



**Programa de Pós-Graduação em Instrumentação, Controle e  
Automação de Processos de Mineração (PROFICAM)  
Escola de Minas, Universidade Federal de Ouro Preto (UFOP)  
Associação Instituto Tecnológico Vale (ITV)**

**Dissertação**

**CLASSIFICAÇÃO DE FALHAS EM PROCESSO INDUSTRIAL DE MINERAÇÃO A  
PARTIR DE UMA REPRESENTAÇÃO FUZZY DE SÉRIES TEMPORAIS: ESTUDO  
DE CASO EM UMA USINA DE CARAJÁS (S11D)**

**Gabriel Vinícios Moreira Fernandes**

**Ouro Preto  
Minas Gerais, Brasil  
2022**

**Gabriel Vinícios Moreira Fernandes**

**CLASSIFICAÇÃO DE FALHAS EM PROCESSO INDUSTRIAL DE MINERAÇÃO A PARTIR DE UMA REPRESENTAÇÃO FUZZY DE SÉRIES TEMPORAIS: ESTUDO DE CASO EM UMA USINA DE CARAJÁS (S11D)**

Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração da Universidade Federal de Ouro Preto e do Instituto Tecnológico Vale, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Controle e Automação.

Orientador: Prof. Frederico Gadelha Guimarães, D.Sc.

Coorientador: Prof. Agnaldo José da Rocha Reis, D.Sc.

Ouro Preto  
2022

## SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

F363c Fernandes, Gabriel Vinícios Moreira.

Classificação de falhas em processo industrial de mineração a partir de uma representação fuzzy de séries temporais [manuscrito]: estudo de caso em uma usina de Carajás (S11D). / Gabriel Vinícios Moreira Fernandes. - 2022.

80 f.: il.: color., gráf., tab..

Orientador: Prof. Dr. Frederico Gadelha Guimarães.

Coorientador: Prof. Dr. Agnaldo José da Rocha Reis.

Dissertação (Mestrado Profissional). Universidade Federal de Ouro Preto. Programa de Mestrado Profissional em Instrumentação, Controle e Automação de Processos de Mineração. Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração.

Área de Concentração: Engenharia de Controle e Automação de Processos Mineraiis.

1. Sistemas difusos - Fuzzy Systems. 2. Indústria mineral. 3. Localização de falhas (Engenharia). I. Guimarães, Frederico Gadelha. II. Reis, Agnaldo José da Rocha. III. Universidade Federal de Ouro Preto. IV. Título.

CDU 681.5:622.2

Bibliotecário(a) Responsável: Maristela Sanches Lima Mesquita - CRB-1716



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DE OURO PRETO  
REITORIA  
ESCOLA DE MINAS  
PROGR. POS GRAD. PROF. INST. CONT. E AUT.  
PROCESSOS DE MIN.



**FOLHA DE APROVAÇÃO**

**Gabriel Vinícios Moreira Fernandes**

**Classificação de falhas em processo industrial de mineração a partir de uma representação fuzzy de séries temporais: Estudo de caso em uma usina de Carajás (S11D)**

Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração (PROFICAM), Convênio Universidade Federal de Ouro Preto/Associação Instituto Tecnológico Vale - UFOP/ITV, como requisito parcial para obtenção do título de Mestre em Engenharia de Controle e Automação na área de concentração em Instrumentação, Controle e Automação de Processos de Mineração

Aprovada em 06 de setembro de 2022

**Membros da banca**

Doutor - Frederico Gadelha Guimarães - Orientador - Universidade Federal de Minas Gerais  
Doutor - Agnaldo José da Rocha Reis - Universidade Federal de Ouro Preto  
Doutor - Alan Kardek Rêgo Segundo - Universidade Federal de Ouro Preto  
Doutor - Rodrigo César Pedrosa Silva - Universidade Federal de Ouro Preto  
Doutor - Leonardo Amaral Mozelli - Universidade Federal de Minas Gerais

Frederico Gadelha Guimarães, orientador do trabalho, aprovou a versão final e autorizou seu depósito no Repositório Institucional da UFOP em 21/11/2022



Documento assinado eletronicamente por **Saul Emanuel Delabrida Silva, VICE-COORDENADOR(A) DE CURSO DE PÓS-GRADUAÇÃO EM INST. CONT. E AUTOMAÇÃO DE PROCESSOS DE MINERAÇÃO**, em 22/11/2022, às 15:36, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufop.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0429413** e o código CRC **FD121254**.

Referência: Caso responda este documento, indicar expressamente o Processo nº 23109.015671/2022-86

SEI nº 0429413

R. Diogo de Vasconcelos, 122, - Bairro Pilar Ouro Preto/MG, CEP 35402-163  
Telefone: (31)3552-7352 - [www.ufop.br](http://www.ufop.br)

*Agradeço a Deus pela vida!*

# Agradecimentos

Agradeço a Deus em primeiro lugar, por iluminar meu caminho durante toda a minha vida. Sem ele não seria possível chegar até aqui. Agradeço a minha mãe Maria da Conceição, ao meu pai José Carlos e minha irmã Maria Thereza por me apoiarem ao longo dessa jornada. Agradeço ao meu tio Geraldo (*in memoriam*) pelos momentos compartilhados ao longo da vida. Família é o centro de tudo! Agradeço aos orientadores Frederico Gadelha e Agnaldo Reis pelos ensinamentos, paciência e tempo dedicado no suporte necessário a conclusão deste trabalho. Agradeço a minha companheira Priscila Carvalho pela paciência, incentivo e ajuda durante o processo da minha dissertação. Não obstante, obrigada a Vale SA por impulsionar o desenvolvimento de seus colaboradores e por disponibilizar os dados para a realização da pesquisa. Não obstante, obrigada a Vale SA por impulsionar o desenvolvimento de seus colaboradores e por disponibilizar os dados para a realização da pesquisa.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ), do Instituto Tecnológico Vale (ITV) e da Universidade Federal de Ouro Preto (UFOP).

*"Ao vencido, ódio ou compaixão;  
ao vencedor, as batatas"*  
**(Machado de Assis, *Quincas  
Borba* (1994)).**

## **Resumo**

Resumo da Dissertação apresentada ao Programa de Pós Graduação em Instrumentação, Controle e Automação de Processos de Mineração como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

### **CLASSIFICAÇÃO DE FALHAS EM PROCESSO INDUSTRIAL DE MINERAÇÃO A PARTIR DE UMA REPRESENTAÇÃO FUZZY DE SÉRIES TEMPORAIS: ESTUDO DE CASO EM UMA USINA DE CARAJÁS (S11D)**

Gabriel Vinícios Moreira Fernandes

Setembro/2022

Orientadores: Frederico Gadelha Guimarães

Agnaldo José da Rocha Reis

O Brasil é um dos mais importantes produtores de minérios do mundo e com potencial para crescer ao longo dos anos. O setor de mineração demanda a adoção de tecnologia da informação para o desenvolvimento de sistemas especializados que permitam uma melhor eficiência da produção. O mercado de mineração deve aderir a inovação para automação de tarefas repetitivas, integração de sistemas, melhoria contínua de processos, redução de riscos de desastres e adaptação ao contexto global. Nesta perspectiva, o estudo implementou inteligência artificial para classificar falhas de sensores na britagem secundária na Usina A do Projeto Ferro S11D, da Empresa Vale, localizada em Canaã dos Carajás, Pará, região Norte do Brasil. O trabalho de pesquisa testou modelos matemáticos, desenvolveu uma metodologia com modelos Fuzzy Time Series e classificador baseado em árvore de decisão e obteve-se resultados com dados coletados da respectiva Planta O resultado deste estudo contribuiu para o desempenho da plantas de beneficiamento de minério de ferro, melhorou a eficiência do sistema de britagem, reduziu paradas inesperadas e mitigou irregularidades no processo produtivo. O resultado obtido com a metodologia proposta foi o aumento da acurácia de 79,3% para 98,9% e f-score de 58,8% para 98,9%.

**Palavras-chave:** Sistemas difusos, Mineração, Detecção de Falhas.

**Macrotema:** Usina; **Linha de Pesquisa:** Tecnologias da Informação, Comunicação e Automação Industrial; **Tema:** Manutenção Preventiva, Preditiva e Corretiva; **Área Relacionada da Vale:** Automação de Processo e beneficiamento Mineral.

## Abstract

Abstract of Dissertation presented to the Graduate Program on Instrumentation, Control and Automation of Mining Process as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

# CLASSIFICATION OF FAILURES IN MINING INDUSTRIAL PROCESS FROM A FUZZY REPRESENTATION OF TIME SERIES: CASE STUDY AT THE PLANT IN CARAJÁS (S11D)

Gabriel Vinicios Moreira Fernandes

September/2022

Advisors: Frederico Gadelha Guimarães

Agnaldo José da Rocha Reis

Brazil is one of the most important mineral producers in the world and with potential to grow over the years. The mining sector demands adoption of information technology to develop specialist systems that allow better production. The mining market should join innovation toward automation of repetitive tasks, continuous improvement, disaster risk reduction and adaptation to the global context. In this perspective, the study aims to implement artificial intelligence to classify sensor failure in secondary screening at Plant A of Iron S11D, from Vale Company, located in Canaã dos Carajás, Pará, North of Brazil. The research tested mathematical models, developed an application with Fuzzy Time Series models, and simulated results with data collected from Plant, until it was able to validate the sensor failures. This study contributed to performance improvements in iron ore processing plants, crushing system efficiency and reducing the number of the unexpected stops. The result obtained with a proposed methodology of accuracy from 79,3% to 98,9% and f-score that was previously 58,8% and became 98,9%.

**Keywords:** Fuzzy Systems, Mining, Failure Detection.

**Macrotheme:** Plant; **Research Line:** Information Technology, Communication, and Automation Technology; **Theme:** Preventive, Predictive, and Corrective Maintenance; **Related Area of Vale:** Industrial Automation and Mineral processing.

# Lista de Figuras

Figura 1.1	Vista superior da Usina do S11D. . . . .	17
Figura 1.2	Overview do processo de peneiramento primário. . . . .	18
Figura 1.3	Detalhes das Linhas 1 e 2 do Peneiramento primário. . . . .	20
Figura 1.4	Detalhamento da indicação de nível dos silos. . . . .	21
Figura 2.1	Processo de Fuzzificação. . . . .	25
Figura 2.2	Tipos de particionamentos para 20 conjuntos nebulosos. . . . .	30
Figura 2.3	Funções de pertinência triangular, trapezoidal e gaussiana. . . . .	30
Figura 2.4	Treinamento de uma série temporal fuzzy multivariada. . . . .	32
Figura 2.5	Processo de predição da variável endógena. . . . .	33
Figura 2.6	Grânulos de informação fuzzy. . . . .	33
Figura 2.7	Processo de conversão de uma série temporal multivariada em uma série temporal univariada. . . . .	34
Figura 2.8	Processo de treinamento da <i>PWFTS</i> . . . . .	35
Figura 2.9	Dinâmica de aplicação do teste de raiz unitária ADF. . . . .	38
Figura 3.1	Sequência de processamento dos dados com melhoria proposta. . . . .	41
Figura 3.2	Metodologia de construção do classificador com os pesos e regras da <i>PWFTS</i> . . . . .	41
Figura 3.3	Correia transportadora móvel (TR-2011KS-10) posicionada no silo de número 6 (SI-2012KS-06). . . . .	42
Figura 3.4	Correia transportadora móvel (TR-2011KS-10) posicionada no silo de número 6 (SI-2012KS-06). . . . .	42
Figura 3.5	Correia transportadora móvel (TR-2011KS-10) posicionada no silo de número 6 (SI-2012KS-06). . . . .	43
Figura 3.6	Correia transportadora móvel (TR-2011KS-10) posicionada no silo de número 6 (SI-2012KS-06). . . . .	43
Figura 3.7	Correia transportadora móvel (TR-2011KS-10) posicionada no silo de número 6 (SI-2012KS-06). . . . .	44
Figura 3.8	Sensor do tipo radar VEGAPULS 69. . . . .	44
Figura 3.9	Funcionamento esperado do sensor de nível do silo. . . . .	45
Figura 3.10	Indicação das falhas do sensor de nível do silo – taxa de variação indevida. . . . .	45

Figura 3.11	Indicação das falhas do sensor de nível do silo – “congelamento” da leitura do sensor. . . . .	46
Figura 3.12	Análise inicial dos dados-Visualização de LIT_2012KS_0251. . . . .	47
Figura 3.13	Análise inicial dos dados-Visualização de AL_2012KS_06M1_SpeedActual. . . . .	47
Figura 3.14	Análise inicial dos dados-Visualização de WIT_1085KS_2300_BeltLoad. . . . .	49
Figura 3.15	Análise inicial dos dados-Visualização WIT_1085KS_2300_Rate. . . . .	49
Figura 3.16	Análise inicial dos dados-Visualização de LIT_2012KS_0251 com falhas. . . . .	49
Figura 3.17	Análise inicial dos dados-Visualização de AL_2012KS_06M1_SpeedActual com falhas. . . . .	50
Figura 3.18	Análise inicial dos dados-Visualização de WIT_1085KS_2300_BeltLoad com falhas. . . . .	50
Figura 3.19	Análise inicial dos dados-Visualização WIT_1085KS_2300_Rate com falhas. . . . .	50
Figura 3.20	Particionamentos aplicados a variável LIT_2012KS_0251 -10 conjuntos nebulosos. . . . .	51
Figura 3.21	Particionamentos aplicados a variável AL_2012KS_06M1_SpeedActual -10 conjuntos nebulosos. . . . .	51
Figura 3.22	Particionamentos aplicados a variável WIT_1085KS_2300_BeltLoad -10 conjuntos nebulosos. . . . .	51
Figura 3.23	Particionamentos aplicados a variável WIT_1085KS_2300_Rate -10 conjuntos nebulosos. . . . .	51
Figura 4.1	Decomposição de sazonalidade e tendência da variável LIT considerada neste classificador. . . . .	54
Figura 4.2	Decomposição de sazonalidade e tendência da variável ALS considerada neste classificador. . . . .	55
Figura 4.3	Decomposição de sazonalidade e tendência da variável BL considerada neste classificador. . . . .	56
Figura 4.4	Decomposição de sazonalidade e tendência da variável Rate considerada neste classificador. . . . .	57
Figura 4.5	Gráfico de autocorrelação de LIT. . . . .	57
Figura 4.6	Gráfico de autocorrelação de ALS. . . . .	58
Figura 4.7	Gráfico de autocorrelação de WIT_1095KS_2300_BeltLoad. . . . .	58
Figura 4.8	Gráfico de autocorrelação de WIT_1095KS_2300_Rate. . . . .	59
Figura 4.9	Gráfico de autocorrelação parcial de LIT. . . . .	59
Figura 4.10	Gráfico de autocorrelação parcial de ALS. . . . .	59
Figura 4.11	Gráfico de autocorrelação parcial de WIT_1095KS_2300_BeltLoad. . . . .	60
Figura 4.12	Gráfico de autocorrelação parcial de WIT_1095KS_2300_Rate. . . . .	60
Figura 4.13	Gráfico de autocorrelação de LIT - dados com as falhas. . . . .	60
Figura 4.14	Gráfico de autocorrelação de ALS - dados com as falhas. . . . .	61

Figura 4.15	Gráfico de autocorrelação de WIT_1095KS_2300_BeltLoad. . . . .	61
Figura 4.16	Gráfico de autocorrelação de WIT_1095KS_2300_Rate - dados com as falhas. . . . .	61
Figura 4.17	Gráfico de autocorrelação parcial de LIT - dados com as falhas. . . . .	62
Figura 4.18	Gráfico de autocorrelação parcial de ALS - dados com as falhas. . . . .	62
Figura 4.19	Gráfico de autocorrelação parcial de WIT_1095KS_2300_BeltLoad - dados com as falhas. . . . .	62
Figura 4.20	Gráfico de autocorrelação parcial de WIT_1095KS_2300_Rate - dados com as falhas. . . . .	63
Figura 4.21	Gráfico de correlação cruzada de LIT - dados com as falhas. . . . .	63
Figura 4.22	Gráfico de autocorrelação parcial de ALS - dados com as falhas. . . . .	63
Figura 4.23	Gráfico de correlação cruzada de WIT_1095KS_2300_BeltLoad - dados com as falhas. . . . .	64
Figura 4.24	Gráfico de autocorrelação parcial de WIT_1095KS_2300_Rate - dados com as falhas. . . . .	64
Figura 4.25	Gráfico de correlação cruzada de LIT o próprio LIT. . . . .	64
Figura 4.26	Gráfico de correlação cruzada de ALS com LIT. . . . .	65
Figura 4.27	Gráfico de correlação cruzada de BL com LIT. . . . .	65
Figura 4.28	Gráfico de correlação cruzada de Rate e com LIT. . . . .	65
Figura 5.1	Gráfico do modelo da <i>PWFT</i> de LIT. . . . .	66
Figura 5.2	Gráfico do modelo da <i>PWFTS</i> de ALS. . . . .	67
Figura 5.3	Gráfico do modelo da <i>PWFTS</i> de WIT_1095KS_2300_BeltLoad . . . . .	68
Figura 5.4	Gráfico do modelo da <i>PWFTS</i> de WIT_1095KS_2300_Rate . . . . .	69

# Lista de Tabelas

Tabela 2.1	Matriz de confusão de um classificador. . . . .	36
Tabela 2.2	Matriz de Confusão para 2 classes. . . . .	36
Tabela 3.1	Particionamento do UoD da variável LIT_2012KS_0251 . . . . .	48
Tabela 3.2	Particionamento do UoD da variável AL_2012KS_06M1_SpeedActual . . . . .	48
Tabela 3.3	Particionamento do UoD da variável WIT_1085KS_2300_BeltLoad . . . . .	48
Tabela 3.4	Particionamento do UoD da variável WIT_1085KS_2300_Rate . . . . .	52
Tabela 4.1	Tabela das variáveis e tags de campo. . . . .	53
Tabela 4.2	Teste ADF para LIT. . . . .	54
Tabela 4.3	Teste ADF para ALS. . . . .	54
Tabela 4.4	Teste ADF para BL. . . . .	55
Tabela 4.5	Teste ADF para Rate. . . . .	56
Tabela 4.6	Resultados do Teste de Levene. . . . .	56
Tabela 5.1	Matriz de Confusão XGBoost . . . . .	70
Tabela 5.2	Matriz de Confusão XGBoost + <i>PWFTS</i> . . . . .	70
Tabela 5.3	Comparativo de Métricas . . . . .	71

