
Mar 2025	99.13011	90.71771	107.5425	86.26445	111.9958
Apr 2025	104.53051	95.80071	113.2603	91.17943	117.8816
May 2025	102.59803	93.56196	111.6341	88.77856	116.4175
Jun 2025	103.66352	94.33124	112.9958	89.39103	117.9360
Jul 2025	102.67132	93.05194	112.2907	87.95975	117.3829
Aug 2025	106.03498	96.13683	115.9331	90.89706	121.1729
Sep 2025	108.95530	98.78602	119.1246	93.40272	124.5079
Oct 2025	107.53220	97.09882	117.9656	91.57572	123.4887
Nov 2025	102.58206	91.89112	113.2730	86.23167	118.9325
Dec 2025	102.55674	91.61428	113.4992	85.82170	119.2918

Figura 4.7 – Projeção de demanda per capita: valores numéricos. Elaborado pelo autor.

Os recortes em azul mostram os dados previstos para o consumo de 12 meses e a escala de predição de valores; para 80% e 95%. Com valores flutuando entre 100 e 108 l/hab/dia, o perfil individual de consumo mostra-se estabilizado.

#### Forecasts from ARIMA(0,1,1)(2,0,0)[12]

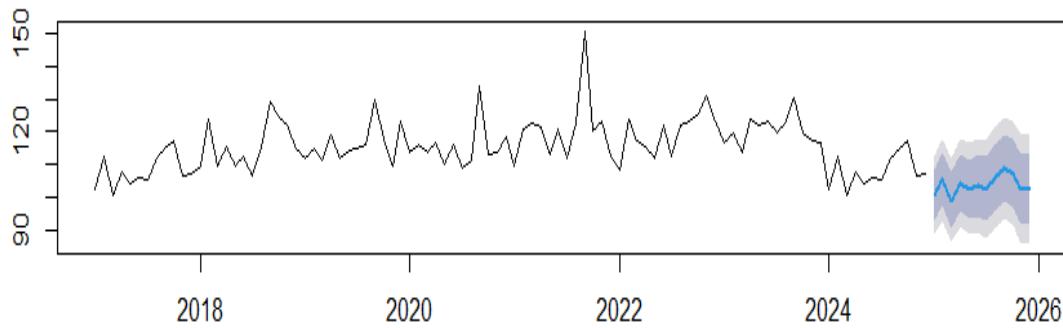


Figura 4.8 – Projeção de demanda per capita. Eixo y – consumo per capita em l/hab/dia; eixo x – tempo em anos. Fonte: Elaborado pelo autor.

Para o final do ano de 2025 até 2026 a linha azul do gráfico reflete uma tendência de estabilização dos valores em torno da média histórica característica do sistema.

## 4.2 DEMANDA MENSAL – VOLUME DISTRIBUIDO PELO SISTEMA (M<sup>3</sup>)

Para o histórico de demanda mensal, volume distribuído e medido nas unidades de consumo, seguem os resultados provenientes das saídas de processamento estatístico no software RStudio.

Esses dados representam os volumes de água que são demandados mensalmente pelo sistema distribuidor, sofrendo influências dos fatores econômicos, sociais, climáticos e sazonais. As figuras 4.9 e 4.10 apresentam o resultado de saída do script R, “*data frame*” e a série temporal do período de 8 anos, em versões numéricas e gráficas, respectivamente.

Em uma avaliação inicial dos dados históricos é possível observar o pico de consumo em novembro de 2022, fato que também aparece quando da avaliação da demanda per capita. A organização dos dados em vetores facilita a visualização do horizonte de tempo da pesquisa, ao passo que a escolha da unidade em metros cúbicos visa a facilitar a leitura e entendimento.

```
> ConsumoÁgua <- as.vector(t(Dados_Consumo))
> print(ConsumoÁgua)
[1] 36702 34523 36854 37703 36906 37818 35506 39239 39503 37317 34030 36091
[13] 36396 36279 35908 37237 37129 36579 37770 40023 39611 41950 36859 38302
[25] 39320 39971 39157 39651 39166 38793 38131 41142 43604 44042 41774 40521
[37] 39626 38022 39613 41009 39877 39428 41055 41208 44946 42240 37878 43895
[49] 40104 37155 40400 40154 39016 40179 39001 39875 46438 40171 38420 42291
[61] 38820 38850 43766 41903 40327 41560 39917 43672 51983 42746 42464 40187
[73] 38759 40076 41887 39907 40078 42171 40228 43744 42619 44909 45103 44042
[85] 41661 40202 41662 42871 45400 43287 43474 43903 46387 45772 40678 43099
>
> Serie <- ts(ConsumoÁgua, start = c(2017,1), end = c(2024,12), frequency=12)
> print(Serie)
   Jan   Feb   Mar   Apr   May   Jun   Jul   Aug   Sep   Oct   Nov   Dec
2017 36702 34523 36854 37703 36906 37818 35506 39239 39503 37317 34030 36091
2018 36396 36279 35908 37237 37129 36579 37770 40023 39611 41950 36859 38302
2019 39320 39971 39157 39651 39166 38793 38131 41142 43604 44042 41774 40521
2020 39626 38022 39613 41009 39877 39428 41055 41208 44946 42240 37878 43895
2021 40104 37155 40400 40154 39016 40179 39001 39875 46438 40171 38420 42291
2022 38820 38850 43766 41903 40327 41560 39917 43672 51983 42746 42464 40187
2023 38759 40076 41887 39907 40078 42171 40228 43744 42619 44909 45103 44042
2024 41661 40202 41662 42871 45400 43287 43474 43903 46387 45772 40678 43099
> plot(Serie)
```

Figura 4.9 – Vetor e série de dados históricos: valores numéricos. Elaborado pelo autor.

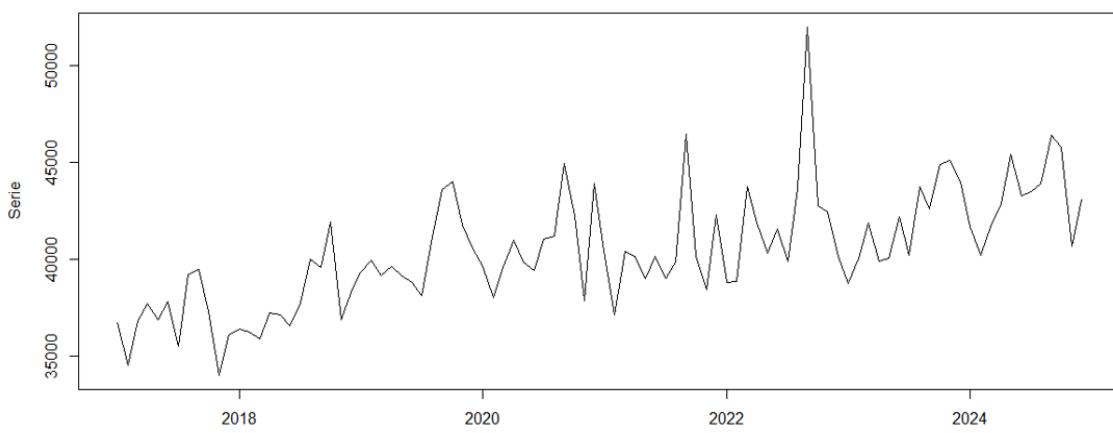


Figura 4.10 – Série Temporal – demanda de 8 anos (consumo mensal). Eixo y – consumo mensal em  $m^3$ ; eixo x – tempo em anos. Elaborado pelo autor.

Observando o comportamento do gráfico, identificamos um pico de consumo no mês de setembro de 2022, outlier que representa situação possível de ocorrer dada a natureza do sistema, por uma elevação da demanda ou algum vazamento na rede de distribuição.

Dando sequência na apresentação de resultados, como estabelecido no capítulo 3 – Metodologia, os parâmetros retornados pelo algoritmo R de otimização computacional estão destacados na figura 4.11. Ressaltando que a melhor versão dos modelos testados foi o ARIMA (0,1,2) (1,0,0).

```
> summary(SARIMA_OTM)
Series: Serie
ARIMA(0,1,2)(1,0,0)[12]

Coefficients:
          ma1      ma2     sar1
        -0.6331  -0.2217  0.4532
  s.e.   0.1085   0.1083  0.0918

sigma^2 = 3960280: log likelihood = -856.75
AIC=1721.5    AICC=1721.94    BIC=1731.71

Training set error measures:
               ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set 285.7339 1948.145 1458.562 0.5246489 3.52805 0.7574229 -0.03567054
```

Figura 4.11 – Parâmetros do melhor modelo encontrado. Fonte: Elaborado pelo autor.

Desta forma, o modelo  $(p, d, q)$  ( $P, D, Q$ ) ajustado retornou os parâmetros em nível ótimo, referentes ao Erro Percentual Médio Absoluto; Erro Quadrático Médio

Raíz; Erro Médio Absoluto; e Critério de Informação de Akaike. Segue o próximo passo de aferição do modelo que será a análise dos resíduos.

Na figura 4.12 temos a saída do comando R utilizado para a análise de resíduos do modelo, já em sua versão otimizada pelo algoritmo computacional. Destaca-se a confirmação da hipótese H<sub>0</sub> de normalidade dos dados.

```
> qqnorm(resid(SARIMA_OTM))
> qqline(resid(SARIMA_OTM))
>
> # H0 = distribuição normal : p > 0.05
> # Ha = distribuição != normal : p <= 0.05
> shapiro.test(resid(SARIMA_OTM))

shapiro-wilk normality test

data: resid(SARIMA_OTM)
W = 0.97839, p-value = 0.1138
```

Figura 4.12 – Análise de Resíduos: gráfico. Fonte: Elaborado pelo autor.

As informações gráficas exibidas na figura 4.12, por sua vez, denotam a independência dos resíduos e o comportamento da função de autocorrelação - ACF, dado que as linhas paralelas estão em sua quase totalidade dentro dos limites estabelecidos pelas faixas azuis. Esse estudo pertence a uma região estabilidade em matéria de crescimento populacional. Neste caso, as variações são relacionadas a outros fatores, mais inerentes ao consumo da água distribuída.

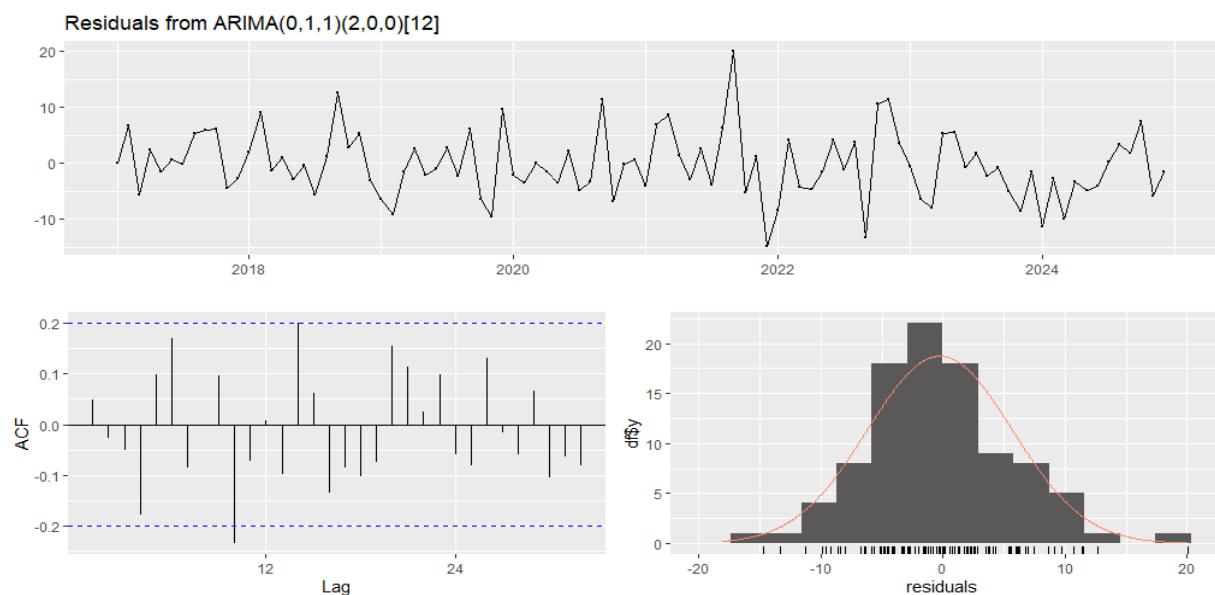


Figura 4.13 – Análise de Resíduos: informações gráficas. Fonte: Elaborado pelo autor.

O teste de estacionariedade para a série temporal restou comprovado após análise dentro do ambiente Rstudio, conforme a figura 4.14.

```

> library("urca")
> # Teste pp (Philips-Perron)
> # H0 = é estacionária: p > 0.05
> # Ha = não é estacionária: p <= 0.05
> estacionariedade <- ur.kpss(serie)
> summary(estacionariedade)

#####
# KPSS Unit Root Test #
#####

Test is of type: mu with 3 lags.

Value of test-statistic is: 1.7334

critical value for a significance level of:
      10pct 5pct 2.5pct 1pct
critical values 0.347 0.463 0.574 0.739

```

Fig. 4.14 Teste de Estacionariedade. Fonte: Elaborado pelo autor.

Tendo a modelagem na versão ótima sido validada, as figuras 4.15 e 4.16 refletem as projeções realizadas para um horizonte de 12 meses, nas versões numéricas e gráficas, respectivamente.

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2025	42868.37	40318.02	45418.72	38967.95	46768.79
Feb 2025	42165.61	39449.05	44882.18	38010.98	46320.25
Mar 2025	42827.27	40085.58	45568.97	38634.21	47020.33
Apr 2025	43375.18	40608.59	46141.78	39144.05	47606.32
May 2025	44521.30	41730.04	47312.57	40252.43	48790.18
Jun 2025	43563.71	40747.98	46379.44	39257.43	47869.99
Jul 2025	43648.46	40808.48	46488.43	39305.09	47991.83
Aug 2025	43842.88	40978.86	46706.90	39462.74	48223.02
Sep 2025	44968.61	42080.74	47856.47	40552.00	49385.21
Oct 2025	44689.89	41778.38	47601.40	40237.12	49142.67
Nov 2025	42381.33	39446.36	45316.30	37892.68	46869.98
Dec 2025	43478.51	40520.27	46436.75	38954.27	48002.75

Figura 4.15 - Previsão de demanda mensal com resíduos (12 meses): valores numéricos. Fonte: Elaborado pelo autor.

Os recortes em azul mostram os dados previstos para o consumo de 12 meses e a escala de predição de valores; para 80% e 95%. Vejamos o comportamento e a distribuição dos valores graficamente, observando os aspectos que caracterizam os dados dessa série temporal.

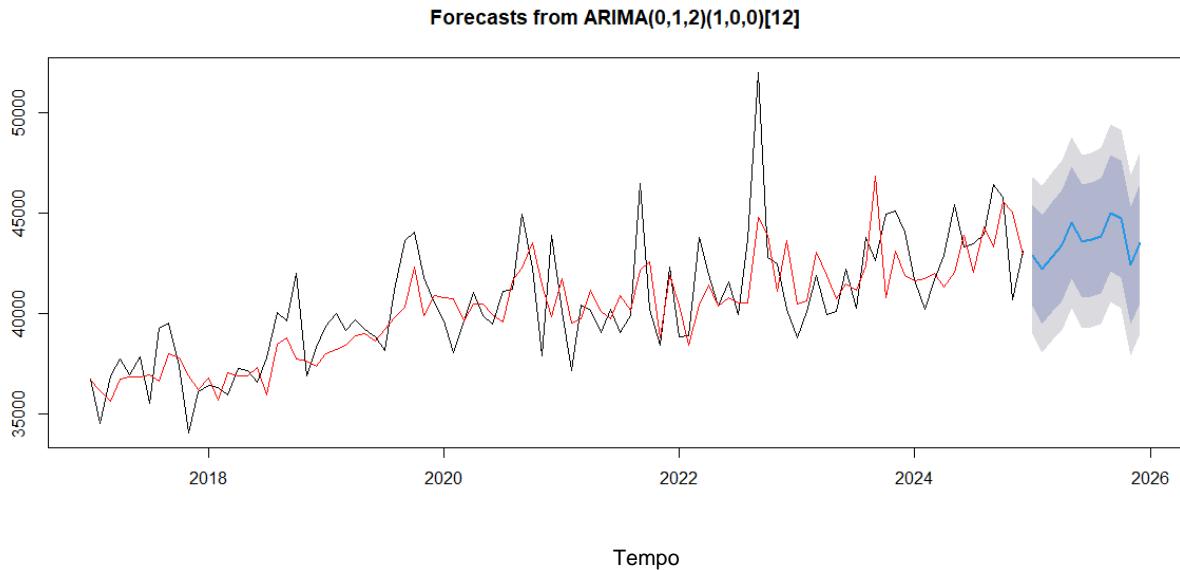


Figura 4.16 - Previsão de demanda mensal com resíduos (12 meses). Eixo y – consumo mensal em  $m^3$ ; eixo x – tempo em anos. Fonte: Elaborado pelo autor.

