

UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ - UNIOESTE  
PROGRAMA DE PÓS-GRADUAÇÃO EM TECNOLOGIAS, GESTÃO E  
SUSTENTABILIDADE – PPGTGS (MESTRADO PROFISSIONAL)

ALYSSON GUILHERME DE LIMA GUIMARÃES

**MODELOS ESTATÍSTICOS DE SÉRIES TEMPORAIS PARA  
PREVISÃO DO COMPORTAMENTO DE INSTRUMENTOS  
DA BARRAGEM DE ITAIPU**

DISSERTAÇÃO

FOZ DO IGUAÇU  
2024

ALYSSON GUILHERME DE LIMA GUIMARÃES

**MODELOS ESTATÍSTICOS DE SÉRIES TEMPORAIS PARA  
PREVISÃO DO COMPORTAMENTO DE INSTRUMENTOS DA  
BARRAGEM DE ITAIPU**

Dissertação apresentada ao **Programa de Pós-Graduação em Tecnologias, Gestão e Sustentabilidade** da Universidade Estadual do Oeste do Paraná, como requisito parcial para a obtenção do título de **Mestre**.

Área de Concentração: Tecnologia e Gestão.

Orientador: Prof. Dr. Emerson Lazzarotto

Co-Orientador: Prof. Me. Edivaldo José da Silva Júnior.

FOZ DO IGUAÇU  
2024

Ficha de identificação da obra elaborada através do Formulário de Geração Automática do Sistema de Bibliotecas da Unioeste.

de Lima Guimarães, Alysson Guilherme  
MODELOS ESTATÍSTICOS DE SÉRIES TEMPORAIS PARA PREVISÃO DO  
COMPORTAMENTO DE INSTRUMENTOS DA BARRAGEM DE ITAIPU / Alysson  
Guilherme de Lima Guimarães; orientador Emerson Lazzarotto;  
coorientador Edivaldo José da Silva Júnior. -- Foz do Iguaçu,  
2024.  
49 p.

Dissertação (Mestrado Acadêmico Campus de Foz do Iguaçu)  
-- Universidade Estadual do Oeste do Paraná, Centro de  
Engenharias e Ciências Exatas, Programa de Pós-Graduação em  
Tecnologias, Gestão e Sustentabilidade, 2024.

1. Séries Temporais. 2. Piezômetros. 3. ITAIPU. 4.  
Barragem. I. Lazzarotto, Emerson, orient. II. da Silva  
Júnior, Edivaldo José, coorient. III. Título.

ALYSSON GUILHERME DE LIMA GUIMARÃES

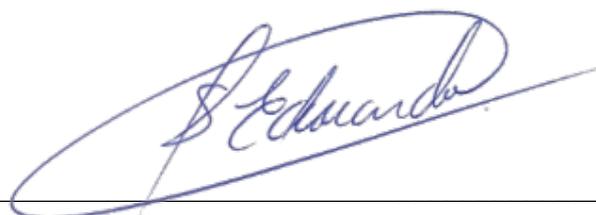
**MODELOS ESTATÍSTICOS DE SÉRIES TEMPORAIS PARA  
PREVISÃO DO COMPORTAMENTO DE INSTRUMENTOS DA  
BARRAGEM DE ITAIPU**

Dissertação apresentada ao Programa de Pós-Graduação em Tecnologias, Gestão e Sustentabilidade - PPGTGS da Universidade Estadual do Oeste do Paraná e aprovada pela banca examinadora:

Documento assinado digitalmente  
 **EMERSON LAZZAROTTO**  
Data: 12/12/2024 16:16:32-0300  
Verifique em <https://validar.iti.gov.br>

---

Prof. Dr. Emerson Lazzarotto (orientador)  
Professor do PPGTGS – Campus de Foz do Iguaçu



---

Prof. Dr. Eduardo Cesar Dechechi (membro permanente do PGTGS)  
Professor do PPGTGS – Campus de Foz do Iguaçu

Documento assinado digitalmente  
 **SHEILA REGINA ORO**  
Data: 12/12/2024 18:17:42-0300  
Verifique em <https://validar.iti.gov.br>

---

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Sheila Regina Oro (membro externo à Instituição)  
Professora da Universidade Tecnológica Federal do Paraná – Campus Francisco Beltrão

---

Prof. Dr. Luciano Panek  
Coordenador do Mestrado Profissional em Tecnologias, Gestão e Sustentabilidade  
Portaria N° 0595/2024-GRE - UNIOESTE – Campus de Foz do Iguaçu

Foz do Iguaçu, 01 de Agosto de 2024

Dedico este trabalho a minha mãe e minha avó, que deram todo o suporte que alguém poderia desejar durante este período da minha vida e não me deixaram desistir nunca.

## **AGRADECIMENTOS**

Agradeço ao meu orientador, Prof. Emerson e Coorientador Edivaldo, que estiveram sempre dispostos a atender e ouvir durante esse processo cheio de mudanças e reviravoltas, ao Prof. Eduardo Dechechi que as contantes perguntas sobre a dissertação ajudaram ela a tomar forma e a incentivar a sua conclusão e aos vários colegas que deram suas considerações e apoio durante esse tempo difícil.

*"Dar de si antes de pensar em si"*  
Arthur Frederick Sheldon

## RESUMO

GUIMARÃES, A. G. de L. (2024). *Modelos estatísticos de séries temporais para previsão do comportamento de instrumentos da barragem de Itaipu*. Dissertação de Mestrado – Programa de Pós-Graduação em Tecnologias, Gestão e Sustentabilidade - PPGTGS, Universidade Estadual do Oeste do Paraná – UNIOESTE, Foz do Iguaçu, Paraná, Brasil.

A dissertação aborda a utilização de modelos estatísticos de séries temporais para prever o comportamento de instrumentos de medição instalados na barragem da Central Hidrelétrica Binacional de Itaipu. A motivação da pesquisa reside na importância da segurança estrutural das barragens, especialmente no contexto brasileiro, onde falhas têm causado impactos ambientais, financeiros e sociais significativos. A pesquisa adota uma abordagem quantitativa e descritiva, com a definição e a comparação de três métodos estatísticos ajustados para as particularidades das séries temporais dos piezômetros inseridos na fundação da barragem. Destacaram-se os métodos ajustados de suavização exponencial em um contexto onde os blocos em que os instrumentos estavam inseridos apresentaram maior variabilidade no centro e maior melhor acurácia na previsibilidade aos extremos.

**Palavras-chave:** Séries temporais, Piezômetros, Barragem de Itaipu.

## ABSTRACT

GUIMARÃES, A. G. de L. *Statistical Time Series Models for Predicting the Behavior of Instruments at the Itaipu Dam*. Master's Dissertation - Postgraduate Program in Technologies, Management and Sustainability - PPGTGS, State University of Western Paraná - UNIOESTE, Foz do Iguaçu, Paraná, Brazil.

The dissertation addresses the use of statistical time series models to predict the behavior of measuring instruments installed at the Itaipu Binational Hydroelectric Dam. The motivation for the research lies in the importance of structural safety of dams, especially in the Brazilian context, where failures have caused significant environmental, financial, and social impacts. The research adopts a quantitative and descriptive approach, defining and comparing three statistical methods adjusted for the particularities of the time series of piezometers embedded in the dam's foundation. Highlighted were the adjusted exponential smoothing methods in a context where the blocks containing the instruments showed greater variability in the center and better accuracy in predictability at the extremes.

**Key-words:** Time series, piezometer, Itaipu dam.

## LISTA DE FIGURAS

FIGURA 1 – DIAGRAMA REPRESENTATIVO DO ALGORITMO DE BUSCA .....	18
FIGURA 2 – FLUXOGRAMA DO PROCESSO DE BUSCA .....	18
FIGURA 3 – ANÁLISE DA INTENSIDADE DO ÍNDICE CITATION .....	19
FIGURA 4 – ANÁLISE DA INTENSIDADE DO ÍNDICE CO-CITATION .....	20
FIGURA 5 – ANÁLISE DA INTENSIDADE DO ÍNDICE BIBLIGRAPHIC COUPLING .....	21
FIGURA 6 - PIEZÔMETRO STANDPIPE GENÉRICO.....	26
FIGURA 12 – FLUXOGRAMA DE UM PROCESSO DE PREDIÇÃO DE DADOS.....	39
FIGURA 13 – FLUXOGRAMA DETALHADO APLICADO.....	40
FIGURA 14 – TRECHO F DA BARRAGEM DE ITAIPU .....	42
FIGURA 15 – BLOCOS ANALISADOS EM DESTAQUE .....	42
FIGURA 16– FREQUÊNCIA DE MEDIÇÕES AO DECORRER DOS ANOS .....	44
FIGURA 17 – COMPORTAMENTO DO PIEZÔMETRO PS-008 NO INTERVALO 1981-2022 .....	45
FIGURA 18 – PS-008 COM NOVO INTERVALO DEFINIDO .....	46
FIGURA 19 – COMPONENTE DE TENDÊNCIA DO PS-008 .....	47
FIGURA 20 – COMPONENTE SAZONAL DO PS-008 .....	48
FIGURA 21– RUÍDO DO PS-008 .....	48
FIGURA 22 – RESUMO DAS COMPONENTES DO PS-008.....	49
FIGURA 23 – SEPARAÇÃO DE SÉRIE TEMPORAL EM INTERVALOS .....	51

## LISTA DE TABELAS

TABELA 1 – RELAÇÃO DOS PIEZÔMETROS DE ANÁLISE .....	43
TABELA 2 – PERÍODO DE ENCHIMENTO DO RESERVATÓRIO DA BARRAGEM .....	45
TABELA 3 – MODELOS DE PREDIÇÃO AJUSTADOS .....	50
TABELA 4 – RESPECTIVOS ERROS PERCENTUAIS (MAPE) .....	51

## Sumário

1	INTRODUÇÃO .....	13
1.1	JUSTIFICATIVA .....	15
1.2	OBJETIVO GERAL .....	16
1.3	OBJETIVOS ESPECÍFICOS .....	16
2	REVISÃO DA LITERATURA .....	16
2.1	Teoria do Enfoque Meta Analítico Consolidado .....	17
2.1.1	Revisão bibliométrica através do mapeamento científico .....	19
2.2	Barragens .....	22
2.2.1	Piezômetro .....	25
2.3	Séries temporais e análise de dados .....	26
2.3.1	Componentes de uma série temporal .....	27
2.3.2	Modelos de predição .....	30
2.4	O ambiente R .....	36
2.4.1	R na estatística .....	37
2.4.2	O software “RStudio” .....	37
3	METODOLOGIA .....	39
4	ESTUDO DE CASO .....	42
5	RESULTADOS .....	44
5.1	Limpeza e exploração de dados .....	44
5.2	Análise exploratória do objeto de estudo .....	46
5.3	Seleção e implementação de modelos .....	49
5.4	Avaliação e validação dos modelos .....	51
6	CONCLUSÃO .....	53
	BIBLIOGRAFIA .....	54

## 1 INTRODUÇÃO

As barragens são estruturas destinadas à acumulação de água para quaisquer usos, à disposição final ou temporária de rejeitos e à acumulação de resíduos industriais que apresentem pelo menos uma das seguintes características: a) Altura do maciço, medida do encontro do pé do talude de jusante com o nível do solo até a crista de coroamento do barramento, maior ou igual a 15 (quinze) metros; b) Capacidade total do reservatório maior ou igual a 3.000.000m<sup>3</sup> (três milhões de metros cúbicos); c) Reservatório que contenha resíduos perigosos conforme normas técnicas aplicáveis; d) Categoria de dano potencial associado médio ou alto, em termos econômicos, sociais, ambientais ou de perda de vidas humanas; e) Categoria de risco alto, a critério do órgão fiscalizador (BRASIL, 2010).

Um dos requisitos fundamentais do desenvolvimento socioeconômico no mundo é a disponibilidade de água em quantidades adequadas e devida qualidade. Para compensar as variações no ciclo hidrológico, barragens e reservatórios são um requisito para manter vazão consistente de fluxo diário necessário em rios ao longo do ano (COMISSÃO INTERNACIONAL DE GRANDES BARRAGENS, 2008).

Dentre os benefícios que são supridos pelo uso de barragem, destacam-se:

- Suprimento de água para uso doméstico e industrial;
- Atendimento da demanda agrícola para fornecimento de alimentos;
- Controle de enchentes;
- Energia hidrelétrica;
- Navegação fluvial;
- Recreação;
- Gestão integrada da água em bacias fluviais.

A preocupação em relação à segurança das barragens não é recente, com a regulamentação de segurança de barragens, conforme estabelecido na Lei No. 12.334/2010 - Política Nacional de Segurança de Barragens e resoluções complementares, emanadas do Conselho Nacional de Recursos Hídricos (CNRH), que tem por finalidade, estabelecer diretrizes para que sejam garantidos os meios necessários a sua segurança e de suas estruturas hidráulicas complementares e, paralelamente, contribuir para a consecução de esforços no sentido de capacitar profissionais para a tarefa de implementação da lei e monitoramento dos resultados almejados (COMITÊ BRASILEIRO DE BARRAGENS, 2024).

Cabe ressaltar que, apesar dos esforços do Comitê Brasileiro de Barragens (CBDB) em busca da regulamentação, conforme se atesta no resgate da leitura dos seguintes documentos: Diretrizes Para a Inspeção e Avaliação de Segurança de Barragens em Operação (1983), Segurança de barragens: Recomendações para a Formulação e Verificação de Critérios e Procedimentos (1986) e Guia Básico de Segurança de Barragens (2001), somente com mais de 30 anos de atraso, vimos a promulgação da lei brasileira sobre segurança de barragens se concretizar em 2010. Trata-se de um documento relevante, um marco legal e um grande desafio, para o qual estamos todos envolvidos e focados para a sua consecução (COMITÊ BRASILEIRO DE BARRAGENS, 2024).

O melhor caminho para o sucesso da regulamentação, ora vigente, passa pela adoção desses princípios e no compromisso de que as ações serão formuladas com base no entendimento do conceito de segurança global que traduz cidadania, no momento em que passamos a entender o significado das seguintes aspectos relevantes: i) estruturais, no sentido de que se demonstre que barragem é capaz de suportar a todos os esforços aplicados, durante a vida útil e não induza sentimento de insegurança ou inquietação, para a população afetada, em caso de acidente, ii) operacionais, cujo entendimento extrapola ao funcionamento dos dispositivos hidromecânicos e, se traduz pela capacidade do empreendimento cumprir todas as funções para as quais foi projetada, de acordo com o que desejam os que a utilizam; iii) econômicos e financeiros, relativos a, respectivamente: retorno do capital investido, durante a vida útil do empreendimento e existência assegurada de recursos necessários para a sua conclusão, levando em consideração eventuais problemas de natureza conjuntural; iv) relativos ao investimento social, referentes às compensações justas decorrentes de expectativas de alterações sociais promovidas pelo empreendimento e que corresponderiam ao atendimento das necessidades prioritárias da população afetada e v) ambientais, com base nas alterações impostas ao meio ambiente, os quais devem rigorosamente ocorrer dentro de valores permissíveis (COMITÊ BRASILEIRO DE BARRAGENS, 2024).