# Lista de Siglas e Abreviaturas

**AR** Modelo auto-regressivo

**FIG** Fuzzy Information Granule

**FLR** Fuzzy Logical Relationship

**FLRG** Fuzzy Logical Relationship Group

**FTS** Fuzzy Time Series

**HOFLR** High Order Fuzzy Logical Rules

**HOFTS** High Order Fuzzy Time Series

**I4.0** Industria 4.0

**IA** Inteligencia Artificial

**LHS** Left Hand Side

**MIMO** Multiple Input Multiple Output

**ML** Machine Learning

**PWFTS** Probabilistic Weighted Fuzzy Time Series

**RHS** Right Hand Side

**SCADA** Supervisory Control and Data Acquisition

**SDCD** Sistema Digital de Controle Distribuído

**UoD** Universo de Discurso

**XGBoost** Extreme Gradient Boosting

# Sumário

<b>1</b>	<b>Introdução</b>	<b>16</b>
1.1	Estudo de caso . . . . .	19
1.2	Motivação . . . . .	19
1.3	Objetivos . . . . .	20
1.3.1	Objetivos específicos . . . . .	20
1.4	Contribuições . . . . .	21
1.5	Publicações Científicas . . . . .	21
1.6	Estrutura do Trabalho . . . . .	21
<b>2</b>	<b>Referencial Teórico e Fundamentação Científica</b>	<b>22</b>
2.1	Séries Temporais . . . . .	22
2.2	Aplicação de Agrupamentos Fuzzy . . . . .	23
2.3	Fuzzy Time Series – Treinamento e Classificação . . . . .	24
2.4	Modelos de alta ordem . . . . .	29
2.5	Aplicação de Fuzzy Time Series . . . . .	31
2.6	Aplicação de Fuzzy Time Series Multivariadas . . . . .	31
2.7	Probabilistic Weighted Fuzzy Time Series (PWFTS) . . . . .	34
2.8	XGBoost . . . . .	35
2.9	Avaliação de modelos - Matriz de confusão . . . . .	36
2.10	Análise de Dick-Fuller Aumentada . . . . .	37
2.11	Teste homocedasticidade de Levene . . . . .	38
<b>3</b>	<b>Materiais e Métodos</b>	<b>40</b>
3.1	Metodologia . . . . .	40
3.1.1	Descrição dos modos de falha . . . . .	41
3.1.2	Modo de falha (sensor de nível de silo) - VEGAPULS 69 . . . . .	43
3.2	Universo dos dados . . . . .	45
<b>4</b>	<b>Caracterização dos Dados</b>	<b>53</b>
4.1	Caracterização da Série temporal estudada . . . . .	53
4.2	Decomposição da Série Temporal . . . . .	53

4.2.1	LIT . . . . .	53
4.2.2	ALS . . . . .	54
4.2.3	BL . . . . .	55
4.2.4	Rate . . . . .	55
<b>5</b>	<b>Resultados e Discussão</b>	<b>66</b>
<b>6</b>	<b>Conclusão</b>	<b>72</b>
<b>7</b>	<b>Trabalhos Futuros</b>	<b>73</b>
	<b>Referências Bibliográficas</b>	<b>74</b>
	<b>Apêndices</b>	<b>79</b>

# 1 Introdução

O Brasil é um dos mais importantes produtores de minérios do mundo e com potencial para crescer ao longo dos anos, ampliando a quantidade de explorações ao longo do seu território ou aplicando melhoria em seus processos, otimizando a produção (HUMPHREYS *et al.*, 2015). Para otimizar o processo produtivo, o setor de mineração demanda a adoção de tecnologia para o desenvolvimento de sistemas especializados e inteligentes que permitam essa melhora na produção. Nesse sentido, o mercado de mineração deve abraçar a inovação para automação de tarefas repetitivas, integração de sistemas, melhoria contínua de processos, redução de riscos de desastres e adaptação ao contexto global (QI, 2020).

Uma das formas de aplicação da automação industrial é a implementação do monitoramento do processo em tempo real, em que são disponibilizados todos os dados da planta em um único local, por meio de um sistema Supervisory Control and Data Acquisition (SCADA), (LEBUKAN *et al.*, 2019). No sistema do presente estudo, é utilizado um Sistema Digital de Controle Distribuído (SDCD) do fabricante ABB, da série 800xA de versão 6.0. Este sistema processa dados e lógicas de controle industrial, além de permitir armazenar o histórico de dados para análise e consulta posterior (XU, 2014).

A partir de dados históricos de um sistema, mesmo que faltem dados e/ou leituras incorretas, é possível aplicar técnicas de Inteligência Artificial (IA) para análises e, assim, extrair informações dos dados. Vale pontuar que a aplicação de um sistema de classificação baseado em dados é considerada um sistema inteligente (MONARD e BARANAUSKAS, 2003). Existem na literatura, diversos algoritmos propostos para realizar funções de classificação, sendo que o algoritmo Extreme Gradient Boosting (XGBoost) se destaca em relação aos demais devido a sua eficiência no processo de classificação, conforme descrito em (SAHIN, 2020). Também é recorrente estudos que fazem uso de dados dispostos em uma série temporal, que corresponde a amostras de um mesmo evento igualmente espaçados no tempo Chen (1996). Avaliações de uma série temporal podem ser no sentido de realizar previsões ou classificações dos dados Ismail e Efendi (2011). O trabalho aqui descrito fez o uso de classificação dos dados.

Sistemas inteligentes ou sistemas baseados em inteligência computacional surgiram para contornar dificuldades encontradas pelos métodos tradicionais na modelagem e entendimento de sistemas complexos. A detecção de falhas se encontra também nesse âmbito, pois em sistemas de grande porte, com muitos sensores e grande quantidade de dados constantemente gerados, o processo de diagnóstico humano torna-se impreciso. Para reduzir o tempo e melhorar os diagnósticos faz-se necessário a análise e a coleta de dados sobre o estado do sistema, utilizando medições, testes e sintomas de mau funcionamento, além da migração para um processo automático (ZOU *et al.*, 2018). O diagnóstico automático de falhas tornou-se um campo importante nas últimas décadas e após a adoção das práticas da Indústria 4.0 (I4.0), é apontado como tendência.

I4.0 refere-se à 4ª Revolução Industrial, que engloba automação industrial, tecnologia

de informação e inteligência de dados, além das principais inovações de cada um desses campos Schwab (2017). A Quarta Revolução propõe integração desses sistemas, de forma cooperativa, tendo impacto significativo na produtividade, pois aumenta a eficiência do uso de recursos no desenvolvimento de produtos em larga escala. Por um lado, a demanda de interconexão de milhares de sensores e atuadores está em constante crescimento, por outro lado, a quantidade de dados gerados cresce exponencialmente na mesma proporção. Esta gama de dados transforma o processo de obtenção de informações a partir dos dados uma iniciativa para a melhoria da produção e procedimentos industriais (SATYANARAYANAN *et al.*, 2009).

No contexto de algoritmos de classificação baseados em árvores de decisão, tem se destacado na literatura o XGBoost (CHEN e GUESTRIN, 2016). Este algoritmo de Machine Learning (ML), utiliza-se de um gradiente para geração de modelos mais precisos. Durante o processo de treinamento, este algoritmo compara a resposta objetivada com a atual e utiliza-se da diferença para otimizar o aprendizado. O algoritmo do XGBoost é tido como um dos melhores algoritmos de classificação na atualidade devido a sua robustez e velocidade de convergência (ALIM *et al.*, 2020).



Figura 1.1: Vista superior da Usina do S11D.

Fonte: Vale(2021).

O peneiramento primário e britagem secundária, é o início da área industrial das Usinas do S11D. Etapas anteriores a essa área no processo pertencem a mina ou ao transportador de longa distância que une as duas áreas. Conforme apresentado na figura 1.1, o transportador de longa distância destacado na figura pelo número 1, ele transporta o material da mina para ser processado no Peneiramento Primário e britagem secundária, sinalizado pelo número 2 na

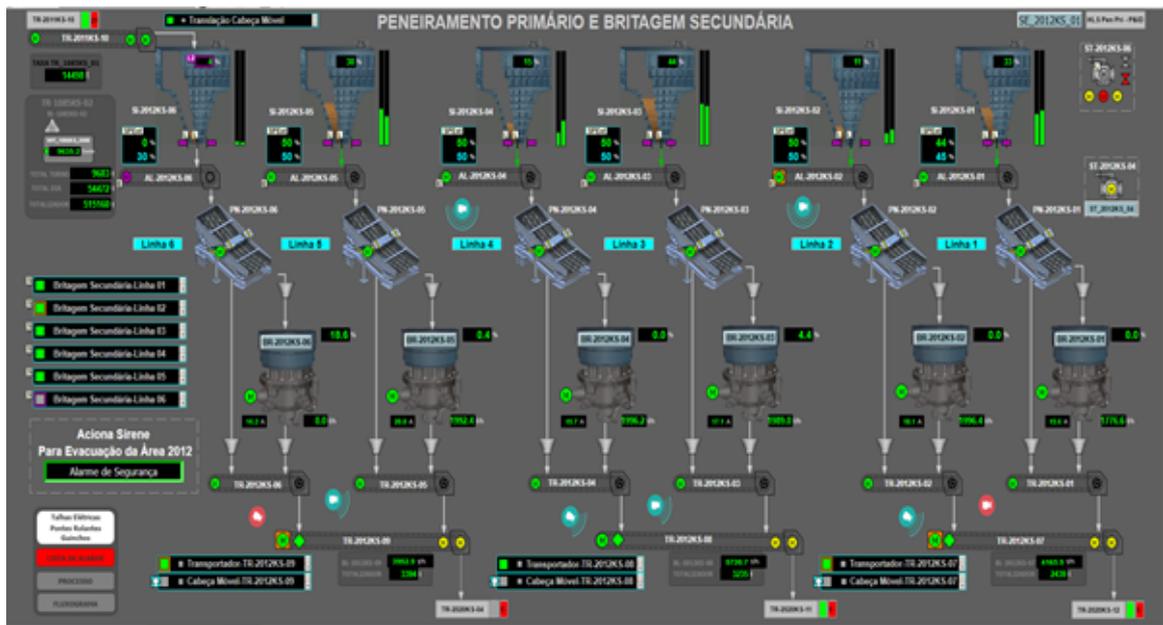


Figura 1.2: Overview do processo de peneiramento primário.  
 Fonte: Vale(2021).

figura 1.1. O edifício destacado pelo número 2, recebe o material oriundo da mina do S11D de uma granulometria maior e cominui, buscando níveis granulométricos menores, na figura 1.2, temos o sistema de supervisão Supervisory Control and Data Acquisition de todo o processo industrial existente na figura 1.2. Na parte superior da imagem estão representados os seis silos que recebem e armazenam o minério oriundo da Mina. Na 1.2, O material que sai dos silos, cai respectivamente em um alimentador que destina na sequência o material para uma peneira e a partir deste ponto inicia-se o processo de classificação pro granulometria do minério na Usina do S11D. Cada silo desta área apresenta sistema de sensoriamento próprio, incluindo medição do seu nível, indicado na figura 1.2 por valores percentuais em cada silo existente na área.

Na figura 1.2, é possível observar diversas indicações de sensores na área estudada. Cada leitura de sensoriamento é representada na tela por um número ou barra percentual. A partir do processo industrial, foi selecionado para a metodologia apresentada neste trabalho, um conjunto de 4 variáveis existentes na área. Nesta parte do processo é realizada a leitura do nível do silo para controlar a quantidade de minério armazenada no mesmo, a velocidade do alimentador que faz a retirada de material do próprio silo, a taxa de material que será adicionada ao silo de minério e o nível de carregamento de minério na correia transportadora que enche os silos de minério. A escolha destas variáveis se deu pelo fato delas influenciarem diretamente na medição de nível dos silos de minério, representados na figura 1.2, objeto de estudo deste trabalho.

No mercado atual, as empresas para sobreviverem, devem buscar aprimoramento constante. Uma das linhas de aprimoramento é a manutenção, definida por KARDEC e NASCIF (2001) como uma forma de garantir a disponibilidade da função dos equipamentos e instalação de forma a atender um processo de produção e a preservação do meio ambiente, com confiabi-

lidade, segurança e custos adequados. A melhoria no processo de detecção de falhas, permite a adoção de manutenções preditivas em detrimento a manutenções corretivas, causando uma elevação no patamar da manutenção, trazendo redução de custos, minimização dos tempos de paradas e dos riscos/acidentes.

Nesse contexto, este estudo tem como objetivo a aplicação de IA para detecção de falhas no sistema de britagem secundária e peneiramento primário da Usina na Planta S11D. Para o desenvolvimento do sistema inteligente, foram utilizados modelos de lógica nebulosa e arvores de decisão. Os dados foram coletados da respectiva planta para simulação e validação do processo de classificação de falhas nos sensores de nível do peneiramento, visando a redução de paradas não programadas, perdas produtivas e/ou desgastes prematuros de equipamentos, além de possibilitar o aumento do nível de segurança dos funcionários que atuam nessa área. A Figura 1.2 exibe um retrato do peneiramento primário e britagem secundária obtidos a partir do sistema Supervisory Control and Data Acquisition (SCADA).

Este trabalho se apresenta como um estudo de caso para a usina da mina do S11D, porém a metodologia apresentada no capítulo 3, é aplicável a outros problemas de classificação e previsão de falhas no setor mineral. O estudo de caso trouxe uma aplicação prática da metodologia proposta nesse trabalho, mas a mesma não se limita a esse problema ou aplicação. A metodologia se demonstrou eficiente e aparenta ser próspera para outros problemas no contexto da mineração.

## **1.1 Estudo de caso**

Este trabalho apresenta uma aplicação prática de classificação e de falhas de sensores de nível da britagem secundária e peneiramento primário da Usina A da mina do S11D. Foram utilizados dados oriundos do sistema de supervisão SCADA do 800xA e feita a análise das séries temporais utilizando Fuzzy time Series e posteriormente um classificador baseado em árvore de decisão, o XGboost.

## **1.2 Motivação**

A melhoria no processo de detecção de falhas nos sensores de nível por congelamento, permite a adoção de manutenções preditivas em detrimento a manutenções corretivas, buscando maior eficiência de equipamentos, redução de custos, minimização dos tempos de paradas e dos riscos/acidentes no processo de beneficiamento mineral. Este tipo de falha é considerada crítica no meio em que está inserida, pois pode causar danos as pessoas equipamentos próximos.

De acordo (VALADÃO e ARAUJO, 2012), em um processo de mineração é muito comum a utilização de silos de armazenamento de minério, que funcionam como “pulmões” para controlar a vazão de minério de ferro. Para a medição de nível destes silos, utilizam-se sensores de medição de nível, que normalmente são de difícil acesso e não são manuteníveis durante a

operação do sistema por motivos de segurança. Falha no sensoriamento de medição do nível dos silos pode causar o transbordo do mesmo. Este tipo de falha pode trazer enormes paradas ao sistema para limpeza ou desobstrução da área, dano a equipamentos adjacentes e enorme risco as pessoas que operam o sistema e se encontram nas proximidades destes silos.

Desta forma, uma IA que permita diagnóstico do sistema de forma automatizada, reduzindo a necessidade de inspeções locais, agilize o diagnóstico e aumente a segurança para as pessoas inseridas no processo, deve ser de interesse da Vale e da sociedade. Entende-se que esta solução, se incorporada ao sistema, o deixará mais robusto.

### 1.3 Objetivos

O objetivo geral é desenvolver um sistema inteligente baseado em séries temporais nebulosas, capaz detectar e classificar as falhas de congelamento dos sensores de nível do sistema de britagem secundária da Usina A, na Planta S11D. Combinado com o uso de um algoritmo de árvore de decisão, o XGBoost, separar uma condição de operação normal de uma onde há a falha dos sensores de nível dos silos de minério. O sistema visa classificar e identificar anomalias de congelamento de leitura dos sensores nível de forma automática, para que se possa antecipar intervenções de manutenção e/ou manutenções corretivas, assim sendo caracterizada como uma ferramenta auxiliar de manutenção. Será investigado as falhas de "congelamento de leitura" dos sensores de nível.

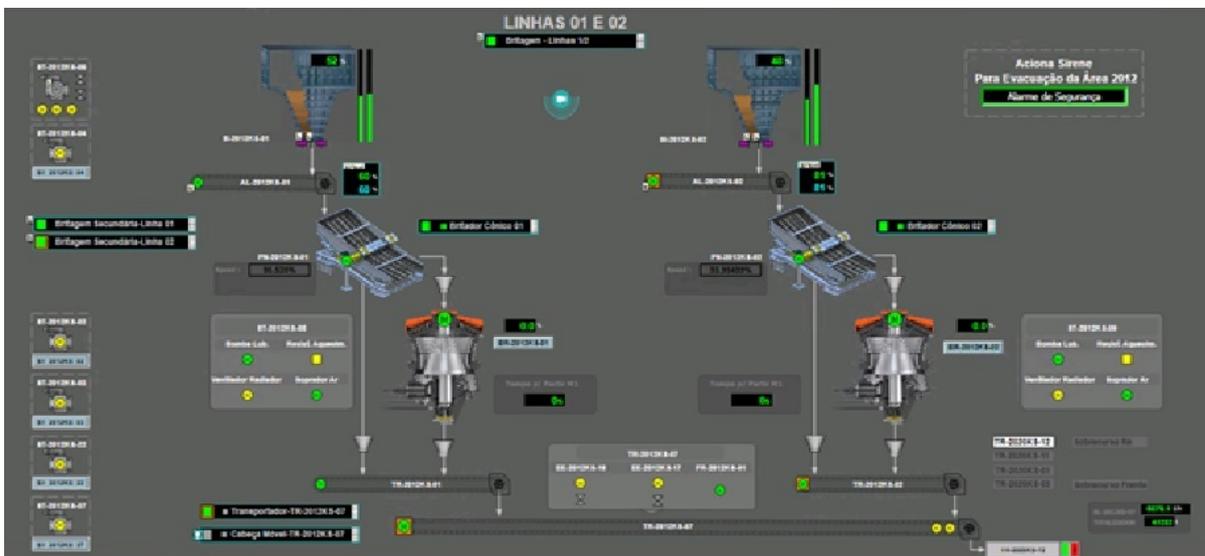


Figura 1.3: Detalhes das Linhas 1 e 2 do Peneiramento primário.  
Fonte: Vale (2021).

#### 1.3.1 Objetivos específicos

Os objetivos específicos deste estudo consistem em:



Figura 1.4: Detalhamento da indicação de nível dos silos.  
Fonte: Vale (2021).

1. Obter dados reais do ambiente de mineração, tratá-los e processá-los;
2. Validar técnicas de processamento de dados utilizando modelos de Fuzzy Time Series e XGBoost (machine learning);
3. Simular, testar e comparar a eficiência de cada um dos métodos.