Para o início do ano de 2025 até início de 2026 a linha azul do gráfico reflete uma tendência de estabilização dos valores em torno da média histórica característica do sistema. O conhecimento dessa informação facilita a realização de bons planos de operação e manutenção do sistema de abastecimento e seus componentes.

### 4.3 ÍNDICES DE PERDAS FÍSICAS NA DISTRIBUIÇÃO - IPD

Variável de grande importância para o Saneamento, o índice de perdas na distribuição deve ser monitorado e controlado ao longo das operações e vida útil dos sistemas. Para o histórico de oitos anos, seguem os resultados provenientes das saídas de processamento estatístico no software RStudio, numéricos e gráficos, figuras 4.17 e 4.18, respectivamente.

```
> IndicePerda <- as.vector(t(IPD))
> print(IndicePerda)
[1] 0.22571255 0.19150852 0.25409549 0.20244032 0.24043058 0.21039930 0.28578114 0.26291028
[9] 0.09636875 0.16546301 0.19729106 0.19279053 0.20485587 0.15896739 0.25468218 0.20073943
[17] 0.23946431 0.24288598 0.25783151 0.23615433 0.24010932 0.22048611 0.25378322 0.27281230
[25] 0.21815069 0.18652021 0.24568652 0.24173875 0.28428856 0.29659651 0.32290385 0.33417691
[33] 0.35994219 0.33871191 0.27214246 0.30583026 0.32091605 0.29943654 0.29002975 0.24380875
[41] 0.26101209 0.21951942 0.26723951 0.25966647 0.19174654 0.25385415 0.27952920 0.21512529
[49] 0.26022194 0.20930110 0.27920870 0.25182609 0.25884337 0.21087829 0.26279538 0.29649495
[57] 0.24818189 0.34262056 0.32804782 0.32701644 0.36630269 0.25245324 0.28907715 0.29247521
[65] 0.31836900 0.28148397 0.34312516 0.31528642 0.15853222 0.31625855 0.25011746 0.32435142
[73] 0.32561693 0.27329567 0.27933412 0.29378982 0.31955988 0.24571937 0.29828441 0.23987889
[81] 0.25020473 0.22952647 0.20755106 0.21369575
```

Figura 4.17 – Índices de Perdas: valores numéricos. Fonte: Elaborado pelo autor.

Esses dados representam os percentuais de volumes de água que são perdidos de forma física pelo sistema distribuidor, impactados pelos níveis de operação, resistência dos materiais empregados nas tubulações, concepções de projeto, dentre outros. A organização dos dados em vetores facilita a visualização do horizonte de tempo da pesquisa, totalizando um espaço de 96 meses.

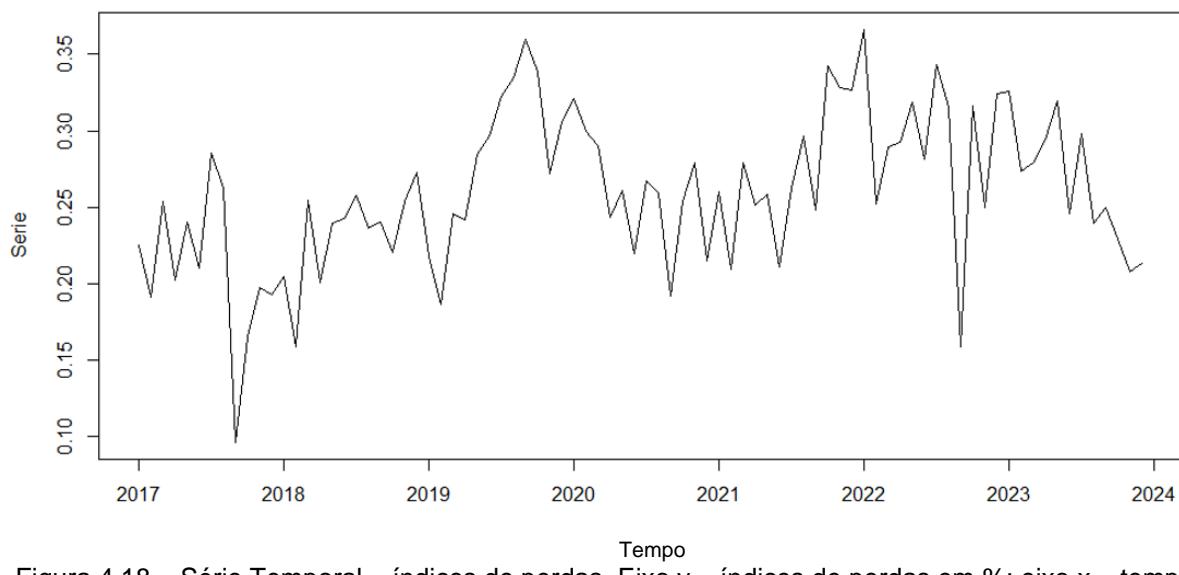


Figura 4.18 – Série Temporal – índices de perdas. Eixo y – índices de perdas em %; eixo x – tempo em anos. Fonte: Elaborado pelo autor.

Pela análise gráfica é possível observar que os índices de perdas acompanham o perfil do sistema até agora estudado. Com variações em certo padrão ao longo dos meses e anos; e também um nível de queda acentuada para os últimos dados coletados.

Seguindo com a sequência e apresentação de resultados, como estabelecido no capítulo 3 – Metodologia, os parâmetros retornados pelo algoritmo R de otimização computacional estão destacados na figura 4.19. Ressaltando que a melhor versão dos modelos testados foi o ARIMA (0,1,1) (1,0,0).

Desta forma, o modelo  $(p, d, q)$  ( $P, D, Q$ ) ajustado retornou os parâmetros em nível ótimo, referentes ao Erro Percentual Médio Absoluto; Erro Quadrático Médio Raíz; Erro Médio Absoluto; e Critério de Informação de Akaike. Segue o próximo passo de aferição do modelo que será a análise dos resíduos.

```

> ### Best model: ARIMA(0,1,2)(1,0,0)[24]
>
> summary(SARIMA_OTM)
Series: Serie
ARIMA(0,1,1)(1,0,0)[12]

Coefficients:
      m1      sar1
      -0.5942  0.2578
  s.e.  0.0942  0.1188

sigma^2 = 0.001816: log likelihood = 144.52
AIC=-283.05  AICc=-282.75  BIC=-275.79

Training set error measures:
      ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set -0.0004169667 0.04184531 0.03232338 -3.13373 14.23595 0.6325538 -0.0203888

```

Figura 4.19 – Parâmetros do modelo otimizado. Fonte: Elaborado pelo autor.

Para validação do modelo, a figura 4.20 apresenta a saída do comando R utilizado para a análise de resíduos, já em sua versão otimizada pelo algoritmo computacional. Destaca-se a confirmação da hipótese H<sub>0</sub> de normalidade dos dados.

```

> # Análise dos resíduos (qualidade do modelo)
> checkresiduals(SARIMA_OTM)

Ljung-Box test

data: Residuals from ARIMA(0,1,1)(1,0,0)[12]
Q* = 10.275, df = 15, p-value = 0.8021

Model df: 2. Total lags used: 17

```

4.20 – Teste de resíduos: parâmetro. Fonte: Elaborado pelo autor.

Na figura 4.21, por sua vez, temos as informações gráficas exibidas; denotando a independência dos resíduos e o comportamento da função de autocorrelação - ACF, apresentando as linhas paralelas em sua quase totalidade dentro dos limites estabelecidos pelas faixas azuis. Esse estudo e domínio das variáveis do processo permitem a adoção de medidas de prevenção e aumento da eficiência operacional. Analisando até este ponto, as evidências apontam na direção de um sistema com dados que seguem certa tendência e correlação.

Parametrizando os planos de operação e manutenção, a conjugação dos dados de demanda volumétrica, consumo de energia e tendência a perdas no processo eleva as possibilidades de acerto nas tomadas de decisão. Implantar melhorias e conduzir o funcionamento de redes de abastecimento requer o uso de critérios baseados em informações confiáveis.

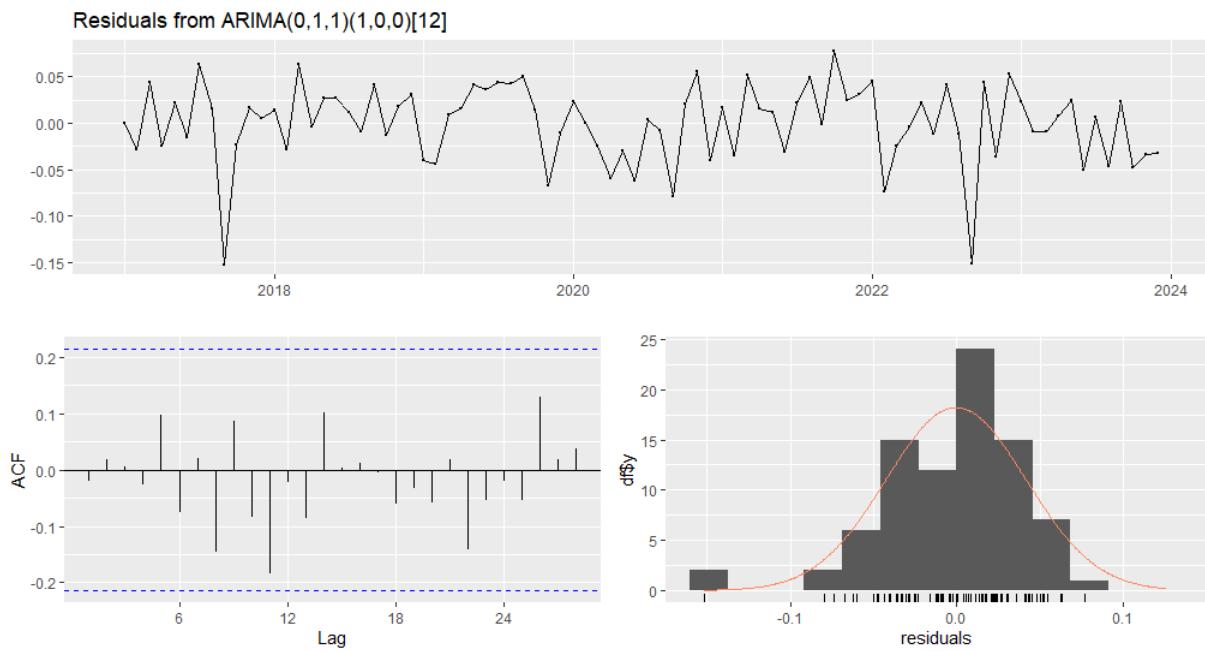


Figura 4.21 – Análise de resíduos: informações gráficas. Fonte: Elaborado pelo autor.

O teste de estacionariedade para a série temporal restou comprovado após análise dentro do ambiente Rstudio, conforme a figura 4.22.

```
> library("urca")
> # Teste pp (Philips-Perron)
> # H0 = é estacionária: p > 0.05
> # Ha = não é estacionária: p <= 0.05
> estacionariedade <- ur.kpss(serie)
> summary(estacionariedade)

#####
# KPSS Unit Root Test #
#####

Test is of type: mu with 3 lags.

value of test-statistic is: 0.6798

Critical value for a significance level of:
      10pct  5pct 2.5pct  1pct
critical values 0.347 0.463  0.574 0.739
```

Fig. 4.22 Teste de Estacionariedade. Fonte: Processamento Rstudio.

Tendo a modelagem na versão ótima sido validada, as figuras 4.23, 4.24 e 4.25 refletem as projeções realizadas para um horizonte de 12 meses, nas versões numéricas e gráficas, respectivamente.

```
> print(Previsao)
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2024	0.2335147	0.1789037	0.2881257	0.14999443	0.3170350
Feb 2024	0.2200249	0.1610881	0.2789617	0.12988882	0.3101609
Mar 2024	0.2215817	0.1586156	0.2845479	0.12528338	0.3178801
Apr 2024	0.2253088	0.1585562	0.2920615	0.12321943	0.3273982
May 2024	0.2319531	0.1616174	0.3022887	0.12438395	0.3395222
Jun 2024	0.2129149	0.1391702	0.2866597	0.10013205	0.3256978
Jul 2024	0.2264677	0.1494646	0.3034707	0.10870158	0.3442337
Aug 2024	0.2114091	0.1312801	0.2915381	0.08886231	0.3339559
Sep 2024	0.2140714	0.1309339	0.2972089	0.08692351	0.3412193
Oct 2024	0.2087400	0.1226991	0.2947809	0.07715178	0.3403282
Nov 2024	0.2030741	0.1142247	0.2919235	0.06719062	0.3389576
Dec 2024	0.2046584	0.1130865	0.2962302	0.06461128	0.3447055

Figura 4.23 – Dados de previsão (dados já consumados): valores numéricos. Fonte: Elaborado pelo autor.

Essa projeção foi realizada com dados até dezembro de 2023. Ao final deste capítulo é exibida uma tabela contendo o cálculo do nível de assertividade da previsão.

Jan 2025	0.2097683	0.11128496	0.3082515	0.0591510604	0.3603854
Feb 2025	0.2062902	0.10393748	0.3086429	0.0497552259	0.3628252
Mar 2025	0.2066916	0.10061051	0.3127727	0.0444545680	0.3689286
Apr 2025	0.2076525	0.09796973	0.3173354	0.0399071609	0.3753979
May 2025	0.2093656	0.09619565	0.3225356	0.0362870943	0.3824441
Jun 2025	0.2044571	0.08790424	0.3210099	0.0262049068	0.3827092
Jul 2025	0.2079513	0.08811110	0.3277915	0.0246715111	0.3912311
Aug 2025	0.2040688	0.08102898	0.3271086	0.0158956305	0.3922420
Sep 2025	0.2047552	0.07859691	0.3309135	0.0118127312	0.3976977
Oct 2025	0.2033806	0.07417909	0.3325822	0.0057839168	0.4009774
Nov 2025	0.2019198	0.06974509	0.3340946	-0.0002239944	0.4040636
Dec 2025	0.2023283	0.06724579	0.3374108	-0.0042625637	0.4089191

Figura 4.24 – Dados de previsão (dados projetados): valores numéricos. Fonte: Processamento Rstudio.

Os recortes em azul mostram os dados previstos para o consumo de 12 meses e a escala de predição de valores; para 80% e 95%. Vejamos o comportamento e a distribuição dos valores graficamente (figura 4.24), observando os aspectos que caracterizam os dados dessa série temporal.

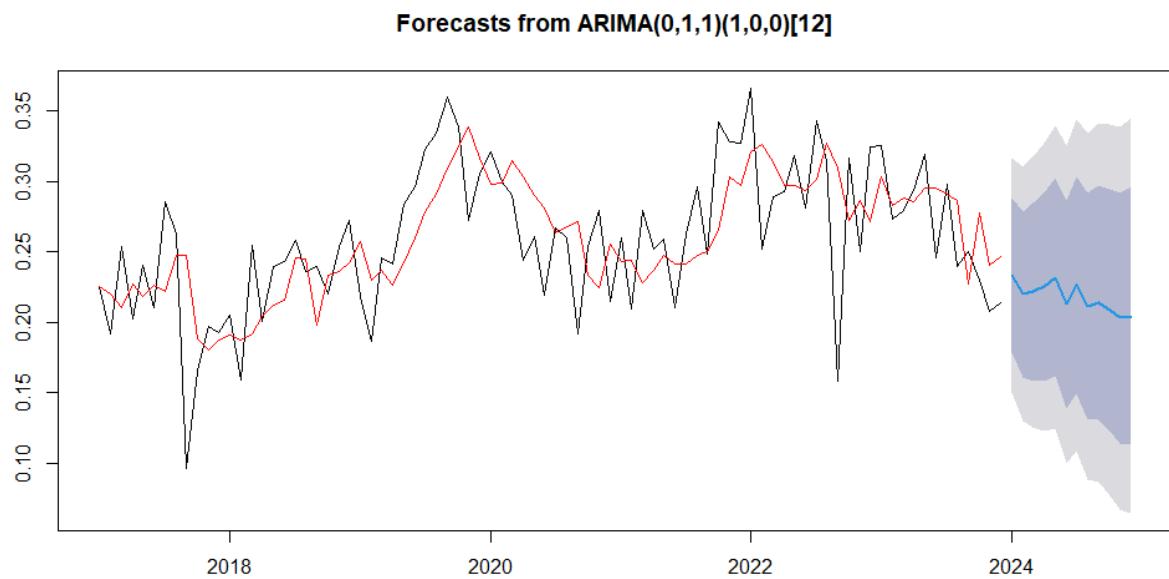


Figura 4.25 – Dados de previsão: gráfico. Fonte: Elaborado pelo autor. Eixo y – índices de perdas em %; eixo x – tempo em anos.

Por se tratar de um sistema com assistência técnica de alto nível, a previsão da série temporal aponta para a redução e estabilização do índice de perda. Corroborando o aspecto de estabilidade na gestão de demanda, influenciada pelas variáveis estudadas anteriormente.

#### 4.4 CONSUMO DE ENERGIA ELÉTRICA

Sendo a energia elétrica o segundo maior custo financeiro na produção de água, atrás apenas de produtos químicos, torna-se relevante o estudo e monitoramento deste insumo. Para o histórico de consumo de energia pelo sistema automatizado, seguem os resultados provenientes das saídas de processamento estatístico no software RStudio, numéricos e gráficos, nas figuras 4.26 e 4.27, respectivamente.

Esses dados representam os totais de energia em kwh que são demandados mensalmente pelo sistema distribuidor, sofrendo influências diretas de fatores como volume de produção e consumo populacional.

Em uma avaliação inicial dos dados históricos é possível observar o pico de consumo no primeiro semestre de 2017, seguido de uma estabilização que comprova as ações de melhoria na eficiência do sistema.