Do exposto, os diversos atores responsáveis por estruturas de barragens e seus reservatórios, são legalmente comprometidos com a qualidade e segurança desses empreendimentos. Esse tem sido o compromisso do CBDB, oportunidade em que registramos a constituição de uma nova comissão técnica, a CT12 - Usos Múltiplos. São muitos os nossos desafios e evidente a necessidade de estabelecermos parcerias com associação ou instituições engajadas no tema segurança de barragens, lembrando que a Lei No. 12.334/2010 reconhece a importância do fomento a cultura de segurança e o envolvimento de representações da

sociedade, em todas as fases de discussão desses empreendimentos. O maior desafio será eliminar os entraves decorrentes de influências nocivas, que não combinam com barragens; como por exemplo: burocracia, ingerência política, falta de recursos materiais e financeiros, deixar para depois, vaidades e falta de comunicação entre setores de ações complementares (operação, manutenção e segurança) e amadorismo (COMITÊ BRASILEIRO DE BARRAGENS, 2024).

A lei, de forma precisa e oportuna, reconhece a importância do envolvimento das ações de segurança, em todas as fases, ou seja, desde a concepção até a operação e eventual descomissionamento da estrutura (COMITÊ BRASILEIRO DE BARRAGENS, 2024).

Usinas hidrelétricas têm estado presentes na matriz energética brasileira há mais de um século, sendo atualmente responsáveis pela maior percentagem da produção de energia elétrica no território nacional, com cerca de 65% da fatia (Balanço Energético Nacional, 2024).

Possuindo uma finalidade de controle do fluxo de água, barragens são construídas com múltiplas possíveis funções, desde fornecimento doméstico de água, irrigação, navegação, recreação, controle de sedimentação e enchentes, ou obtenção de energia elétrica. Uma mesma barragem pode desempenhar diversas dessas funções, sendo chamadas “Barragens de usos múltiplos (COMISSÃO INTERNACIONAL DE GRANDES BARRAGENS, 2008).

Diversos procedimentos são aplicados para mitigar o risco de ruptura e promover maior segurança às barragens, sendo o monitoramento por meio da instrumentação um dos um deles.

Os instrumentos utilizados para monitorar geram dados no tempo, que após o processamento, geram informações importantes sobre o comportamento das estruturas aos responsáveis de engenharia. Esses dados, ordenados cronologicamente, são chamados de séries temporais dos fenômenos monitorados (MORETTIN, 2005; REIS, 2024)

Entretanto, para se obter informações relevantes, esses dados devem ser interpretados e correlacionados com outros dados para sua compreensão e extração de padrões.

Dessa forma, neste trabalho foram aplicadas técnicas de predição estatística de séries temporais para responder a seguinte pergunta: **Qual é a previsão de comportamento dos instrumentos que ajudam a nortear o possível comportamento da barragem?**

## 1.1 JUSTIFICATIVA

A Lei 12.334 (BRASIL, 2010) estabelece a política nacional de segurança de barragens do Brasil (PNSB), definindo que segurança de barragem é algo que deve manter a integridade

estrutural e operacional, sendo que essa segurança influi diretamente na sustentabilidade e seus efeitos sociais e ambientais.

Uma Falha estrutural não ocorre de uma vez. Trata-se de um processo gradual a longo prazo. Se um modelo de predição comportamental pode ser estabelecido com sucesso, falhas estruturais podem ser detectadas em tempo suficiente, principalmente quando se fala em degradação gradual. A predição desses tipos de modelos é essencial para qualquer tipo de monitoramento de saúde estrutural, uma vez que anomalias podem ser observadas comparando as predições com os dados adquiridos (LI *et al.*, 2020).

A presente pesquisa busca mostrar uma forma pela qual o comportamento futuro de parte de barragem pode ser estimado, com base no comportamento de instrumentos de monitoramento.

## 1.2 OBJETIVO GERAL

Realizar a previsão dos dados de piezômetros inseridos na fundação da Barragem de Itaipu.

## 1.3 OBJETIVOS ESPECÍFICOS

- i. Realizar uma análise exploratória para compreender as características dos dados destes piezômetros;
- ii. Identificar os *outliers*;
- iii. Selecionar e validar modelos de previsão.

## 2 REVISÃO DA LITERATURA

A previsão de séries temporais é uma técnica amplamente utilizada em diversos campos para antecipar comportamentos futuros com base em dados históricos. Na engenharia civil e na gestão de infraestruturas, a aplicação de métodos de previsão em instrumentos de medição de barragens, como a de Itaipu, é crucial para a segurança e a operação eficiente dessas estruturas. Estudos anteriores têm demonstrado que a análise de séries temporais pode identificar padrões e tendências que são essenciais para a manutenção preventiva e para a mitigação de riscos. A literatura sobre modelos de séries temporais é vasta, abrangendo desde métodos tradicionais,

como ARIMA (*Autoregressive Integrated Moving Average*) e suas variações sazonais (SARIMA), até abordagens mais recentes que utilizam técnicas de aprendizado de máquina, como redes neurais recorrentes (RNN) e *Long Short-Term Memory* (LSTM) (NUNES et al, 2023).

A revisão da literatura irá abordar essas metodologias, discutindo suas vantagens, limitações e aplicabilidades específicas na previsão do comportamento dos instrumentos de medição da barragem de Itaipu, iniciando com uma aplicação da Teoria do Enfoque Meta Analítico Consolidado para realizar um levantamento do estado atual de pesquisas nesse enfoque e sua evolução, considerando métricas como *co-authorship*, *co-citation*, dentre outros.

## 2.1 Teoria do Enfoque Meta Analítico Consolidado

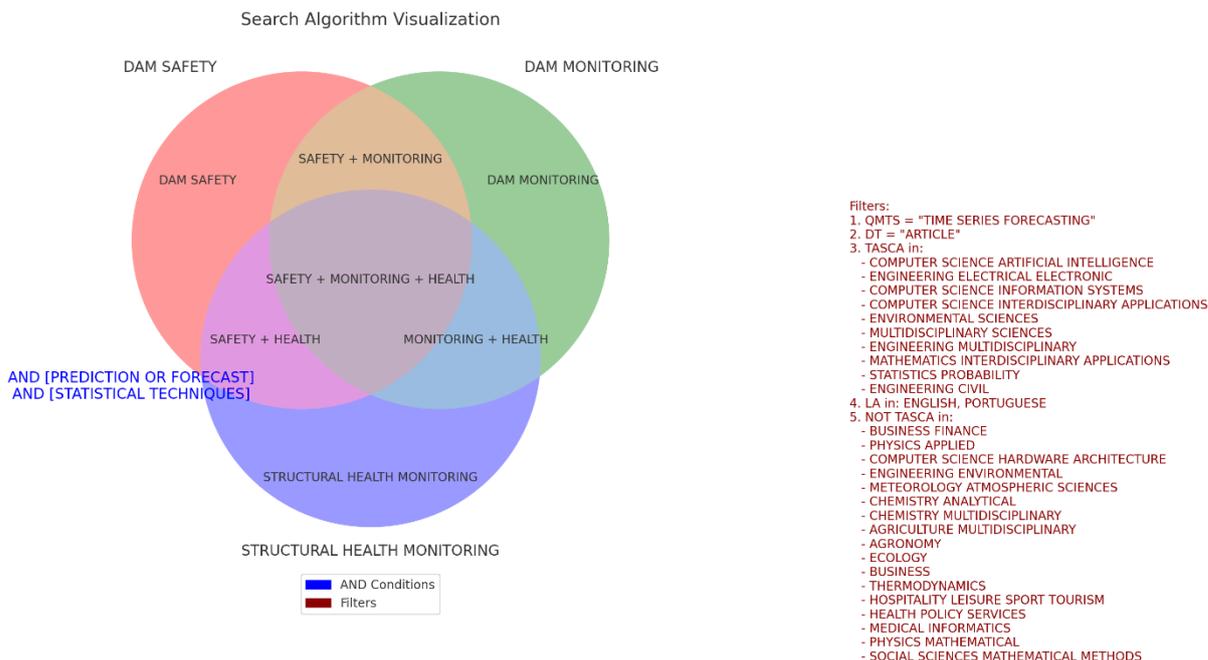
O presente estudo pode ser classificado, quanto à modalidade da pesquisa como exploratório, com uma natureza quanto ao seu objetivo descritiva e uma abordagem quantitativa. Utilizou-se a Teoria do Enfoque Meta Analítico Consolidado – TEMAC, de Mariano e Rocha (2017), onde ocorre a divisão em três etapas distintas na sua aplicação:

- Preparação da pesquisa;
- Apresentação e interrelação dos dados;
- Detalhamento, modelo integrador e validação por evidências.

A preparação consiste ao preparar o algoritmo de busca a ser aplicado nas bases de pesquisa, sendo a *Web of Science* a base de dados selecionada por representar uma base internacional e confiável de ciência.

A pesquisa foi realizada entre os dias 01/03/2024 a 03/03/2024, utilizando o algoritmo representado na Figura 1 de busca, onde se obtiveram 134 resultados, que foram exportados para análise, através da própria plataforma da base de dados.

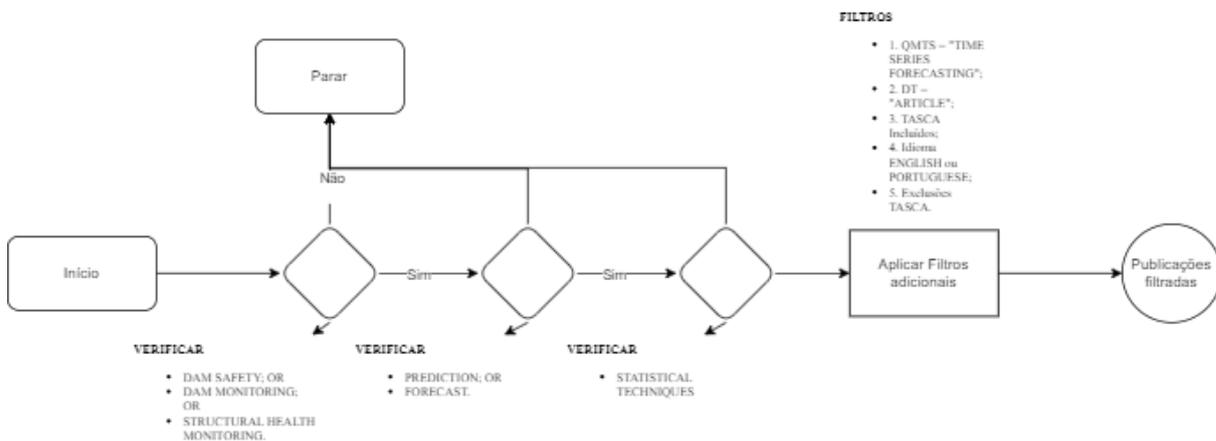
Figura 1 – Diagrama representativo do algoritmo de busca



Fonte: Elaborado pelo autor

A Figura 2 mostra o fluxo realizado na busca das publicações:

Figura 2 – Fluxograma do processo de busca



Fonte: Elaborado pelo autor

As próximas duas etapas foram realizadas por meio do mapeamento científico proporcionado pelo Software VosViewer. As análises via mapeamento se baseiam no conceito de *Citation*, *Co-citation*, *Bibliographic coupling*, *Co-authorship* e *Title Field*:

- *Citation*: Define uma influência baseada no número de citações que um trabalho recebe.
- *Co-citation*: Estabelece ligações entre diferentes autores cujas obras são citadas juntas em outros trabalhos.

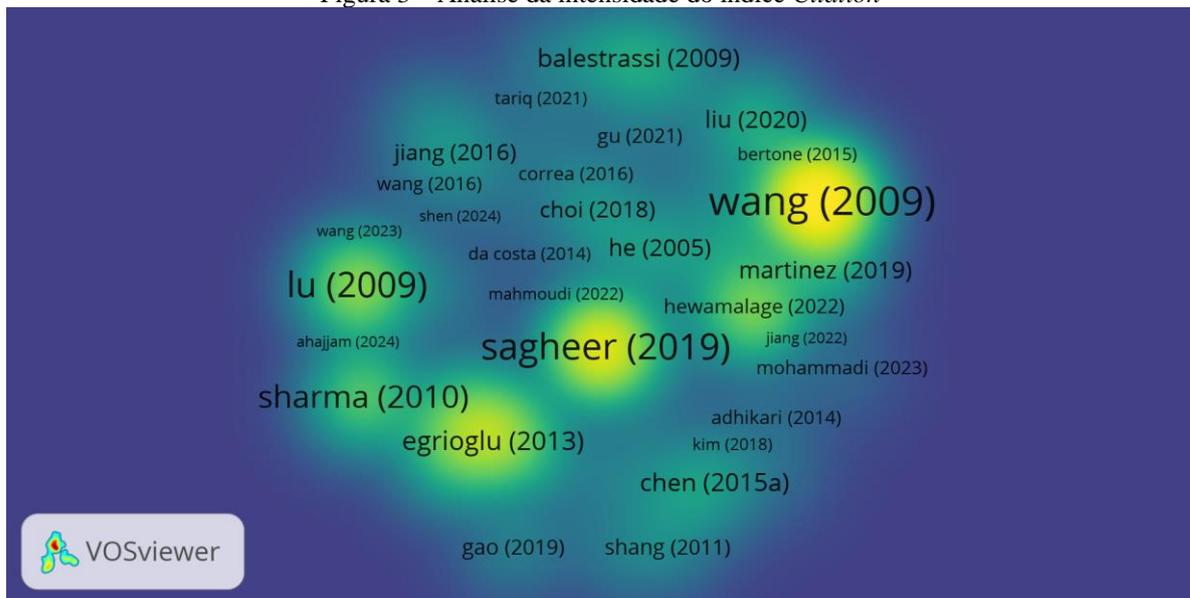
- *Bibliographic Coupling*: Conecta obras diferentes que compartilham referências comuns, ligando-as pelas suas bibliografias.
- *Co-authorship*: Relaciona os coautores que aparecem frequentemente juntos nos artigos analisados.
- *Title Field*: Analisa as palavras mais recorrentes nos títulos dos artigos em estudo.

A questão da pesquisa bibliométrica está relacionada ao campo histórico em séries temporais e a evolução do seu uso em predição em equipamentos de acompanhamento da saúde de infraestruturas críticas.