## 1.4 Contribuições

O presente trabalho trouxe a partir da metodologia aplicada uma forma de extrair características de uma série temporal a partir de uma representação fuzzy de séries temporais combinado com um algoritmo baseado em árvore de decisão, o XGBoost. Também contribuiu para aumentar a assertividade no processo de classificação e detecção de falhas.

## 1.5 Publicações Científicas

O presente trabalho gerou uma publicação de artigo no XXIV Congresso Brasileiro de Automática que ocorreu em Fortaleza, no período de 16/10 a 19/10 do ano de 2022. O artigo foi apresentado no congresso, no período descrito acima.

## 1.6 Estrutura do Trabalho

O trabalho foi dividido em etapas, sendo no Capítulo 2 apresentada a fundamentação científica, conceitos e teorias, além de procedimentos utilizados para a realização do trabalho. No Capítulo 3, a metodologia do trabalho é descrita. No Capítulo 4, a análise dos resultados e discussão são demonstrados. No Capítulo 5, a conclusão da pesquisa é apresentada juntamente com os possíveis trabalhos futuros.

## 2 Referencial Teórico e Fundamentação Científica

Machine Learning, em português, aprendizado de máquina é uma área da inteligência artificial em que é possível criar algoritmos para ensinar uma máquina ou computador a executar uma atividade ou tarefa. Para tornar possível esta funcionalidade, faz-se necessário um conjunto de dados que apresentem algum tipo de correlação entre si e será esta correlação a ser explorada no algoritmo de aprendizado de máquina.

Nessa lógica, ao descobrir os padrões existentes na base de dados é gerado um modelo que pode ser aplicado a uma determinada tarefa específica. Este processo é chamado de treinamento do modelo. Com este modelo treinado, é possível aplicá-lo em novos dados, diferentes dos utilizados durante o processo de treinamento, assim encontrar correlações dos novos dados e gerando classificações ou previsões para realização da tarefa especificada (HATTORI *et al.*, 2018).

É relevante descartar que existem três grandes categorias de aprendizado de máquina: 1) Aprendizado Supervisionado: consiste em dados rotulados, ou seja, dados com saídas conhecidas e o algoritmo aprende comparando a saída do modelo com a saída esperada; 2) Aprendizado não-supervisionado: consiste em dados não rotulados; 3) Aprendizado por reforço: que consiste em aprendizado a partir de tentativa e erro na busca de um objetivo, ao longo das tentativas penalidades ou recompensas são aplicadas para cada tentativa. O algoritmo recebe um conjunto de dados não rotulados e busca encontrar semelhanças entre grupos de dados, gerando os chamados *clusters* ou grupos de dados (OLIVEIRA, 2020).

### 2.1 Séries Temporais

De acordo com Moretti (2004), uma série temporal é um conjunto de dados coletados sequencialmente no tempo e cujo intervalo de coleta é constante ao longo de toda a série temporal, ou seja, são equidistantes no tempo. Também de acordo com Moretti (2004), uma série temporal de sinais igualmente espaçados no tempo, corresponde a uma observação ou amostragem dentre várias outras que poderiam ocorrer a partir de um mesmo fenômeno. Sendo possível, a partir dos dados de uma série temporal, a obtenção de modelos que expliquem o seu comportamento ao longo do tempo.

A partir dos modelos obtidos de uma série temporal, é possível trabalhar as informações contidas nos dados, permitindo investigar o mecanismo gerador da série temporal, classificação de seus valores por padrões existentes ou até mesmo fazer previsões de valores futuros da série temporal de acordo com (MONTGOMERY *et al.*, 2015). Segundo o autor, para uma classificação ou previsão quantitativa, é necessário utilizar dados históricos internos ou externos da série a fim de se captar os padrões de comportamento. Dentre os comportamentos de séries temporais, temos os principais como a estacionariedade, tendência, sazonalidade e homocedasticidade:

1. Estacionariedade: Uma série temporal é considerada estacionária quando suas proprie-

dades como média, variância e desvio padrão são constantes ao longo do tempo (HOEL *et al.*, 1986).

2. Tendência: A tendência de uma série temporal é uma característica de longo prazo, em que a série apresenta tendência de crescimento ou decréscimo de seus valores, gerando a variação de sua média ou variância ao longo do tempo (HOEL *et al.*, 1986).
3. Sazonalidade: A sazonalidade é uma variação cíclica que ocorre na série temporal, indicando a ocorrência de um padrão periódico (BROCKWELL e DAVIS, 2002).
4. Homocedasticidade: A homocedasticidade refere-se a métrica de variância constante ao longo de toda a série temporal. Ou seja, a variância se mantém constante ao longo de toda a série temporal. Para variáveis heterocedásticas, a variância muda ao longo da série (LEVENE, 1960).

Os padrões descritos anteriormente, servem como base e orientam em relação a como os conjuntos de dados serão analisados e a forma de como as séries devem ser modeladas.

## **2.2 Aplicação de Agrupamentos Fuzzy**

O grande número de componentes envolvidos na operação de processos industriais aumenta sua complexidade, juntamente com a probabilidade de falhas ou comportamentos incomuns. Em alguns casos, os processos industriais dependem exclusivamente da experiência do operador da planta para prevenir e identificar falhas. O que torna o processo de identificação de falhas muito simplório e suscetível a erros.

A identificação automática de falhas nos estados funcionais do processo traz suporte para a atuação do operador, reduzindo a incidência de acidentes, redução de danos maiores ao equipamento e produtos defeituosos. No entanto, o uso crescente de sistemas de medição automática gera grandes quantidades de dados que dificultam a detecção de falhas sem uma inteligência aplicada aos mesmos.

A obtenção de sistemas de identificação de falhas adequados requer o uso das variáveis mais informativas para lidar com grandes quantidades de dados, removendo de forma inteligente as variáveis redundantes e irrelevantes.

Neste trabalho, uma metodologia supervisionada baseada em agrupamento Fuzzy é utilizado na identificação de falhas do processo industrial em análise (ESLAMLOUEYAN, 2011)(AMMICHE *et al.*, 2018). Os resultados mostram que um subconjunto de variáveis melhora os percentuais de classificação e evita o uso de variáveis desnecessárias.

## 2.3 Fuzzy Time Series – Treinamento e Classificação

Os trabalhos pioneiros em Fuzzy Time Series (FTS), em português, séries temporais nebulosas, são de (SONG e CHISSOM, 1993), e (CHEN, 1996), os quais apresentam uma família de métodos não paramétricos baseados em dados e na teoria de conjuntos Fuzzy (ZADEH, 1965). Métodos flexíveis e de fácil implementação que propiciam maneiras de trabalhar com dados numéricos e não numéricos (DE LIMA *et al.*, 2019). As etapas metodológicas de uma FTS estão representadas na Figura 2.1 e listadas abaixo:

1. Pré-processamento. Transformações a priori podem ser aplicadas aos dados de uma série temporal a fim de se remover ruído, sazonalidade, tendência, etc.
2. Particionamento: A série temporal a ser avaliada, deve ser particionada em conjuntos nebulosos. A quantidade  $K$  de conjuntos nebulosos deve ser ajustada evitando o overfitting e o underfitting. Após o particionamento, criamos uma variável linguística fuzzificada, definida como  $\tilde{A}$ , por exemplo (Representado em letras maiúsculas com  $\sim$ ).
3. Fuzzificação: A representação linguística dos dados é criada utilizando a variável  $\tilde{A}$  definida, com o número de partições e abrangência dos dados.
4. Extração e representação das regras: Para um modelo,  $M$  é uma representação de  $F$ , em regras de pertinência dos conjuntos nebulosos que abrangem os dados.

Após criado o modelo, temos de realizar o processo de treinamento do mesmo. O processo de treinamento está representado na Figura 2.1 e ocorre conforme segue abaixo:

1. Pré-processamento: uma ou mais transformações podem ser aplicadas aos dados de entrada da série temporal. Este pré-processamento pode ser normalização, tratamento de dados não reconhecidos e etc.
2. Fuzzificação: A representação linguística dos dados de  $F$  é criada a partir da variável linguística  $\tilde{A}$ . Os dados são divididos nos conjuntos nebulosos criados.
3. Inferência: A partir dos lags de  $F$  e do modelo  $M$ , faz-se a estimativa de  $F$ .
4. Desfuzzificação: Realiza-se a transformação de  $F$  estimado em dados numéricos da série de origem.
5. Pós-processamento: Uma ou mais transformações de dados pode ser aplicado a série temporal obtida, como por exemplo o processo inverso de uma normalização

A definição de ordem de um modelo de série temporal nebulosa, é relativo à quantidade de lags passados o mesmo considera em sua construção, também definido como ordem do

modelo. Para modelos de primeira ordem, por exemplo, utilizamos um 'lag' apenas. Para modelos de segunda ordem, 2 lags e assim sucessivamente. Na explicação que será apresentada a seguir, será considerada a Etapa 0 já realizada (pré-processamento). Para um modelo mais simples (invariante no tempo), temos a seguinte sequência de passos.

A Figura 2.1 representa todo o sequenciamento e as etapas do processo de Fuzzificação e extração das regras de um modelo de série temporal nebulosa. O procedimento de modelagem baseia-se na criação de  $k$  conjuntos nebulosos, que nesta explicação faremos como sendo 7 ( $A_0, A_1, A_2, \dots, A_6$ ). A partir dessa definição, faremos a divisão do Universo de Discurso (UoD) da série em seus valores mínimos e máximos, nos conjuntos nebulosos propostos. Essa definição refere-se ao processo de Fuzzificação, que associa para cada valor série  $x(t)$  considerando um grau de pertinência com cada um dos  $k$  conjuntos nebulosos.

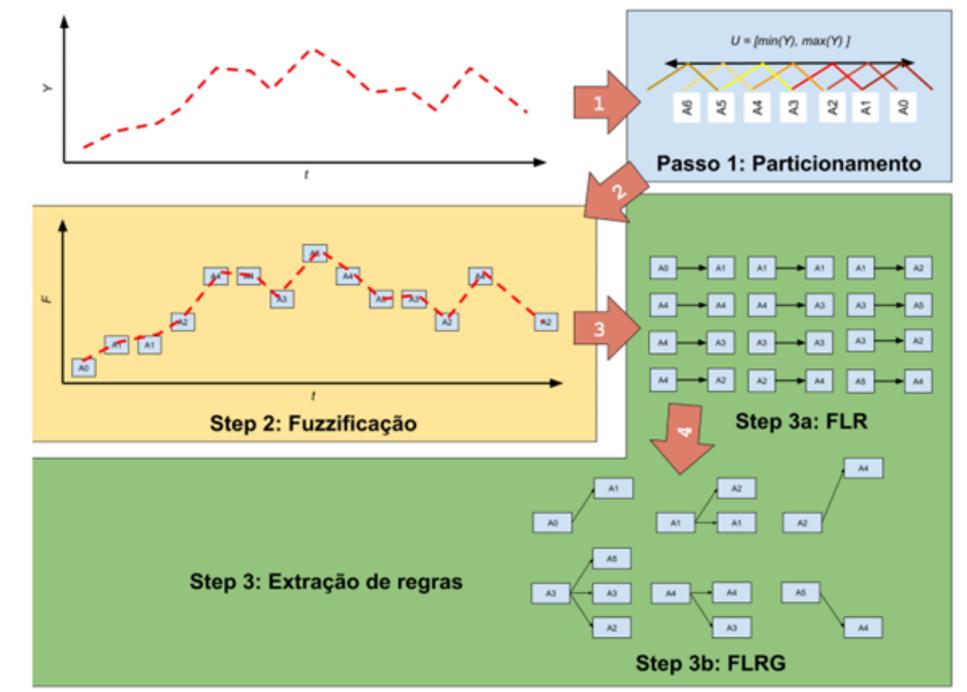


Figura 2.1: Processo de Fuzzificação.

Fonte: Dias (2021).

1. Passo 1) Dividir o Universo de Discurso (UoD) e criar os conjuntos nebulosos:

A definição de como serão as partições e quantidade de partições do UoD é certamente uma etapa de suma importância para os modelos FTS no que diz respeito a qualidade ou custo computacional do modelo. É nesse momento também onde se observa as condições de “overfitting” e “underfitting” nas definições de número de intervalos, comprimentos, pontos médios e grau de pertinência (SONG e CHISSOM, 1993). Também de acordo com (SONG e CHISSOM, 1993), define-se particionamento em grade, aquele cuja faixa de dados é dividida em intervalos de comprimento igual.

Dado uma série temporal  $X(t)$ , conseguimos particioná-la em  $k$  intervalos de igual comprimento nos  $k$  conjuntos de partição. Os conjuntos devem apresentar sobreposição entre si com um grau de pertinência que pode variar entre 0 e 1. A Figura 2.1 ilustra esta etapa 1, onde existem 7 conjuntos ( $A_1...A_7$ ) com as suas respectivas funções de pertinência, onde cada conjunto pode ser representado por uma função de pertinência EQ.

2. Passo 2) Fuzzificar os elementos da Série temporal e criar as Fuzzy Logical Relationship Fuzzy Logical Relationship (FLR):

Como representado na Figura 2.1, a etapa 2 corresponde a associação de cada elemento da série temporal ao seu respectivo conjunto nebuloso. Definidos os conjuntos nebulosos  $A_0$  até  $A_7$ , deve-se fuzzificar os elementos da série e associar a cada elemento a um conjunto nebuloso  $A_i$  tal que  $A_i = \max_T(a_i)$ , conforme ilustra a Figura 2.1. A partir da série fuzzificada, é possível gerar o conjunto de regras de transição lógicas para toda a série temporal, considerando todas as transições distintas entre os conjuntos de particionamento. O formato  $A_j \rightarrow A_k$  é conhecido como Fuzzy Logical Relationship (FLR) para as regras de transição. Neste formato de representação, identificamos o precedente e o conseqüente (CHEN, 1996), onde  $A_j$ , precedente, é o conjunto nebuloso da série temporal em  $X(t-1)$  e este irá gerar o conseqüente, que é o elemento  $A_k$  no instante de tempo  $X(t)$ .

3. Passo 3) Associar as FLRs criando os Fuzzy Logical Relationship Group (FLRGs):

A partir de todas as regras (FLRs) obtidas da série temporal, e fazendo o agrupamento destas regras pelo precedente, obtemos o conjunto de regras distintas, criando os Fuzzy Logical Relationship Groups (FLRGs). Por exemplo, o conjunto de regras em 2.1, obtido com base na Figura 2.1 é agrupado conforme evidenciado em 2.2. É possível notar que cada precedente um conjunto de FLRs os seus respectivos conseqüentes, são agrupados 2.2.

Na equação 2.1, apresentamos os conjuntos das FLRs, que compõe a série temporal:

$$A_1 \rightarrow A_2, A_2 \rightarrow A_2, A_2 \rightarrow A_3, A_3 \rightarrow A_4, A_4 \rightarrow A_4, A_5 \rightarrow A_3, A_3 \rightarrow A_5 \quad (2.1)$$

Ao agrupar pelo precedente, tem-se:

$$\begin{aligned} &A_1 \rightarrow A_2 \\ &A_2 \rightarrow A_2, A_3, A_4 \\ &A_3 \rightarrow A_2, A_3, A_4 \\ &A_4 \rightarrow A_3, A_3, A_5 \\ &A_5 \rightarrow A_4 \end{aligned} \quad (2.2)$$

4. Passo 4) Predizer  $F(t)$  a partir de  $F(t - 1)$ :

A proposta de (CHEN, 1996) que é uma evolução da proposta de (SONG e CHISSOM, 1993), que é o agrupamento das FLRs, criando as FLRGs e logo na sequência, torna-se possível seguir com o processo de desfuzzificação. A proposta de (CHEN, 1996) é mais simples e de custo computacional menor. Ao agrupar todas as FLRs e colocar no formato de produto dos conjuntos nebulosos, é possível por um produto de matrizes, separar a matriz de relações  $R$  que é derivada a partir do conjunto de regras obtidas em 2.2 e o vetor que contém os conjuntos nebulosos modelados para a variável. Para cada FLRG, pode-se extrair os vetores de pertinência dos conjuntos nebulosos que compõe a regra. A matriz  $R$  obtida é uma matriz quadrada de ordem igual ao número de conjuntos nebulosos. Este passo a passo pode ser descrito na equação (2.4) e é originado de 2.2. A matriz  $R$  também é chamado de conseqüente e a matriz dos conjuntos nebulosos de precedente. Escreve-se:

$$[A_{1(t)}, \dots, A_{n(t)}]^T = R \times [A_{1(t-1)}, \dots, A_{n(t-1)}]^T \quad (2.3)$$

$$[A_{1(t)}, \dots, A_{n(t)}]^T = \begin{bmatrix} \omega_{11} & \dots & \omega_{1n} \\ \dots & \dots & \dots \\ \omega_{n1} & \dots & \omega_{nn} \end{bmatrix} \times [A_{1(t-1)}, \dots, A_{n(t-1)}]^T \quad (2.4)$$

5. Passo 5) Defuzificar:

O processo de defuzificação transforma o conjunto de pertinência de  $F(t)$  em um valor pontual da série temporal. No intervalo de tempo  $(t - 1)$ , o conjunto nebuloso de  $F(t - 1)$  é  $A_j$ , então a definição do valor de  $F(t)$  defuzificado é definido da seguinte forma:

- (a) Existindo apenas uma regra cujo precedente é  $A_j$ , e a partição de pertinência maior do conseqüente  $A_k$  corresponde a uma partição  $u_k$ , então escolhe-se o centroide ( $C_k$ ) desta partição:  $f(t) = C_k$ .
- (b) Existindo um número maior que um de regras com o precedente  $A_j$ , cujas partições de máxima pertinência dos conseqüentes são  $u_{k1}, u_{k2}, \dots, u_{kp}$ , então o resultado da defuzificação será a média dos  $p$  centros:  $f(t) = \frac{(u_{k1} + u_{k2} + \dots + u_{kn})}{p}$  ou escolhe-se o centroide destas funções de pertinência  $u_k$ .

Na sua modelagem mais simples (invariante no tempo) a série pode ser descrita conforme em 2.1, onde  $R$  é uma matriz das relações nebulosas que descrevem a série e  $\circ$  é o operador relacional Fuzzy Max-Min, gerando assim  $F(t)$  que representa a série temporal fuzzificada. Essa formulação também pode ser entendida como um conjunto de regras no formato SE  $X(t - 1)$  ENTÃO  $X(t)$ . Se forem utilizados  $m$  termos então tem-se 2.2, que pode ser interpretado como uma regra no formato SE  $X(t - 1)$  ou  $X(t - 2)$  ... ou  $X(t - m)$  então  $X(t)$ .

$$[A_{1(t)}, \dots, A_{n(t)}]^T = R \times [A_{1(t-1)}, \dots, A_{n(t-1)}]^T \quad (2.5)$$

$$[A_{1(t)}, \dots, A_{n(t)}]^T = R \times [A_{1(t-m)}, \dots, A_{n(t-m)}]^T \quad (2.6)$$

O procedimento de modelagem e predição se baseia na criação de  $k$  conjuntos nebulosos a partir da divisão do UoD de uma série de valores  $X_t$  em intervalos sobrepostos. O processo de fuzzificação associa, para cada valor  $X_t$  da série  $X(t)$ , um grau de pertinência para cada um dos  $k$  conjuntos. Esse procedimento é descrito a seguir.