```

> Serie <- ts(ConsumoÁgua, start = c(2017,1), end = c(2023,12), frequency=12)
> print(serie)
   Jan   Feb   Mar   Apr   May   Jun   Jul   Aug   Sep   Oct   Nov   Dec
2017 13920 14400 19480 19320 15560 14520 10520 16360 4120  8400  9080  9080
2018  9840  8440 12040 11440  4360  9200  9800  9320 11000  9440  9400 10120
2019  9640 10120  9760  8880 10800  9760  9800  9800 11560  9920  9960 10000
2020 11800  9520 10360 10160 10880  9520 10760 10680 10200 11920 10480 10640
2021 10560 10120  9080 10400 10400 10360 11560 10520 13400 10760 10680 10680
2022 10680 12560 10920 11040 11120 10280 11160 11120 11200 11000 11000 11040
2023 11080 11120 11000 10988 10988 10988 11029 11029 11029 10988 10988 10988

```

Figura 4.26 – Dados históricos - kwh. Fonte: Processamento Rstudio.

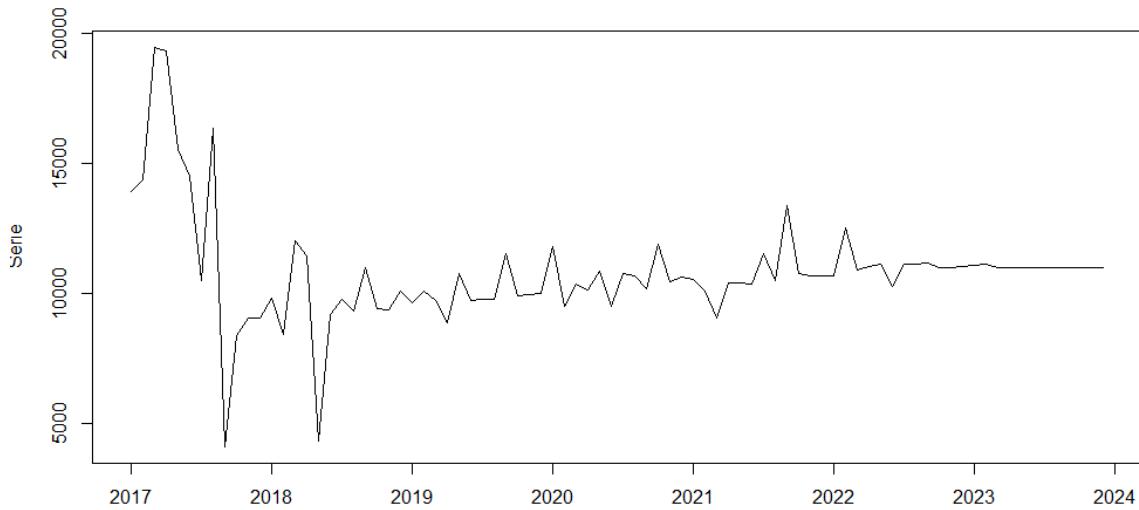


Figura 4.27 – Série histórica: gráfico. Eixo x: consumo em kwh; eixo y: tempo. Fonte: Elaborado pelo autor.

Dando sequência na apresentação de resultados, como estabelecido no capítulo 3 – Metodologia, os parâmetros retornados pelo algoritmo R de otimização computacional estão destacados na figura 4.28. Ressaltando que a melhor versão dos modelos testados foi o ARIMA (0,1,2) (1,0,0).

```

> ### Best model: ARIMA(0,1,2)(1,0,0)[24]
>
> summary(SARIMA_0TM)
Series: Serie
ARIMA(0,0,5) with non-zero mean

Coefficients:
          ma1      ma2      ma3      ma4      ma5       mean
        0.3710  0.5562  0.3694  0.4877  0.4391  10877.3004
  s.e.  0.1025  0.0988  0.1128  0.0991  0.1035   568.8318

sigma^2 = 2957013: log likelihood = -742.89
AIC=1499.78  AICc=1501.26  BIC=1516.8

Training set error measures:
               ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set -22.72704 1657.045 1023.343 -3.305592 11.16532 0.6720177 -0.07729659

```

Figura 4.28 – Teste de resíduos: parâmetro. Fonte: Elaborado pelo autor.

Como visto nos destaques em verde, o modelo  $(p, d, q)$  ( $P, D, Q$ ) ajustado retornou os parâmetros em nível ótimo, referentes ao Erro Percentual Médio Absoluto; Erro Quadrático Médio Raíz; Erro Médio Absoluto; e Critério de Informação de Akaike. Segue o próximo passo de aferição do modelo que será a análise dos resíduos.

Na figura 4.28 temos a saída do comando R utilizado para a análise de resíduos do modelo, já em sua versão otimizada pelo algoritmo computacional. Destaca-se a confirmação da hipótese  $H_0$  de normalidade dos dados.

```
> # Análise dos resíduos (qualidade do modelo)
> checkresiduals(SARIMA_OTM)

Ljung-Box test

data: Residuals from ARIMA(0,0,5) with non-zero mean
Q* = 11.232, df = 12, p-value = 0.5091

Model df: 5. Total lags used: 17
```

Figura 4.29 – Teste de resíduos: parâmetro. Fonte: Elaborado pelo autor.

Para a verificação de independência dos resíduos e distribuição normal da série, temos as informações gráficas exibidas na figura 4.29; estas, por sua vez, exibem e evidenciam também o comportamento da função de autocorrelação - ACF, dado que as linhas paralelas estão em sua quase totalidade dentro dos limites estabelecidos pelas faixas azuis.

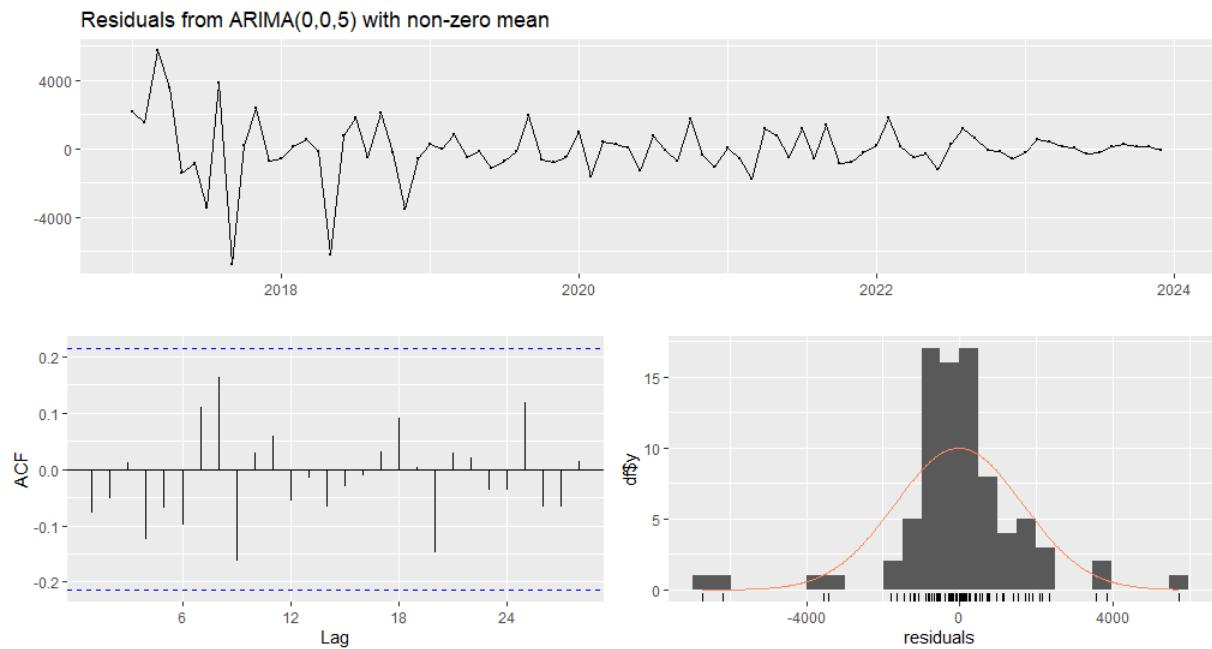


Figura 4.30 – Análise de resíduos - gráfico. Fonte: Elaborado pelo autor.

O teste de estacionariedade para a série temporal restou comprovado após análise dentro do ambiente Rstudio, conforme a figura 4.30.

```

> library("urca")
> # Teste pp (Philips-Perron)
> # H0 = é estacionária: p > 0.05
> # Ha = não é estacionária: p <= 0.05
> estacionariedade <- ur.kpss(serie)
> summary(estacionariedade)

#####
# KPSS Unit Root Test #
#####

Test is of type: mu with 3 lags.