### 2.1.1 Revisão bibliométrica através do mapeamento científico

A primeira análise realizada foi por meio de *Citation*, utilizando dados adquiridos da base *Web of Science (Clarivate Analytics)*, por meio do software “VOSViewer”, cujo mapa resultante está disposto na :

Figura 3 – Análise da intensidade do índice *Citation*



Fonte: Elaborado pelo autor

Visualiza-se manchas amarelas, representando os trabalhos mais frequentemente citados, destacando-se cinco documentos. Wang (2009) tem um foco na comparação da performance de diversos métodos de predição utilizando inteligência artificial, enquanto Lu (2009) trata de predição de séries temporais financeiras por meio de dois tipos de métodos, análise de componentes independentes e *support vector regression*. Sharma (2010) utiliza análise de séries temporais como uma forma de detectar resultados anômalos de sensores, de forma a verificar a prevalência dos erros nos dados reais, já Egrioglu (2013) aplica predição de séries temporais

com modelos modernos, aplicando o uso híbrido de redes neurais e “*Fuzzy c-means*”. Finalizando as manchas amarelas, tem-se Sagheer (2019) com a predição de produção de petróleo por meio de LSTM, um tipo mais específico de rede neural. O Quadro 1 mostra os artigos produzidos pelos autores identificados:

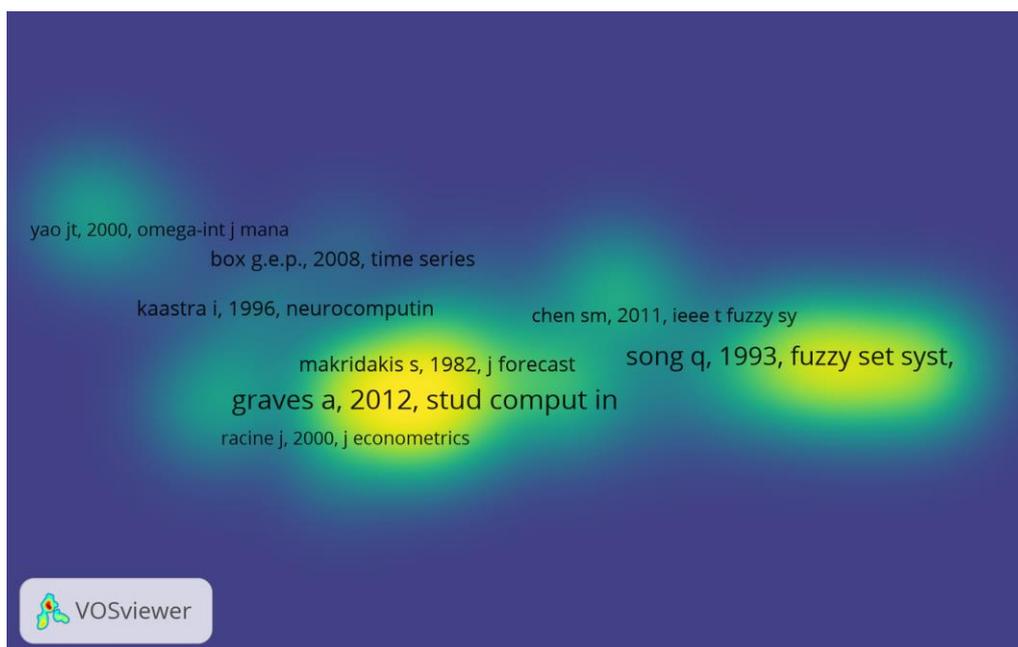
Quadro 1 – Artigos destacados pelo índice *Citation*

<b>Autor</b>	<b>Artigo</b>
<b>Wen-Chuan Wang</b>	<i>A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series</i>
<b>Chi-Jie Lu</b>	<i>Financial time series forecasting using independent component analysis and support vector regression</i>
<b>Abhishek B. Sharma</b>	<i>Sensor faults: Detection methods and prevalence in real-world datasets</i>
<b>Erol Egrioglu</b>	<i>Fuzzy time series forecasting with a novel hybrid approach combining fuzzy c-means and neural networks</i>
<b>Alaa Sagheer</b>	<i>Time series forecasting of petroleum production using deep LSTM recurrent networks</i>

Fonte: Elaborado pelo autor

A segunda análise consistiu em *Co-citation*, também partindo da base de dados *Web of Science (Clarivate Analytics)* e criando o mapa pelo *software “VOSviewer”* para melhor visualização, conforme a Figura 4:

Figura 4 – Análise da intensidade do índice *Co-citation*



Fonte: Elaborado pelo autor

Foca-se nas manchas amarelas, onde se destacam duas obras no critério de *Co-citation*. Graves (2012) é uma obra cujo foco está em um sistema de transdução para uso de Redes Neurais Recorrentes, enquanto Song (1993) que traz a definição de Séries Temporais *Fuzzy*, servindo como base para muitos próximos trabalhos na área que fazem uso de metodologias de predição nessas características. O Quadro 2 traz as obras destacadas:

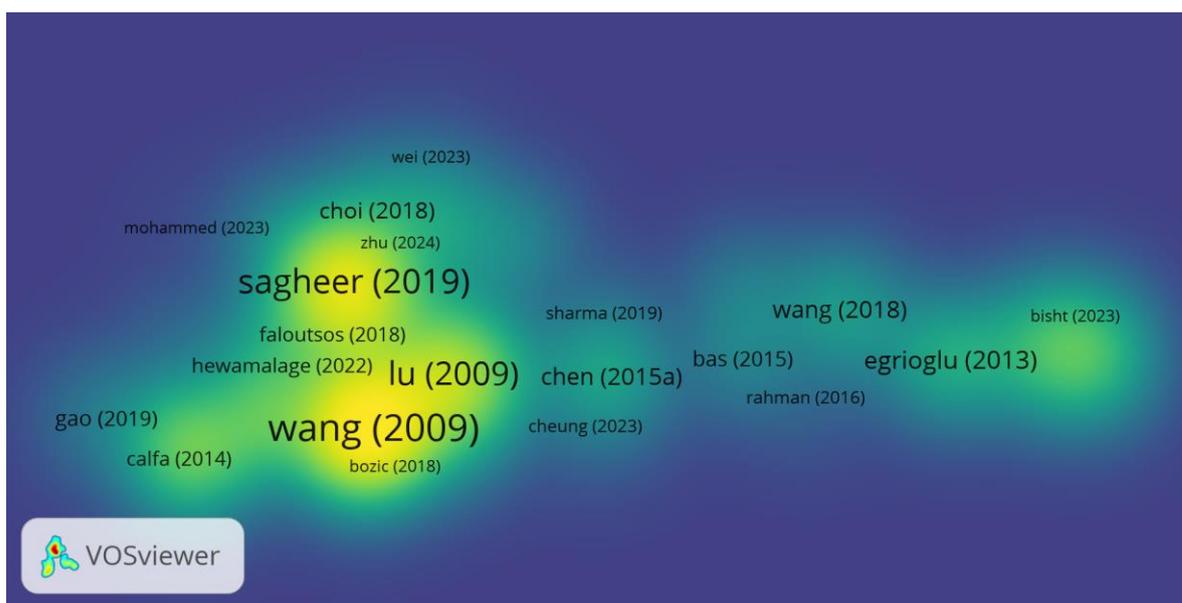
Quadro 2 – Artigos destacados pelo índice *Co-citation*

<b>Autor</b>	<b>Artigo</b>
<b>Alex Graves</b>	<i>Sequence Transduction with Recurrent Neural Networks</i>
<b>Qiang Song</b>	<i>Fuzzy time series and its models</i>

Fonte: Elaborado pelo autor

A terceira análise consistiu em *Bibliographic Coupling*, também partindo da base de dados *Web of Science (Clarivate Analytics)* e criando o mapa pelo *software “VOSviewer”* para melhor visualização, exibido na

Figura 5 – Análise da intensidade do índice *Bibliographic Coupling*



Fonte: Elaborado pelo autor

Verifica-se pela Figura que três manchas amareladas maiores, representadas por Sagheer (2019), Lu (2009) e Wang (2009). Sagheer (2019), relacionado com Faloutsos (2018) e Zhu (2024), possuem foco no uso de modelos mais recentes de predição, fazendo uso de redes neurais, LSTM e comparações entre metodologias mais antigas na predição. Já Wang (2009) e Lu (2009), em conjunto com Bozic (2018) tratam de métodos com fundamentos estabelecidos na Estatística e Probabilidade na forma de aplicar sua predição. O Quadro 3 mostra os autores dos artigos identificados no mapa:

Quadro 3 – Artigos destacados pelo índice *Bibliographical Coupling*

<b>Autor</b>	<b>Artigo</b>
<b>Wen-Chuan Wang</b>	<i>A comparison of performance of several artificial intelligence methods for forecasting 22ompone discharge time series</i>
<b>Chi-Jie Lu</b>	<i>Financial time series forecasting using 22omponente22e 22omponente analysis and support vector regression</i>
<b>Alaa Sagheer</b>	<i>Time series forecasting of petroleum production using deep LSTM recurrent networks</i>

Fonte: Elaborado pelo autor

## 2.2 Barragens

Usar definição da lei 12334 ... 14066

Definidas como barreiras ou estruturas que cruzam córregos, rios ou canais com o intuito de controlar o fluxo de água, as barragens variam de tamanho, partindo desde pequenos maciços de terra até enormes estruturas de concreto, suas funções usualmente estão concentradas nas áreas de fornecimento de água, energia hidrelétrica e irrigação (COMISSÃO INTERNACIONAL DE GRANDES BARRAGENS, 2008).

As barragens possuem classificação variada, de acordo com o material utilizado pela sua construção. Elas são chamadas barragens de gravidade, barragens em arco e barragens de contrafortes quando seu material de construção consiste em concreto, pedra ou alvenaria. Já em casos da composição consistir de terra e rochas em sua primazia, a nomeação passa a ser barragem em aterro, tipo que representa quase 75% de todas as barragens do mundo (COMISSÃO INTERNACIONAL DE GRANDES BARRAGENS, 2008).

Como parte integral da infraestrutura mundial, barragens devem cumprir certos requisitos técnicos e administrativos para garantir sua operação segura. Segundo a Comissão internacional de grandes barragens (2008, p. 19)

[...] o projeto, a construção e a operação de todas as barragens devem observar os seguintes requisitos técnicos:

- As barragens, suas fundações e seus encontros devem ser estáveis sob todas as condições de carga;
- As barragens e suas fundações devem ser suficientemente vedadas e ter procedimento adequados de controle de vazamentos para garantir a operação segura e para manter a capacidade de armazenamento;

- As barragens devem ter borda livre suficiente para evitar transbordamento de ondas e, no caso de barragens de terra devem incluir uma margem para recalque da fundação e do maciço;
- As barragens devem ter capacidade suficiente de vertimento da vazão para evitar transbordamento dos reservatórios em casos de enchente.

Para operar adequadamente, além destes requisitos, as barragens necessitam possuir alguns componentes básicos específicos. Um reservatório, um vertedouro, estruturas de descarga e uma unidade de controle. No caso de uso para produção de energia, estes mesmos passam a incluir condutos forçados, geradores e subestações (COMISSÃO INTERNACIONAL DE GRANDES BARRAGENS, 2008).

Dentro destes componentes, alguns termos são fundamentais, apresentados no Quadro 4:

Quadro 4 – Alguns termos básico de barragens

<b>TERMO</b>	<b>EXPLICAÇÃO</b>
<b>Montante</b>	Ponto referencial visualizado pelo observador que olha em direção à nascente de um curso de água (águas acima), ou seja, a nascente é o ponto mais a montante do rio.
<b>Jusante</b>	Ponto referencial visualizado pelo observador que olha em direção à foz de um curso de água (águas abaixo), ou seja, a foz é o ponto mais a jusante de um rio.
<b>Margem direita</b>	Situada à direita do observador que olha para jusante (para onde corre o fluxo de água, águas abaixo).
<b>Margem esquerda</b>	Situada à esquerda do observador que olha para jusante.

Fonte: (LAZZAROTTO, 2016)

Barragens possuem importância fundamental em diversos aspectos, se destacando no papel socioeconômico quando adequadamente planejadas, projetadas, construídas e mantidas, uma vez que contribuem para atender demandas de fornecimento de água e energia. Isso se dá devido ao fundamental requisito de um fluxo consistente de água e suprimento efetivo de energia para as diversas regiões, sendo as variações do ciclo hidrológico compensadas com as diversas barragens existentes (COMISSÃO INTERNACIONAL DE GRANDES BARRAGENS, 2008).

As barragens são obras de grande porte de engenharia com profundo impactos sociais e econômicos em todas as suas fases de existência, desde a construção e operação até sua desativação, implicando que os protocolos de segurança para assegurar o ocorrido sem incidentes necessitam ser compreensivos ao considerar os riscos inerentes de barragens.

Portanto, é de suma importância o acompanhamento e a avaliação permanente do comportamento da barragem. Isto se dá através de inspeções visuais e instrumentação (LAZZAROTTO, 2016).

A segurança absoluta é impraticável, sendo assim necessária uma gestão de riscos para garantir que os mesmos não excedam níveis aceitáveis. O monitoramento remoto por meio de instrumentos é a forma mais comum para prevenir falhas e desastres, sendo assim, o comportamento de uma barragem deve então ser continuamente monitorado, devendo ser preconizada a realização periódica da segurança de barragens (COMISSÃO INTERNACIONAL DE GRANDES BARRAGENS, 2008) (BRASIL, 2010).

À operação e manutenção de uma barragem deve então ser dada atenção contínua e as ferramentas que permitem que esse tipo de acompanhamento exista e seja viável são aqueles que fazem parte do conceito de instrumentação, que se resume ao monitoramento de infiltração, pressão e deslocamentos (LAZZAROTTO, 2016).

A instrumentação compreende o conjunto de dispositivos e ferramentas instalados e utilizados nas barragens ou suas redondezas, que buscam efetuar medições que alimentam um ciclo de análise e tomada de decisões em relação ao comportamento estrutural e seus parâmetros de desempenho (COMISSÃO INTERNACIONAL DE GRANDES BARRAGENS, 2008).

Partindo do conceito de instrumentação, suas particularidades variam de obra a obra, sendo impossível estabelecer normas padrões de equipamentos e ferramentas usadas de forma geral. Além disso, o monitoramento gera informações, geralmente criando ao longo do tempo um conjunto de dados chamado de séries temporais. É a análise e interpretação desses dados por equipe capacitada que permite garantir a operação e manutenção geral.

A monitoração de grandezas físicas em uma barragem de concreto é fundamental para garantir sua segurança e integridade ao longo do tempo. Segundo Dunicliff (1988), a instrumentação em estruturas que envolvem solo e rocha (geotécnicas) são um casamento entre as capacidades dos instrumentos de medição e a capacidade da equipe. Diversos instrumentos são utilizados para medir e monitorar parâmetros-chave que afetam o comportamento da estrutura da barragem.

Algumas grandezas físicas comumente monitoradas em barragens de concreto incluem:

- Nível de água: A medição do nível de água é essencial para avaliar a quantidade de água armazenada na barragem e seu impacto nas condições de segurança. Essa grandeza está correlacionada com a pressão hidrostática exercida sobre a estrutura.

- Pressão: A medição da pressão da água dentro da barragem é importante para monitorar a distribuição de cargas e identificar possíveis vazamentos ou variações significativas de pressão que possam indicar problemas estruturais.
- Deformação: A deformação da barragem é monitorada para detectar movimentos ou deslocamentos indesejados. Instrumentos como extensômetros são utilizados para medir a deformação em diferentes pontos da estrutura e identificar possíveis áreas de tensão excessiva.
- Temperatura: A variação de temperatura pode causar expansão ou contração do concreto, afetando a estabilidade da barragem. Sensores de temperatura são usados para monitorar variações significativas e fornecer informações sobre os efeitos térmicos na estrutura.
- Inclinação: A medição da inclinação da barragem é importante para detectar possíveis movimentos de rotação ou deslizamento. Sensores de inclinação são utilizados para monitorar e registrar qualquer mudança significativa na inclinação da barragem.

Dentre os instrumentos necessários para o monitoramento da saúde estrutural de uma barragem, cujos dados serão estudados neste trabalho, destacam-se os Piezômetros, Extensômetros e Termômetro Superficial.

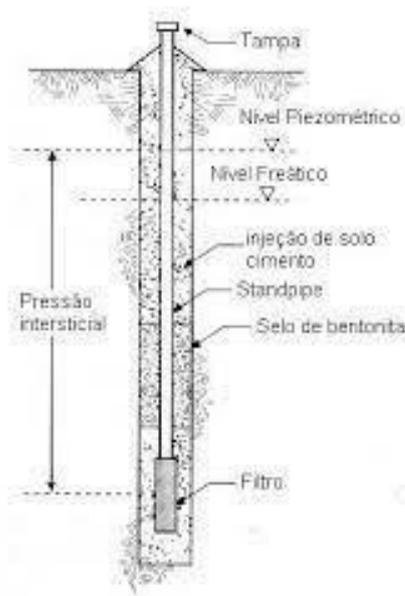
### 2.2.1 Piezômetro

É um instrumento de medição de pressão hidráulica, existindo diversos tipos disponíveis para aplicação. De um modo geral, piezômetros podem ser agrupados de acordo com a existência de um diafragma impermeável entre o transdutor e a tampa superior, consistindo principalmente de piezômetros elétricos e pneumáticos, enquanto os que não possuem um diafragma são principalmente representados por piezômetros “*Standpipe*” ou “*Casagrande*”, cuja instalação é feita de forma vertical e são normalmente instalados em furos de sondagem executados a partir das galerias de drenagem, conforme a Figura 6. O piezômetro “*Standpipe*” ficou popularmente conhecido pelo termo “*Casagrande*” após publicação de “*Measurement methods for monitoring pore water pressure during construction of Logan Airport in Boston*” (DUNICLIFF *apud* CASAGRANDE, 1949, 1958). Sendo este o tipo específico responsável pelo conjunto de dados do presente estudo.