- **Etapa 1) Dividir o UoD e criar os conjuntos nebulosos**

Dado o UoD,  $U = [U_{min}; U_{max}]$  da série temporal  $X(t)$ , deve-se inicialmente particioná-lo em  $m$  intervalos  $u_1, u_2, \dots, u_m$  de igual tamanho cujos centros ou centroides são  $c_1, c_2, \dots, c_m$ . A partir dos  $m$  intervalos são definidos  $k$  conjuntos nebulosos sobrepostos  $A_1, A_2, \dots, A_k$ , descritos em (2.3), onde cada  $A_i \in [0; 1]$ ,  $1 \leq i \leq k$  representa o grau de pertinência do intervalo  $u_j$ ,  $1 \leq j \leq m$ , ao conjunto  $A_i$ . Cada conjunto  $A_i$  pode ser simplesmente referenciado por uma função de pertinência  $f_{a_i}(t)$ . O operador  $\oplus$  representa a operação de concatenação.

$$A1 = f_{a1}(u_1) = u_1 \oplus f_{a1}(u_2) = u_2 \oplus \dots \oplus f_{a1}(u_m) = u_m \quad (2.7)$$

A partição do UoD é certamente uma das etapas cruciais dos métodos FTS devido a sua influência na precisão das previsões. O número de intervalos, seus comprimentos e definição dos pontos médios são parâmetros que devem ser escolhidos com atenção. Este esquema de partição proposto em (SONG e CHISSOM, 1993) é chamado de particionamento em grade. Nele a faixa de dados é dividida em intervalos de igual comprimento.

- **Etapa 2) Fuzzificar os elementos da série temporal e criar as Fuzzy Logical Relationship**

Definidos os conjuntos nebulosos, deve-se fuzzificar os elementos da série e associar a cada elemento o conjunto  $A_i$  tal que  $A_i = \max_{faig}$ . Com a série fuzzificada, pode-se então gerar o conjunto de regras lógicas de transição, percorrendo toda a série temporal e registrando as transições distintas entre conjuntos. As regras tem o formato  $A_j \rightarrow A_k$ . Esse formato é conhecido como Fuzzy Logical Relationship (FLR), onde o precedente  $A_j$  é o conjunto nebuloso da série temporal no momento  $F(t-1)$  e o conseqüente  $A_k$  é o conjunto referente ao momento  $F(t)$ .

- **Etapa 3) Associar as FLR criando os FLRGs**

A partir de todas as regras (FLRs) obtidas da série temporal, e fazendo o agrupamento destas regras pelo precedente, obtemos o conjunto de regras distintas, criando os Fuzzy Logical

Relationship Groups (FLRGs). Por exemplo, o conjunto de regras em 2.1, obtido com base na Figura 2.1 é agrupado conforme evidenciado em 2.2. É possível notar que cada precedente um conjunto de FLRs os seus respectivos consequentes, são agrupados 2.1. Na equação 2.1, apresentamos os conjuntos das FLRs, que compõe a série temporal:

Ao agrupar pelo precedente, tem-se:

- **Etapa 4) Predizer  $F(t)$  a partir de  $F(t - 1)$**

A proposta de (CHEN, 1996) que é uma evolução da proposta de (SONG e CHISSOM, 1993), que é o agrupamento das FLRs, criando as FLRGs e logo na sequência, torna-se possível seguir com o processo de defuzzificação. A proposta de (CHEN, 1996) é mais simples e de custo computacional menor. Ao agrupar todas as FLRs e colocar no formato de produto dos conjuntos nebulosos, é possível por um produto de matrizes, separar a matriz de relações R que é derivada a partir do conjunto de regras obtidas em 2.2 e o vetor que contém os conjuntos nebulosos modelados para a variável. Para cada FLRG, pode-se extrair os vetores de pertinência dos conjuntos nebulosos que compõe a regra. A matriz R obtida é uma matriz quadrada de ordem igual ao número de conjuntos nebulosos. Este passo a passo pode ser descrito na equação 2.4 e é originado de 2.2. A matriz R também é chamado de consequente e a matriz dos conjuntos nebulosos de precedente. Escreve-se:

- **Etapa 5) Defuzzificar**

O processo de defuzzificação transforma o conjunto de pertinência de  $F(t)$  em um valor pontual da série temporal. No intervalo de tempo  $(t - 1)$ , o conjunto nebuloso de  $F(t - 1)$  é  $A_j$ , então a definição do valor de  $F(t)$  defuzzificado é definido da seguinte forma:

- 1): Existindo apenas uma regra cujo precedente é  $A_j$ , e a partição de pertinência maior do consequente  $A_k$  corresponde a uma partição  $u_k$ , então escolhe-se o centroide ( $C_k$ ) desta partição:  $f(t) = C_k$ .
- 2): Existindo um número maior que um de regras com o precedente  $A_j$ , cujas partições de máxima pertinência dos consequentes são  $u_{k1}, u_{k2}, \dots, u_{kp}$ , então o resultado da defuzzificação será a média dos  $p$  centros:  $f(t) = ((u_{k1} + u_{k2} + \dots + u_{kn})) / p$  ou escolhe-se o centroide destas funções de pertinência  $u_k$ .

## 2.4 Modelos de alta ordem

Os modelos de alta ordem High Order Fuzzy Time Series (HOFTS) são essencialmente baseados nos trabalhos de (HWANG *et al.*, 1998) e (CHEN, 2014) e diferenciam-se dos modelos de primeira ordem por usar dois ou mais lags para o processo de predição definir o valor futuro da série. Em modelos de alta ordem, define-se os High Order Fuzzy Logical Rules (HOFLR) no

formato  $LHS \rightarrow RHS$ , onde o precedente, Left Hand Side (LHS) é um conjunto dos conjuntos fuzzy definidos por  $F(t - (n - 1)) \rightarrow F(t)$ , onde  $n$  é a ordem do modelo, e o conseqüente RHS é o conjunto resumido das regras de geração dos conjuntos fuzzy para  $F(t + 1)$ .

A partir da pesquisa de (HUARNG, 2001b) tornou-se evidente o impacto que o tamanho das partições do UoD tem sobre o poder preditivo dos modelos de séries temporais nebulosas. Em (HUARNG, 2001a), temos dois algoritmos para a definição de sugestões do número de conjuntos nebulosos. Sendo uma baseada na distribuição dos dados e outra no valor médio. Não apenas o tamanho ou quantidade das partições, mas sua forma e distribuição também tem impacto nos modelos (modelo do particionamento). Em (CHENG *et al.*, 2006) é desenvolvida uma metodologia de particionamento do UoD baseada na entropia da série temporal. Além da entropia, temos o particionamento pelo Cmeans.

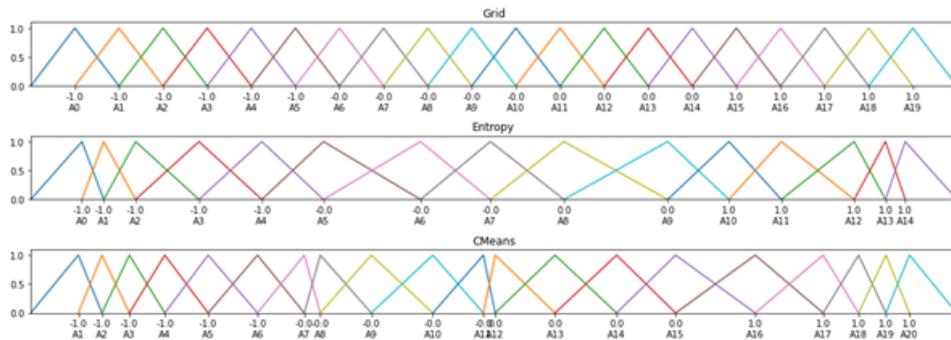


Figura 2.2: Tipos de particionamentos para 20 conjuntos nebulosos.  
Fonte: Autoria própria.

Além do número de partições e do tipo de particionamento da variável, temos a possibilidade de variar a função de pertinência, conforme na Figura 2.3.

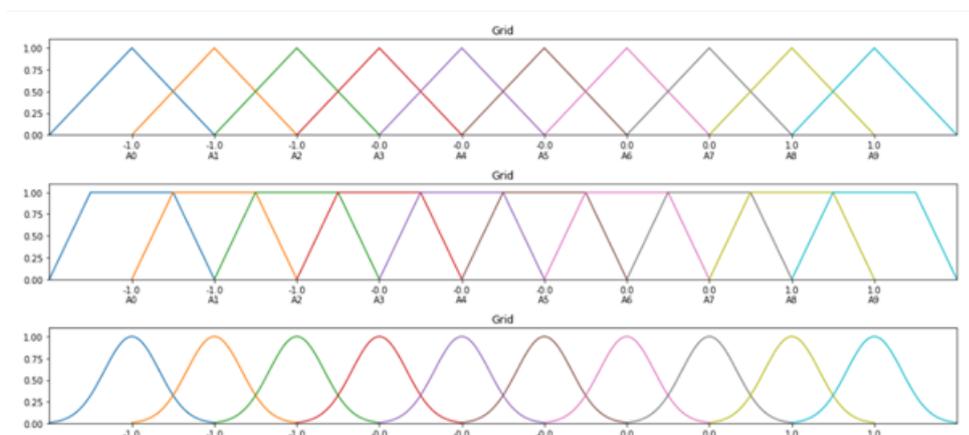


Figura 2.3: Funções de pertinência triangular, trapezoidal e gaussiana.  
Fonte: Autoria própria.

## 2.5 Aplicação de Fuzzy Time Series

O conceito “Fuzzy” pode ser entendido como uma situação em que não responder simplesmente “sim ou não”. Mesmo conhecendo as informações necessárias sobre a situação, dizer algo entre “sim ou não” como, por exemplo, “talvez”, “quase”, o que se torna mais apropriado. As classificações passam a admitir graus de pertinência.

Para se aplicar o conceito “Fuzzy”, temos duas etapas no processo de classificação. O primeiro é composto de uma análise qualitativa em que são tabelados níveis de classificação para a variável em questão. Em uma segunda etapa de caráter quantitativo, esses níveis são transformados em valores matemáticos e busca-se alguma referência nos dados montados até então, como, por exemplo, média, centro de massa etc (ESLAMLOUEYAN, 2011).

A aplicação dos conceitos Fuzzy pode ser estendido à previsão de valores futuros de séries temporais, também conhecidas como Fuzzy Time Series. As Fuzzy Time Series são métodos de previsão não-paramétricos propostos por (SONG e CHISSOM, 1993) baseados na teoria dos conjuntos difusos de (ZADEH, 1965). São métodos que permitem lidar com dados numéricos e linguísticos.

## 2.6 Aplicação de Fuzzy Time Series Multivariadas

Para realizar a detecção de falhas de Sensores de nível dos silos de minério da Usina A, do S11D, existem diversos fatores que podem influenciar na existência ou determinação da falha, caracterizando uma série temporal multivariada pela influência de mais de uma variável.

De acordo com (DE LIMA *et al.*, 2019), uma série temporal multivariada é uma sequência de instâncias em que cada instância é uma sequência de  $N$  números reais, sendo que cada um desses números reais deve ser entendido como uma variável, assim definindo uma série temporal multivariada como:

$$\begin{aligned} Y &\in R^{n \times T} \\ y(t) &\in R^n \quad t = 1 \dots T \\ v &= v_1, \dots, v_n : \text{Conjunto das variáveis} \\ v_1 &\in R^1 \quad n = |v| \end{aligned} \tag{2.8}$$

O conjunto de variáveis que compõe uma série temporal multivariada é dividida em: 1) Variável endógena ou alvo: se refere ao valor de interesse de previsão; 2) Variável exógena ou explicativa: são valores que auxiliam a explicar as variações na variável endógena.

Para a definição de variáveis que irão compor um modelo de série temporal multivariada, deve-se selecionar variáveis de real influência no modelo, de forma a reduzir o tamanho do modelo, tempo de treinamento e evitar o overfitting (em português, sobreajuste). Para a definição das variáveis que realmente influenciam no modelo, pode-se utilizar uma matriz de

correlação entre a variável alvo e as variáveis endógenas, lembrando que a correlação é uma métrica linear. Porém, existem outras formas de verificar essa dependência como, por exemplo, a otimização de hiper parâmetros.

Cada variável de uma série temporal multivariada apresenta o seu próprio particionamento como uma variável nebulosa, tornando os modelos multivariados mais descritivos, porém bem maiores e bem mais complexos (DE LIMA *et al.*, 2019). A Figura 2.4 retrata as etapas do treinamento Fuzzy.

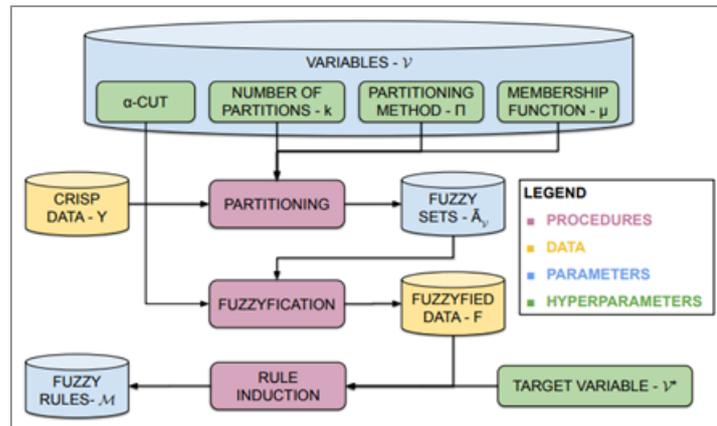


Figura 2.4: Treinamento de uma série temporal fuzzy multivariada.

Fonte: (DE LIMA *et al.*, 2019).

Cada variável que compõe o modelo contém o seu número de partições, o seu método de partição (classificação linguística), funções de pertinência específicas e  $\alpha - CUT$ , conforme descrito na Figura 2.5. Todos os particionamentos e processos de fuzzificação têm como objetivo a variável alvo ou endógena.

O processo de predição é semelhante ao processo de predição para uma série temporal univariada, apresentando apenas algumas variações e tratativas. Como características, estes modelos apresentam: a) Modelos de previsão são de 1ª ordem, sendo possível a previsão de apenas mais um valor por vez; b) Múltiplas entradas e apenas uma saída; c) Previsão escalar e intervalar.

O modelo de séries temporais multivariadas é composto pelo conjunto das variáveis, sendo que cada variável possui o seu conjunto específico de parâmetros, especificação de qual será a variável endógena e o conjunto de regras que compõem o modelo (DE LIMA *et al.*, 2019).

Uma forma de abranger todos esses conjuntos de informação e aumentar a capacidade de predição é a adoção do conceito do Fuzzy Information Granule (FIG), que é caracterizado por: I) Modelo de alta ordem, previsão de N valores; II) Multiple Input Multiple Output (MIMO) (múltiplas entradas e múltiplas saídas); III) Previsão escalar, intervalar ou probabilística para N valores à frente.

O grânulo de informação nebuloso (FIG) é uma combinação dos particionamentos de cada uma das variáveis que compõem o modelo, onde a união/intersecção das funções de perti-

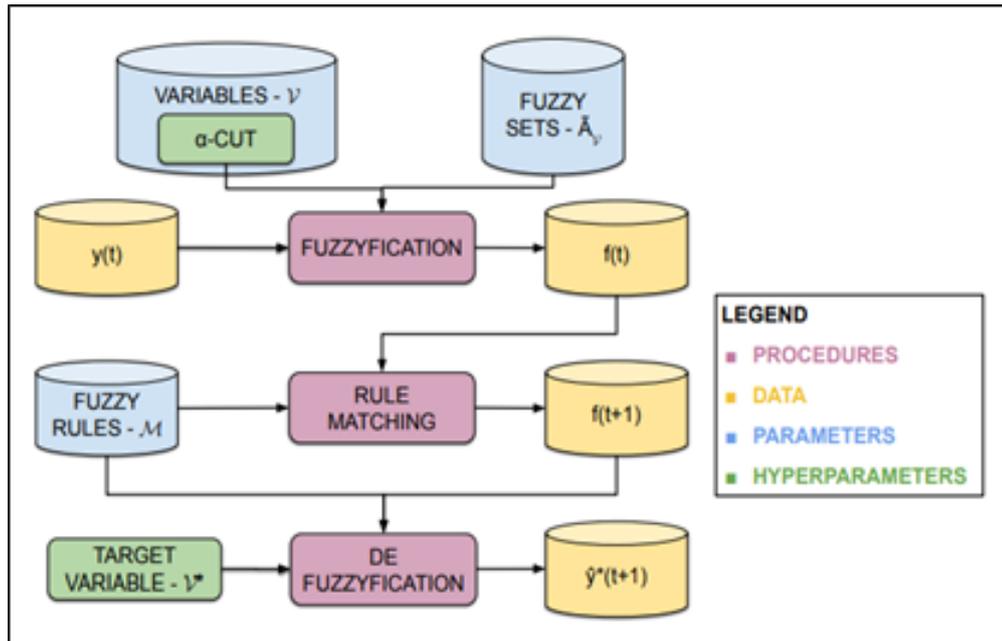


Figura 2.5: Processo de predição da variável endógena.  
 Fonte: (DE LIMA *et al.*, 2019).

nência de vários conjuntos nebulosos, sendo um de cada variável, gera um grânulo de informação nebuloso (FIG). A abstração em grânulos de informação, faz a projeção de um espaço de alta dimensionalidade e um espaço de baixa dimensionalidade.