Value of test-statistic is: 0.1682

critical value for a significance level of:
      10pct 5pct 2.5pct 1pct
critical values 0.347 0.463 0.574 0.739

```

Fig. 4.31 Teste de Estacionariedade. Fonte: Elaborado pelo autor.

Seguindo com a apresentação de resultados, e tendo a modelagem na versão ótima sido validada, as figuras 4.32, 4.33 e 4.34 refletem as projeções realizadas para um horizonte de 12 meses, nas versões numéricas e gráficas, respectivamente.

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2024		11144.56	8940.809	13348.31	11144.56	14514.91
Feb 2024		11059.02	8708.518	13409.53	7464.236	14653.81
Mar 2024		10960.76	8309.910	13611.61	6906.633	15014.89
Apr 2024		10886.23	8113.199	13659.26	6645.243	15127.22
May 2024		10848.99	7874.984	13822.99	6300.641	15397.33
Jun 2024		10877.30	7749.822	14004.78	6094.235	15660.37
Jul 2024		10877.30	7749.822	14004.78	6094.235	15660.37
Aug 2024		10877.30	7749.822	14004.78	6094.235	15660.37
Sep 2024		10877.30	7749.822	14004.78	6094.235	15660.37
Oct 2024		10877.30	7749.822	14004.78	6094.235	15660.37
Nov 2024		10877.30	7749.822	14004.78	6094.235	15660.37
Dec 2024		10877.30	7749.822	14004.78	6094.235	15660.37

Figura 4.32 – Dados para previsão: 2024. Fonte: Elaborado pelo autor.

Os dados de consumo de energia elétrica referentes ao ano de 2024 já foram consumados e serão apresentados na seção de avaliação de assertividade das previsões, localizada ao final deste capítulo.

Estendendo a previsão até final de 2025, obteve-se uma sequência estável no valor de 10877,30 kwh de consumo mensal para o sistema.

Jan 2025	10877.30	7749.822	14004.78	6094.235	15660.37
Feb 2025	10877.30	7749.822	14004.78	6094.235	15660.37
Mar 2025	10877.30	7749.822	14004.78	6094.235	15660.37
Apr 2025	10877.30	7749.822	14004.78	6094.235	15660.37
May 2025	10877.30	7749.822	14004.78	6094.235	15660.37
Jun 2025	10877.30	7749.822	14004.78	6094.235	15660.37
Jul 2025	10877.30	7749.822	14004.78	6094.235	15660.37
Aug 2025	10877.30	7749.822	14004.78	6094.235	15660.37
Sep 2025	10877.30	7749.822	14004.78	6094.235	15660.37
Oct 2025	10877.30	7749.822	14004.78	6094.235	15660.37
Nov 2025	10877.30	7749.822	14004.78	6094.235	15660.37
Dec 2025	10877.30	7749.822	14004.78	6094.235	15660.37

Figura 4.33 – Dados para previsão: 2025. Fonte: Elaborado pelo autor.

Os recortes em azul mostram os dados previstos para o consumo de 12 meses e a escala de predição de valores; para 80% e 95%. Vejamos o comportamento e a distribuição dos valores graficamente, observando os aspectos que caracterizam os dados dessa série temporal.

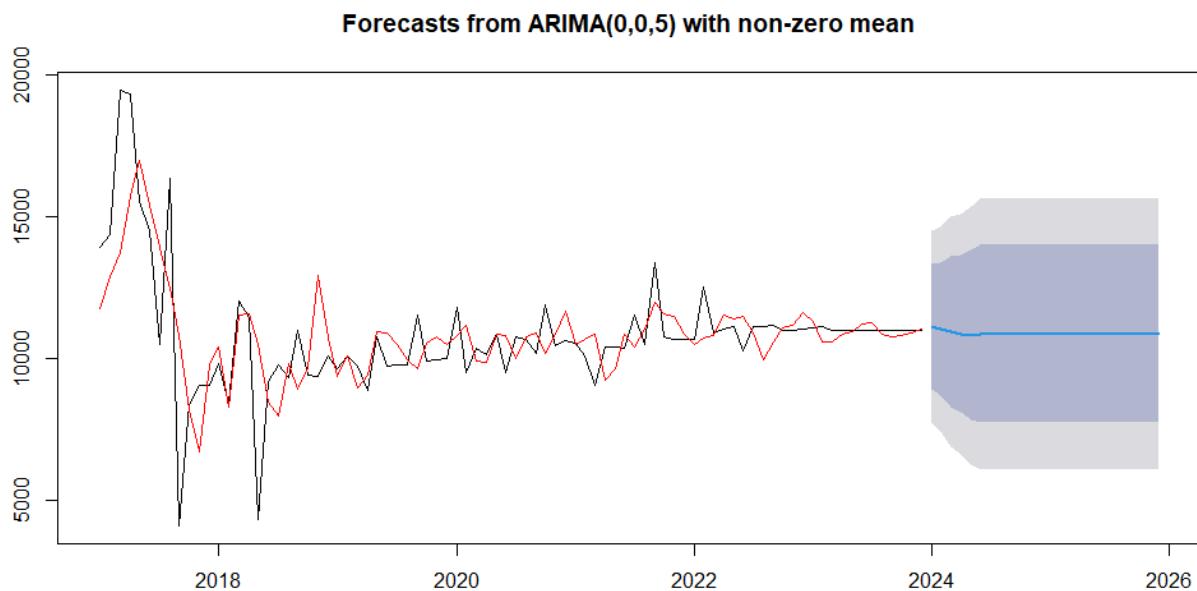


Figura 4.34 – Gráfico para previsão: 2025. Fonte: Elaborado pelo autor.

Para o início do ano de 2025 até início de 2026 a linha azul do gráfico reflete uma tendência de estabilização dos valores. Sendo o consumo de energia influenciado pela demanda operacional, a correlação dos fatores aponta para a característica padrão do sistema de abastecimento ora estudado. Informações e parâmetros de desempenho alimentam e facilitam a realização de bons planos de operação e manutenção de sistemas de produção e seus componentes.

#### 4.5 VERIFICAÇÃO DA EFICIÊNCIA DO MODELO DE SÉRIES TEMPORAIS

Tendo em vista que a modelagem de séries temporais visa ao estabelecimento de previsões, foi verificada a exatidão do modelo através da comparação com os dados de consumo referentes à demanda mensal do sistema de abastecimento, aferidos nos meses de janeiro e fevereiro do ano corrente (2025) – ver tabela 4.5:

Ano	Mês	Consumo Autorizado Faturado (m <sup>3</sup> /mês)	Previsão	Diferença (m <sup>3</sup> )	Eficiência (%)
2025	janeiro	41960	42868	908	97,88
2025	fevereiro	41472	42165	693	98,36

Tabela 4.1 – Nível de eficiência do modelo. Fonte: elaboração própria

As diferenças encontradas nos primeiros meses, 908 e 693 metros cúbicos, respectivamente, geram os percentuais de eficiência apresentados na tabela.

Referente às variáveis de consumo de energia elétrica e índices de perdas na distribuição, foram realizadas projeções para 2024 e 2025, sendo as primeiras já verificadas e presentes nas tabelas 4.2 e 4.3

MÊS	PREVISÃO	REAL	DIFERENÇA (%)
JAN	11144,56	11080	-0,58%
FEV	11059,02	11120	0,55%
MAR	10960,76	11000	0,36%
ABR	10886,23	10988	0,93%
MAI	10848,99	10988	1,28%
JUN	10877,3	10988	1,02%
JUL	10877,3	11029	1,39%
AGO	10877,3	11029	1,39%
SET	10877,3	11029	1,39%
OUT	10877,3	10988	1,02%
NOV	10877,3	10988	1,02%
DEZ	10877,3	10988	1,02%

Tabela 4.2 – Nível de eficiência do modelo - Energia. Fonte: elaboração própria.

MÊS	PREVISÃO	REAL	DIFERENÇA (%)
JAN	23,3	32,56	39,74%
FEV	22	27,33	24,23%
MAR	22	27,93	26,95%
ABR	22	29,38	33,55%
MAI	23	31,96	38,96%
JUN	21	24,57	17,00%
JUL	22	29,83	35,59%
AGO	21	23,99	14,24%
SET	21	25,02	19,14%
OUT	21	22,95	9,29%
NOV	21	20,76	-1,14%
DEZ	20	21,37	6,85%

Tabela 4.3 – Nível de eficiência do modelo - IPD. Fonte: elaboração própria.

Observando as tabelas com previsões já verificadas, é evidente que para a previsão de demanda mensal e consumo energético houve assertividade maior, acima de 97%. Ao passo que, para a previsão de perdas, os níveis de eficácia situaram-se entre 60,25 e 99%.

#### 4.6 COMPORTAMENTO DA VAZÃO MÍNIMA NOTURNA

A vazão mínima noturna é um parâmetro importante na investigação de ocorrências de vazamento nas redes de abastecimento de um setor. Dada a sua relevância, os dados abaixo visam a comparar os valores em horários de pico no consumo e em horários noturnos, quais sejam, aqueles situados entre 00:00h e 05:00h. A série temporal da figura 4.35 representa um total de 17.280 medições horárias, referente a um período de 24 meses.

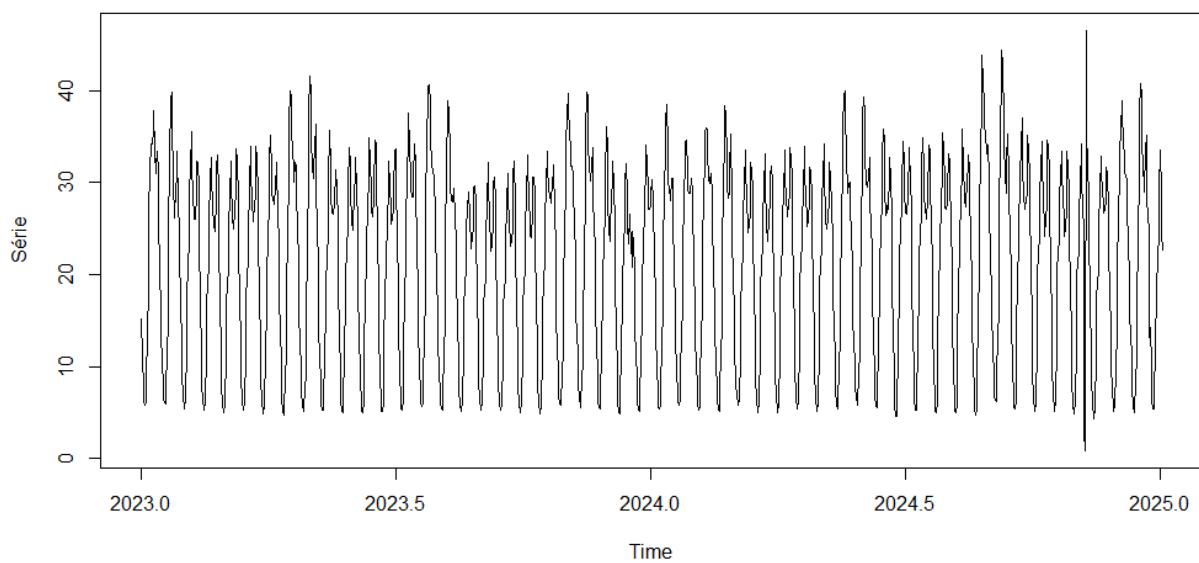


Figura 4.35 – Série Temporal – vazão mínima noturna (24 meses). Eixo x – vazão em l/s; eixo y – tempo. Fonte: Elaborado pelo autor.

Neste caso, a série temporal indica o nível estável de vazão mínima noturna, que por sua vez coaduna com baixo índice de perdas e estabilidade operacional do sistema. A figura 4.36 apresenta os valores médios evidenciando os horários de menor demanda horária.

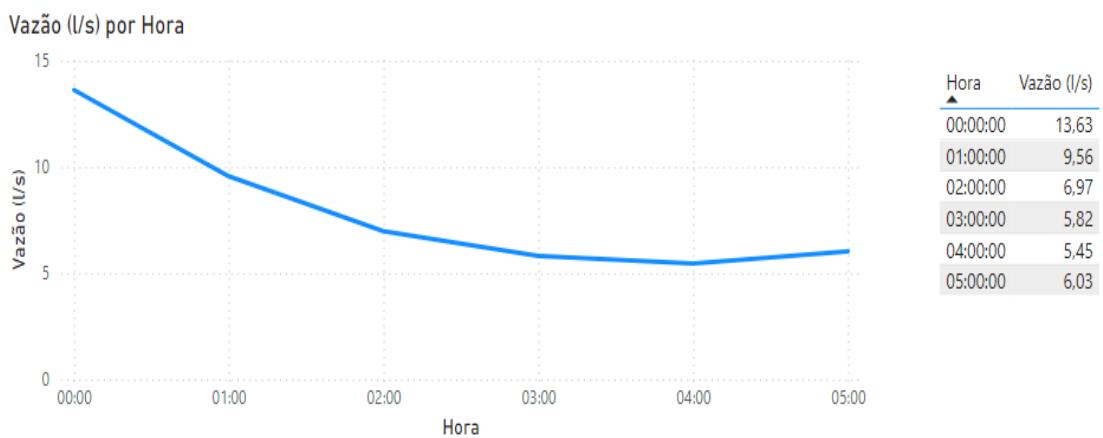


Figura 4.36 – Valores médios – vazão diurna (12 meses). Fonte: Elaboração própria.

O texto de revisão bibliográfica conceitua a vazão mínima noturna como um parâmetro importante no estudo e combate das perdas físicas na distribuição. As vazões no período de madrugada variam entre 5 l/s e 6 l/s evidenciando normalidade para o referido período de consumo. A figuras 4.37 e 4.38 apresentam os valores médios evidenciando os horários de maior demanda horária.

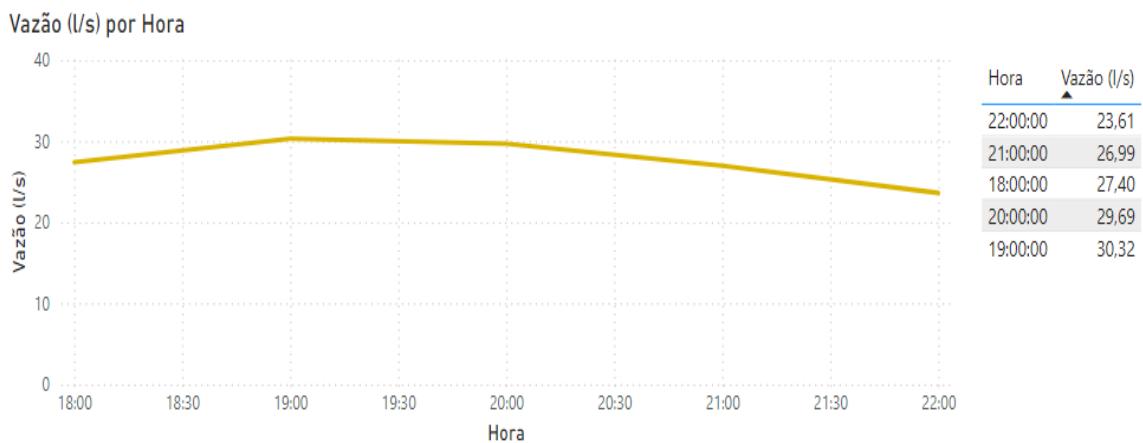


Figura 4.37 – Valores médios – horários de maior vazão. Fonte: Elaboração própria.

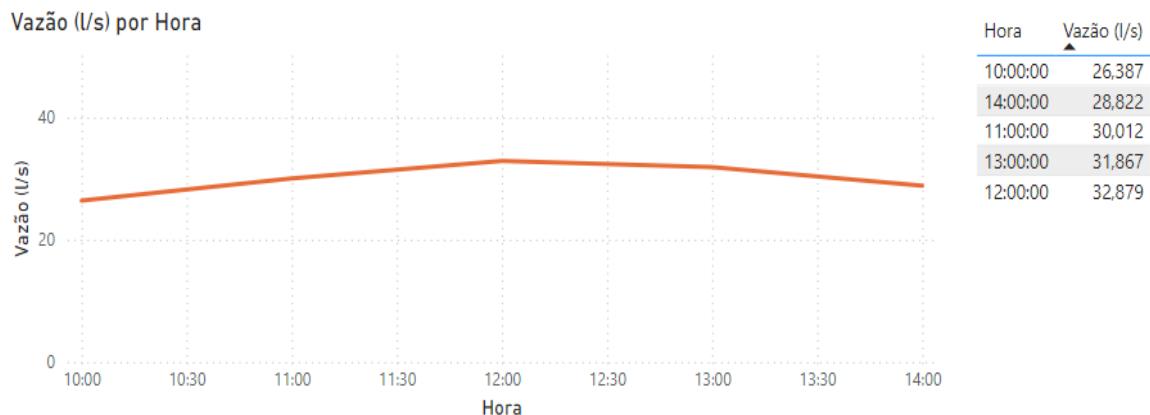


Figura 4.38 – Valores médios – horários de maior vazão. Fonte: Elaboração própria.

Os valores de vazão nos períodos de pico no consumo foram apresentados em consonância com a demanda do sistema e os índices de perda entre volume de entrada e volume medido (autorizado).

#### 4.7 Equações ajustadas para os modelos ARIMA e análise dos parâmetros

Conforme descrito no capítulo de Metodologia, o modelo ARIMA com parâmetro de sazonalidade possui o formato  $(p, d, q) (P, D, Q)$  em que [adaptado de Barros (2021) et al]:

- P é a ordem do polinômio autorregressivo não sazonal;
- p é a ordem do polinômio autorregressivo sazonal;
- q é a ordem do polinômio de médias móveis não sazonal;
- Q é a ordem do polinômio de médias móveis sazonal
- d é a ordem de diferença não sazonal;
- D é a ordem de diferença sazonal.

De acordo com a Revisão de Literatura, a modelagem de Séries Temporais – métodos ARIMA/SARIMA busca definir parâmetros que otimizem as medidas de RMSE (Root Mean Square Error), MAPE (Mean Absolute Percentage Error) e AIC (Critério de Informação de Akaike).

O ajuste final dos modelos, a partir dos critérios de otimização computacional da linguagem R, estabeleceu as equações dos modelos para Demanda Per Capita, Demanda Mensal, Índices de Perdas e Consumo de energia com lags de defasagem 0, 1 e 2, a despeito de o código ter sido programado para um máximo de 5.

1. Modelo Ajustado – Demanda Per Capita: ARIMA (0,1,1) (2,0,0)
2. Modelo Ajustado – Demanda Mensal: ARIMA (0,1,2) (1,0,0)
3. Modelo Ajustado – Índice de Perdas: ARIMA (0,1,1) (1,0,0)
4. Modelo Ajustado – Consumo de Energia Elétrica: ARIMA (0,1,2) (1,0,0)

## **5. CONCLUSÕES E SUGESTÃO DE TRABALHOS FUTUROS**

O processamento dos dados históricos e os resultados gerados denotam a evolução e estabilidade do sistema instrumentado de abastecimento de água. Planos de produção e operação podem ser projetados a partir dos parâmetros modelados.

Para um planejamento operacional de produção e distribuição de água o estudo apontou demanda per capita variando entre 120 e 130 litros por habitante dia; enquanto o volume disponibilizado mensal oscila entre 41 e 43 mil metros cúbicos de água.

Nos últimos 12 meses a perda máxima no processo distribuidor foi de 25%, índice compatível com as recomendações da literatura técnica de saneamento. O consumo energético caiu de 0,5 kwh/m<sup>3</sup> para 0,3 kwh/m<sup>3</sup>, denotando ganho de eficiência energética.