O piezômetro *Standpipe* consiste em um tubo de medição vertical inserido no solo ou concreto da barragem, com um tubo de aço inoxidável ou plástico, com entradas na parte inferior para permitir a permeabilidade de água, sendo envolta com material filtrante, areia grossa, brita e, sobre essas camadas, areia fina (MACHADO, 2007). Essa água que adentra o tubo é chamada de água piezométrica e reflete a pressão hidráulica que age sob aquela

profundidade em que o piezômetro está inserido, sendo o local de medição isolado de qualquer contato com a pressão atmosférica, ou com camada diferente da que se deseja realizar a medição (MACHADO, 2007).

Figura 6 - Piezômetro Standpipe genérico



Fonte: (ANA, 2016)

O piezômetro é conectado a um dispositivo de leitura, que permite o monitoramento contínuo da pressão hidráulica que age na posição em que os piezômetros são instalados, posições estratégicas, como áreas críticas da fundação ou zonas onde ocorrem variações significativas de pressão, determinados por estudos geotécnicos e engenharia de barragens.

É importante ressaltar limitação destes instrumentos quando há mudanças bruscas de nível d'água nos reservatórios, pois apresenta atraso a resposta a esta variação até a equalização da pressão (MACHADO, 2007).

### 2.3 Séries temporais e análise de dados

O termo “série temporal” se refere a uma coletânea de dados e observações feitas sequencialmente ao longo do tempo, de forma que as observações vizinhas são dependentes, ou seja, uma série temporal é nada mais do que um conjunto de observações ou dados com ordem temporal com dependência (BARROS, 2009; WOOLDRIDGE, 2016).

Segundo Cryer e Chan (2008), uma sequência de variáveis aleatórias é chamada de Processo Estocástico e serve como um modelo, enquanto a série temporal é a realização de um processo estocástico. Em geral, a análise dessas séries consiste em um exame do conjunto de dados ao longo do tempo, de modo que seja encontrado um modelo matemático que possa gerar

esse conjunto, sendo que um modelo é uma representação simplificada da realidade que preserva uma equivalência adequada. Ele se torna desejável quanto maior for seu poder de representatividade, sendo que esse poder é verificado pela etapa de validação, onde se mede a adequabilidade do modelo à realidade.

Existem vários objetivos no estudo de séries temporais, dentre os quais se destacam: descrever a série, verificar suas características mais relevantes, verificar suas possíveis relações com outras séries e, por fim, prever a continuação dessa série, baseada em seu comportamento passado. O último objetivo, de predição, é uma das funções de maior importância quando aplicados à instrumentação e o seu papel em gerenciamento de riscos inerentes (HYNDMAN, 2018).

### 2.3.1 Componentes de uma série temporal

Componentes de séries temporais são diferentes padrões ou fatores que podem ser identificados em uma série temporal, a fim de entender e modelar seu comportamento ao longo do tempo. Esses componentes são úteis para decompor a série temporal em partes distintas, facilitando a análise e a previsão de tendências futuras (BROCKWELL; DAVIS, 2016) (HYNDMAN, 2018).

Ao decompor uma série temporal em seus componentes, é possível analisar cada parte separadamente e compreender melhor a estrutura dos dados. Isso pode ajudar a identificar padrões, tendências e flutuações significativas, além de fornecer informações valiosas para a previsão e o planejamento futuro. Existem várias técnicas e modelos estatísticos que podem ser aplicados para identificar e modelar os componentes de séries temporais, como a decomposição clássica, análise espectral, modelos autoregressivos, entre outros (NIELSEN, 2011).

Dentre as formas para separar esse componente da série como um todo, destaca-se a decomposição, onde é possível separar os vários componentes de formas variadas, como o modelo clássico aditivo onde se considera que cada a série completa é uma soma das componentes de tendência, sazonalidade e ruído, conforme a Equação (1):

$$Y_t = T_t + S_t + e_t \quad (1)$$

Existem geralmente quatro componentes principais em uma série temporal:

Tendência ( $T_t$ ): A tendência ou ciclo-tendência representa a direção geral do comportamento da série temporal ao longo do tempo e para fins de equacionamento, costuma

englobar o conceito do ciclo ao descrever o comportamento. Pode ser uma tendência crescente, decrescente ou até mesmo uma tendência constante. A identificação da tendência é importante para entender a evolução de longo prazo dos dados e pode ajudar a prever o comportamento futuro da série temporal.

Sazonalidade ( $S_t$ ): A sazonalidade refere-se a padrões que se repetem em intervalos fixos de tempo, geralmente com uma duração menor do que um ano. Esses padrões podem ser diários, semanais, mensais ou anuais e podem ser influenciados por fatores como estações do ano, feriados, eventos recorrentes, entre outros. A detecção e a modelagem da sazonalidade são importantes para entender flutuações regulares na série temporal.

Ciclo ( $m_t$ ): O ciclo representa flutuações de médio ou longo prazo que não são sazonais. Diferente da sazonalidade, o ciclo não segue um padrão fixo e pode ter uma duração maior do que um ano. Essas flutuações podem ser causadas por fatores econômicos, políticos ou outros eventos que ocorrem em intervalos irregulares. A identificação do ciclo é útil para entender oscilações de longo prazo na série temporal.

Ruído ( $e_t$ ): ruído refere-se a variações aleatórias e imprevisíveis na série temporal. Essas variações podem ser causadas por diversos fatores, como erros de medição, eventos imprevistos ou outros fatores não explicados pelos componentes anteriores. O ruído pode dificultar a análise e a previsão precisa da série temporal, uma vez que não segue nenhum padrão discernível.

### 2.3.1.1 Tendência

A tendência em séries temporais refere-se à direção geral do comportamento dos dados ao longo do tempo. Ela indica se a série está aumentando, diminuindo ou permanecendo estável ao longo de um período prolongado. A identificação e análise da tendência são fundamentais para compreender as mudanças de longo prazo nos dados e ajudam a prever seu comportamento futuro (HYNDMAN, 2018).

Existem diferentes tipos de tendência que podem ser observados em séries temporais:

- Tendência Crescente: Nesse caso, os valores da série aumentam de forma sistemática ao longo do tempo. Isso pode ser indicativo de um crescimento contínuo ou de uma mudança estrutural que causa um aumento nos dados;
- Tendência Decrescente: Aqui, os valores da série diminuem de forma sistemática ao longo do tempo. Isso pode ser resultado de uma diminuição contínua ou de uma

mudança estrutural que leva a uma queda nos dados;

- **Tendência Horizontal:** Nesse tipo de tendência, os valores da série permanecem relativamente estáveis ao longo do tempo, sem apresentar uma inclinação clara para cima ou para baixo. Isso pode indicar uma estabilidade ou um equilíbrio nas observações;
- **Tendência Não Linear:** Em certas situações, a tendência pode ser mais complexa e não seguir uma linha reta ou uma curva simples. A série pode exibir um comportamento não linear, com oscilações e mudanças irregulares ao longo do tempo.

Para identificar a tendência em uma série temporal, várias técnicas podem ser aplicadas, incluindo:

- **Visualização de dados:** A representação gráfica da série temporal, por meio de gráficos como linhas ou pontos, pode ajudar a identificar padrões de tendência visualmente. Observar a direção geral dos dados ao longo do tempo pode fornecer uma primeira indicação da existência e da natureza da tendência;
- **Médias móveis:** As médias móveis são usadas para suavizar os dados, removendo flutuações de curto prazo e destacando a tendência subjacente. Diferentes janelas de média móvel podem ser aplicadas para obter diferentes níveis de suavização e revelar a tendência de longo prazo;
- **Análise de regressão:** A regressão linear é outra abordagem popular para determinar a tendência em séries temporais. Nesse método, um modelo de regressão é ajustado aos dados, onde o tempo é tratado como a variável independente e os valores da série temporal são as variáveis dependentes. O coeficiente de inclinação estimado pelo modelo de regressão representa a tendência. Se o coeficiente for positivo, indica uma tendência crescente, enquanto um coeficiente negativo indica uma tendência decrescente;

#### 2.3.1.2 Sazonalidade

O componente sazonal em séries temporais refere-se a padrões regulares e previsíveis que se repetem em intervalos fixos de tempo. Esses padrões são influenciados por fatores sazonais, como estações do ano, feriados, eventos recorrentes e outros ciclos periódicos. A identificação e análise do componente sazonal são importantes para entender flutuações regulares nos dados e ajudam a prever o comportamento futuro da série temporal em períodos específicos. O componente sazonal exibe um padrão de repetição regular ao longo do tempo,

com oscilações que ocorrem em intervalos fixos, também possuindo diferentes durações e periodicidades.

Em algumas séries temporais, a variação sazonal é pronunciada, enquanto em outras apresenta maior sutileza, podendo apresentar simetria, com flutuações superiores ou inferiores à linha base.

Dentre as formas para separar esse componente da série como um todo, destaca-se a decomposição, onde é possível separar os vários componentes de formas variadas, como o modelo clássico aditivo onde se considera que cada a série completa é uma soma das componentes de tendência, sazonalidade e ruído, conforme a Equação (2):

$$y_t = S_t + T_t + e_t \quad (2)$$

Uma vez identificado o componente sazonal, ele pode ser modelado e incorporado em técnicas de previsão. Isso pode ser utilizando modelos específicos para séries temporais sazonais, como modelos sazonais ARIMA (SARIMA) ou modelos de suavização exponencial sazonal (ETS).

### 2.3.1.3 Ruídos

O ruído refere-se às flutuações não-sistemáticas ou aleatórias que não podem ser explicadas pelos demais componentes, sendo caracterizado por variações imprevisíveis e irregulares nos dados, sem uma estrutura ou padrão aparente. É geralmente referido como um componente residual.

Quando se comenta sobre variações imprevisíveis, refere-se a parte que não pode ser explicada de um conjunto de dados, é estocástico (BARROS, 2009), apresenta uma distinta falta de correlação em uma distribuição aleatória e simétrica.

A presença do ruído pode ter grande impacto na análise (NIELSEN, 2011), devido à imprevisibilidade e incerteza que introduz nos dados, podendo obscurecer tendências e padrões.

### 2.3.2 Modelos de predição

Uma série temporal é uma sequência de observações ou medidas coletadas em intervalos regulares de tempo. Essas observações são organizadas de forma cronológica, permitindo o estudo do comportamento e da evolução da variável ao longo do tempo.

A ideia de prever séries temporais envolve estimar ou inferir os valores futuros de uma variável ao longo do tempo com base em padrões e informações obtidas dos dados históricos dessa variável (HYNDMAN, 2018).

A previsão de séries temporais é uma área de estudo que busca entender e modelar os padrões e tendências presentes nos dados históricos para fazer projeções e estimativas para o futuro. Ela se baseia na suposição de que a estrutura temporal dos dados passados é útil para prever os valores futuros. A previsão pode ser feita em diferentes escalas de tempo, desde curto prazo até longo prazo, dependendo do contexto e do objetivo da análise.

Existem vários métodos e técnicas para a previsão de séries temporais, incluindo abordagens estatísticas, como modelos ARIMA (Média Móvel Integrada Autoregressiva) e modelos de suavização exponencial, além de abordagens mais avançadas, como modelos de espaço de estado, redes neurais e aprendizado de máquina. Esses métodos procuram identificar padrões, tendências, sazonalidades e outros componentes presentes nos dados históricos, e usá-los para fazer projeções e estimativas futuras.

A previsão de séries temporais tem uma ampla gama de aplicações em diferentes campos, como finanças, economia, meteorologia, ciência dos dados, saúde, entre outros. Ela desempenha um papel importante no planejamento, tomada de decisões, otimização de recursos, gestão de riscos e análise de tendências ao longo do tempo (ZHOU *et al*, 2021).

#### 2.3.2.1 Método “Ingênuo”

O método “Ingênuo”, também chamado de Método da Persistência, consiste em uma abordagem simples e direta para a previsão de séries temporais, onde ele assume que não há mudanças ou tendências nos dados que foram a série temporal e que o padrão observado irá se manter no futuro.

É um método de fácil implementação, com elevada eficiência computacional, sem a necessidade da construção de modelos complexos ou análise estatística sofisticada. A simplicidade, no entanto, trabalha se torna uma característica negativa ao realizar a aplicação do método em séries temporais que venham a apresentar maior complexidade e errática variação.

Segundo Hyndman (2018), o uso desse método consiste na consideração do último valor observado como o mesmo de todas as observações futuras, ou seja, se pressupõe que não haverá alterações significativas nos valores e o padrão se repetirá.

Dentro do método “Ingênuo”, existe uma vertente que considera o efeito sazonal de uma série temporal, ainda mantendo o princípio exposto anteriormente, sendo um método adequado para casos em são exibidos padrões sazonais regulares e previsíveis.

A aplicação é mais eficaz quando há um ciclo sazonal bem definido na série temporal, onde ele captura a regularidade dos padrões sazonais e projeta-os para o futuro. Ao contrário do método “Ingênuo” tradicional, em que apenas o último valor é usado como previsão futura, para a consideração do padrão sazonal se utiliza o valor observado no mesmo período sazonal do ano anterior como previsão para o próximo período, assumindo que os mesmos padrões irão se repetir ao longo do tempo.

Essa extensão do método original ainda contém limitações similares, onde ele não leva em consideração outros fatores que possam vir a influenciar a sazonalidade, como tendências ao longo do prazo ou efeitos externos, sendo um método menos preciso se houver variações irregulares nos padrões sazonais ao longo do tempo.

#### 2.3.2.2 Método de suavização exponencial

O método de suavização exponencial ou “*Exponential Smoothing (ETS)*” é particularmente adequado para séries temporais com tendência e padrões sazonais. Ele é baseado no princípio de que os valores futuros de uma série temporal são uma combinação ponderada dos valores passados, com pesos decrescentes exponencialmente à medida que os valores se afastam no tempo (MORETTIN, 2018).

É um método de fácil implementação alta eficiência do ponto de vista computacional, sendo baseado na iteração dos valores estimados, prestando atenção no ajuste dos parâmetros de suavização, com alta variação nas abordagens que podem ser utilizadas para alcançar os valores ótimos desses parâmetros.

Em geral, é dividido em três variantes que passam a incorporar a capacidade de lidar com componentes diferentes de uma série temporal:

**Suavização Exponencial Simples (SES):** Adequada para uma série, conforme a Equação (3, cuja tendência ou sazonalidades são inexistentes. Nessa vertente, é atribuído um peso exponencialmente decrescente a cada observação passada, com um parâmetro de suavização que controla a taxa de decaimento do peso (TALKHI *et al*, 2024).

$$y_{T+1|T} = \alpha y_t + \alpha(1 - \alpha)y_{T-1} + \alpha(1 - \alpha)^2 y_{T-2} + \dots \quad (3)$$

O valor atual é calculado com uma combinação ponderada do valor passado e do erro de previsão anterior. A suavização exponencial simples pondera as observações passadas com pesos decrescentes exponencialmente para previsão de valores futuros.