Em outras palavras, transforma uma série temporal multivariada em uma série temporal univariada, possibilitando a previsão da série temporal multivariada de forma semelhante a univariada. De acordo com a Figura 2.6, o particionador é responsável pela criação de grânulo de informação Fuzzy

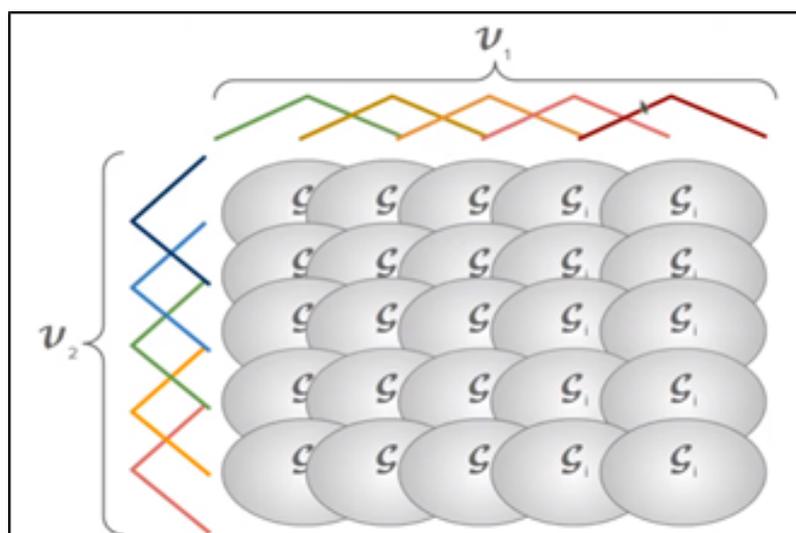


Figura 2.6: Grânulos de informação fuzzy.  
 Fonte: (DE LIMA *et al.*, 2019).

Para uma situação que contém duas variáveis exógenas, sendo que cada variável apre-

sesta 5 particionamentos, teremos um total de 25 Fuzzy Information Granule (FIG) , conforme exibido na Figura 2.6. A intersecção de cada particionamento de cada variável, gera o grânulo de informação.

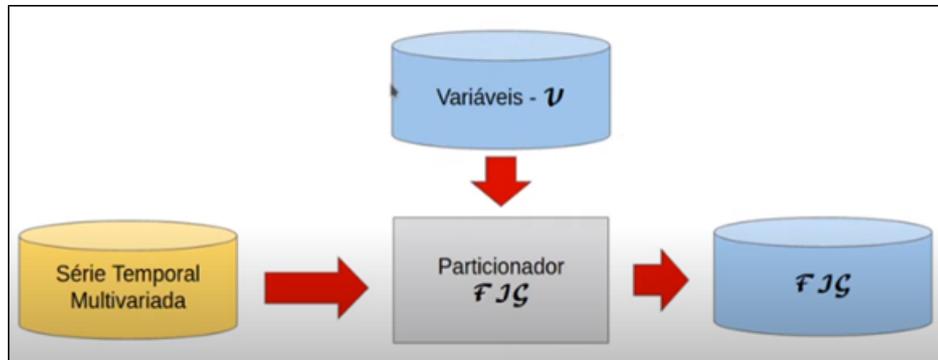


Figura 2.7: Processo de conversão de uma série temporal multivariada em uma série temporal univariada.

Fonte: (DE LIMA *et al.*, 2019).

## 2.7 Probabilistic Weighted Fuzzy Time Series (PWFTS)

A partir de uma série temporal numérica  $Y$  e seus valores individuais  $y(t)$ , uma previsão de valores futuros para esta série normalmente são valores pontuais ou escalares. Este tipo de previsão geralmente é o melhor “palpite” para  $Y$  no tempo de  $t+1$ , considerando o que se sabe de  $Y$  e seus valores passados. Isto é, temos para o valor previsto de  $Y$ , uma incerteza associada a essa previsão. Existem formas de lidar com essa limitação das previsões pontuais, e são as previsões probabilísticas, descritas pelo modelo da PWFTS (DE LIMA *et al.*, 2019).

A previsão probabilística é uma distribuição de probabilidade  $P : U \rightarrow [0, 1]$ , onde  $U$  é o Universo de Discurso de  $Y$ . Isso significa que vamos estimar, para cada valor de previsão uma função de probabilidade  $P(\hat{y}(t+1) = x)$ . Esta é a forma mais completa de representar a incerteza de uma previsão, e nos dá o panorama dos valores possíveis que  $\hat{y}(t+1)$ .

A Probabilistic Weighted Fuzzy Time Series (PWFTS) é um método heurístico e invariante no tempo que pode fazer previsões pontuais, intervalares e probabilísticas para um ou muitos passos à frente (DE LIMA *et al.*, 2019). O método é composto por um conjunto de regras de transição entre os conjuntos nebulosos e os pesos delas ( 2.1 e 2.2 ). O método incorpora todos os hiperparâmetros explorados em uma série temporal fuzzy normal.

Para a representação de pesos e regras do modelo obtido na PWFTS, podemos representar em termos das matrizes do precedente e do conseqüente do modelo (DE LIMA *et al.*, 2019). O precedente também conhecido como matriz Left Hand Side (LHS) e o conseqüente, nomeado de Right Hand Side (RHS). A matriz IA corresponde ao peso das regras do modelo da PWFTS e a matriz LHS corresponde a matriz de markov de transição entre os conjuntos nebulosos. Podemos escrever a relação das matrizes RHS e LHS conforme a equação (2.6). O cálculo

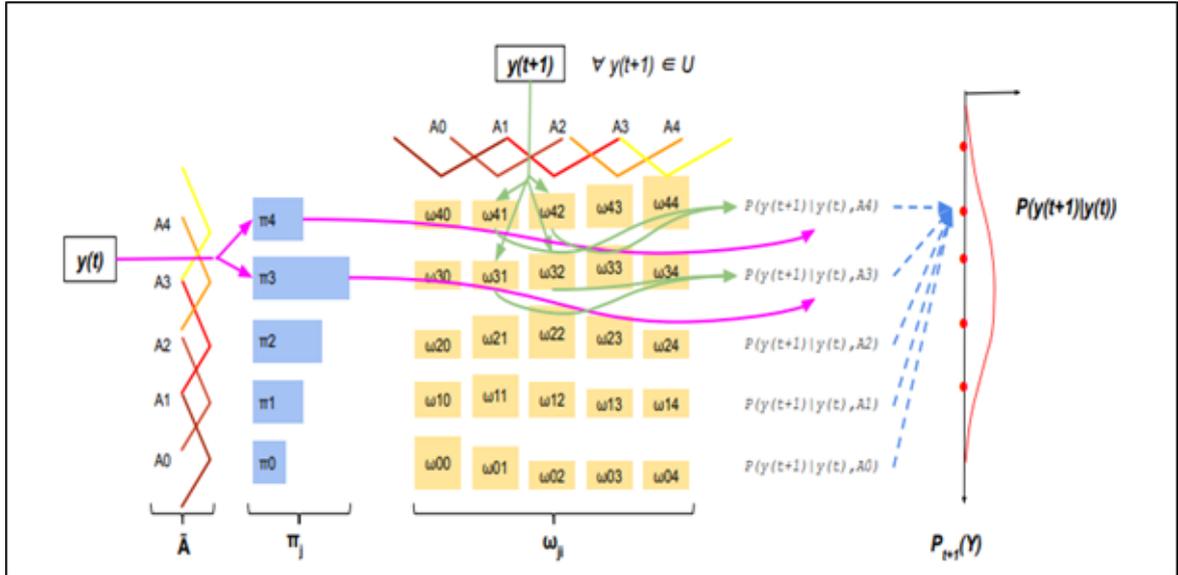


Figura 2.8: Processo de treinamento da *PWFTS*.  
 Fonte: (DE LIMA *et al.*, 2019).

dos valores da matriz LHS (Função de distribuição de probabilidade dos dados de treino), que corresponde aos pesos das FLRs é descrito em (SONG e CHISSOM, 1993)(DE LIMA *et al.*, 2019). LHS e RHS são matrizes compostas por pesos e probabilidades de transição entre os conjuntos nebulosos nas regras do modelo da *PWFTS* 2.12.2, respectivamente. Estas regras descrevem o mais provável comportamento no futuro Right Hand Side (RHS) a partir de algum comportamento passado (Right Hand Side (RHS)) 2.5. Estas matrizes de pesos foram utilizadas neste trabalho e foram obtidas a partir do processo de fuzzificação da *PWFTS* descrito em de Lima *et al.* (2019). De acordo com (DE LIMA *et al.*, 2019), uma série temporal pode ser descrita de acordo com ,onde  $A_n$  corresponde aos conjuntos nebulosos utilizados.

## 2.8 XGBoost

Os métodos de conjunto de classificadores baseados em árvore de decisão são uma técnica de aprendizado de máquina que combina vários modelos de árvore para produzir um modelo preditivo eficaz ou ideal e que permite um bom desempenho preditivo, em especial em comparação ao uso de um único modelo.

Extreme Gradient Boosting (XGBoost) é modelo de aprendizado de máquina utilizado para treinar árvores de decisão impulsionadas por gradiente e outros modelos impulsionados por gradiente. Florestas aleatórias usam a mesma representação e inferência de modelo, como árvores de decisão impulsionadas por gradiente, mas um algoritmo de treinamento diferente.

O algoritmo produz um modelo de previsão na forma de um conjunto impulsionador de árvores de classificação fracas por um gradiente descendente que otimiza a função de perda. Os parâmetros do algoritmo Extreme Gradient Boosting (XGBoost) podem ser separados em três

Tabela 2.1: Matriz de confusão de um classificador.

Classe	predita K1	predita K2	predita Kn
verdadeira C1	M(C1, K1)	M(C1, K2)	M(C1, Kn)
verdadeira C2	M(C2, K1)	M(C2, K2)	M(C2, Kn)
verdadeira CK	M(Ck, K1)	M(Ck, K2)	M(Ck, Kn)

Fonte: (MONARD e BARANAUSKAS, 2003)

Tabela 2.2: Matriz de Confusão para 2 classes.

Classe	predita K1	predita K2
verdadeira C1	VP	FP
verdadeira C2	FN	VN

Fonte: (MONARD e BARANAUSKAS, 2003)

categorias: Parâmetros Gerais, Parâmetros de Tarefa e Parâmetros Booster. Convém sinalizar que o modelo tem sido eficaz na redução do tempo de processo e pode ser usado tanto para tarefas de regressão quanto de classificação (SAHIN, 2020).

## 2.9 Avaliação de modelos - Matriz de confusão

A matriz de confusão ajuda a aferir a eficiência de classificadores na inteligência artificial. Desta forma, é possível distinguir e classificar o modelo com os valores verdadeiros conhecidos no conjunto de dados de teste. A matriz de confusão é construída em função da classificação realizada pelo classificador e exibe a distribuição dos registros testados em termos das suas classes atuais e das classes previstas. Os modelos podem conter duas ou mais classes previstas e a matriz de confusão é um indicativo da qualidade do classificador (HART *et al.*, 2000).

(MONARD e BARANAUSKAS, 2003) explicam que a matriz de confusão de uma hipótese  $H$  oferece uma medida efetiva do modelo de classificação, ao mostrar o número de classificações corretas versus as classificações previstas para cada classe. A Tabela 1 exibe o formato de uma matriz de confusão, onde os resultados são totalizados em duas dimensões: classes verdadeiras e classes previstas, para  $k$  classes diferentes  $K1, K2, \dots, Kn$ . Cada elemento  $M(C_i, C_j)$  da matriz,  $i, j = 1, 2, \dots, k$ , representa o número de exemplos de que realmente pertencem à classe  $C_i$ , mas foram classificados como sendo da classe  $C_j$ .

Para uma matriz de confusão com apenas 2 classes, temos o formato de acordo com a Tabela 2.2:

Na Tabela 3, podemos extrair os verdadeiros positivos ( $VP$ ), verdadeiros negativos ( $VN$ ), falsos positivos ( $FP$ ) e falsos negativos ( $FN$ ). De acordo com as observações existentes em cada elemento da matriz de confusão. É possível extrair métricas como:

$$\text{Taxa de Falso Positivo: } \frac{FP}{FP + VP} \quad (2.9)$$

$$\text{Taxa de Falso Negativo: } \frac{FN}{FN + VN} \quad (2.10)$$

$$\text{Sensibilidade: } \frac{VP}{FN + VP} \quad (2.11)$$

$$\text{Especificidade: } \frac{VN}{FN + VN} \quad (2.12)$$

$$\text{Acurácia: } \frac{VP + VN}{VP + VN + FN + FP} \quad (2.13)$$

$$\text{Precisão: } \frac{VP}{VP + FP} \quad (2.14)$$

$$\text{F-Score: } \frac{2 \times \text{Precisão} \times \text{Revocac\~{a}o}}{\text{Precis\~{a}o} + \text{Revocac\~{a}o}} \quad (2.15)$$

De acordo com (HUGHES-OLIVER, 2018), esclarece que os algoritmos de classifica\~{c}o produzem uma pontua\~{c}o, que correspondem a compara\~{c}o de valores reais e a valores obtidos por meio de classifica\~{c}o ou predi\~{c}o. Os valores classificados corretamente s\~{a}o definidos como verdadeiros e os valores classificados erroneamente, s\~{a}o chamados de falsos.

## 2.10 An\~{a}lise de Dick-Fuller Aumentada

Ao avaliar uma s\~{e}rie temporal em rela\~{c}o a sua estacionariedade, podemos fazer uso da an\~{a}lise de Dick-Fuller aumentada (ADF). A ADF testa para uma s\~{e}rie temporal modelada por uma equa\~{c}o auto regressiva, se as ra\~{i}zes deste modelo s\~{a}o unit\~{a}rias (DICKKEY e FULLER, 1979). Para a identifica\~{c}o da estacionariedade de uma s\~{e}rie temporal, v\~{a}rios procedimentos foram propostos para identificar a presen\~{c}a de raiz unit\~{a}ria em uma serie temporal, entre os quais o teste de Dickey-Fuller Aumentado (ADF) e suas extens\~{o}es que consideram a sua presen\~{c}a como hip\~{o}tese nula (DICKKEY e FULLER, 1979).

O teste de Dickey-Fuller pode ser utilizado em qualquer modelo auto regressivo, Modelo auto-regressivo (AR), independente da ordem do mesmo. A partir destas defini\~{c}oes, conseguimos descrever a hip\~{o}tese nula H0 de Dickey-Fuller da seguinte forma:

$$\begin{cases} H_0 : O \text{ processo possui raiz unit\~{a}ria} - \text{nao estacion\~{a}rio} \\ H_1 : O \text{ processo nao possui raiz unit\~{a}ria} - \text{estacion\~{a}rio} \end{cases} \quad (2.16)$$

Nas s\~{e}ries temporais onde se deseja avaliar a condi\~{c}o de estacionariedade que foram descritos na equa\~{c}o (10), testa-se a hip\~{o}tese nula H0:  $f = 1$  (h\~{a} presen\~{c}a de raiz unit\~{a}ria), contra a alternativa H1:  $f < 1$  (n\~{a}o h\~{a} presen\~{c}a de raiz unit\~{a}ria), podendo o processo ser considerado estacion\~{a}rio. De acordo com Silveira *et al.* (2022), o fato de que ao n\~{a}o rejeitar a hip\~{o}tese

nula, não se encontram evidências de que não há presença de raiz unitária, sendo mais plausível considerar a sua presença, o que conduz a uma série temporal não estacionária (SILVEIRA *et al.*, 2022).

De acordo com a Figura 2.9, temos o fluxograma do teste de ADF. O teste ADF tem os resultados de acordo com graus de pertinência, neste trabalho serão apresentados métricas para 1%, 5% e 10%.

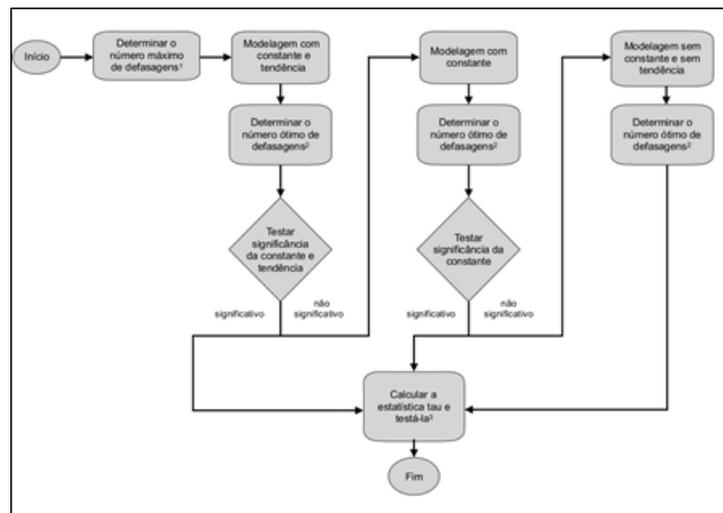


Figura 2.9: Dinâmica de aplicação do teste de raiz unitária ADF.  
Fonte: Silveira *et al.* (2022).

## 2.11 Teste homocedasticidade de Levene

O teste de homocedasticidade de Levene é uma estatística inferencial utilizada para verificar a homogeneidade das variâncias da série temporal. Estatisticamente, presume-se que as variâncias de amostras de uma série temporal (sub-amostras), são iguais. O teste de Levene avalia essa suposição para uma série temporal, sendo que na hipótese nula ( $H_0$ ), as variâncias são iguais, ou seja, temos uma série homocedástica. Caso a hipótese nula seja negada considerando um nível significância (normalmente de 0,05), temos uma série heterocedástica, representando que há diferença significativa entre as variâncias das amostras da série temporal (LEVENE, 1960), sendo esta a hipótese 1 ( $H_1$ ). O teste de Levene equivale a uma análise de variância entre grupos de dados de uma variável, e utiliza os desvios em relação à média dos grupos (partes), podendo-se tomar os valores absolutos dos desvios ou o quadrado dos desvios.

O teste proposto por Levene baseia-se na transformação dos dados originais e realiza uma análise de variância, e utiliza o teste F para testar a existência de homogeneidade das variâncias. A transformação, nada mais é do que a obtenção dos resíduos. O teste de Levene pode ser definido conforme:

$$\begin{cases} H_0 : \text{As variancias das sub – amostras são iguais – homocedasticidade} \\ H_1 : \text{A menos que as sub – amostras tenham variancias diferentes das demais – heterocedastica} \end{cases} \quad (2.17)$$

## 3 Materiais e Métodos

Esta seção tem como objetivo mostrar os procedimentos para o desenvolvimento da pesquisa e a metodologia aplicada. O trabalho desenvolvido em FTS, apresenta um método resultante da combinação de um classificador para a classificação de um tipo de falha em um processo industrial.

### 3.1 Metodologia

O controle de processos industriais modernos é baseado em dados e na inteligência que se pode extrair dos mesmos, de forma que não se pode controlar o que não se pode medir e muito menos melhorar e otimizar um processo não historiado (JAHANSHAH *et al.*, 2015).

A proposta foi desenvolver modelos baseados em dados reais do processo. Este modelo aplica detecção e diagnóstico de falhas em processos industriais (BENNER JR, 1985), de sensores de nível nos silos de minério de ferro. Foi utilizada a linguagem Python para construção dos modelos e o processamento dos dados. Foi utilizado o Google Colab Pro para o processamento e biblioteca PyFTS (SILVA *et al.*, 2018) como base para as análises.