As séries temporais modeladas contemplaram os seguintes parâmetros de desempenho do sistema: vazão mínima noturna, consumo per capita, volume total mensal distribuído e índices de perdas físicas no processo.

A análise diagnóstica e prospectiva auxilia no ganho de eficiência das operações. Os resultados descritos na seção anterior apontam normalidade e consonância com a literatura. Perfil de consumo energético, índices de perdas, vazões e demanda populacional foram aferidos, modelados e projetados com razoável confiabilidade.

A utilização de recursos computacionais no gerenciamento dos dados e informações técnicas garantem a celeridade de relatórios utilizados na gestão e tomada de decisão. Tecnologias são elementos impulsionadores da boa governança empresarial.

A análise do Distrito de Medição e Controle foi realizada seguindo o método estabelecido para o modelo ARIMA e suas variantes. Isto no que diz respeito aos parâmetros operacionais. A modelagem das séries temporais para vazão horária e volume de consumo (mensal e per capita), comumente chamados de demanda, retornou valores de previsão compatíveis com as condições operacionais do Sistema; além de apresentar estabilidade e previsibilidade - conforme relatórios do Stúdio R discorridos na seção de “Resultados”. A análise da série histórica para o consumo de

energia elétrica e os valores consumidos por volume de água distribuída denotam normalidade e eficiência energética, de acordo com os preceitos da literatura. Este conjunto de resultados, por sua vez, servirá de insumo básico para o planejamento de produção e operação do sistema. Quanto aos índices de perda física, estatisticamente evidenciam uma estabilidade e aproximação dos valores estabelecidos em requisitos regulatórios, com variação entre 16% e 25% para os últimos 12 meses.

Avaliar a série histórica do consumo per capita e da demanda mensal do sistema de abastecimento possibilitou a produção de informações estratégicas para subsídio de planejamentos táticos e operacionais. Ao passo que o detalhamento de parâmetros como vazão mínima noturna e índices de perda física permitiram validar uma razoável estabilidade operacional do setor escolhido para realização dos estudos. Também restou comprovada eficiência razoável no atendimento das políticas de combate a perdas físicas na distribuição.

A partir dos dados já publicados para a demanda do sistema nos meses de janeiro e fevereiro de 2025, foi possível verificar um grau de assertividade de 98% para o modelo aplicado nas séries temporais, corroborando com as variáveis estatísticas parametrizadas e avaliadas pelo algoritmo da linguagem R.

Como sugestão de trabalho futuro, pode ser realizada a investigação de variáveis causais no aumento e redução de consumo; bem como dos fatores que influenciam no índice de perda física na distribuição de água tratada. Outro objeto de pesquisa seria avaliar, para os meses subsequentes, a eficiência das projeções de demanda mensal do SAA ora estudado. O resultado pretendido seria o alcance de melhor sustentabilidade econômica, social e ambiental das companhias estaduais de saneamento, incluindo a melhoria na prestação dos serviços à população atendida em cada região.

## REFERENCIAS BIBLIOGRÁFICAS

BARROS, Anna Carolina; MATTOS , Daiane Marcolino de; OLIVEIRA, Ingrid Christyane Luquett de; FERREIRA, Pedro Guilherme Costa; DUCA, Victor Eduardo Leite de Almeida. **Análise de Séries Temporais em R: curso introdutório.** São Paulo – SP, 2021.

BIAHMOU, Alain. **System Engineering.** Publisher: Springer International Publishing Switzerland, 2015.

BLEIDORN, Michel Trarbach; SCHMIDT , Isamara Maria; REIS, José Antonio Tosta; PANI, Deysilara Figueira; PINTO, Wanderson de Paula; SOLCI, Carlo Corrêa; MENDONÇA ,Antônio Sergio Ferreira & Gutemberg Hespanha Brasil. **Investigation of using missing data imputation methodologies effect on the SARIMA model performance: application to average monthly flows.** São Paulo – SO, 2024.

BLEIDORN, Michel Trarbach; SCHMIDT , Isamara Maria; REIS, José Antonio Tosta dos; MENDONÇA, Antônio Sérgio Ferreira; PINTO, Wanderson de Paula; BRASIL , Gutemberg Hespanha. **Use of singular spectral analysis to reconstruct average monthly flow time series with complex behavior.** Vitória – ES, 2023.

BRETAN, Bruno Melo. **Tese Doutoral: Sistemas de Abastecimento de Água inteligentes: Previsão de demanda e controle ótimo em tempo real.** Campinas – SP, 2017.

CARMO, Rogério Pereira da Silva. **Maximizando a Eficiência Energética Um Guia para um Futuro Sustentável** (Portuguese Edition) (p. 22), 2023. Edição do Kindle.

CHAVES, Victor. Modelagem Hidráulica de Sistemas de Abastecimento de Água. ZIGUARAT INTITUTE OF TECHNOLOGY – 2023.

CHECI, Leonardo & BAYER, Fábio M. **Modelos univariados de séries temporais para previsão das temperaturas médias mensais de Erechim, RS.** Santa Maria – RS, 2012.

FEIL, Alexandre André; HAETINGER, Claus. **Mathematical model for estimating water consumption.** Fenasan, São Paulo – SO, 2013.

FREITAS NETO, Francisco Paula de. **Business Intelligence aplicada no apoio à tomada de decisões em segurança pública.** Mossoró, Universidade Federal Rural do Semi-Árido, 2014.

GRACHTEN, Eduardo. **A contribuição dos sistemas de automação na melhoria do desempenho de empresas de saneamento.** Publicação na web, 2015.

HERMOSSILA, José Luis Garcia; SALLES, Cristiano; SILVA, Ethel Cristina Chiari da. **A influência da informação (Telemetria) na gestão de frota:** um estudo de caso em

uma empresa de transportes de médio porte do interior do estado de São Paulo. João Pessoa, 2016.

(Illukkumbura, Anusha. **Introduction to Time Series Analysis** (Easy Statistics), 2021). anushabooks.com. Edição do Kindle.)

IMAMURA, Célia Sayuri; GOMES, Fabrício Maciel. **Obtenção de Modelos Matemáticos por Programação Genética**. São Paulo - SP, 2018

MARGARIDO, Mario Antônio. **MODELOS DE SÉRIES TEMPORAIS: Uma introdução com aplicações práticas**. São Paulo – SP, 2020.

KUSTERS, Daniel. **Análise Preditiva e Previsão de Demanda**. Editora Senac São Paulo – SP, 2023.

MACAÚBAS, Flávio. **Seasonal ARIMA**. Paraíba – PB, 2022.  
<https://www.linkedin.com/pulse/seasonal-arima-sarima-fl%C3%A1vio-maca%C3%BAbas> Acesso em 15/10/2024.

MARQUES, Marcelo Giulian. **Eficiência energética e hidráulica em saneamento**. Instituto de Pesquisas Hidráulicas – UFRGS, 2016.

McDOWALL, David; McCLEARY, Richard; BARTOS, Bradley J. **Interrupted Time Series Analysis**. Oxford University Press, 2019).

NOVARINI, Bernardo; BRETN, Bruno Melo; MEIRELLES, Gustavo; and Edevar LUVIZOTTO JUNIOR, Edevar. **Optimal pressure management in water distribution networks through district-metered area creation based on machine learning**. Porto Alegre, 2019.

Pimentel Gomes, Heber; Sampaio Gomes, Airton; Andrade Filho, Luis Simão; Menezes Salvino, Moisés; Cramer de Otero, Osvaldo Luiz; Oliveira de Carvalho, Paulo Sérgio; Soares de Alencar, Ronildo Inácio; Marques Bezerra, Saulo de Tarso; De Paula Coura, Sebastião; Arnaud da Silva, Simplício. **Sistemas de Bombeamento: Eficiência Energética (Abastecimento de Água Livro 4)** - 2012 (Portuguese Edition) (p. 22). Edição do Kindle.

ROCHA VIANNA, Marcos. **Fundamentos de Hidráulica - Volume 1**: condutos forçados (Portuguese Edition, 2021) (pp. 69-70). Edição do Kindle.

SANTOS, Tomy Moreira. **Protótipo de um Sistema de Telemetria veicular de baixo custo voltado para esportes a motor**. Universidade Estadual de Londrina, Londrina, 2018.

SCHWAB, Klaus. **A quarta revolução industrial**. São Paulo, Edipro, 2016.

SILVA, Carla Silva da. **Tese Doutoral: Previsão multivariada da demanda horária de água em sistemas urbanos de abastecimento**. Campinas – SP, 2003.

SILVA, Jorge Xavier. **Geoprocessamento e Análise Ambiental**. Rio de Janeiro, 2009.

Sistema Nacional de Informações sobre o Saneamento – **Relatório 2022**; Ministério das Cidades. Brasília – DF; 2024.

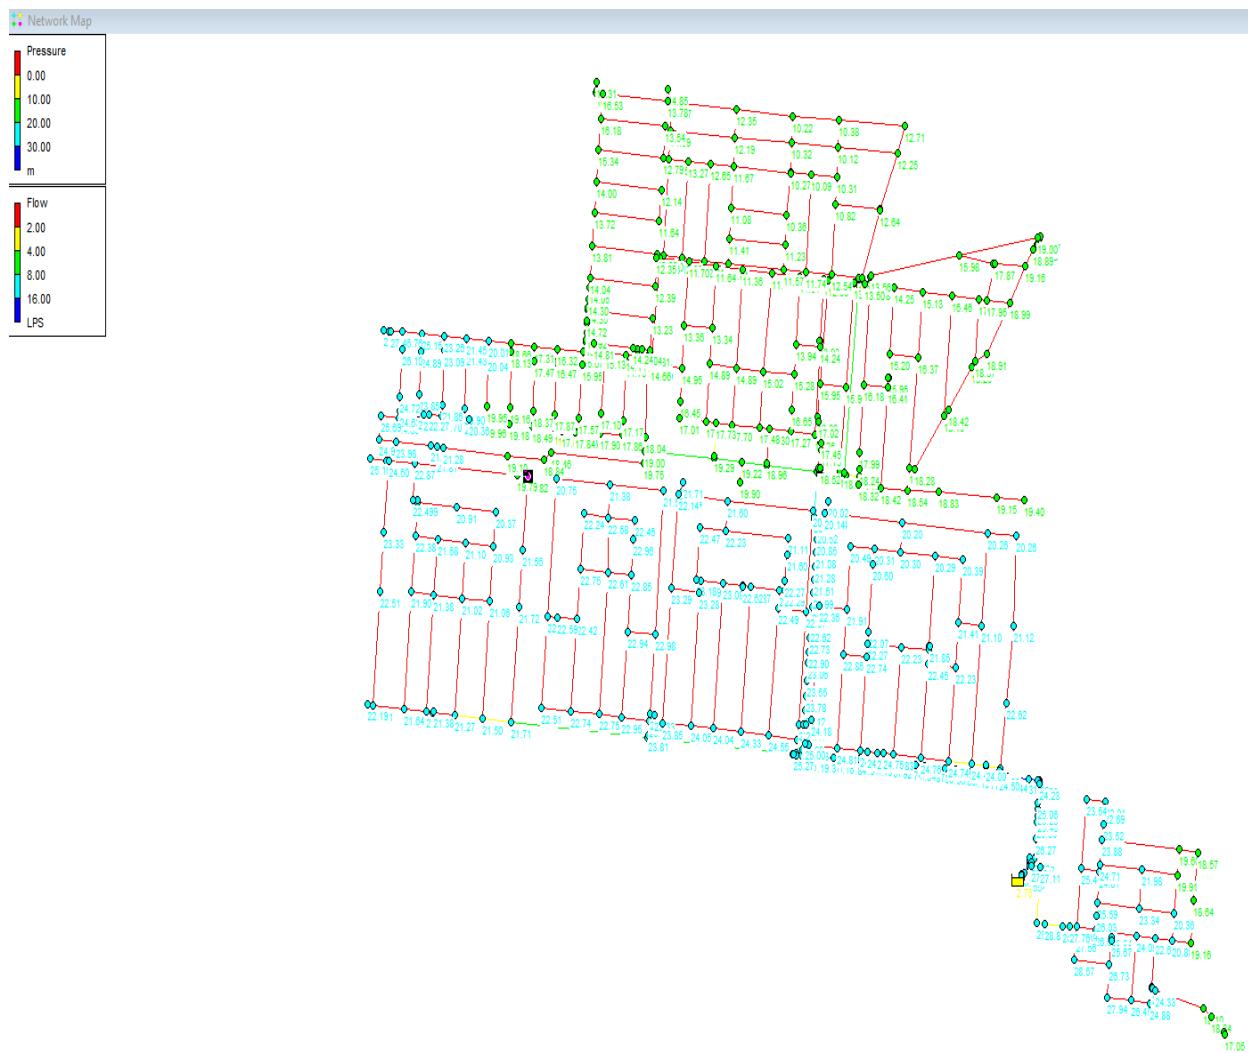
SOBRINHO, Renavan Andrade; BORJA, Patrícia Campos. **Management of water and energy losses in Embasa water supply systems: a study of factors involved in RMS**. Salvador – BA, 2016.

STEVAN JÚNIOR., Sérgio Luiz; LEME, Murilo Oliveira; SANTOS, Max Mauro Dias. **Indústria 4.0: Fundamentos, perspectivas e aplicações**. São Paulo, Érica, 2018.

<<<https://alfacomp.net/2015/10/26/a-contribuicao-dos-sistemas-de-automacao-na-melhoria-do-desempenho-de-empresas-saneamento/>>> (Acesso em 22/09/2024)

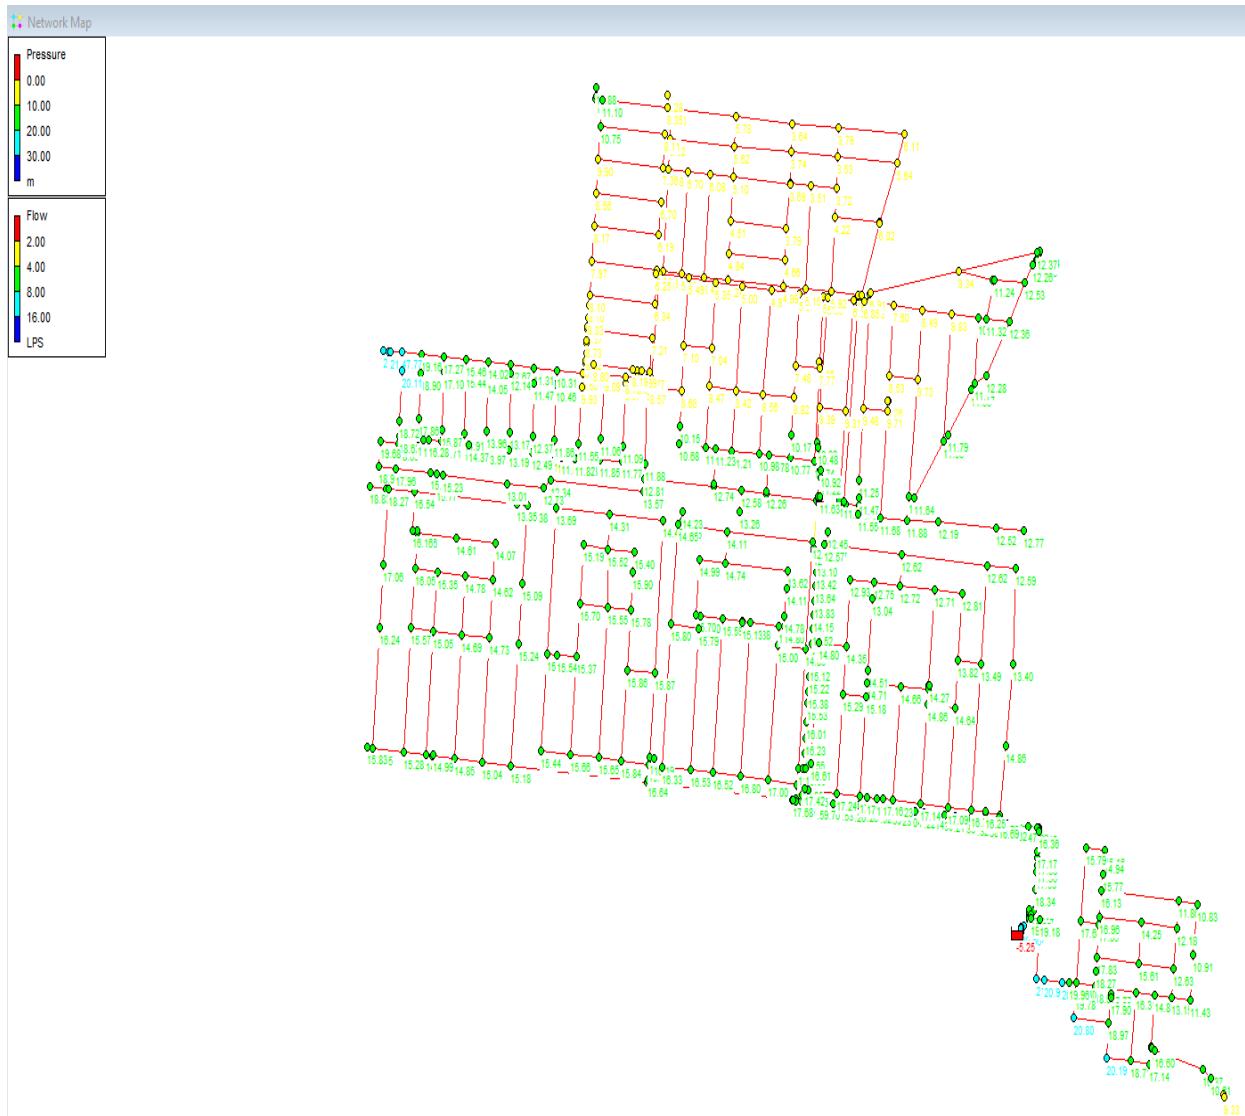
## APÊNDICES

### A. Distribuição de Pressão e Vazão – 12:00h



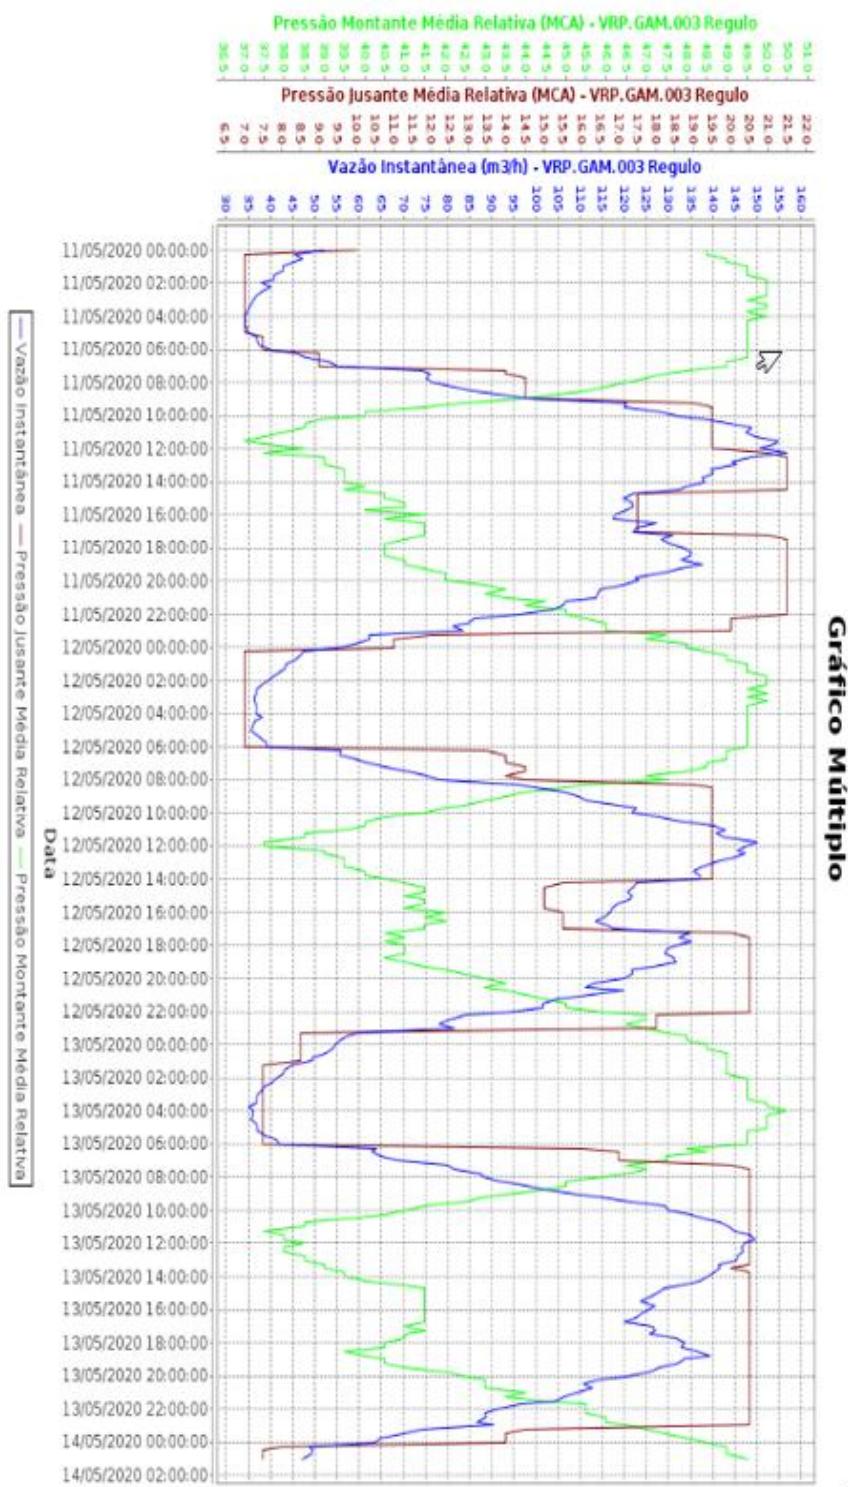
Fonte: Acervo Técnico – Dados de Simulação Hidráulica Software Epanet.

## B. Distribuição de Pressão e Vazão – 03:00h



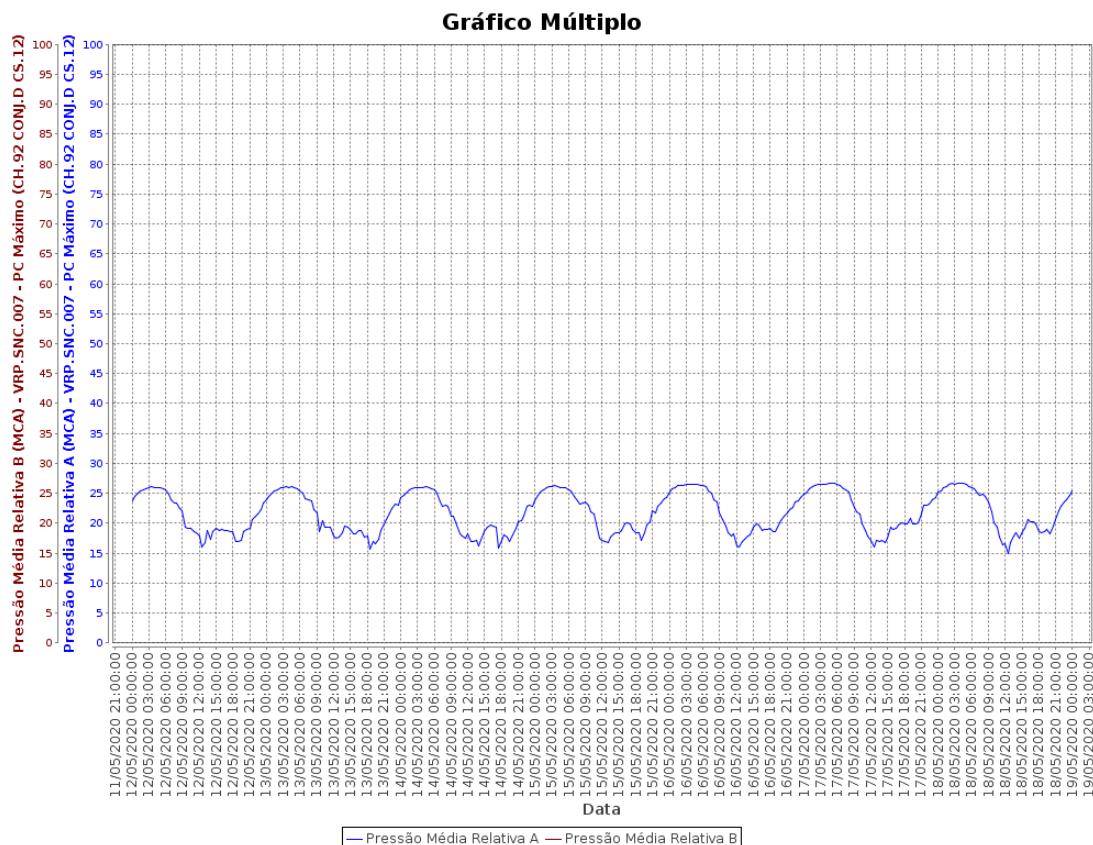
Fonte: Acervo Técnico – Dados de Simulação Hidráulica Software Epanet.

### C. Gráfico de dados hidrodinâmicos de uma rede de abastecimento



Fonte: Sistema de Telemetria – Projeto de Automação Industrial.

D. Gráfico de dados hidrodinâmicos de uma rede de abastecimento



Fonte: Sistema de Telemetria Projeto de Automação Industrial.

## E. Região geográfica do estudo



Fonte: Acervo Técnico Base de Geoprocessamento.

## F. Script das análises de consumo per capita