Este esquema de suavização começa definindo  $S_2$  para  $y_1$ , onde  $S_i$  representa a observação suavizada, e  $y$  representa a observação original. Os subscritos se referem aos períodos de tempo, 1, 2, ..., n. Para o terceiro período,  $S_3 = \alpha y_2 + (1-\alpha) S_2$ ; e assim por diante. Não há  $S_1$ ; a série suavizada inicia com a versão suavizada da segunda observação.

Para qualquer período de tempo  $t$ , o valor suavizado  $S_t$  é encontrado calculando

$$S_t = \alpha y_{t-1} + (1 - \alpha)S_{t-1} \quad 0 \leq \alpha \leq 1 \quad t \geq 3 \quad (4)$$

**Suavização Exponencial Dupla (DES):** Sendo uma extensão da primeira vertente, ele incorpora a capacidade de lidar com a componente de tendência (TALKHI *et al*, 2024). Ela inclui um parâmetro  $\gamma$  para suavizar a tendência ao longo do tempo, conforme a Equação (5):

$$\begin{aligned} S_t &= \alpha y_t + (1 - \alpha)(S_{t-1} + b_{t-1}) & 0 \leq \alpha \leq 1 \\ b_t &= \gamma(S_t - S_{t-1}) + (1 - \gamma)b_{t-1} & 0 \leq \gamma \leq 1 \end{aligned} \quad (5)$$

**Suavização Exponencial Tripla (TES):** Incorpora um parâmetro de sazonalidade, junto aos existentes nos métodos anteriores, para conseguir lidar com a sazonalidade em conjunto com a tendência. Sua relativa vantagem se manifesta em séries temporais com padrões estáveis, entretanto, tem grande dificuldade com mudanças abruptas ou medidas consideradas “outliers” (TALKHI *et al*, 2024).

O conjunto de equações resultantes, conforme a Equação (6), para levar em conta a sazonalidade são chamadas “Holt-Winters”

$$\begin{aligned} S_t &= \alpha \frac{y_t}{I_{t-L}} + (1 - \alpha)(S_{t-1} + b_{t-1}) \\ b_t &= \gamma(S_t - S_{t-1}) + (1 - \gamma)b_{t-1} \\ I_t &= \beta \frac{y_t}{S_t} + (1 - \beta)I_{t-L+m} \\ F_{t+m} &= (S_t + mb_t)I_{t-L+m} \end{aligned} \quad (6)$$

Sendo que,

$y$  é a observação;

$S$  é a observação suavizada;

$b$  é o fator de tendência;

$I$  é o índice sazonal;

$F$  é a previsão em  $m$  períodos adiante;

$t$  é um índice denotando um período;

$\alpha, \beta, \gamma$  são constantes que devem ser estimadas de tal modo que o MSE dos erros seja minimizado, sendo recomendado o uso de um bom pacote de softwares, como o R.

Quando tratando da classificação taxonômica do modelo, segundo Hyndman (2018), cada método possui dois modelos, um com sendo um com erros aditivos e outro com erros multiplicativos. Logo, ao se selecionar um modelo adequado para implementação de acordo com a característica da série temporal, é nomeado seguindo a regra ETS (-,-,-) para (Erro, Tendência, Sazonalidade), indicando se o tipo de modelo utilizados na suavização para as componentes, segundo a Quadro 5:

Quadro 5– Taxonomia de classificação das componentes

<b>Componente</b>	<b>Taxonomia</b>
<b>Erro</b>	{A,M}
<b>Tendência</b>	{N,A,A <sub>d</sub> }
<b>Sazonalidade</b>	{N,A,M}

Fonte: Hyndman (2018)

Sendo,

A = Aditivo;

A<sub>d</sub> = Aditivo amortecido

M = Multiplicativo

N = Nenhum

### 2.3.2.3 Modelo Auto-Regressivo Integrado de Médias Móveis (ARIMA)

O método ARIMA combina componentes autorregressivos (AR), média móvel (MA) e integração (I) para capturar diferentes aspectos das séries temporais, como tendências, sazonalidade e ruídos. Se mostra adequado para o caso da existência de dependência serial,

onde os valores atuais dependem em forma de correlação com os valores passados. Pressupõe-se que o valor atual previsto é uma combinação linear dos valores passados e dos erros residuais.

O modelo ARIMA assume que a série temporal seja estacionária, o que significa que suas propriedades estatísticas não mudam ao longo do tempo. A estacionariedade é geralmente avaliada por meio de análise visual do gráfico da série temporal e também pode ser verificada estatisticamente usando testes como o teste de Dickey-Fuller aumentado (ADF) ou o teste de Kwiatkowski-Phillips-Schmidt-Shin (KPSS). Se a série não for estacionária, será necessário aplicar transformações, como diferenciação, para torná-la estacionária antes de aplicar o modelo ARIMA (NUNES *et al*, 2023).

O modelo ARIMA é especificado por três parâmetros principais:  $p, d$  e  $q$ , sendo  $p$  o que representa o componente regressivo da combinação linear, mais especificamente, o número necessário de componentes regressivos para modelar a dependência serial. Já o componente  $d$  traz o número de diferenças não sazonais necessárias para transformar a série em uma série estacionária. O parâmetro  $q$  serve para capturar a dependência serial dos erros residuais, por meio de médias móveis.

A combinação entre os métodos de diferenciação e os modelos de autoregressão e média móvel resultam em um modelo ARIMA (AutoRegressive Integrated Moving Average model) não-sazonal, que pode ser descrito matematicamente como na (7) (NIELSEN, 2011):

$$y_t = c + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \theta_1 + \theta_1 e_{t-1} + \dots + \theta_q e_{t-q} + e_t \quad (7)$$

$y_t$  é a medida presente na série temporal no instante de tempo  $t$ ;

$\phi_1, \phi_2, \dots, \phi_p$  são os parâmetros autorregressivos, que representam a dependência linear da série;

$\epsilon_t$  é o termo de erro.

Uma das principais vantagens do modelo ARIMA é sua flexibilidade em lidar com uma variedade de padrões e características das séries temporais. Ele pode ser aplicado a séries com tendência, sazonalidade e flutuações aleatórias, permitindo a captura de diferentes componentes e comportamentos presentes nos dados (NUNES *et al*, 2023).

No entanto, o modelo ARIMA também apresenta algumas limitações e pontos fracos. Ele assume que os dados seguem um padrão linear, o que pode não ser adequado para séries temporais com comportamentos não lineares complexos.

Ao longo do tempo, várias variações e adaptações do modelo ARIMA foram desenvolvidas para lidar com diferentes cenários. Algumas delas incluem:

- SARIMA (Seasonal ARIMA): É uma combinação do modelo ARIMA com o modelo ARIMA sazonal, permitindo a modelagem e previsão de séries temporais com componentes autoregressivos, de média móvel, diferenciados e sazonais;
- ARIMAX (ARIMA com variáveis exógenas): É uma extensão do modelo ARIMA que permite incluir variáveis exógenas, além dos valores passados da série temporal, na modelagem e previsão;
- VARIMA (Vector Autoregressive Integrated Moving Average): É uma extensão do modelo ARIMA para séries temporais multivariadas, onde várias séries temporais são modeladas simultaneamente.

## 2.4 O ambiente R

O software R é uma linguagem de programação e ambiente de desenvolvimento amplamente utilizado para análise estatística e visualização de dados. Criado por Ross Ihaka e Robert Gentleman na Universidade de Auckland, Nova Zelândia, o R tem se destacado como uma das ferramentas mais poderosas e flexíveis disponíveis para análise de dados, especialmente em pesquisas acadêmicas e industriais (WICKHAM; ÇETINKAYA-RUNDEL; GROLEMUND, 2023).

R é um conjunto de ferramentas de software para manipulação, cálculo e demonstração gráfica de dados e pode ser considerado uma implementação da linguagem S que foi desenvolvida nos “Laboratórios Bell” por Rick Becker, John Chambers e Allan Wilks, também formando a base dos sistemas “*S-PLUS*” (VENABLES; SMITH, 2024).

O R foi desenvolvido pela primeira vez em meados da década de 1990 e teve sua versão estável inicial lançada em 2000. Desde então, tem experimentado um crescimento significativo em popularidade e adoção. Uma das principais razões para isso é a sua natureza de código aberto, que permite que uma comunidade global de desenvolvedores contribua com pacotes e extensões, expandindo constantemente suas capacidades (WICKHAM; ÇETINKAYA-RUNDEL; GROLEMUND, 2023).

O termo “Ambiente” é usado na pretensão de caracterizá-lo como um sistema completamente planejado e coerente, no lugar de uma acreção incremental de várias ferramentas específicas e inflexíveis, como acaba por ser o caso da maioria dos softwares para análise de dados (VENABLES; SMITH, 2024).

O ambiente R pode então ser caracterizado como um veículo para desenvolvimento de métodos interativos de análise de dados, sendo geralmente compartilhados com a comunidade no formato de “*packages*”. Dito isto, a maioria dos programas escritos em R possuem uma característica efêmera, ou seja, são criados para uma análise única e específica de dados.

#### 2.4.1 R na estatística

O mais comum uso do R é como um sistema estatístico ou para geração de análises e resultados estatísticos, mas essa é apenas uma das formas que o R pode ser feito uso, sendo assim, novamente faz-se uso do termo “Ambiente”, para descrever que o R consiste em um ambiente onde técnicas clássicas e modernas de estatística foram implementadas, sendo cerca de 25 pacotes supridos pela versão básica do R e muitos outros disponíveis na base de dados de pacotes chamada de CRAN (VENABLES; SMITH, 2024).

Existe uma importante divisão de filosofia entre a linguagem S (que é a linguagem em que R é baseado) e outros softwares de estatística presentes no mercado. No S, a análise estatística é feita como uma série de passos, com resultados intermediários sendo mantidos em objetos. Logo, enquanto SAS ou SPSS geram consideráveis resultados de uma análise de regressão, R irá dar um resultado mínimo que ficará mantido dentro de um objeto para que seja utilizado para gerar outros resultados a partir das devidas funções. O R fornece uma ampla variedade de procedimentos estatísticos básicos ou que exigem grande esforço computacional (modelagem linear e não linear, testes estatísticos clássicos, análise de séries temporais, classificação, agrupamento) e recursos gráficos elegantes. Um dos pontos fortes de R é a facilidade com que gráficos de qualidade podem ser produzidos, incluindo símbolos matemáticos e fórmulas, quando necessário. O ambiente R está disponível em uma ampla variedade de plataformas UNIX e sistemas similares (incluindo FreeBSD e Linux), Windows e MacOS (OLIVOTO; GIACOMINI, 2024).

#### 2.4.2 O software “RStudio”

Quem já é usuário de softwares por linhas de comando, como o SAS, provavelmente não notou nenhuma grande diferença até aqui. Toda análise se resume à seguinte sequência dados

> códigos > saída. A experiência do usuário com o R, no entanto, pode ser mais atrativa utilizando o RStudio16 (OLIVOTO; GIACOMINI, 2024).

O Rstudio é um produto de código aberto disponível publicamente em 28/02/2011 que está disponível gratuitamente. Ele é um ambiente de desenvolvimento integrado para R que inclui:

- Janelas de edição de texto a partir das quais o código pode ser enviado para o console e/ou salvo no sistema operacional,
- Listas de objetos em sua área de trabalho,
- Histórico infinito dos comandos facilmente pesquisável com capacidade de inserir, a partir do histórico, um comando no console novamente;
- Interface com o sistema operacional para acesso a arquivos;
- Janela de ajuda com botões de voltar e avançar;
- Download de pacotes.

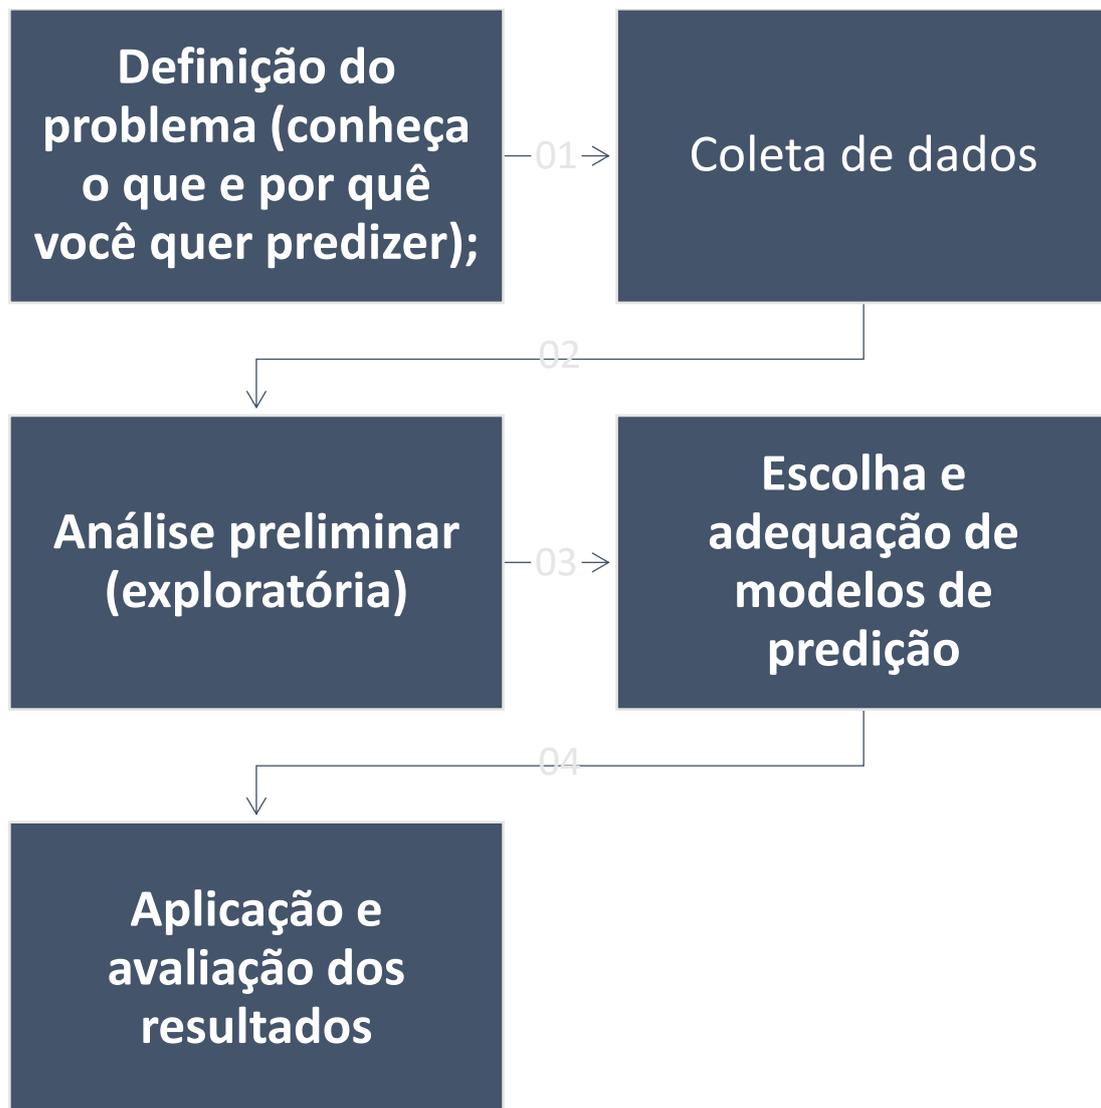
### 3 METODOLOGIA

A metodologia consiste em um tratamento dos dados, buscando permitir um estudo exploratório do comportamento inerente de cada série temporal, com o objetivo de avaliar a adequação delas para o uso dos modelos selecionados.