Em um primeiro passo, considerou-se um classificador clássico como um comparativo para as previsões a serem realizadas. Foi utilizado o classificador do Extreme Gradient Boosting (XGBoost) (SAHIN, 2020) para esta classificação, com 8 “lags”, como abordado por (ISMAIL e EFENDI, 2011). Foi comparado o desempenho de cada um considerando taxas de acerto e falsos positivos, sensibilidade, especificidade, acurácia, precisão e F-Score, cujas as métricas são obtidas a partir das informações contidas na matriz de confusão. Foram utilizados dados reais provenientes do sistema da britagem secundária da Usina A da mina do S11D-Vale. Após obter os modelos, estes serão validados com dados reais extraídos da planta em análise.

O modelo de comparação proposto neste trabalho foi desenvolvido em duas etapas, uma de modelagem e outra de classificação (Figura 3.1). Na etapa de modelagem, foram utilizadas janelas de 100 amostras de dados (conjuntos de dados  $y'(t)$  da Figura 3.2) e obteve-se o modelo (Figura 3.2 com o conjunto de regras e pesos do modelo da *PWFTS*) treinado e validado na *PWFTS*. Foi definido uma janela de 100 dados com o objetivo de se obter uma quantidade de elementos para treinamento e teste do algoritmo de classificação. Após a obtenção do primeiro modelo, a janela de 100 dados será deslizada para os próximos 100 elementos da série e assim sucessivamente até o final da série temporal (processo de janelamento), sendo que para cada nova janela, um novo modelo treinado e testado de *PWFTS* foi obtido, com seus respectivos hiper parâmetros. O conjunto de todos os hiper parâmetros obtidos durante o "janelamento" da série temporal, foi utilizado para o classificador.

Para a modelagem, foram utilizados dados tanto de falhas quanto de operação normal do nível dos silos da britagem secundária, sendo formadas duas bases. Para os dois casos, foram utilizados 80% dos dados para treinamento e 20% para teste. Após estes tratamentos,

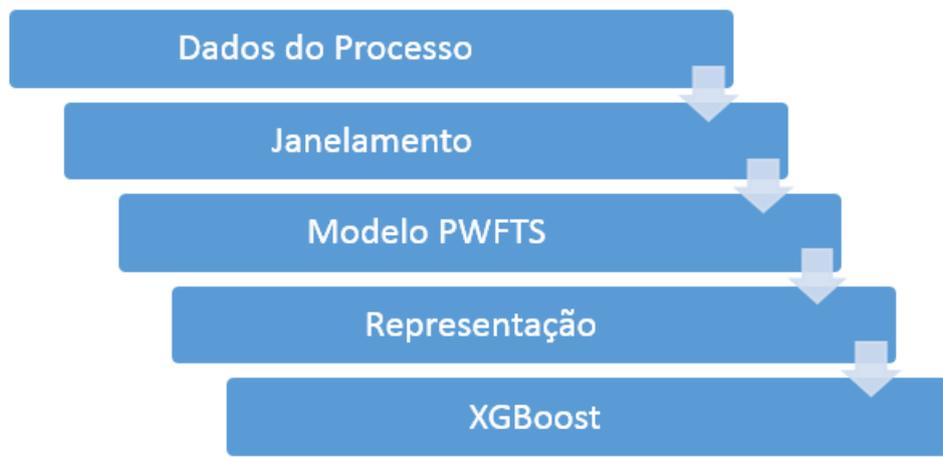


Figura 3.1: Sequência de processamento dos dados com melhoria proposta.  
Fonte: Autoria própria.

os modelos foram colocados em um classificador XGBoost, conforme apresentado na Figura (3.2) para definir a existência ou não da falha e em qual situação melhor se enquadra. Também foi realizado um comparativo com o XGBoost clássico, composto de 8 “lags” de atraso, sendo apresentada de forma comparativa os ganhos obtidos no processo de classificação.

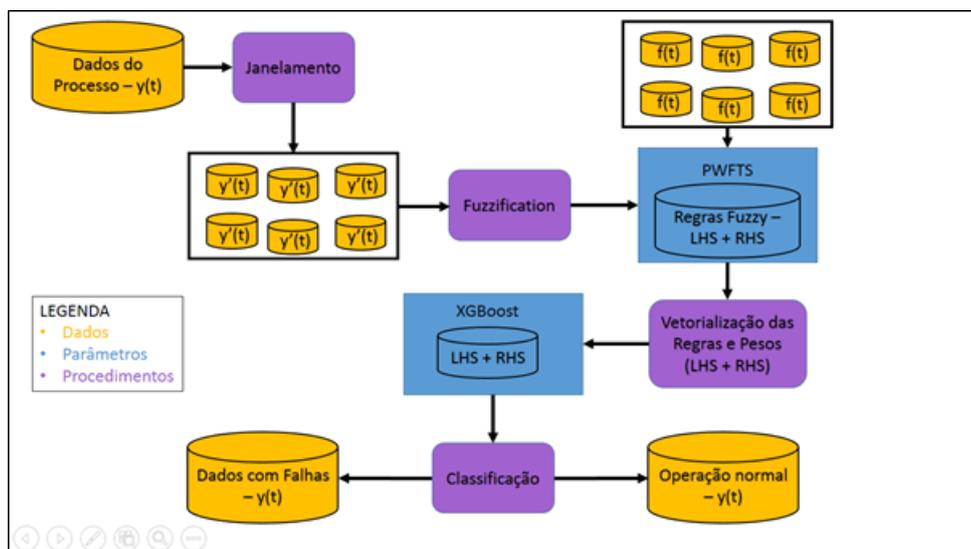


Figura 3.2: Metodologia de construção do classificador com os pesos e regras da *PWFTS*.  
Fonte: Autoria própria.

### 3.1.1 Descrição dos modos de falha

Na britagem secundária, há um sistema de posicionamento de uma correia transportadora móvel, que fica constantemente posicionando entre os seis silos de estocagem de minério existente na área ( Figura 3.3). A correia transportadora móvel se desloca até a posição demarcada por um sensor de posição e a mesma paralisa naquela posição para realizar o enchimento

do silo de minério. Na Figura 3.3 vemos que o transportador móvel está posicionado no silo de número 6, que está identificado pelo tag de campo SI\_2012KS\_06. Ao se posicionar, a correia transportadora inicia o processo de enchimento do silo ao qual ela está posicionada. Quando o minério atinge um nível específico, calculado por um sensor de nível, o processo de enchimento daquele silo é finalizado e a correia transportadora móvel se desloca para o silo seguinte, conforme representado na Figura 3.4. Posicionado no silo subsequente, se inicia o novo processo de enchimento, agora no silo adjacente, a posição de enchimento está sinalizada na Figura 3.4 com uma seta na parte superior do silo, no caso o silo de número 5. Na Figura 3.5, o transportador avançou com o mesmo processo de enchimento anterior, mais dois silos, preenchendo de acordo com a Figura 3.5, o silo de número 3. De acordo com a sequência, após o enchimento do silo 3, o transportador móvel se posiciona para enchimento do silo 2 simbolizado na Figura 3.6. Ao chegar no silo de número 1 e tendo preenchido de minério todos os silos anteriores de acordo com a Figura 3.7, ao finalizar o enchimento deste silo, o transportador móvel inverte o sentido de deslocamento e retorna ao silo de número 5, representado na Figura 3.6 e após o enchimento do mesmo desloca-se para o silo de número 4, representado na Figura 3.5 .Ao perfazer os seis silos existentes na área, o processo continua no sentido contrário, iniciando da direita para esquerda, decrescendo no número dos silos. Este é um processo cíclico, que se repete indefinidamente.



Figura 3.3: Correia transportadora móvel (TR-2011KS-10) posicionada no silo de número 6 (SI-2012KS-06).

Fonte: Vale (2021).



Figura 3.4: Correia transportadora móvel (TR-2011KS-10) posicionada no silo de número 6 (SI-2012KS-06).

Fonte: Vale (2021).



Figura 3.5: Correia transportadora móvel (TR-2011KS-10) posicionada no silo de número 6 (SI-2012KS-06).

Fonte: Vale (2021).



Figura 3.6: Correia transportadora móvel (TR-2011KS-10) posicionada no silo de número 6 (SI-2012KS-06).

Fonte: Vale (2021).

O sistema de enchimento automático dos silos da britagem secundária apresenta um modos de falha conhecidos que está associado a falha do sensor de nível. Este modo de falha é o explorado neste trabalho pois ao falhar o sensor de nível, XXXX o mesmo atrapalha a sequência de enchimentos característicos desse sistema. O primeiro modo refere-se à falha do sensor de nível de qualquer um dos silos. O segundo é a falha no sensor de posicionamento da correia transportadora. O terceiro modo refere-se ao funcionamento incorreto da comporta do silo, ficando indevidamente aberta ou fechada, reduzindo a eficiência da planta como um todo.

### 3.1.2 Modo de falha (sensor de nível de silo) - VEGAPULS 69

O sensor utilizado para realizar as medições de nível é do modelo VEGAPULS 69, da empresa Vega. Sendo que, como descrito, cada silo presente na britagem secundária apresenta um dispositivo redundante desse modelo para medição do seu nível.

O VEGAPULS 69 é apropriado para medição contínua de produtos sólidos, independente da sua composição ou granulometria. Indicado para medição de nível em silos de grande porte, sendo este um dos motivos de seu uso nesta aplicação. Este sensor é do tipo radar, que através de uma antena conectada ao próprio sensor, emite um sinal de radar contínuo que é enviado e refletido pelo produto presente no silo. O sinal refletido é captado pela mesma antena novamente com o eco.

O princípio de medição é baseado na diferença de frequências entre o sinal enviado



Figura 3.7: Correia transportadora móvel (TR-2011KS-10) posicionada no silo de número 6 (SI-2012KS-06).

Fonte: Vale (2021).

e recebido, e é proporcional à distância a ser medida, sendo este um indicativo da altura de material existente, quando se conhece a dimensão total do silo. Com a determinação da altura de enchimento de material, a mesma é convertida em um sinal analógico de saída e enviada como um sinal de saída de medição.

Como vantagens adicionais ao uso desse sensor para esta aplicação de medição:

1. Medição ausente de interferências como vapor ou pó;
2. Livre de manutenção e não necessita de contato com o produto;
3. Maior disponibilidade ao sistema, pois não necessita de manutenção e sem desgaste após o processo de operação;
4. Apresenta problemas com partículas sólidas que se projetem indevidamente a sua frente, acarretando falsos positivos;



Figura 3.8: Sensor do tipo radar VEGAPULS 69.

Fonte: Vega (2022).

O primeiro modo de falha a ser descrito refere-se à falha do sensoriamento de nível dos silos da britagem secundária, ou falhas no sensor de radar modelo VEGAPULS 69. Este modo de falha está presente em qualquer um dos silos. De acordo com o sistema descrito

anteriormente, apresenta-se abaixo duas imagens com curvas características do funcionamento deste sensor. Na Figura 3.9, tem-se o correto funcionamento do mesmo. Já na Figura 3.10, vê-se o funcionamento incorreto do sensor em vermelho, identifica-se a falha de medição incorreta do sensor por uma taxa de variação indevida da sua leitura.

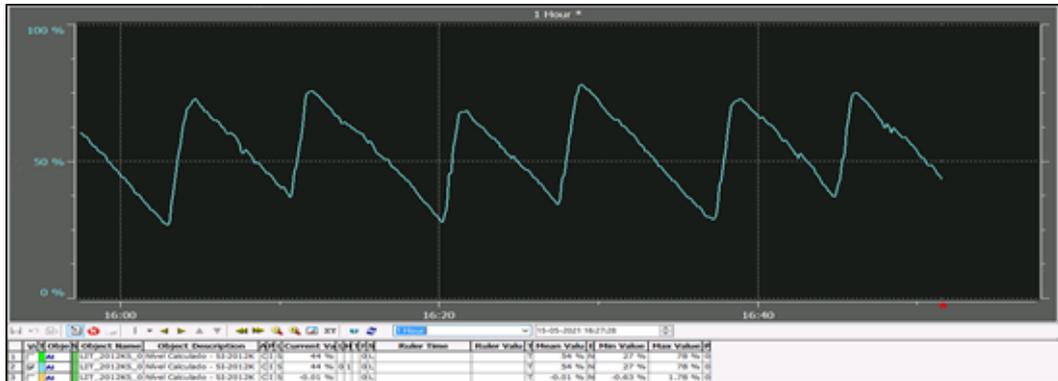


Figura 3.9: Funcionamento esperado do sensor de nível do silo.  
Fonte: Vale (2021).

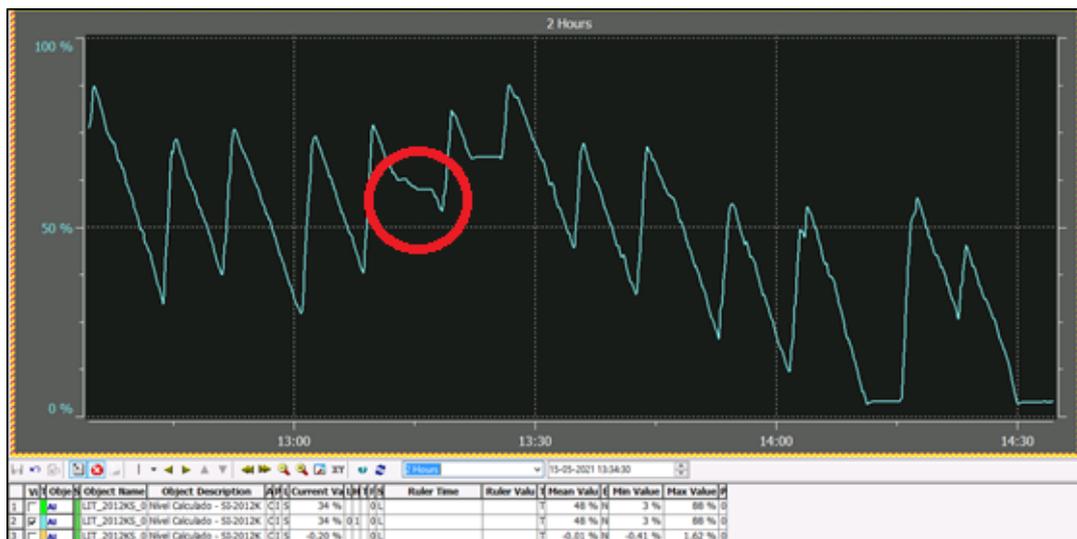


Figura 3.10: Indicação das falhas do sensor de nível do silo – taxa de variação indevida.  
Fonte: Vale (2021).

Na Figura 3.11, temos um exemplo de medição de sensor congelada. Sendo este também um modo de falha comum neste tipo de sensoriamento. Este modo de falha, foi o tipo de falha explorada pelo classificador da metodologia deste trabalho.

## 3.2 Universo dos dados

No Universo de Discurso (UoD) proposto, pretende-se identificar tanto situações em que existe falha dos sensores de nível dos silos (para os modos de falha descritos na Figura 3.11),

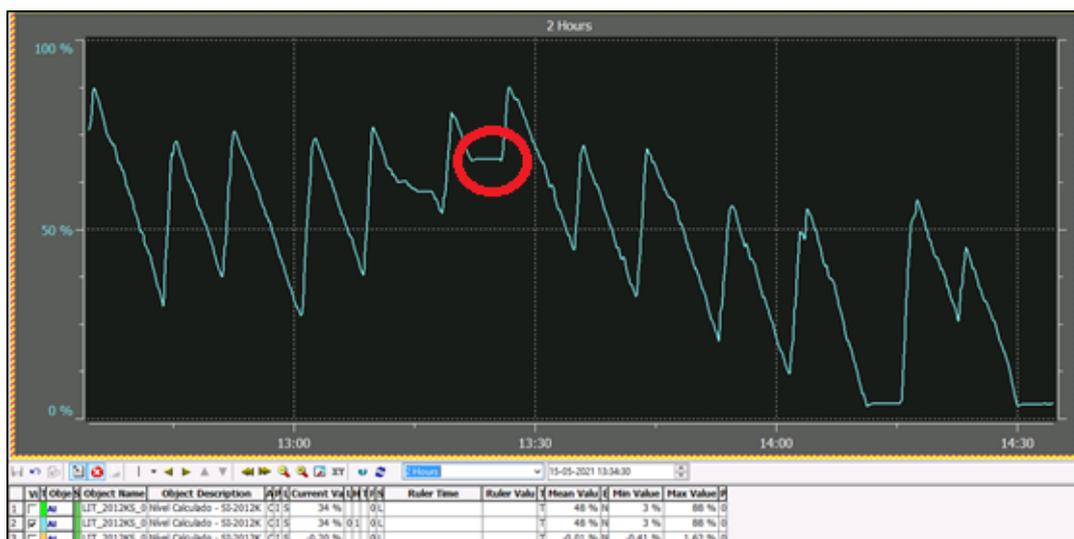


Figura 3.11: Indicação das falhas do sensor de nível do silo – “congelamento” da leitura do sensor.

Fonte: Vale (2021).

quanto situações de um cenário de operação normal (Figura 3.9), onde os sensores apresentaram medições esperadas.

Para este objetivo, foram coletados dados tanto de operação normal quanto de operação em que o sensor apresenta falha. Foi extraída a mesma quantidade de dados para as duas situações em que existem falhas (Figura 3.11) e o de comportamento normal (Figura 3.9). Para se ter uma maior abrangência do processo, foram coletadas uma variável endógena e três variáveis exógenas que apresentam uma relação de causalidade com as falhas na variável analisada, a saber:

1. Variável endógena: Nível do silo (LIT\_2012KS\_0251);
2. Variável exógena: Velocidade do alimentador (AL\_2012KS\_06M1\_SpeedActual),
3. Variável exógena: Taxa do alimentador (WIT\_1085KS\_2300\_Rate);
4. Variável exógena: Carregamento do transportador móvel (WIT\_1085KS\_2300\_BeltLoad);

A definição dos nomes destas variáveis corresponde ao TAG de localização do sensor no sistema da usina de britagem. O comportamento das variáveis observadas onde não se encontram falhas (Dados de operação normal) é retratado nas Figuras 24, a seguir.

A partir dos dados, cada variável mencionada acima foi particionada durante o processo de fuzzificação em partições triangulares e cujo os particionamentos para cada variável se encontram nas Figuras 3.20, 3.21, 3.22 e 3.23. A adoção dos particionamentos triangulares se deu por ser o mais simples existente no momento.