```
<<install.packages("readxl")>>

library('readxl')

Dados_Consumo <-
read_excel("C:/Users/user/Documents/Dissertação_Mestrado/Análise de
Dados/Tratamento e Modelagem/Consumo Autorizado (mensal).xlsx")

print(Dados_Consumo)

str(Dados_Consumo)

ConsumoÁgua <- as.vector(t(Dados_Consumo))

print(ConsumoÁgua)

Serie <- ts(ConsumoÁgua, start = c(2017,1), end = c(2024,12), frequency=12)

print(Serie)

plot(Serie)

##### Média Móvel #####
library("forecast")

Media_Movel <- ma(Serie, order = 7, centre = TRUE)

plot(Media_Movel)

print(Media_Movel)

plot(Serie, xlab = "Tempo (meses)", col = "blue")

lines(Media_Movel, col="red")

### NORMALIDADE

qqnorm(Serie)

qqline(Serie)

# Ho = distribuição normal : p > 0.05

# Ha = distribuição != normal : p <= 0.05

shapiro.test(Serie)

#### ESTACIONARIDADE

library("urca")
```

```

# Teste pp (Philips-Perron)

# Ho = é estacionária: p > 0.05

# Ha = não é estacionária: p <= 0.05

estacionaridade <- ur.pp(Serie)

summary(estacionaridade)

##### AUTOCORRELAÇÃO

acf(Serie)

pacf(Serie)

tsdisplay(Serie)

# Teste de Autocorrelação (Ljung-Box)

# Ho = não é autocorrelacionado: p > 0.05

# Ha = é autocorrelacionado: p <= 0.05

Box.test(Serie, type = "Ljung-Box")

### DECOMPOSIÇÃO

decomposicao <- decompose(Serie)

plot(decomposicao, col = "brown")

#efecto sazonal por ano

ggseasonplot(window(Serie, start=c(2017), end=2024))

### AUTOARIMA

library("forecast")

Modelo_AUTO <- auto.arima(Serie, trace = T, stepwise = F, approximation = F,
max.p = 5, max.q = 5, max.P = 2, max.Q = 2)

# Trace: apresenta no console a lista dos modelos.

# stepwise: seleção gradual(processo mais rápido, porém menos minucioso)

# approximation: seleção do melhor modelo por aproximação

#      (indicado para séries muito longas, diminui tempo computacional)

```

```

# Drift do modelo é um parâmetro que representa a tendência temporal num passeio aleatório.

# Interessante dobrar as ordens máximas: max.p = 10, max.q = 10, max.P = 4, max.Q = 4

### Best model: ARIMA(0,1,2)(1,0,0)[12]

summary(Modelo_AUTO)

# Análise dos resíduos (qualidade do modelo)

checkresiduals(Modelo_AUTO)

plot(resid(Modelo_AUTO))

qqnorm(resid(Modelo_AUTO))

qqline(resid(Modelo_AUTO))

# Ho = distribuição normal : p > 0.05

# Ha = distribuição != normal : p <= 0.05

shapiro.test(resid(Modelo_AUTO))

acf(resid(Modelo_AUTO))

pacf(resid(Modelo_AUTO))

plot(Serie)

lines(Serie-Modelo_AUTO$resid, col= "red")

Previsao <- forecast(Modelo_AUTO,h=12)

plot(Previsao)

lines(Serie-Modelo_AUTO$resid, col= "red")

print(Previsao)

```

## G. Script das análises de consumo mensal (m<sup>3</sup>)

```
> library('readxl')
```

Mensagem de aviso:

pacote 'readxl' foi compilado no R versão 4.4.3

```
>
```

```
> Dados_Consumo <- read_excel("C:/Users/user/Documents/Dissertação_Mestrado/Análise de Modelagem/Consumo Autorizado (mensal).xlsx")
```

```
>
```

```
> print(Dados_Consumo)
```

```
# A tibble: 8 × 12
```

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
--	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----	-----

```
<dbl> <dbl>
```

```
1 36702 34523 36854 37703 36906 37818 35506 39239 39503 37317 34030 36091
```

```
2 36396 36279 35908 37237 37129 36579 37770 40023 39611 41950 36859 38302
```

```
3 39320 39971 39157 39651 39166 38793 38131 41142 43604 44042 41774 40521
```

```
4 39626 38022 39613 41009 39877 39428 41055 41208 44946 42240 37878 43895
```

```
5 40104 37155 40400 40154 39016 40179 39001 39875 46438 40171 38420 42291
```

```
6 38820 38850 43766 41903 40327 41560 39917 43672 51983 42746 42464 40187
```

```
7 38759 40076 41887 39907 40078 42171 40228 43744 42619 44909 45103 44042
```

```
8 41661 40202 41662 42871 45400 43287 43474 43903 46387 45772 40678 43099
```

```
>
```

```
> str(Dados_Consumo)
```

```
tibble [8 × 12] (S3: tbl_df/tbl/data.frame)
```

```
$ Jan: num [1:8] 36702 36396 39320 39626 40104 ...
```

```
$ Fev: num [1:8] 34523 36279 39971 38022 37155 ...
```

```
$ Mar: num [1:8] 36854 35908 39157 39613 40400 ...
```

```

$ Abr: num [1:8] 37703 37237 39651 41009 40154 ...
$ Mai: num [1:8] 36906 37129 39166 39877 39016 ...
$ Jun: num [1:8] 37818 36579 38793 39428 40179 ...
$ Jul: num [1:8] 35506 37770 38131 41055 39001 ...
$ Ago: num [1:8] 39239 40023 41142 41208 39875 ...
$ Set: num [1:8] 39503 39611 43604 44946 46438 ...
$ Out: num [1:8] 37317 41950 44042 42240 40171 ...
$ Nov: num [1:8] 34030 36859 41774 37878 38420 ...
$ Dez: num [1:8] 36091 38302 40521 43895 42291 ...

>
>
> ConsumoÁgua <- as.vector(t(Dados_Consumo))
> print(ConsumoÁgua)
[1] 36702 34523 36854 37703 36906 37818 35506 39239 39503 37317 34030 36091
[13] 36396 36279 35908 37237 37129 36579 37770 40023 39611 41950 36859 38302
[25] 39320 39971 39157 39651 39166 38793 38131 41142 43604 44042 41774 40521
[37] 39626 38022 39613 41009 39877 39428 41055 41208 44946 42240 37878 43895
[49] 40104 37155 40400 40154 39016 40179 39001 39875 46438 40171 38420 42291
[61] 38820 38850 43766 41903 40327 41560 39917 43672 51983 42746 42464 40187
[73] 38759 40076 41887 39907 40078 42171 40228 43744 42619 44909 45103 44042
[85] 41661 40202 41662 42871 45400 43287 43474 43903 46387 45772 40678 43099
>
> Serie <- ts(ConsumoÁgua, start = c(2017,1), end = c(2024,12), frequency=12)
> print(Serie)

      Jan  Feb  Mar  Apr  May  Jun  Jul  Aug  Sep  Oct  Nov  Dec
2017 36702 34523 36854 37703 36906 37818 35506 39239 39503 37317 34030 36091

```

```
2018 36396 36279 35908 37237 37129 36579 37770 40023 39611 41950 36859 38302  
2019 39320 39971 39157 39651 39166 38793 38131 41142 43604 44042 41774 40521  
2020 39626 38022 39613 41009 39877 39428 41055 41208 44946 42240 37878 43895  
2021 40104 37155 40400 40154 39016 40179 39001 39875 46438 40171 38420 42291  
2022 38820 38850 43766 41903 40327 41560 39917 43672 51983 42746 42464 40187  
2023 38759 40076 41887 39907 40078 42171 40228 43744 42619 44909 45103 44042  
2024 41661 40202 41662 42871 45400 43287 43474 43903 46387 45772 40678 43099
```

```
> plot(Serie)
```

```
>
```

```
> ##### Média Móvel #####
```

```
> library("forecast")
```

Registered S3 method overwritten by 'quantmod':

```
method      from  
as.zoo.data.frame zoo
```

Mensagem de aviso:

pacote ‘forecast’ foi compilado no R versão 4.4.3

```
> Media_Movel <- ma(Serie, order = 7, centre = TRUE)  
> plot(Media_Movel)  
> print(Media_Movel)
```

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug
2017	NA	NA	NA	36573.14	36935.57	37647.00	37713.14	37188.43
2018	36179.71	36152.86	36517.00	36756.86	37275.00	37751.00	38614.14	38560.14
2019	39315.71	38918.00	39194.29	39169.86	39430.14	39949.14	40647.00	40950.29
2020	40658.14	40063.14	39728.00	39804.29	40030.29	41019.43	41394.71	40947.43
2021	40260.86	39800.29	40129.00	39429.86	39397.14	40723.29	40690.57	40442.86
2022	40603.00	40625.29	41073.86	40734.71	41427.86	43304.00	43158.29	43238.43

	Sep	Oct	Nov	Dec
2017	37072.00	36868.86	36979.29	36503.43
2018	38727.71	39119.29	39433.71	39310.00
2019	41143.86	41262.86	41247.29	41028.86
2020	41521.43	41618.00	41060.86	40945.43
2021	40910.71	40716.57	40695.00	41250.86
2022	43218.43	42818.29	42841.00	42586.00
2023	43259.43	43186.57	43182.86	42885.43
2024	43800.00	NA	NA	NA

```

> plot(Serie, xlab = "Tempo (meses)", col = "blue")
> lines(Media_Movel, col="red")
>
> ### NORMALIDADE
> qqnorm(Serie)
> qqline(Serie)
> # H0 = distribuição normal : p > 0.05
> # Ha = distribuição != normal : p <= 0.05
> shapiro.test(Serie)
```

### Shapiro-Wilk normality test

```

data: Serie
W = 0.97245, p-value = 0.04061
```

```
>  
> ##### ESTACIONARIDADE  
> library("urca")
```

Mensagem de aviso:

pacote 'urca' foi compilado no R versão 4.4.3

```
> # Teste pp (Philips-Perron)  
> # Ho = é estacionária: p > 0.05  
> # Ha = não é estacionária: p <= 0.05  
> estacionaridade <- ur.pp(Serie)  
> summary(estacionaridade)
```

```
#####
```

```
# Phillips-Perron Unit Root Test #
```

```
#####
```

Test regression with intercept

Call:

```
lm(formula = y ~ y.l1)
```

Residuals:

Min	1Q	Median	3Q	Max
-4616	-1360	-426	1457	9566

Coefficients:

```

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

(Intercept) 1.643e+04 3.355e+03 4.898 4.08e-06 ***
y.l1      5.950e-01 8.280e-02 7.186 1.64e-10 ***
---
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

```

Residual standard error: 2387 on 93 degrees of freedom

Multiple R-squared: 0.357,      Adjusted R-squared: 0.3501

F-statistic: 51.64 on 1 and 93 DF, p-value: 1.636e-10

Value of test-statistic, type: Z-alpha is: -35.7503

```

aux. Z statistics

Z-tau-mu      4.7679

>
>
> ##### AUTOCORRELAÇÃO
> acf(Serie)
> pacf(Serie)
> tsdisplay(Serie)
>
> # Teste de Autocorrelação (Ljung-Box)
> # Ho = não é autocorrelacionado: p > 0.05
> # Ha = é autocorrelacionado: p <= 0.05

```

```
> Box.test(Serie, type = "Ljung-Box")
```

Box-Ljung test

data: Serie

X-squared = 34.45, df = 1, p-value = 4.374e-09

```
>
```

```
>
```

```
> ### DECOMPOSIÇÃO
```

```
> decomposicao <- decompose(Serie)
```

```
> plot(decomposicao, col = "brown")
```

```
>
```

```
>
```

```
> #efecto sazonal por ano
```

```
> ggseasonplot(window(Serie, start=c(2017), end=2024))
```

```
>
```

```
>
```

```
>
```

```
> ### SARIMA_OTM
```

```
> library("forecast")
```

```
>
```

```
> SARIMA_OTM <- auto.arima(Serie, trace = T, stepwise = F, approximation = F,
+                               max.p = 5, max.q = 5, max.P = 2, max.Q = 2)
```

ARIMA(0,1,0) : 1769.231

ARIMA(0,1,0)	with drift	: 1771.257
ARIMA(0,1,0)(0,0,1)[12]		: 1754.689
ARIMA(0,1,0)(0,0,1)[12] with drift		: 1756.805
ARIMA(0,1,0)(0,0,2)[12]		: 1755.663
ARIMA(0,1,0)(0,0,2)[12] with drift		: 1757.828
ARIMA(0,1,0)(1,0,0)[12]		: 1753.065
ARIMA(0,1,0)(1,0,0)[12] with drift		: 1755.182
ARIMA(0,1,0)(1,0,1)[12]		: 1755.172
ARIMA(0,1,0)(1,0,1)[12] with drift		: 1757.338
ARIMA(0,1,0)(1,0,2)[12]		: Inf
ARIMA(0,1,0)(1,0,2)[12] with drift		: Inf
ARIMA(0,1,0)(2,0,0)[12]		: 1755.185
ARIMA(0,1,0)(2,0,0)[12] with drift		: 1757.35
ARIMA(0,1,0)(2,0,1)[12]		: 1757.222
ARIMA(0,1,0)(2,0,1)[12] with drift		: 1759.437
ARIMA(0,1,0)(2,0,2)[12]		: Inf
ARIMA(0,1,0)(2,0,2)[12] with drift		: Inf
ARIMA(0,1,1)		: 1745.036
ARIMA(0,1,1)	with drift	: Inf
ARIMA(0,1,1)(0,0,1)[12]		: 1729.752
ARIMA(0,1,1)(0,0,1)[12] with drift		: Inf
ARIMA(0,1,1)(0,0,2)[12]		: 1728.59
ARIMA(0,1,1)(0,0,2)[12] with drift		: Inf
ARIMA(0,1,1)(1,0,0)[12]		: 1723.868
ARIMA(0,1,1)(1,0,0)[12] with drift		: Inf
ARIMA(0,1,1)(1,0,1)[12]		: Inf

ARIMA(0,1,1)(1,0,1)[12] with drift : Inf  
ARIMA(0,1,1)(1,0,2)[12] : Inf  
ARIMA(0,1,1)(1,0,2)[12] with drift : Inf  
ARIMA(0,1,1)(2,0,0)[12] : 1724.166  
ARIMA(0,1,1)(2,0,0)[12] with drift : Inf  
ARIMA(0,1,1)(2,0,1)[12] : Inf  
ARIMA(0,1,1)(2,0,1)[12] with drift : Inf  
ARIMA(0,1,1)(2,0,2)[12] : Inf  
ARIMA(0,1,1)(2,0,2)[12] with drift : Inf  
ARIMA(0,1,2) : 1739.953  
ARIMA(0,1,2) with drift : Inf  
ARIMA(0,1,2)(0,0,1)[12] : 1725.826  
ARIMA(0,1,2)(0,0,1)[12] with drift : Inf  
ARIMA(0,1,2)(0,0,2)[12] : 1725.917  
ARIMA(0,1,2)(0,0,2)[12] with drift : Inf  
ARIMA(0,1,2)(1,0,0)[12] : 1721.943  
ARIMA(0,1,2)(1,0,0)[12] with drift : Inf  
ARIMA(0,1,2)(1,0,1)[12] : Inf  
ARIMA(0,1,2)(1,0,1)[12] with drift : Inf  
ARIMA(0,1,2)(1,0,2)[12] : Inf  
ARIMA(0,1,2)(1,0,2)[12] with drift : Inf  
ARIMA(0,1,2)(2,0,0)[12] : 1723.475  
ARIMA(0,1,2)(2,0,0)[12] with drift : Inf  
ARIMA(0,1,2)(2,0,1)[12] : Inf  
ARIMA(0,1,2)(2,0,1)[12] with drift : Inf  
ARIMA(0,1,3) : 1740.701

ARIMA(0,1,3)	with drift	: Inf
ARIMA(0,1,3)(0,0,1)[12]		: 1727.756
ARIMA(0,1,3)(0,0,1)[12] with drift		: Inf
ARIMA(0,1,3)(0,0,2)[12]		: 1727.991
ARIMA(0,1,3)(0,0,2)[12] with drift		: Inf
ARIMA(0,1,3)(1,0,0)[12]		: 1724.015
ARIMA(0,1,3)(1,0,0)[12] with drift		: Inf
ARIMA(0,1,3)(1,0,1)[12]		: Inf
ARIMA(0,1,3)(1,0,1)[12] with drift		: Inf
ARIMA(0,1,3)(2,0,0)[12]		: 1725.535
ARIMA(0,1,3)(2,0,0)[12] with drift		: Inf
ARIMA(0,1,4)		: 1742.257
ARIMA(0,1,4)	with drift	: Inf
ARIMA(0,1,4)(0,0,1)[12]		: 1729.526
ARIMA(0,1,4)(0,0,1)[12] with drift		: Inf
ARIMA(0,1,4)(1,0,0)[12]		: 1725.537
ARIMA(0,1,4)(1,0,0)[12] with drift		: Inf
ARIMA(0,1,5)		: 1743.566
ARIMA(0,1,5)	with drift	: Inf
ARIMA(1,1,0)		: 1762.364
ARIMA(1,1,0)	with drift	: 1764.384
ARIMA(1,1,0)(0,0,1)[12]		: 1746.43
ARIMA(1,1,0)(0,0,1)[12] with drift		: 1748.58
ARIMA(1,1,0)(0,0,2)[12]		: 1746.148
ARIMA(1,1,0)(0,0,2)[12] with drift		: 1748.35
ARIMA(1,1,0)(1,0,0)[12]		: 1742.042

ARIMA(1,1,0)(1,0,0)[12] with drift : 1744.201  
ARIMA(1,1,0)(1,0,1)[12] : Inf  
ARIMA(1,1,0)(1,0,1)[12] with drift : Inf  
ARIMA(1,1,0)(1,0,2)[12] : Inf  
ARIMA(1,1,0)(1,0,2)[12] with drift : Inf  
ARIMA(1,1,0)(2,0,0)[12] : 1743.77  
ARIMA(1,1,0)(2,0,0)[12] with drift : 1745.975  
ARIMA(1,1,0)(2,0,1)[12] : Inf  
ARIMA(1,1,0)(2,0,1)[12] with drift : Inf  
ARIMA(1,1,0)(2,0,2)[12] : Inf  
ARIMA(1,1,0)(2,0,2)[12] with drift : Inf  
ARIMA(1,1,1) : 1741.836  
ARIMA(1,1,1) with drift : Inf  
ARIMA(1,1,1)(0,0,1)[12] : 1726.681  
ARIMA(1,1,1)(0,0,1)[12] with drift : Inf  
ARIMA(1,1,1)(0,0,2)[12] : 1726.433  
ARIMA(1,1,1)(0,0,2)[12] with drift : Inf  
ARIMA(1,1,1)(1,0,0)[12] : 1722.27  
ARIMA(1,1,1)(1,0,0)[12] with drift : Inf  
ARIMA(1,1,1)(1,0,1)[12] : Inf  
ARIMA(1,1,1)(1,0,1)[12] with drift : Inf  
ARIMA(1,1,1)(1,0,2)[12] : Inf  
ARIMA(1,1,1)(1,0,2)[12] with drift : Inf  
ARIMA(1,1,1)(2,0,0)[12] : 1723.718  
ARIMA(1,1,1)(2,0,0)[12] with drift : Inf  
ARIMA(1,1,1)(2,0,1)[12] : Inf

ARIMA(1,1,1)(2,0,1)[12] with drift	: Inf
ARIMA(1,1,2)	: 1740.273
ARIMA(1,1,2) with drift	: Inf
ARIMA(1,1,2)(0,0,1)[12]	: 1727.466
ARIMA(1,1,2)(0,0,1)[12] with drift	: Inf
ARIMA(1,1,2)(0,0,2)[12]	: 1727.548
ARIMA(1,1,2)(0,0,2)[12] with drift	: Inf
ARIMA(1,1,2)(1,0,0)[12]	: 1723.347
ARIMA(1,1,2)(1,0,0)[12] with drift	: Inf
ARIMA(1,1,2)(1,0,1)[12]	: Inf
ARIMA(1,1,2)(1,0,1)[12] with drift	: Inf
ARIMA(1,1,2)(2,0,0)[12]	: 1724.315
ARIMA(1,1,2)(2,0,0)[12] with drift	: Inf
ARIMA(1,1,3)	: 1742.502
ARIMA(1,1,3) with drift	: Inf
ARIMA(1,1,3)(0,0,1)[12]	: Inf
ARIMA(1,1,3)(0,0,1)[12] with drift	: Inf
ARIMA(1,1,3)(1,0,0)[12]	: Inf
ARIMA(1,1,3)(1,0,0)[12] with drift	: Inf
ARIMA(1,1,4)	: 1744.43
ARIMA(1,1,4) with drift	: Inf
ARIMA(2,1,0)	: 1749.99
ARIMA(2,1,0) with drift	: 1751.873
ARIMA(2,1,0)(0,0,1)[12]	: 1737.637
ARIMA(2,1,0)(0,0,1)[12] with drift	: 1739.766
ARIMA(2,1,0)(0,0,2)[12]	: 1737.972

ARIMA(2,1,0)(0,0,2)[12] with drift	:	1740.164
ARIMA(2,1,0)(1,0,0)[12]	:	1733.789
ARIMA(2,1,0)(1,0,0)[12] with drift	:	1735.952
ARIMA(2,1,0)(1,0,1)[12]	:	Inf
ARIMA(2,1,0)(1,0,1)[12] with drift	:	Inf
ARIMA(2,1,0)(1,0,2)[12]	:	Inf
ARIMA(2,1,0)(1,0,2)[12] with drift	:	Inf
ARIMA(2,1,0)(2,0,0)[12]	:	1734.88
ARIMA(2,1,0)(2,0,0)[12] with drift	:	1737.086
ARIMA(2,1,0)(2,0,1)[12]	:	Inf
ARIMA(2,1,0)(2,0,1)[12] with drift	:	Inf
ARIMA(2,1,1)	:	1742.881
ARIMA(2,1,1) with drift	:	Inf
ARIMA(2,1,1)(0,0,1)[12]	:	1728.422
ARIMA(2,1,1)(0,0,1)[12] with drift	:	Inf
ARIMA(2,1,1)(0,0,2)[12]	:	1728.453
ARIMA(2,1,1)(0,0,2)[12] with drift	:	Inf
ARIMA(2,1,1)(1,0,0)[12]	:	1724.373
ARIMA(2,1,1)(1,0,0)[12] with drift	:	Inf
ARIMA(2,1,1)(1,0,1)[12]	:	Inf
ARIMA(2,1,1)(1,0,1)[12] with drift	:	Inf
ARIMA(2,1,1)(2,0,0)[12]	:	1725.916
ARIMA(2,1,1)(2,0,0)[12] with drift	:	Inf
ARIMA(2,1,2)	:	1742.501
ARIMA(2,1,2) with drift	:	Inf
ARIMA(2,1,2)(0,0,1)[12]	:	1728.977

ARIMA(2,1,2)(0,0,1)[12] with drift : Inf  
ARIMA(2,1,2)(1,0,0)[12] : Inf  
ARIMA(2,1,2)(1,0,0)[12] with drift : Inf  
ARIMA(2,1,3) : Inf  
ARIMA(2,1,3) with drift : Inf  
ARIMA(3,1,0) : 1752.135  
ARIMA(3,1,0) with drift : 1754.051  
ARIMA(3,1,0)(0,0,1)[12] : 1738.672  
ARIMA(3,1,0)(0,0,1)[12] with drift : 1740.815  
ARIMA(3,1,0)(0,0,2)[12] : 1739.076  
ARIMA(3,1,0)(0,0,2)[12] with drift : 1741.297  
ARIMA(3,1,0)(1,0,0)[12] : 1734.906  
ARIMA(3,1,0)(1,0,0)[12] with drift : 1737.098  
ARIMA(3,1,0)(1,0,1)[12] : Inf  
ARIMA(3,1,0)(1,0,1)[12] with drift : Inf  
ARIMA(3,1,0)(2,0,0)[12] : 1736.489  
ARIMA(3,1,0)(2,0,0)[12] with drift : 1738.733  
ARIMA(3,1,1) : 1744.048  
ARIMA(3,1,1) with drift : Inf  
ARIMA(3,1,1)(0,0,1)[12] : 1730.3  
ARIMA(3,1,1)(0,0,1)[12] with drift : Inf  
ARIMA(3,1,1)(1,0,0)[12] : 1726.248  
ARIMA(3,1,1)(1,0,0)[12] with drift : Inf  
ARIMA(3,1,2) : 1744.141  
ARIMA(3,1,2) with drift : Inf  
ARIMA(4,1,0) : 1746.027

```

ARIMA(4,1,0)      with drift      : 1747.689
ARIMA(4,1,0)(0,0,1)[12]           : 1732.719
ARIMA(4,1,0)(0,0,1)[12] with drift : 1734.74
ARIMA(4,1,0)(1,0,0)[12]           : 1727.776
ARIMA(4,1,0)(1,0,0)[12] with drift : 1729.926
ARIMA(4,1,1)                  : 1741.355
ARIMA(4,1,1)      with drift     : Inf
ARIMA(5,1,0)                  : 1744.203
ARIMA(5,1,0)      with drift     : 1745.592

```

Best model: ARIMA(0,1,2)(1,0,0)[12]

```

>
> # Trace: apresenta no console a lista dos modelos.
> # stepwise: seleção gradual(processo mais rápido, porém menos minucioso)
> # approximation: seleção do melhor modelo por aproximação
> #      (indicado para séries muito longas, diminui tempo computacional)
> # Drift do modelo é um parâmetro que representa a tendência temporal num passeio aleatório
> # Interessante dobrar as ordens máximas: max.p = 10, max.q = 10, max.P = 4, max.Q = 4
>
> #### Best model: ARIMA(0,1,2)(1,0,0)[12]
>
> summary(SARIMA_OTM)
Series: Serie

```

ARIMA(0,1,2)(1,0,0)[12]

Coefficients:

ma1	ma2	sar1
-0.6331	-0.2217	0.4532
s.e.	0.1085	0.1083
	0.0918	

sigma^2 = 3960280: log likelihood = -856.75

AIC=1721.5 AICc=1721.94 BIC=1731.71

Training set error measures:

ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Training set	285.7339	1948.145	1458.562	0.5246489	3.52805	0.7574229
>						-0.03567054
>						
> # Análise dos resíduos (qualidade do modelo)						
> checkresiduals(SARIMA_OTM)						

Ljung-Box test

data: Residuals from ARIMA(0,1,2)(1,0,0)[12]

Q\* = 28.057, df = 16, p-value = 0.03113

Model df: 3. Total lags used: 19

>

```
> plot(resid(SARIMA_OTM))

>

> qqnorm(resid(SARIMA_OTM))