A metodologia proposta segue um processo sistemático dividido em várias etapas, desde a coleta e preparação dos dados até a validação e implementação do modelo de previsão. A

Figura 7 traz um fluxograma dos passos a serem seguidos quando tratando de uma típica previsão a partir de dados.

Figura 7 – Fluxograma de um processo de predição de dados



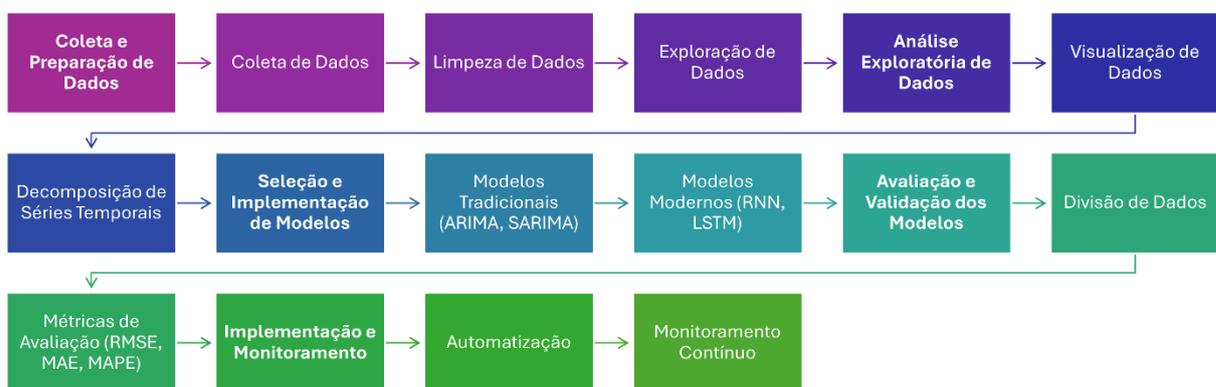
Fonte: Elaborada pelo autor

Em suma, o processo de previsão consiste em definir com exatidão a existência do problema no qual se necessita de uma previsão baseada em um histórico de dados existentes, de forma a efetivamente garantir que as respostas que busca responderão de fato o que deseja.

A partir dessa definição, existe a coleta de informação, seja a partir de instrumentos analíticos e digitais, pesquisa documental ou quaisquer que sejam os meios para adquirir o volume necessário para basear possíveis análises posteriores, onde esses dados irão então passar por uma análise exploratória generalizada, aos quais uma caracterização eficiente da natureza e detalhes de comportamento dos mesmo se faz necessária, pois é a partir dessa informação que modelos adequados de previsão de dados podem ser escolhidos e adaptados, de forma a funcionarem adequadamente à situação particular.

A avaliação dos resultados dos modelos selecionados geralmente se dá a comparar com os dados já existentes, buscando diminuir os erros da melhor forma possível, partindo então para a implementação dos modelos elencados como mais adequados para a situação presente. A Figura 8 traz de forma mais detalhada esse processo.

Figura 8 – Fluxograma detalhado aplicado



Fonte: Elaborado pelo autor

## I. Coleta e Preparação de dados

**a. Coleta de Dados:** Recolher dados históricos dos instrumentos de medição (piezômetros, inclinômetros, etc.)

**b. Limpeza de Dados:** Remover outliers, tratar valores ausentes e normalizar os dados para garantir consistência.

**c. Exploração de Dados:** Analisar estatisticamente os dados para entender padrões, sazonalidades e tendências.

## **II. Análise Exploratória de Dados**

**a. Visualização de Dados:** Utilizar gráficos de séries temporais, histogramas e correlações para identificar padrões.

**b. Decomposição de Séries Temporais:** Decompor as séries em componentes de tendência, sazonalidade e ruído.

## **III. Seleção e Implementação de Modelos**

**a. Modelos Tradicionais:** ARIMA (SARIMA), Suavização Exponencial.

**b. Modelos Modernos:** Redes Neurais, Machine Learning.

## **IV. Avaliação e Validação de Modelos**

**a. Divisão de Dados:** Separar os dados em conjuntos de treinamento e teste.

**b. Métricas de Avaliação:** Utilizar métricas como RMSE (Root Mean Square Error), MAE (Mean Absolute Error) e MAPE (Mean Absolute Percentage Error) para avaliar a performance dos modelos.

## **V. Implementação e Monitoramento**

**a. Automatização:** Desenvolver scripts para automatizar a coleta de novos dados e a atualização das previsões.

**b. Monitoramento Contínuo:** Implementar um sistema de monitoramento contínuo para ajustar os modelos conforme novos dados são coletados e para detectar anomalias em tempo real.

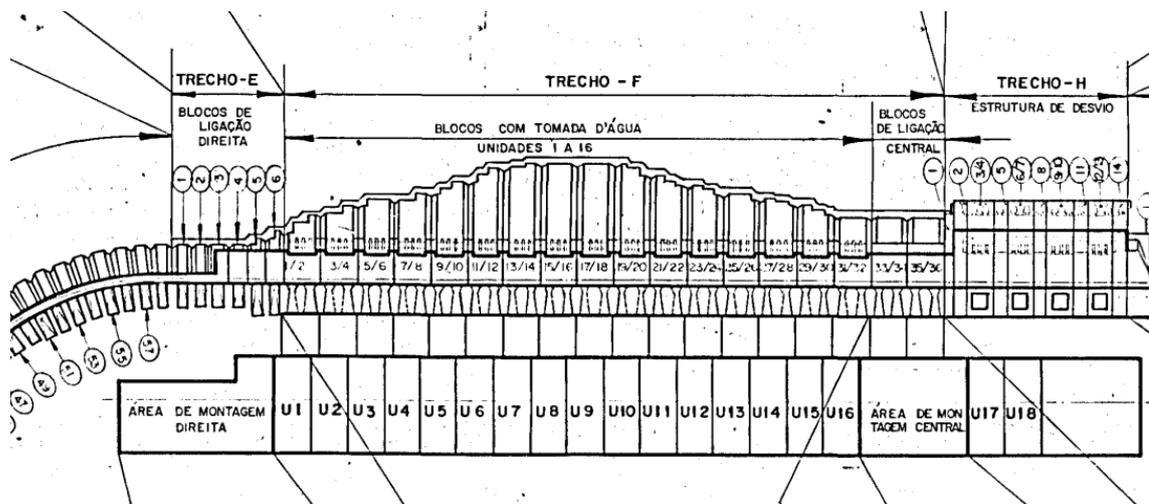
O escopo desse trabalho trata das etapas I – b, até IV – B, não entrando na automação e monitoramento contínuo para adequação constante a novos dados que viriam a ser disponíveis.

#### 4 ESTUDO DE CASO

A Barragem de Itaipu é dividida em trechos, sendo o trecho F a parte específica em que os instrumentos os quais geraram os dados pelos quais a predição será realizada se encontram.

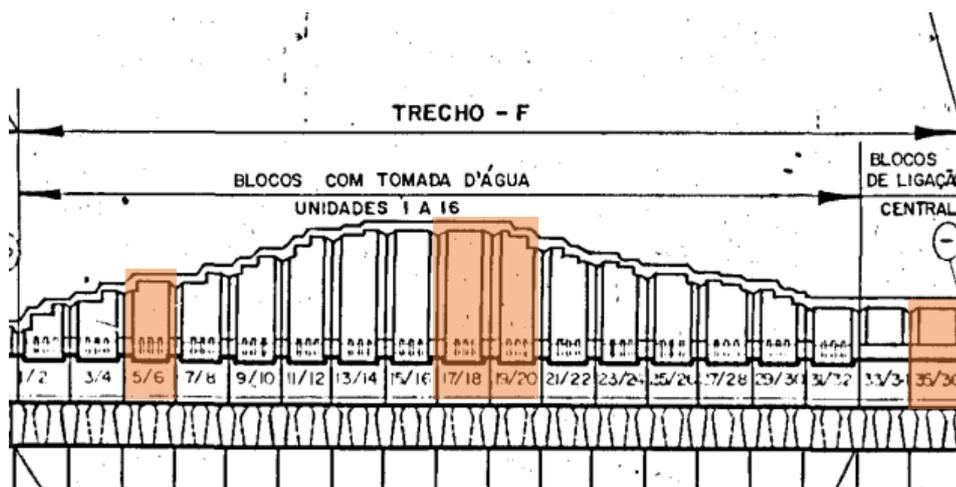
O presente trabalho tem como objetivo criar um modelo de predição de séries temporais oriundas da Usina Hidrelétrica de Itaipu para piezômetros do trecho F da barragem, conforme Figura 9.

Figura 9 – Trecho F da Barragem de Itaipu



Foram selecionados 4 blocos, destacados em vermelho na Figura 10.

Figura 10 – Blocos analisados em destaque



A Tabela 1 discrimina os nomes dos instrumentos, assim como a quantidade de observações presentes no conjunto de dados recebidos.

Tabela 1 – Relação dos piezômetros de análise

<b>Bloco</b>	<b>Instrumentos</b>	<b>Quantidade de observações</b>
5/6	PS-006	1599
	PS-007	1608
	PS-008	2240
	PS-009	2227
	PS-010	2240
	PS-011	2240
17/18	PS-061	2231
	PS-062	2236
	PS-063	1380
	PS-064	1376
19/20	PS-071	1429
	PS-072	1411
	PS-073	2281
	PS-074	2263
	PS-075	1368
35/36	PS-131	2240
	PS-132	1380
	PS-133	1193
	PS-134	1377

PS-135	1391
PS-136	1375

Fonte: Itaipu

A quantidade de observações mostradas consiste desde o início da instrumentação na barragem, em meados de 1981, estendendo-se até junho de 2022. Para realização das etapas citadas na metodologia, todos os dados passaram por um tratamento sistemático, sendo utilizado para fins demonstrativos o “PS-008”, mas considerando que as etapas citadas foram aplicadas para todos os 22 instrumentos.

## 5 RESULTADOS

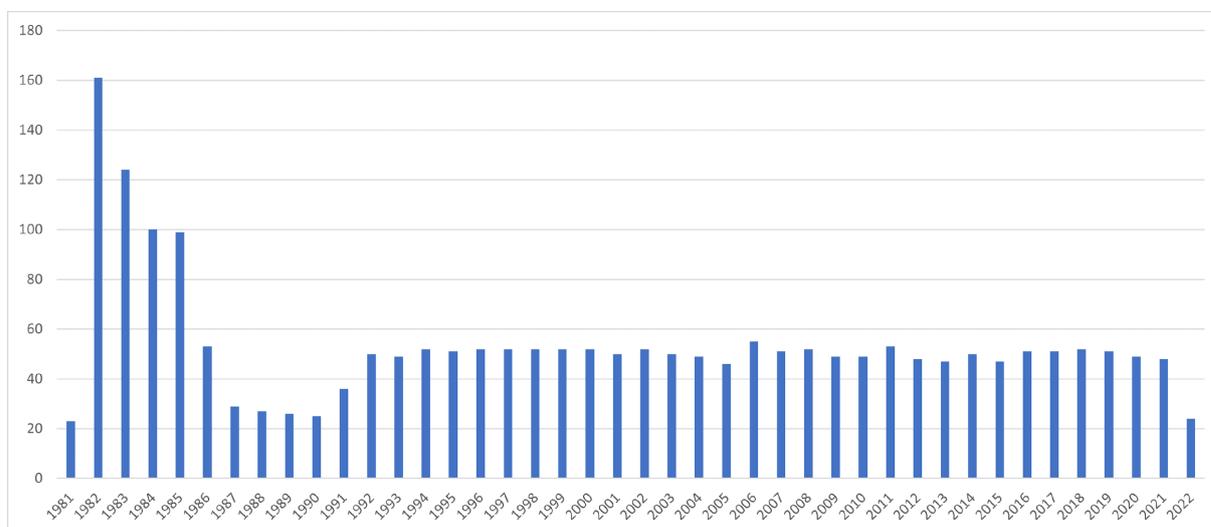
Partindo da metodologia apresentada, o presente capítulo mostra os resultados advindos das etapas mostradas I – b, até IV – c.

### 5.1 Limpeza e exploração de dados

Os dados recebidos passaram por uma análise inicial, visto a grande variação de observações em alguns casos, buscou-se encontrar uma regularidade das quantidades de medidas, sejam elas diárias, semanais, quinzenais etc.

A Figura 11 mostra a frequência das medições do “PS-008”.

Figura 11– Frequência de medições ao decorrer dos anos



Fonte: Elaborado pelo autor

Nota-se que a maior parte da variação se encontra nos anos iniciais, até assumir uma relativa estabilidade, a partir do ano de 1992.

Segundo Itaipu (1994), a barragem passou por 3 fases distintas de enchimento até que seu reservatório estivesse devidamente cheio conforme os limites estabelecidos em projeto, conforme a Tabela 2.

Tabela 2– Período de enchimento do reservatório da barragem

<b>ENCHIMENTO</b>	<b>INICIO</b>	<b>FIM</b>
<b>FASE 1</b>	13/10/1982	27/10/1982
<b>FASE 2</b>	27/10/1982	meados de abril/1984
<b>FASE 3</b>	meados de abril/1984	27/05/1984

Fonte: Itaipu (1994)

Primeiramente, visto a alta variação de observações, decidiu-se por trabalhar com intervalos mensais para a composição da série temporal dos instrumentos. Para tanto, os valores foram agrupados por mês e uma média aritmética simples foi realizada para chegar a um valor representativo para cada mês.

Os dados resultantes foram então transformados em uma série temporal dentro do software “RStudio”, por meio do Comando 1:

```
ps008 <- ts(data, start = 1981, frequency = 12) (1)
```

Onde:

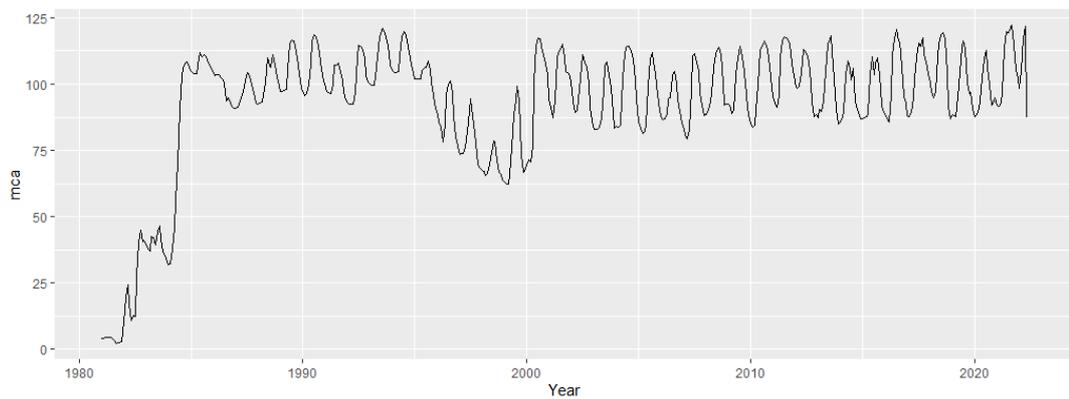
*data* representa o conjunto de dados importado para o software;

*start* representa o ano de início a se computar os dados;

*frequency* representa o número de divisões em que o ano será dividido.

A Figura 12 mostra a diferença de escala entre os valores nos primeiros anos e um certo nível de estabilização em uma faixa de medidas após 1984.