Nas tabelas 3.1, 3.2, 3.3 e 3.4, apresentamos os valores de particionamento para cada variável. Por se tratar de um particionamento triangular, foi listado o valor inicial, final e in-

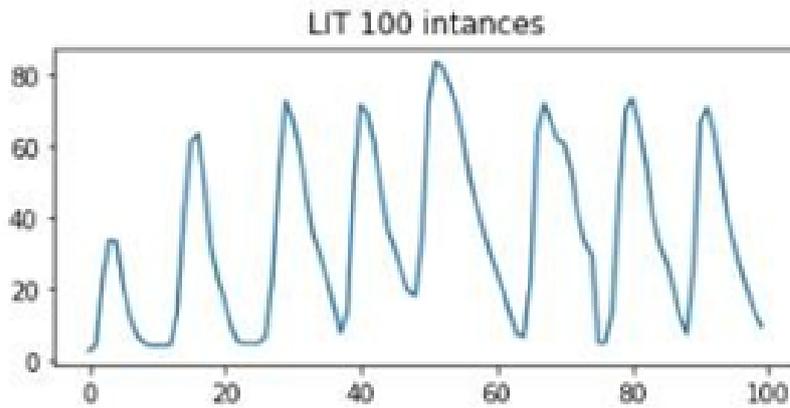


Figura 3.12: Análise inicial dos dados-Visualização de LIT\_2012KS\_0251.  
 Fonte: Autoria própria.

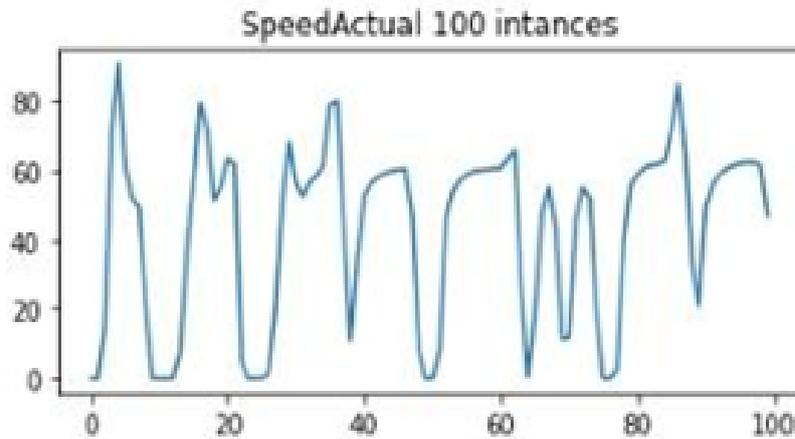


Figura 3.13: Análise inicial dos dados-Visualização de AL\_2012KS\_06M1\_SpeedActual.  
 Fonte: Autoria própria.

termediário do particionamento. Como todas as variáveis foram particionadas por 10 conjuntos nebulosos, valor obtido a partir de testes empíricos sobre os dados.

Tabela 3.1: Particionamento do UoD da variável LIT\_2012KS\_0251

Conjunto Nebuloso	Valor Inicial	Valor Intermediário	Valor Final
A0	-13,0	-4,0	5,0
A1	-4,0	5,0	14,0
A2	5,0	14,0	24,0
A3	14,0	24,0	33,0
A4	24,0	33,0	42,0
A5	33,0	42,0	51,0
A6	42,0	51,0	60,0
A7	51,0	60,0	69,0
A8	60,0	69,0	78,0
A9	69,0	78,0	87,0

Fonte: Autoria própria

Tabela 3.2: Particionamento do UoD da variável AL\_2012KS\_06M1\_SpeedActual

Conjunto Nebuloso	Valor Inicial	Valor Intermediário	Valor Final
A0	-10,0	0,0	10,0
A1	0,0	10,0	19,0
A2	10,0	19,0	29,0
A3	19,0	29,0	38,0
A4	29,0	38,0	48,0
A5	38,0	48,0	57,0
A6	48,0	57,0	67,0
A7	57,0	67,0	76,0
A8	67,0	76,0	86,0
A9	76,0	86,0	96,0

Fonte: Autoria própria

Tabela 3.3: Particionamento do UoD da variável WIT\_1085KS\_2300\_BeltLoad

Conjunto Nebuloso	Valor Inicial	Valor Intermediário	Valor Final
A0	-80,0	-6,0	68,0
A1	-6,0	68,0	143,0
A2	68,0	143,0	217,0
A3	143,0	217,0	292,0
A4	217,0	292,0	367,0
A5	292,0	367,0	441,0
A6	367,0	441,0	516,0
A7	441,0	516,0	590,0
A8	516,0	590,0	665,0
A9	590,0	665,0	740,0

Fonte: Autoria própria

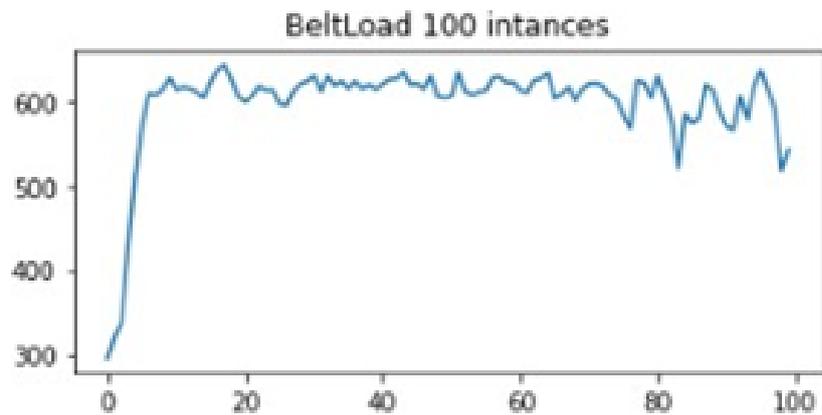


Figura 3.14: Análise inicial dos dados-Visualização de WIT\_1085KS\_2300\_BeltLoad.  
 Fonte: Autoria própria.

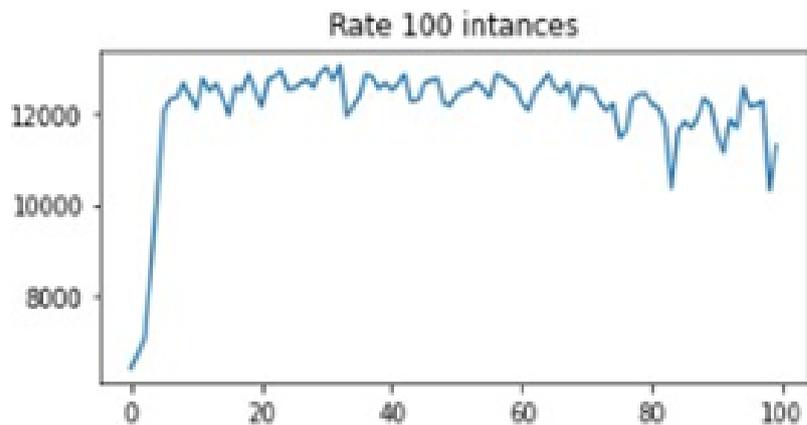


Figura 3.15: Análise inicial dos dados-Visualização WIT\_1085KS\_2300\_Rate.  
 Fonte: Autoria própria.

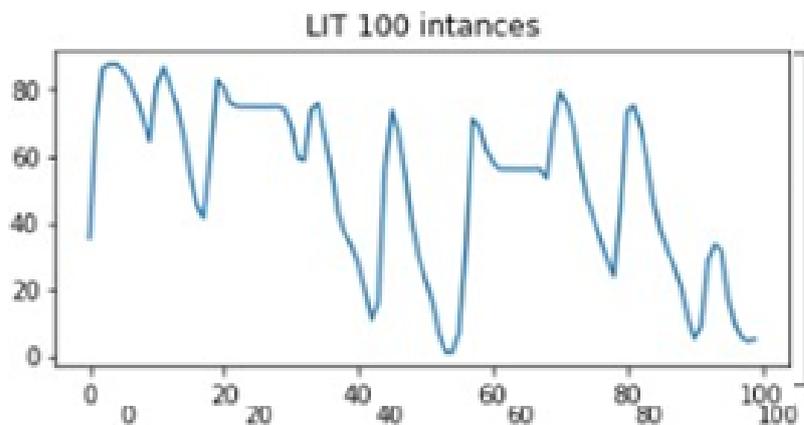


Figura 3.16: Análise inicial dos dados-Visualização de LIT\_2012KS\_0251 com falhas.  
 Fonte: Autoria própria.

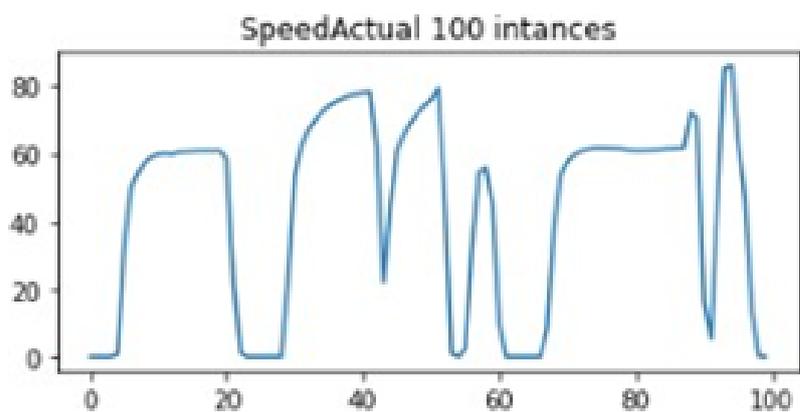


Figura 3.17: Análise inicial dos dados-Visualização de AL\_2012KS\_06M1\_SpeedActual com falhas.

Fonte: Autoria própria.



Figura 3.18: Análise inicial dos dados-Visualização de WIT\_1085KS\_2300\_BeltLoad com falhas.

Fonte: Autoria própria.

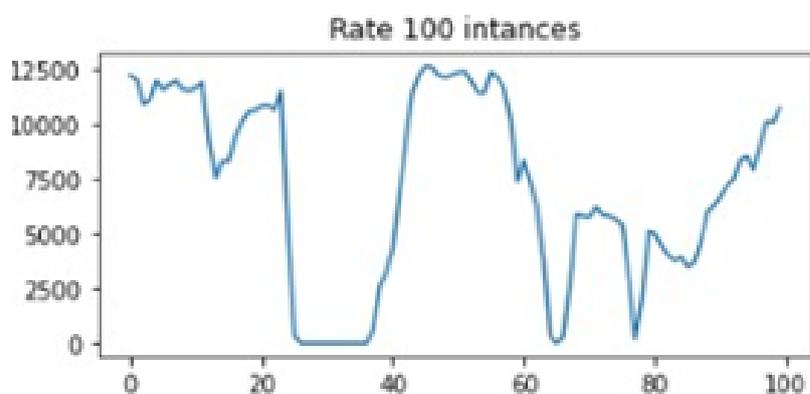


Figura 3.19: Análise inicial dos dados-Visualização WIT\_1085KS\_2300\_Rate com falhas.

Fonte: Autoria própria.

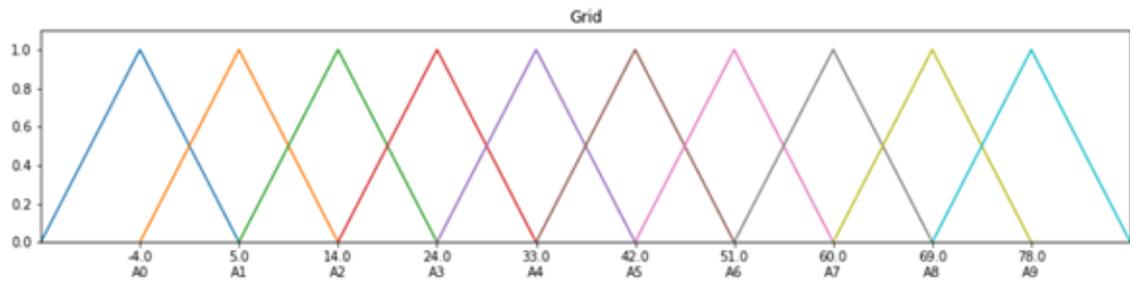


Figura 3.20: Particionamentos aplicados a variável LIT\_2012KS\_0251 -10 conjuntos nebulosos.

Fonte: Autoria própria.

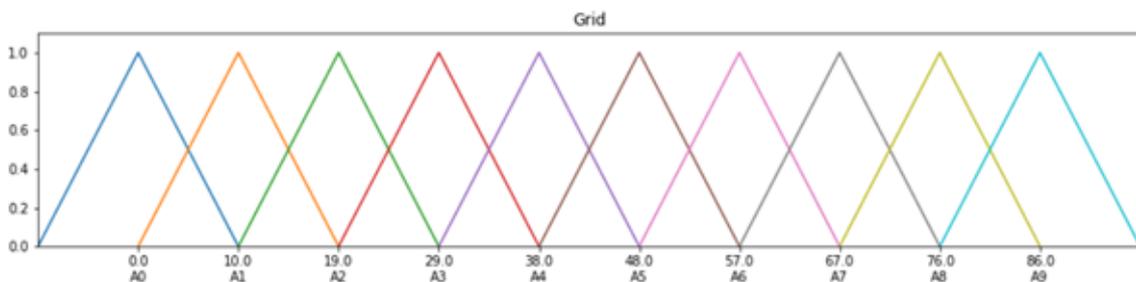


Figura 3.21: Particionamentos aplicados a variável AL\_2012KS\_06M1\_SpeedActual -10 conjuntos nebulosos.

Fonte: Autoria própria.

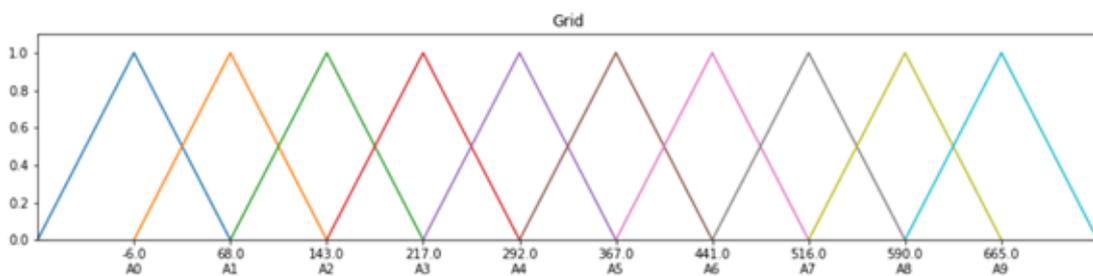


Figura 3.22: Particionamentos aplicados a variável WIT\_1085KS\_2300\_BeltLoad -10 conjuntos nebulosos.

Fonte: Autoria própria.

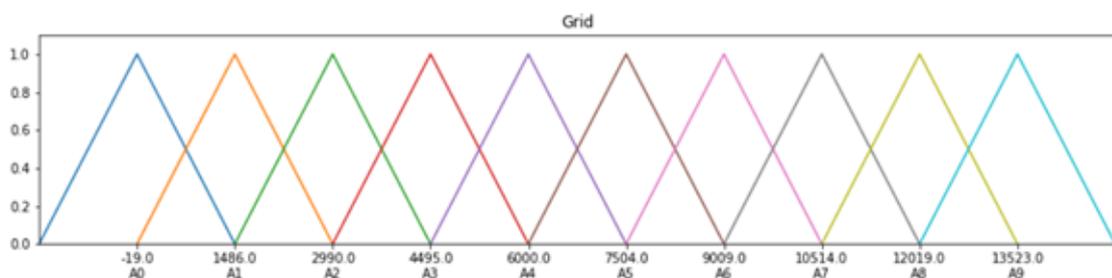


Figura 3.23: Particionamentos aplicados a variável WIT\_1085KS\_2300\_Rate -10 conjuntos nebulosos.

Fonte: Autoria própria.

Tabela 3.4: Particionamento do UoD da variável WIT\_1085KS\_2300\_Rate

Conjunto Nebuloso	Valor Inicial	Valor Intermediário	Valor Final
A0	-1524,0	-19,0	1486,0
A1	-19,0	1486,0	2990,0
A2	1486,0	2990,0	4495,0
A3	2990,0	4495,0	6000,0
A4	4495,0	6000,0	7504,0
A5	6000,0	7504,0	9009,0
A6	7504,0	9009,0	10514,0
A7	9009,0	10514,0	12019,0
A8	10514,0	12019,0	13523,0
A9	12019,0	13523,0	15027,0

Fonte: Autoria própria

## 4 Caracterização dos Dados

Será apresentado neste capítulo uma caracterização das séries temporais utilizadas para a construção da metodologia proposta neste trabalho. Neste capítulo, também será definida uma abreviação das séries temporais utilizadas, com o intuito de facilitar o entendimento e auxiliar a leitura, torná-la mais simples. As abreviações e descrições destas variáveis se encontram na 4.1 e serão adotadas em todo o trabalho a partir deste tópico. Vale ressaltar que as variáveis escolhidas apresentam uma relação de causalidade com a variável de nível, variável a qual se deseja classificar as falhas de congelamento na nova metodologia.

### 4.1 Caracterização da Série temporal estudada

Para o entendimento de comportamento dos dados a serem analisados e classificados, foram aplicadas as técnicas de decomposição da série temporal em tendência e sazonalidade. Em conjunto, também realizado os testes de auto correlação (ACF), auto correlação parcial (PACF), função de correlação cruzada (CCF), ADF e o teste de homocedasticidade de Levene.

### 4.2 Decomposição da Série Temporal

A partir da função “seasonal\_decompose”, presente na biblioteca 'statsmodels' do python. Foi possível decompor os sinais das variáveis utilizadas neste estudo. Sendo possível entender a sazonalidade e tendência de cada variável considerada nesse estudo.

#### 4.2.1 LIT

Conforme a Figura 4.1, nota-se que o sinal é composto em sua maior parte por sazonalidade e apresenta uma pequena tendência de decréscimo.

Para esta variável foi realizado o teste ADF, que retornou resultado representado na Tabela 4.2. De acordo com a Tabela 4.2, vemos que para todos os graus de pertinência, a série é estatisticamente estacionária.

Para este teste, foi encontrado uma estatística do teste ADF: -8,884 e p-Valor:  $1,294 \cdot 10^{-14}$

Tabela 4.1: Tabela das variáveis e tags de campo.