> qqline(resid(SARIMA_OTM))

>

> # H0 = distribuição normal : p > 0.05

> # Ha = distribuição != normal : p <= 0.05

> shapiro.test(resid(SARIMA_OTM))
```

### Shapiro-Wilk normality test

```
data: resid(SARIMA_OTM)
W = 0.97839, p-value = 0.1138
```

```
>

> acf(resid(SARIMA_OTM))

> pacf(resid(SARIMA_OTM))

>

> plot(Serie)

> lines(Serie-SARIMA_OTM$resid, col= "red")

>

> Previsao <- forecast(SARIMA_OTM,h=12)

> plot(Previsao)

> lines(Serie-SARIMA_OTM$resid, col= "red")

>

> print(Previsao)
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2025	42868.37	40318.02	45418.72	38967.95	46768.79
Feb 2025	42165.61	39449.05	44882.18	38010.98	46320.25
Mar 2025	42827.27	40085.58	45568.97	38634.21	47020.33
Apr 2025	43375.18	40608.59	46141.78	39144.05	47606.32
May 2025	44521.30	41730.04	47312.57	40252.43	48790.18
Jun 2025	43563.71	40747.98	46379.44	39257.43	47869.99
Jul 2025	43648.46	40808.48	46488.43	39305.09	47991.83
Aug 2025	43842.88	40978.86	46706.90	39462.74	48223.02
Sep 2025	44968.61	42080.74	47856.47	40552.00	49385.21
Oct 2025	44689.89	41778.38	47601.40	40237.12	49142.67
Nov 2025	42381.33	39446.36	45316.30	37892.68	46869.98
Dec 2025	43478.51	40520.27	46436.75	38954.27	48002.75
> Previsao <- forecast(SARIMA_OTM,h=24)					
> plot(Previsao)					
> Previsao <- forecast(SARIMA_OTM,h=24)					
> plot(Previsao)					
> print(Previsao)					

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 2025	42868.37	40318.02	45418.72	38967.95	46768.79
Feb 2025	42165.61	39449.05	44882.18	38010.98	46320.25
Mar 2025	42827.27	40085.58	45568.97	38634.21	47020.33
Apr 2025	43375.18	40608.59	46141.78	39144.05	47606.32
May 2025	44521.30	41730.04	47312.57	40252.43	48790.18
Jun 2025	43563.71	40747.98	46379.44	39257.43	47869.99
Jul 2025	43648.46	40808.48	46488.43	39305.09	47991.83

Aug 2025	43842.88	40978.86	46706.90	39462.74	48223.02
Sep 2025	44968.61	42080.74	47856.47	40552.00	49385.21
Oct 2025	44689.89	41778.38	47601.40	40237.12	49142.67
Nov 2025	42381.33	39446.36	45316.30	37892.68	46869.98
Dec 2025	43478.51	40520.27	46436.75	38954.27	48002.75
Jan 2026	43373.99	40045.29	46702.69	38283.18	48464.80
Feb 2026	43055.51	39633.33	46477.68	37821.74	48289.27
Mar 2026	43355.37	39891.13	46819.60	38057.28	48653.45
Apr 2026	43603.67	40097.89	47109.46	38242.04	48965.31
May 2026	44123.09	40576.24	47669.94	38698.65	49547.53
Jun 2026	43689.11	40101.67	47276.56	38202.59	49175.64
Jul 2026	43727.52	40099.93	47355.11	38179.61	49275.43
Aug 2026	43815.63	40148.34	47482.92	38207.00	49424.26
Sep 2026	44325.80	40619.24	48032.36	38657.10	49994.50
Oct 2026	44199.49	40454.06	47944.92	38471.35	49927.63
Nov 2026	43153.27	39369.38	46937.16	37366.30	48940.24
Dec 2026	43650.50	39828.53	47472.47	37805.30	49495.70

>

## H. Script das análises de vazão horária

```
install.packages("readxl")  
library('readxl')  
  
Vazão_Horária <-  
read_excel("C:/Users/user/Documents/Dissertação_Mestrado/Análise de  
Dados/Tratamento e Modelagem/Vazão Horária (Autorizado).xlsx")  
  
print(Vazão_Horária)  
  
print  
  
str(Vazão_Horária)  
  
Vetor_Vazão <- as.vector(t(Vazão_Horária))  
  
print(Vetor_Vazão)  
  
> Série <- ts(Vetor_Vazão, start = c(2023,7), end = c(2024,8), frequency=694)  
  
> print(Série)  
  
Time Series:  
  
Start = c(2023, 7)  
  
End = c(2024, 8)  
  
Frequency = 694  
  
[1] 13.74758871 9.21989527 6.28725407 5.40774498 5.05612222 6.21316790  
11.81049865 18.20873129 21.53615678  
  
[10] 22.79049721 26.20466855 29.46747198 33.15254854 30.16209720  
25.18868151 23.77176189 23.65746768 26.18350910  
  
[19] 28.07225355 30.88234243 31.81839555 30.09675179 26.24324881  
18.62738722 13.25647427 9.10662618 6.86420959  
  
[28] 5.10440777 4.97004004 5.76834976 11.49215136 17.88260760  
21.78144302 22.27008575 26.77879060 28.46269754  
  
[37] 33.49802278 31.34114555 27.57818521 27.40053555 26.29593461  
27.59428059 28.80197813 33.76416626 32.75487061  
  
[46] 30.64007050 25.93689712 18.30415689 14.55536273 9.94442029  
6.61343799 5.40629826 5.44361257 6.36501734
```

[55] 12.19334734 18.81775665 21.50499147 23.54142548 25.83230855  
 29.02590895 33.97979361 31.21190227 28.16472569

[64] 26.62416814 25.30104650 25.83725182 28.17220052 31.69849536  
 31.38050966 28.39994456 25.89421778 17.53026144

[73] 14.33045171 9.65253659 6.50330339 5.47833474 5.17951871 6.14426604  
 11.93220723 18.71690532 21.10423896

[82] 23.16134990 28.25526841 30.62914875 34.19970071 31.35133340  
 25.60504656 25.20025555 24.93519707 26.20738077

[91] 28.21867768 32.18098981 30.65682898 27.67945852 23.64529082  
 17.51573356 14.69238281 10.76262290 7.62526519

[100] 5.96179349 5.43306329 5.97505542 10.11278690 13.16659433  
 18.45672978 25.06986612 32.48631652 35.94461320

[109] 39.38711643 39.99216334 38.28546969 32.26309322 29.69720538  
 28.81112582 29.92205585 30.03050241 27.52598136

[118] 24.28234701 20.89674966 14.81258435 13.20330588 9.82783572  
 7.70724816 6.74684121 5.88969665 5.95371575

[127] 9.14846159 11.57045714 16.97223433 24.64753335 32.25766780  
 37.12824306 39.30344575 37.60712045 32.91274837

[136] 30.02863385 29.59502773 29.82162663 30.29417416 32.74160859  
 28.27883889 24.97058245 23.15399551 17.44309411

[145] 13.38963634 9.28674757 6.84913915 5.63633297 5.51974829 6.67968752  
 12.26140531 18.47041392 21.37207028

[154] 24.35564950 28.78870077 33.03716968 35.76340075 34.63849115  
 29.27565610 26.49950568 26.86601817 27.57679911

[163] 27.06398293 31.05553166 32.68410015 30.53017702 26.34856052  
 18.48313330 14.25660685 8.78050252 5.83688993

[172] 4.66694394 4.67435862 5.65031826 11.53706115 18.97937160  
 21.34229129 25.22057056 27.19129756 29.46590506

[181] 34.43968213 32.39089041 29.17552814 26.72797314 26.91098824  
 26.58215170 28.55577259 33.79183524 33.72799714

[190] 30.26511841 27.06024542 18.80684560 13.69303384 9.63746626  
 6.50854796 5.35325038 5.27994792 6.31450137

[199] 12.24928869 18.76953127 22.39028740 23.85380484 27.15869598  
 31.73888423 34.87383067 31.57425458 28.40018578

[208] 27.33356241 26.08120728 28.15309121 28.36492093 34.05966673  
 33.41145833 28.81426036 26.29490983 20.45410167

[217] 14.44064665 9.58743247 6.51517892 5.34963349 5.01531154 6.16126542  
 12.03257618 19.14562831 21.94275672

[226] 23.60345545 27.42669751 31.54272757 35.41033729 33.84186910  
 29.95454775 27.24072866 27.07917398 27.85234610

[235] 28.98937848 33.12735122 32.17279097 29.25021687 26.89555600  
 19.21941307 14.29175107 9.79835801 6.23896849

[244] 5.14467590 5.00349634 5.95033999 11.83919265 19.55705043  
 21.78216639 23.99088545 27.80442257 31.73074601

[253] 35.83321266 31.99972289 28.35810906 28.04030415 27.34085658  
 30.27615013 29.00698074 32.96049140 31.56846797

[262] 28.38565772 24.47759940 18.70279940 15.05642360 10.19947189  
 7.51929016 5.58503329 4.81186100 5.34273125

[271] 9.54198008 14.53842357 21.64442275 26.92949454 32.63894943  
 38.99227193 43.82619584 40.99748027 38.61611404

[280] 36.72761154 34.80040770 33.85187604 33.20167821 34.09420799  
 30.63368044 26.02050772 22.95994905 17.04734519

[289] 15.88107643 12.13421100 8.85609568 6.73647285 6.34524503  
 6.16018035 10.19483023 12.29009927 17.26664953

[298] 26.66763093 34.24141604 42.70212440 44.45294399 42.95693487  
 36.76474457 34.06473042 31.03925530 28.85115245

[307] 32.48306093 35.25734221 30.66484610 27.72099247 25.31364533  
 19.08848147 14.98565294 9.98342257 6.78873697

[316] 5.68950134 5.43565537 6.31450142 12.96489212 20.42986833  
 22.44951417 24.63523588 30.66852331 34.06858819

[325] 37.09129060 31.60373252 28.71979866 27.15871525 27.39684671  
 28.01102480 28.99082518 35.14612246 33.36570482

[334] 31.05896746 28.15333233 20.44620465 15.23883591 9.54023192  
 6.44827620 5.27699412 5.10054979 6.13251112

[343] 12.63370471 20.19772383 22.21535002 24.37704951 28.65855287  
31.53657900 34.54113614 31.52934529 28.71961829

[352] 24.66820984 24.12609720 26.14227673 27.45490939 34.66971690  
34.06545410 31.02979116 27.92956680 20.23027585

[361] 15.58792693 10.03104504 6.90074030 5.39146895 5.21598908  
6.25777634 12.73714795 20.98861890 21.90393515

[370] 24.32406193 28.54118452 30.63066676 33.44431156 31.73068581  
27.98719629 26.44470984 24.19300960 24.92308067

[379] 27.06753950 33.40271746 31.65666008 29.08709494 24.51557659  
18.35563750 13.66837859 8.44382954 5.98632809

[388] 4.94616848 4.90807053 6.16735390 12.20468027 19.83018649  
21.39009447 22.55111879 26.92545557 29.51497399

[397] 34.23797967 30.39158971 27.21462685 25.14624316 2.91341144  
0.87866104 46.55562782 34.66392994 32.87133512

[406] 27.46111867 25.78664473 16.30835269 12.05741224 9.11006219  
5.68654753 4.72770784 4.34118201 5.47429591

[415] 11.31576726 17.58855375 18.88786411 20.73766642 25.04607842  
29.25817401 32.83808471 31.01652915 29.25751130

[424] 27.53996699 26.71266177 27.13782768 28.06833537 31.61578910  
30.97397016 27.09321950 23.18226767 17.65239201

[433] 14.59713793 10.51643279 7.36307023 5.88903355 5.21996773  
5.65086085 9.73795563 14.03471017 20.97704458

[442] 26.10454038 31.14655663 33.24146446 35.81157188 38.91426729  
36.84829559 35.28947245 31.89115527 31.15505644

[451] 30.72289759 30.27138783 27.57390502 23.20023142 20.04376446  
15.66683553 13.77700624 10.94437207 7.64244549

[460] 5.80632713 5.08324896 5.20326966 8.55571227 10.91411074  
16.84859680 23.96008142 31.32330278 37.65202999

[469] 40.73959529 39.64391658 35.47140268 30.81976995 30.46428922  
28.96381903 33.48650872 35.19754289 28.88931084

[478] 25.85099602 25.43010953 13.24544275 14.28270879 10.08843316  
6.36893569 5.48834155 5.35698784 6.38804494

[487] 12.46937689 17.85517939 19.10626456 21.29062970 25.12647092  
29.40562312 33.49524981 28.89672588 24.43455817

[496] 22.71790466 22.39073209 23.06292083 23.97267140 29.37498771  
29.97268755 28.58032535 24.88780667 16.33744742

[505] 12.07453422 7.78467805 5.71229881 4.96668433 4.75383994 5.83004500  
11.07121568 18.46012778 19.28680281

[514] 19.92972664 22.58314435 26.25155423 30.61086710 28.27373905  
24.13855040 22.66623262 23.09467843 24.45944147

[523] 25.70816208 30.88147025 31.63252306 29.69511966 26.06052872  
18.62879495 13.73516776 9.35607460 6.54382077

[532] 5.35049855 5.19975727 6.26526532 11.96290166 17.42886165  
19.27352793 21.52261064 25.51411197 27.47279083

[541] 31.10086335 29.16896840 25.82354660 24.53913883 24.21775427  
24.30861077 27.33751189 33.51115312 33.02541160

[550] 29.50829279 26.77613803 19.30630202 14.87057839 10.64579413  
7.24974990 5.97828962 5.68099763 6.73941558

[559] 12.71416858 18.94153787 20.46276207 22.91318353 27.20416207  
30.89051838 32.33060269 30.07118958 26.96212701

[568] 24.94887011 25.92471520 27.02171543 26.62560275 32.62171257  
32.50355065 29.65103064 25.57980090 17.28015691

[577] 13.87142032 10.08922186 7.13207103 5.65616461 5.24415671  
6.36830072 12.67543961 19.01321878 21.57143881

[586] 23.96692648 28.09777179 31.14123058 33.71162747 30.31353995  
27.94118411 26.42026539 25.55320973 26.26369193

[595] 25.85773520 30.14005773 29.30802903 27.30851033 23.34188745  
17.57630047 14.28973061 10.25364897 7.13397885

[604] 5.67147612 5.08916657 5.41845805 9.51206332 13.79811580  
20.57194721 26.50628140 30.87054701 35.12501076

[613] 35.97854095 37.52905147 36.03651959 31.81830320 26.45062711  
27.52764615 27.51941168 29.21824171 27.36521927

[622] 23.13797972 19.91777783 14.10684321 13.49724513 10.12894840  
6.90465758 5.72377948 5.12375419 5.10929663

```
[631] 8.37524114 10.94671203 16.65860592 23.65792880 31.28410727  
36.67997063 40.36799353 39.86730102 34.88784794  
  
[640] 31.07368059 30.75125892 29.14664094 31.36020497 34.97416735  
29.29576988 25.88854532 24.14118965 18.15678342  
  
[649] 15.01981658 10.33512674 7.16933921 5.61745576 5.35861143  
6.67303946 12.92314293 20.29411104 22.66759705  
  
[658] 25.39038791 27.81619345 31.96542229 32.24893498 30.24342224  
24.49949877 20.68570861 21.98997920 23.19068981  
  
[667] 24.99695377 9.50216604 0.02055001 46.35308267 30.37288189  
16.65414405 12.40695527 8.60216629 6.22684178  
  
[676] 4.69398231 4.28983408 5.50792299 11.65872353 18.32798218  
20.78995157 23.53838119 27.52115086 28.96366536  
  
[685] 32.07319507 31.01529633 29.53640473 26.45928891 26.43387883  
25.30325279 27.70744932 32.24429847 32.38185227  
  
[694] 31.40633048 26.91590909 19.23307599  
  
> plot(Série)  
  
> plot(Série)
```

## I. Script análise consumo de energia

```
install.packages("readxl")
```

```
library('readxl')
```

```
Dados_Consumo <-  
read_excel("C:/Users/User/Documents/Dissertação_Mestrado/Análise de  
Dados/Tratamento e Modelagem/ConsumoEnergiaMensal.xlsx")
```

```
print(Dados_Consumo)
```

```
str(Dados_Consumo)
```

```
ConsumoEnergia <- as.vector(t(Dados_Consumo))  
print(ConsumoEnergia)
```

```
Serie <- ts(ConsumoEnergia, start = c(2017,1), end = c(2024,12), frequency=12)  
print(Serie)
```

```
plot(Serie)
```