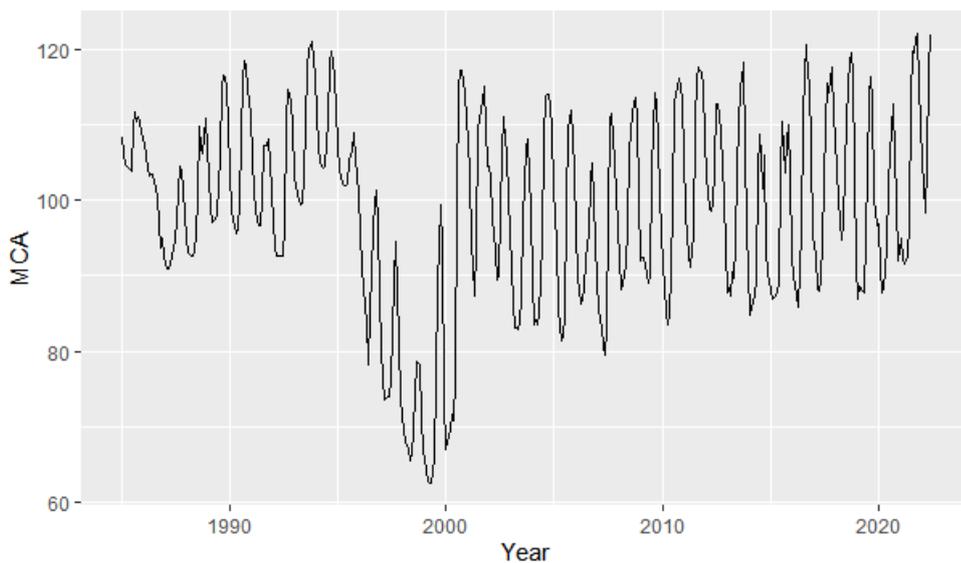
Figura 12 – Comportamento do Piezômetro PS-008 no intervalo 1981-2022



Fonte: Elaborado pelo autor

Baseado nessa diferença de escala, houve a tomada de decisão em descartar as medidas anteriores a janeiro de 1985 de todas as amostras, para razões de análise e predição de comportamento futuro. A Figura 13 traz o resultado da plotagem, após a retirada do intervalo citado.

Figura 13 – PS-008 com novo intervalo definido



Fonte: Elaborado pelo autor

A partir dessa etapa, com o conjunto de dados a ser analisado propriamente selecionado, se faz necessário partir para uma análise exploratória da série temporal, categorizando os componentes para ajustar os modelos corretamente para previsão.

## 5.2 Análise exploratória do objeto de estudo

As informações necessárias para ajustar os modelos de previsão para o conjunto de dados consistem em seus componentes estruturais: Tendência, Sazonalidade e Ruídos.

É possível ter hipóteses preliminares por meio de uma inspeção visual da série temporal plotada, como no caso da Figura 8, onde as primeiras conclusões que podem ser estimadas consistem na presença de uma característica sazonal visível e uma tendência diminuída.

Ainda utilizando o RStudio, foi aplicado um método de decomposição multiplicativo, com o Comando (2), para retirar efetivamente o as componentes para melhor compreensão da característica da série, demonstrados nas Figura 14Figura 15Figura 16.

```
decompose(ps008, type = c("multiplicative")) (2)
```

Onde:

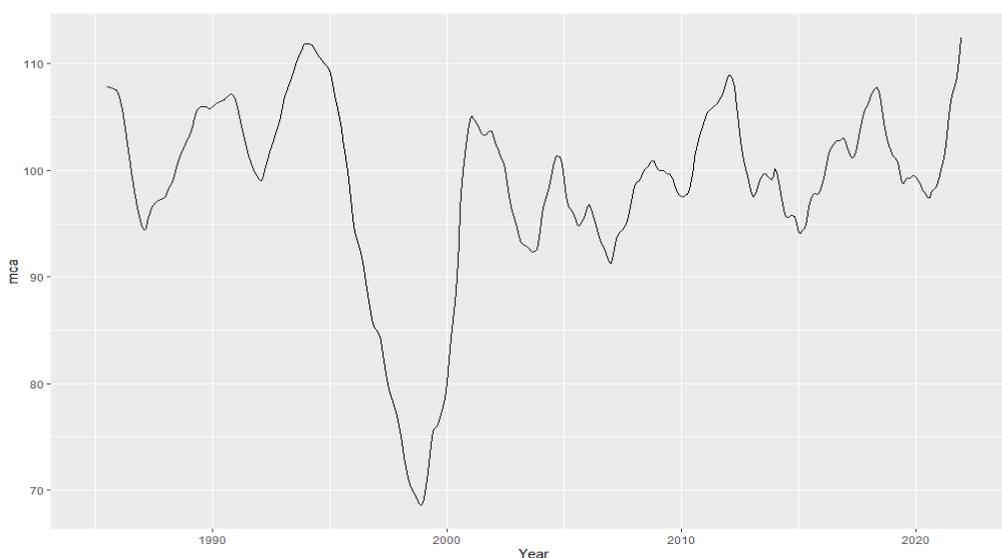
*decompose* representa a função que realiza a decomposição da série temporal;

*ps008* é a série que foi transformada em um objeto *ts*;

*type* é o tipo de método de decomposição selecionado.

A Figura 14 demonstra a componente de tendência obtida por meio do método de decomposição multiplicativo.

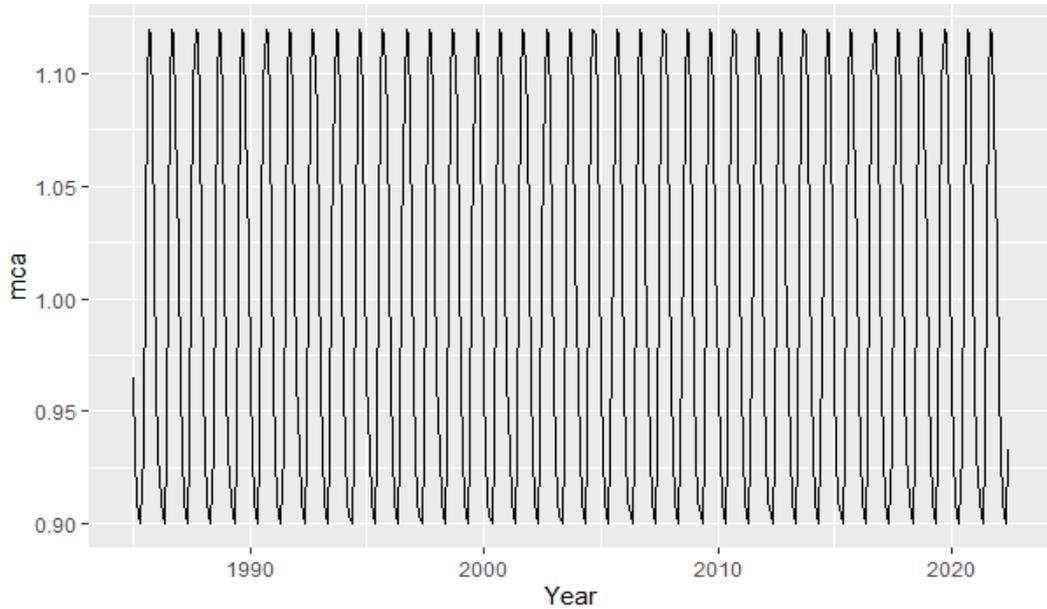
Figura 14 – Componente de Tendência do PS-008



Fonte: Elaborado pelo autor

A componente de tendência se mostra, em uma inspeção visual da sua característica, pouco expressiva, possuindo uma descontinuidade que aparenta como uma anormalidade do comportamento do instrumento durante o intervalo.

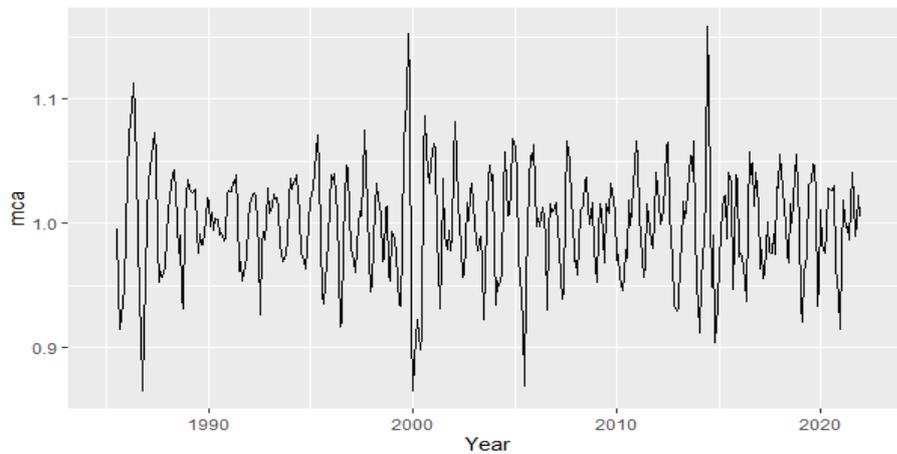
Figura 15 – Componente Sazonal do PS-008



Fonte: Elaborado pelo autor

A componente sazonal se mostra consistente durante todo seu intervalo temporal, afirmando a necessidade de um método que possa modelar o efeito sazonal quando realizando a predição de comportamento. Ao mesmo tempo, se observa que irregularidades e *outliers* estarão expressos nas outras componentes e sendo responsabilidade de outros fatores, independentes das mudanças sazonais.

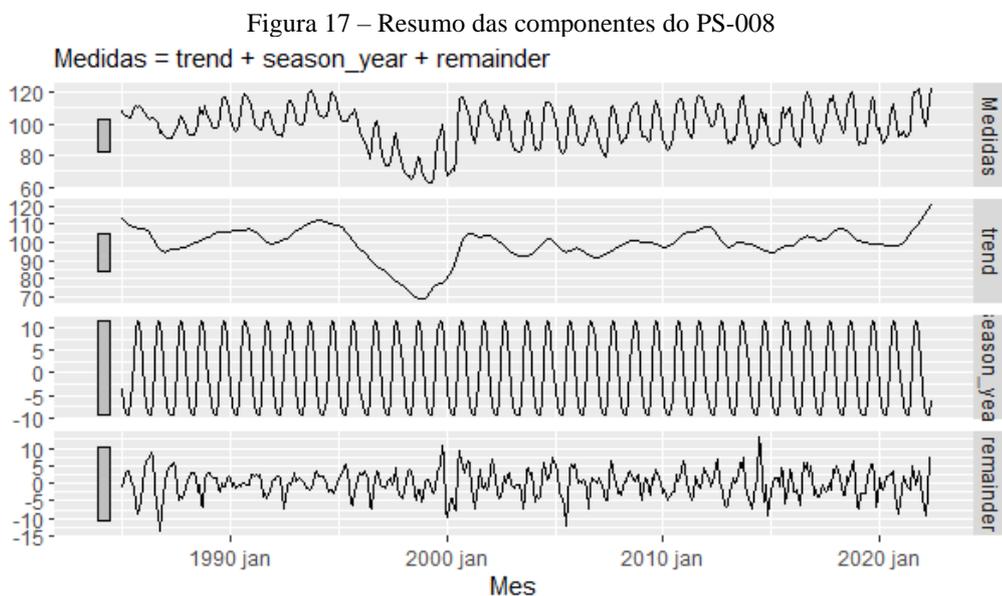
Figura 16– Ruído do PS-008



Fonte: Elaborado pelo autor

O componente de ruído se mostra consistente de forma que há pouca variação ao redor do eixo médio em 1,0 e com pouco peso no comportamento da série como um todo, entretanto, existem alguns picos em que o efeito se passa a ser mais expressivo.

A Figura 17 mostra os componentes gerais da série, em um formato conjunto.



Fonte: Elaborado pelo autor

O mesmo procedimento foi aplicado para caracterização dos 21 instrumentos. Partindo dessas informações, começa a próxima etapa, de seleção e ajuste de métodos de predição.

### 5.3 Seleção e implementação de modelos

Foram selecionados para verificação três modelos de predição, variando entre modelos tradicionais estocásticos, por meio de uso de pacotes de funções existentes no ambiente R. O Quadro 6 traz as respectivas funções utilizadas e os métodos.

Quadro 7– Relação dos métodos e suas funções em R

<b>Função</b>	<b>Método</b>
<i>ets</i>	Suavização Exponencial
<i>autoarima</i>	ARIMA
<i>snaive</i>	Ingênuo Sazonal

Fonte: Elaborado pelo autor

Foram aplicadas ainda dentro do ambiente R as funções de forma a determinar quais adequações seriam necessárias para aplicar os três métodos, sendo disponíveis na Tabela 3 os modelos selecionados:

Tabela 3 – Modelos de predição ajustados

<b>Instrumento</b>	<b>ETS</b>	<b>ARIMA(p,d,q)(P,D,Q)</b>	<b>SNAIVE</b>
<b>PS-006</b>	(A,N,N)	(2,1,2)(0,0,1)	drift
<b>PS-007</b>	(A,N,N)	(1,1,1)(0,0,1)	drift
<b>PS-008</b>	(A,N,A)	(1,0,1)(0,1,1)	drift
<b>PS-009</b>	(M,Ad,M)	(1,0,1)(0,1,2)	drift
<b>PS-010</b>	(A,Ad,N)	(2,1,2)(2,0,0)	drift
<b>PS-011</b>	(A,N,N)	(2,1,2)(2,0,0)	drift
<b>PS-061</b>	(M,Ad,M)	(1,0,1)(0,1,1)	drift
<b>PS-062</b>	(M,N,M)	(1,0,0)(1,1,2)	drift
<b>PS-063</b>	(A,N,A)	(3,0,0)(1,1,2)	drift
<b>PS-064</b>	(A,N,N)	(1,1,3)(0,0,2)	drift
<b>PS-071</b>	(A,Ad,A)	(5,0,0)(0,1,1)	drift
<b>PS-072</b>	(A,N,A)	(2,1,2)(0,0,2)	drift
<b>PS-073</b>	(M,Ad,M)	(2,0,1)(0,1,1)	drift
<b>PS-074</b>	(A,Ad,A)	(3,0,1)(1,1,1)	drift
<b>PS-075</b>	(M,N,N)	(0,1,5)	drift
<b>PS-131</b>	(M,Ad,A)	(1,1,1)(2,0,0)	drift
<b>PS-132</b>	(M,N,N)	(0,1,1)(2,0,0)	drift
<b>PS-133</b>	(A,N,N)	(1,1,1)(0,0,1)	drift
<b>PS-134</b>	(M,N,N)	(3,1,0)(2,0,1)	drift
<b>PS-135</b>	(A,Ad,N)	(3,1,2)	drift
<b>PS-136</b>	(M,Ad,N)	(2,1,4)	drift

Fonte: Elaborado pelo autor

Nota-se uma dificuldade maior de adequação dos modelos, necessitando de variações maiores nos termos sazonais e não-sazonais do modelo Arima para os instrumentos dos blocos centrais. Nos modelos de Suavização exponencial, cada componente pode apresentar um tipo de método variado, sendo o erro variando entre métodos aditivos e multiplicativos e as componentes de tendência e sazonalidade podendo não passar por nenhum método de suavização, além das opções que os erros possuem. A definição disso parte do estudo da

característica de cada série temporal e o levantamento de suas componentes através dos métodos de decomposição.

#### 5.4 Avaliação e validação dos modelos

A série é então dividida em um intervalo de Treino e um intervalo de Teste, conforme a Figura 18, tendo sido definidos do período de 1985 a 2016 e 2017 a 2022, respectivamente. A predição é feita com um modelo adequado e treinado pelo intervalo de treino, sendo avaliada sua taxa de acertos pelo intervalo de teste por meio do erro percentual absoluto médio (MAPE).

Figura 18 – Separação de série temporal em intervalos



Fonte: (HYNDMAN & ATHANASOPOULOS, 2018)

Adequando os modelos adquiridos no conjunto de dados de treino e comparando com o conjunto de teste, foi possível comparar os erros percentuais entre os métodos adquiridos, tendo os resultados visíveis na Tabela 4:

Tabela 4 – Respectiveos erros percentuais (MAPE)

<b>Piezômetros</b>	<b>SNAIVE</b>	<b>ETS</b>	<b>ARIMA</b>
<b>6</b>	1.05	0.703	0.734
<b>7</b>	1.24	1.21	0.877
<b>8</b>	13.1	8.84	10.7
<b>9</b>	13	6.94	9.27
<b>10</b>	1.22	0.492	0.961
<b>11</b>	0.685	0.760	0.382
<b>61</b>	19.7	17.8	14.3
<b>62</b>	12	11.1	10.1
<b>63</b>	358	85.3	150
<b>64</b>	8.13	7.89	8.65
<b>71</b>	7.55	6.61	7.06
<b>72</b>	1.39	1.35	1.13
<b>73</b>	28.7	22.2	25
<b>74</b>	30.1	27.8	28.4
<b>75</b>	2.43	1.82	2.39
<b>131</b>	6.36	1.15	2.38
<b>132</b>	2.39	1.05	1.33
<b>134</b>	4.20	1.46	1.50
<b>135</b>	7.26	1.94	1.78

<b>136</b>	4.65	1.31	1.31
<b>Melhores desempenhos</b>	<b>0</b>	<b>14</b>	<b>7</b>

Fonte: Elaborado pelo autor

Encontra-se destacado na Tabela 4 os melhores desempenhos para cada piezômetro, notando-se uma prevalência do método de Suavização Exponencial, apresentando-se com o menor erro o dobro de vezes em comparação ao método ARIMA.

O método ingênuo sazonal, considerado um método útil apenas para razões comparativas, mostrou ser sempre inferior a métodos mais sofisticados e robustos, sendo de acordo com a teoria vigente. Dito isso, ocorreram erros consideravelmente altos, ultrapassando a marca de 10%, nos piezômetros 61, 63, 73, 74, com foco no PS-063, cujo melhor desempenho tinha um erro de 85%, necessitando uma verificação e seleção de métodos mais contundente que possam ser mais bem adequados para as características apresentadas nessas séries e diminuam os erros para possivelmente trazer confiabilidade à predição.

## 6 CONCLUSÃO

A predição de séries temporais se mostrou um procedimento complexo, sendo necessários uma coleta e análise das particularidades dos dados e o contexto em que eles estão inseridos. A análise exploratória se mostrou como o aspecto mais importante, pois é a partir desse ponto que se conhece a série, tornando assim possível começar a pensar quais métodos devem ser testados.

Foram levantados para análise três métodos a serem adequados para aplicação nos piezômetros presentes nos blocos “5/6”, “17/18”, “19/20” e “35/36”, os quais foram adequados de acordo com as particularidades dos dados extraídos de cada um dos 21 instrumentos. Notou-se uma necessidade de maiores procedimentos de adequação nas séries de dados advindas dos piezômetros presentes nos blocos localizados ao centro do Trecho F.

Ao comparar os resultados da implementação desses modelos com os dados de teste separados inicialmente, o modelo de Suavização Exponencial se mostrou o mais adequado durante 2/3 dos casos, dito isso, observou-se uma preocupante taxa de erro de predição, principalmente nos piezômetros centrais, levando a crer da necessidade de um método de predição mais sofisticado para levar em conta o comportamento observado.

## BIBLIOGRAFIA

ASSIS, Lahis Souza de; BASTOS, Flávia de Souza; FARAGE, Michèle Cristina Resende; BARROS, Giovanna Tavares de. **Influência da temperatura no comportamento mecânico de uma viga de concreto armado**. The Journal Of Engineering And Exact Sciences, [S.L.], v. 9, n. 1, p. 15215-01, 12 jan. 2023. Universidade Federal de Vicosa. <http://dx.doi.org/10.18540/jcecvl9iss1pp15215-01a>.

BARROS, Mônica. **Processos estocásticos**. [s.l.]: Papel Virtual Editora, 2009.

BRASIL. Diário Oficial da União - República Federativa do Brasil - Imprensa Nacional. [S. l.], p. 00012010092100001, 2010.

BALANÇO ENERGÉTICO NACIONAL 2024: **Ano base 2023**. Rio de Janeiro: EPE, 2022a. Disponível em: <https://www.gov.br/mme/pt-br/assuntos/secretarias/sntep/publicacoes/balanco-energetico-nacional/ben-2024>. Acesso em set/2024.

BRASIL. Lei nº 12.337, de 20 de setembro de 2010. **Estabelece a Política Nacional de Segurança de Barragens destinadas à acumulação de água para quaisquer usos, à disposição final ou temporária de rejeitos e à acumulação de resíduos industriais, cria o Sistema Nacional de Informações sobre Segurança de Barragens e altera a redação do art. 35 da Lei nº 9.433, de 8 de janeiro de 1997, e do art. 4º da Lei nº 9.984, de 17 de julho de 2000**. Diário Oficial da União: seção 1, Brasília, DF, 20 set. 2010. Disponível em: <https://www2.camara.leg.br/legin/fed/lei/2010/lei-12334-20-setembro-2010-608607-publicacaooriginal-129691-pl.html>. Acesso em: 15 set. 2024.

COMITÊ BRASILEIRO DE BARRAGENS. **A legislação de segurança de barragens:: Um breve histórico e desafios. Um breve histórico e desafios**. 2024. Disponível em: <https://cbdb.org.br/a-legislacao-de-seguranca-de-barragens-um-breve-historico-e-desafios>. Acesso em: 06 dez. 2024.

COMISSÃO INTERNACIONAL DE GRANDES BARRAGENS. **As Barragens e a Água do Mundo: um livro educativo que explica como as barragens ajudam a administrar a água do mundo**. Comissão Internacional de Grandes Barragens, [S. l.], p. 74, 2008.

COELHO, Nailde de Amorim et al. **Um estudo numérico de efeitos térmicos em barragens**. 2013. Disponível em: <https://materialsandmateriais.blogspot.com/2013/05/artigo-tecnico-at-16-efeitos-termicos.html>. Acesso em: 18 out. 2023.

CRYER, Jonathan D.; CHAN, Kung-Sik. **Time Series Analysis: with applications in r**. 2. ed. New York: Springer Science+Business Media, Llc, 2008. 501 p.

DUNNICLIFF, J. **Geotechnical instrumentation for monitoring field performance**. New York: Wiley, 1988.

EGRIOGLU, Erol; ALADAG, Cagdas Hakan; YOLCU, Ufuk. **Fuzzy time series forecasting with a novel hybrid approach combining fuzzy c-means and neural networks**. Expert

Systems With Applications, [S.L.], v. 40, n. 3, p. 854-857, fev. 2013. Elsevier BV.  
<http://dx.doi.org/10.1016/j.eswa.2012.05.040>.

HICKMANN, Tásia. **Análise da variação térmica sazonal em barragem de contrafortes com uso de cálculo fracionário**. 2016. 139 f. Tese (Doutorado) - Curso de Programa de Pós-Graduação em Métodos Numéricos em Engenharia, Setor de Tecnologia, Universidade Federal do Paraná, Curitiba, 2016. Disponível em: <http://hdl.handle.net/1884/43384>. Acesso em: 18 out. 2023.

HOFFMANN, Karl. **An Introduction to Measurements using Strain Gages**. Darmstadt, Germany: Hottinger Baldwin Messtechnik GmbH, 1989. 273 p. Disponível em: [http://elektron.pol.lublin.pl/users/elekp/MNEQ\\_english/Hoffmann\\_An\\_Introduction\\_to\\_Measurements\\_using\\_Strain\\_Gages.pdf](http://elektron.pol.lublin.pl/users/elekp/MNEQ_english/Hoffmann_An_Introduction_to_Measurements_using_Strain_Gages.pdf). Acesso em: 16 out. 2023.

HYNDMAN, R.J., & ATHANASOPOULOS, G. (2018) **Forecasting: principles and practice**, 2nd edition, OTexts: Melbourne, Australia. OTexts.com/fpp2. Acessado em 16 out. 23.

ITAIPU BINACIONAL. **Hydroelectric Project – Engineering Features**. Curitiba – PR. 1994.

ITAIPU BINACIONAL. **Síntese das Principais Informações de Projeto para o Controle da Instrumentação da Barragem Principal - Trechos E, F e I** (4106.50.06001). Foz do Iguaçu. 1984.

LAZZAROTTO, Emerson. **Obtenção de limites estatísticos de controle em gráficos de controle univariados e multivariados aplicados a dados de instrumentação de barragens**. 2016. UNIVERSIDADE FEDERAL DO PARANÁ, [S. l.], 2016.

LI, Yangtao; BAO, Tengfei; GONG, Jian; SHU, Xiaosong; ZHANG, Kang. **The Prediction of Dam Displacement Time Series Using STL, Extra-Trees, and Stacked LSTM Neural Network**. IEEE Access, [S. l.], v. 8, 2020. DOI: 10.1109/ACCESS.2020.2995592. Disponível em: <https://ieeexplore-ieee-org.ez89.periodicos.capes.gov.br/document/9096332/>. Acesso em: 1 jun. 2022.

LU, Chi-Jie; LEE, Tian-Shyug; CHIU, Chih-Chou. **Financial time series forecasting using independent component analysis and support vector regression**. Decision Support Systems, [S.L.], v. 47, n. 2, p. 115-125, maio 2009. Elsevier BV.  
<http://dx.doi.org/10.1016/j.dss.2009.02.001>.

MACHADO, G. de F. **Monitoramento de Barragens de Contenção de Rejeitos da Mineração**. 2007. Dissertação (Mestrado em Engenharia Mineral) – Escola Politécnica, Universidade de São Paulo, São Paulo – MG, 2007.

MARIANO, A. M.; ROCHA, M. S. **Revisão da Literatura: Apresentação de uma Abordagem Integradora**. In: Anais XXVICongresoInternacionalAEDEM | 2017 AEDEM International Conference -Economy, Business and Uncertainty: ideas for a European and Mediterranean industrial policy. ISBN: 978-84-697-5592-1. Reggio Calabria- Italia. 2017. Disponível em

([https://www.researchgate.net/publication/319547360\\_Revisao\\_da\\_Literatura\\_Apresentacao\\_de\\_uma\\_Abordagem\\_Integradora](https://www.researchgate.net/publication/319547360_Revisao_da_Literatura_Apresentacao_de_uma_Abordagem_Integradora)) acesso em 17 de setembro de 2024.

MORETTIN, Pedro Alberto. **Análise de series temporais**. [S. l.], [s.d.]. Disponível em: [https://books.google.com/books/about/Análise\\_de\\_séries\\_temporais.html?hl=pt-BR&id=UwC5DwAAQBAJ](https://books.google.com/books/about/Análise_de_séries_temporais.html?hl=pt-BR&id=UwC5DwAAQBAJ). Acesso em: 13 jun. 2023.

NIELSEN, Søren Feodor. **Introductory time series with R**. [s.l.: s.n.]. v. 38 DOI: 10.1080/02664763.2010.517940.

NUNES, Lucas Renan Maués; VERAS, Juam Sousa; SILVA, João Pedro Ribeiro; CONTE, Thiago Nicolau Magalhães de Souza; SANTOS, Wilker José Caminha dos; OLIVEIRA, Roberto Célio Limão e. **Uso do ARIMA e SVM para previsão de séries temporais do sistema elétrico brasileiro**. Research, Society And Development, [S.L.], v. 12, n. 3, p. 1-16, 25 fev. 2023. Research, Society and Development. <http://dx.doi.org/10.33448/rsd-v12i3.40438>.

OMEGA (org.). **Termopares de Superfície para Fixação com Cimento**. Disponível em: [https://br.omega.com/temperature/images/CO-K\\_m.jpg](https://br.omega.com/temperature/images/CO-K_m.jpg). Acesso em: 18 out. 2023.

OMEGA (org.). **Termorresistência (Pt-100) para Montagem em Superfície**. Disponível em: [https://br.omega.com/temperature/images/SA1-RTD\\_m.jpg](https://br.omega.com/temperature/images/SA1-RTD_m.jpg). Acesso em: 18 out. 2023.

OMEGA (org.). **Sistema Multi-Canais de Monitoramento de Temperatura por Infravermelho**. Disponível em: [https://br.omega.com/temperature/images/OS-MINIHUB\\_m.jpg](https://br.omega.com/temperature/images/OS-MINIHUB_m.jpg). Acesso em: 18 out. 2023.

PEREIRA, Geraldo Luiz de Carvalho. **Efeitos térmicos em estruturas maciças de concreto**. 1986. 102 f. Dissertação (Mestrado) - Curso de Engenharia, Coordenação dos Programas de Pós-Graduação, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 1986. Cap. 1. Disponível em: <https://pantheon.ufrj.br/bitstream/11422/3658/1/164564.pdf>. Acesso em: 18 out. 2023.

PORTNOI, Marcos. **Extensometria: história, usos e aparelhos. HISTÓRIA, USOS E APARELHOS**. 2001. Disponível em: <https://www.eecis.udel.edu/~portnoi/academic/academic-files/extensometria.html>. Acesso em: 16 out. 2023

REIS, Marcelo Menezes. **INE 7001: análise de séries temporais**. Florianópolis: Universidade Federal de Santa Catarina, 2024. 55 p. Disponível em: <http://www.inf.ufsc.br/~marcelo.menezes.reis/Cap4.pdf>. Acesso em: 15 fev. 2024.

SAGHEER, Alaa; KOTB, Mostafa. **Time series forecasting of petroleum production using deep LSTM recurrent networks**. Neurocomputing, [S.L.], v. 323, p. 203-213, jan. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.neucom.2018.09.082>.

SHARMA, Abhishek B.; GOLUBCHIK, Leana; GOVINDAN, Ramesh. **Sensor faults: Acm Transactions On Sensor Networks**, [S.L.], v. 6, n. 3, p. 1-39, jun. 2010. Association for Computing Machinery (ACM). <http://dx.doi.org/10.1145/1754414.1754419>.

TALKHI, Nasrin; FATEMI, Narges Akhavan; NOOGHABI, Mehdi Jabbari; SOLTANI, Ehsan; NOOGHABI, Azadeh Jabbari. **Using meta-learning to recommend an appropriate time-series forecasting model.** *Bmc Public Health*, [S.L.], v. 24, n. 1, p. 327-345, 10 jan. 2024. Springer Science and Business Media LLC. <http://dx.doi.org/10.1186/s12889-023-17627-y>.

WOOLDRIDGE, Jeffrey M. **Introdução à econometria: uma abordagem moderna.**

ZHOU, Haoyi; ZHANG, Shanghang; PENG, Jieqi; ZHANG, Shuai; LI, Jianxin; XIONG, Hui; ZHANG, Wancai. **Informer: beyond efficient transformer for long sequence time-series forecasting.** *Proceedings Of The Aaai Conference On Artificial Intelligence*, [S.L.], v. 35, n. 12, p. 11106-11115, 18 maio 2021. Association for the Advancement of Artificial Intelligence (AAAI). <http://dx.doi.org/10.1609/aaai.v35i12.17325>.