Tag do Instrumento no Processo	Abreviação	Descrição do Tag	Unidade
LIT_2012KS_0251	LIT	Indicação do sensor de nível	%
AL_2012KS_06M1_SpeedActual	ALS	Velocidade do alimentador	m/s
WIT_1085KS_2300_BeltLoad	BL	Carregamento da correia transportadora	Kg/m
WIT_1085KS_2300_Rate	Rate	Vazão mássica da balança	t/h

Fonte: Autoria própria

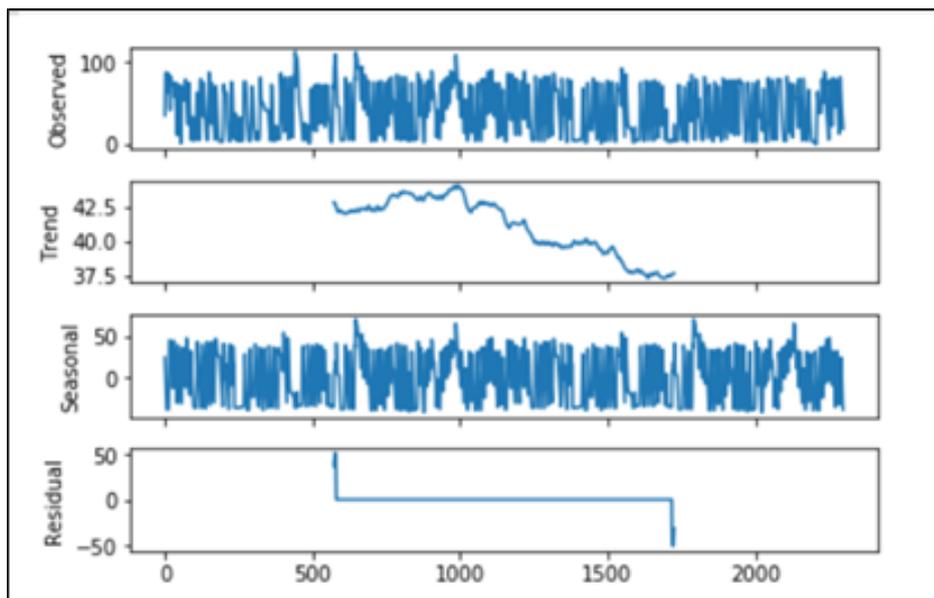


Figura 4.1: Decomposição de sazonalidade e tendência da variável LIT considerada neste classificador.

Fonte: Autoria própria.

Tabela 4.2: Teste ADF para LIT.

Alfa	Valor Crítico	Resultado
1%	-3.433	H0 Rejeitada - Estacionário
5%	-2.862	H0 Rejeitada - Estacionário
10%	-2.567	H0 Rejeitada - Estacionário

Fonte: Autoria própria

#### 4.2.2 ALS

De acordo com a Figura 4.2, nota-se que o sinal é composto em sua maior parte por sazonalidade e apresenta uma pequena tendência de decréscimo.

Para esta variável foi realizado o teste ADF, que retornou resultado representado na tabela 4.3. De acordo com a Tabela 4.3, vemos que para todas os graus de pertinência, a série é estatisticamente estacionária.

Tabela 4.3: Teste ADF para ALS.

Alfa	Valor Crítico	Resultado
1%	-3.433	H0 Rejeitada - Estacionário
5%	-2.862	H0 Rejeitada - Estacionário
10%	-2.567	H0 Rejeitada - Estacionário

Fonte: Autoria própria

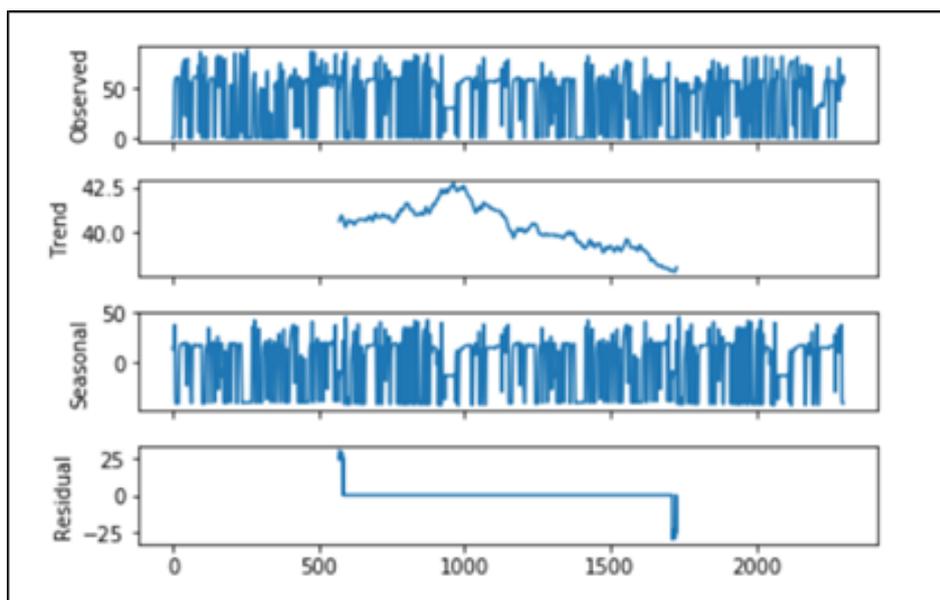


Figura 4.2: Decomposição de sazonalidade e tendência da variável ALS considerada neste classificador.

Fonte: Autoria própria.

Tabela 4.4: Teste ADF para BL.

Alfa	Valor Crítico	Resultado
1%	-3.433	H0 Rejeitada - Estacionário
5%	-2.862	H0 Rejeitada - Estacionário
10%	-2.567	H0 Rejeitada - Estacionário

Fonte: Autoria própria

### 4.2.3 BL

De acordo com a Figura 4.3, podemos notar que o sinal é composto em sua maior parte por sazonalidade e apresenta uma pequena tendência de acréscimo.

Para esta variável foi realizado o teste ADF, que retornou resultado representado na Tabela 4.4. De acordo com a Tabela 4.4, vemos que para todos os os graus de pertinência, a série é estatisticamente estacionária.

### 4.2.4 Rate

De acordo com a Figura 4.3, nota-se que o sinal é composto em sua maior parte por sazonalidade e apresenta uma pequena tendência de acréscimo.

Para esta variável foi realizado o teste ADF, que retornou resultado representado na Tabela 4.5. De acordo com a Tabela 4.5, vemos que para todos os os graus de pertinência, a série é estatisticamente estacionária.

A partir da base de dados, foi realizado o teste de homocedasticidade de Levene. Foi verificado que todos os sinais utilizados neste estudo apresentam variações da variância ao longo

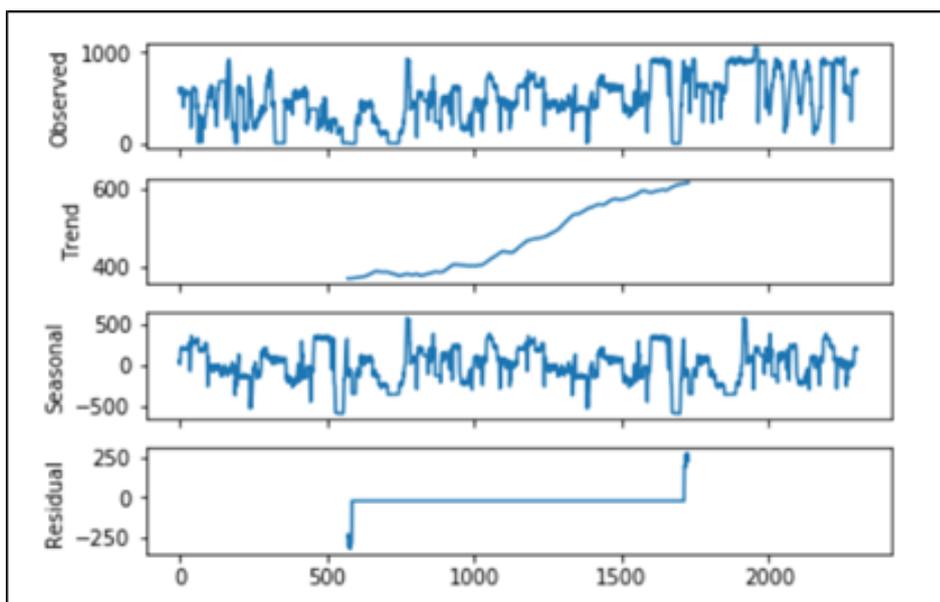


Figura 4.3: Decomposição de sazonalidade e tendência da variável BL considerada neste classificador.

Fonte: Autoria própria.

Tabela 4.5: Teste ADF para Rate.

Alfa	Valor Crítico	Resultado
1%	-3.433	H0 Rejeitada - Estacionário
5%	-2.862	H0 Rejeitada - Estacionário
10%	-2.567	H0 Rejeitada - Estacionário

Fonte: Autoria própria.

da série temporal. De acordo com a Tabela 4.6, pode-se verificar resultados do teste de Levene para cada variável avaliada, bem como as métricas estatísticas de cada teste.

Conforme apresentado na Tabela 4.6, vemos que todas as 4 séries consideradas neste estudo são heterocedásticas. Ao fazer a análise de ACF e PACF das séries temporais, consegue-se entender o tamanho da sua memória e também detalhar a quantidade necessária de “lags” para avaliar, sem problemas, a série temporal. Conforme a Figuras 4.5, 4.6, 4.7 e 4.8 referem-se a análise de ACF e as Figuras 4.9, 4.10, 4.11 e 4.12 referem-se a análise de PACF. A partir das análises de ACF observamos 2 variáveis com memória curta e as outras 2 variáveis com memória longa. Pela análise de PACF das 4 variáveis, considerando um nível de corte de 50,

Tabela 4.6: Resultados do Teste de Levene.

Variável	Estatística	p-Valor	Hocedasticidade
LIT	1,597	0,03	Heterocedástica
ALS	3,358	$9,89 \times 10^{-8}$	Heterocedástica
BL	18,95	$1,937 \times 10^{-49}$	Heterocedástica
Rate	13,356	$2,912 \times 10^{-37}$	Heterocedástica

Fonte: Autoria própria.

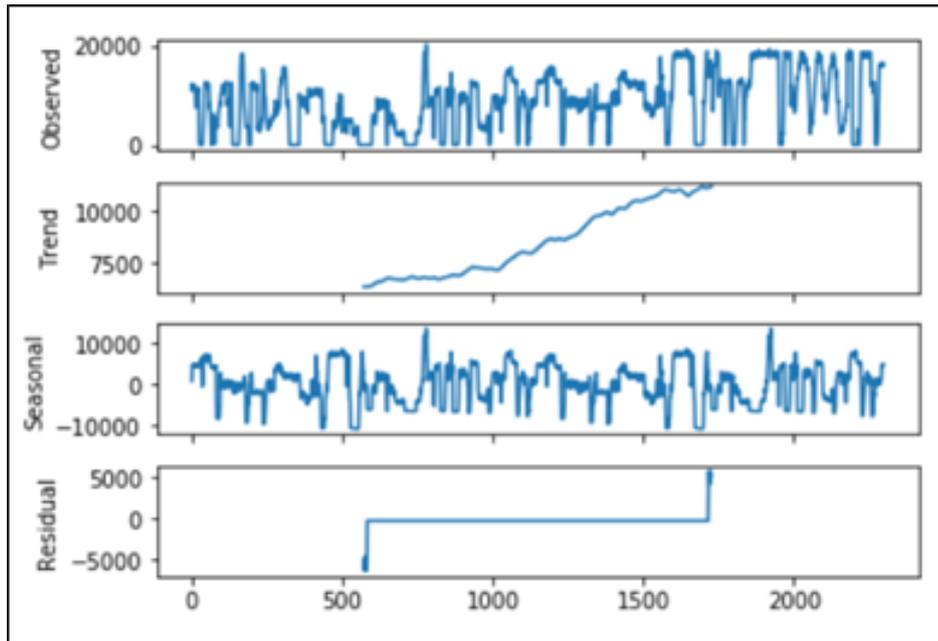


Figura 4.4: Decomposição de sazonalidade e tendência da variável Rate considerada neste classificador.

Fonte: Autoria própria.

observa-se que 2 lags são suficientes para analisar sem perdas significativas as séries temporais.

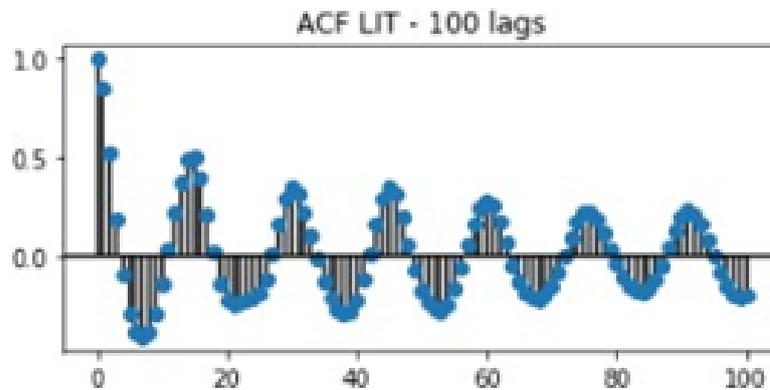


Figura 4.5: Gráfico de autocorrelação de LIT.

Fonte: Autoria própria.

Para o conjunto de dados em que o comportamento das variáveis encontram se com falhas, foi também realizada análise das funções de Autocorrelação (ACF) e Autocorrelação Parcial (PACF), conforme as Figuras 4.13, 4.14, 4.15 e 4.16.

Para este conjunto de dados, foi feita a análise das funções de Autocorrelação (ACF) e Autocorrelação Parcial (PACF) que auxilia na tomada de decisão do número de parâmetros autorregressivos e do número de parâmetros de médias móveis.

Com base nas análises de ACF e PACF (DENIG, 2016) apresentadas para as 4 variáveis consideradas nesta análise, nota-se que a utilização de 4 ‘lags’ seria suficiente para realizar, sem perdas significativas (DEMIR *et al.*, 2020) (Considerando um nível de corte de 50%) para

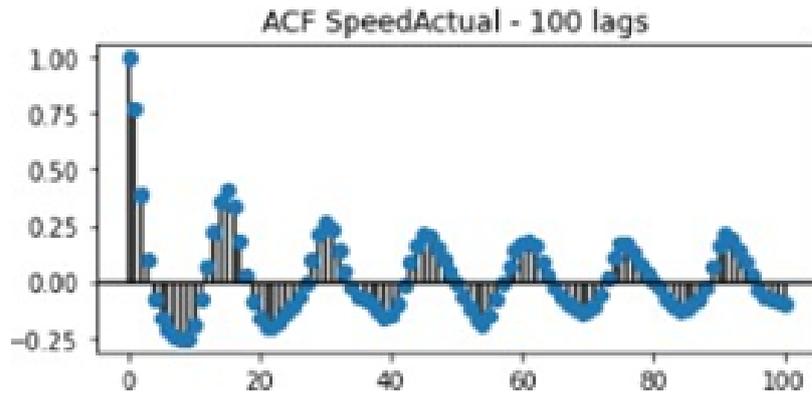


Figura 4.6: Gráfico de autocorrelação de ALS.  
 Fonte: Autoria própria.

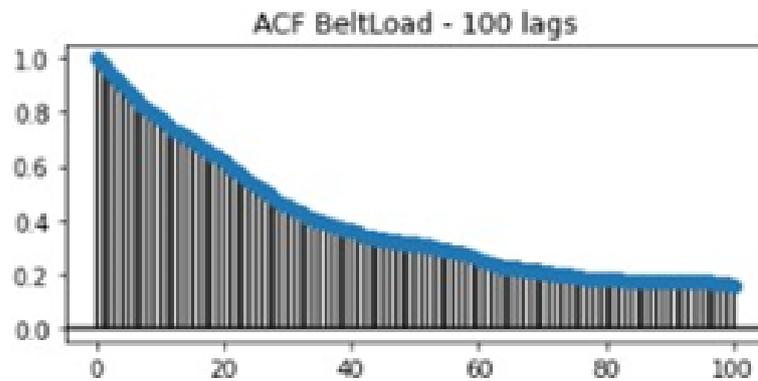


Figura 4.7: Gráfico de autocorrelação de WIT\_1095KS\_2300\_BeltLoad.  
 Fonte: Autoria própria.

processos de classificação e previsão das variáveis consideradas. Como margem de confiança, foi utilizado um total de 8 ‘lags’ (100% a mais) nas análises.

Em adição, foi feita uma análise de correlação cruzada para verificar o quanto estes dados estão relacionados e foi identificado forte relação direta entre a variável endógena e duas variáveis exógenas e foi encontrada uma baixa correlação entre as outras duas variáveis exógenas (CAPACI *et al.*, 2019).

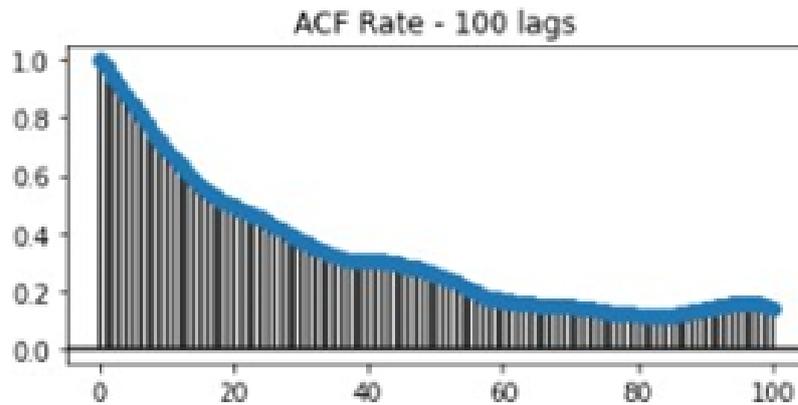


Figura 4.8: Gráfico de autocorrelação de WIT\_1095KS\_2300\_Rate.  
 Fonte: Autoria própria.

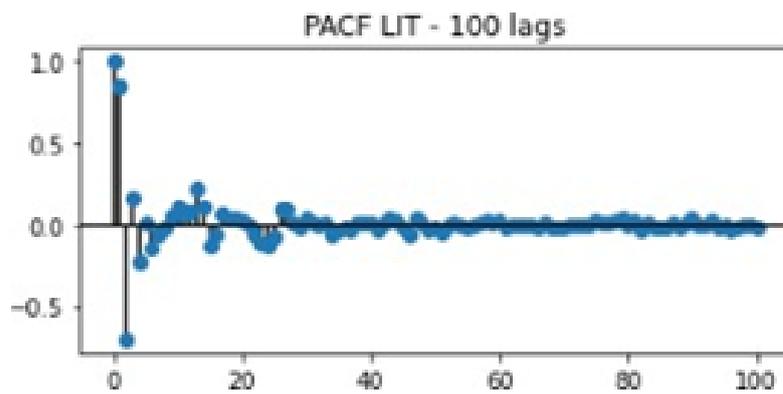


Figura 4.9: Gráfico de autocorrelação parcial de LIT.  
 Fonte: Autoria própria.

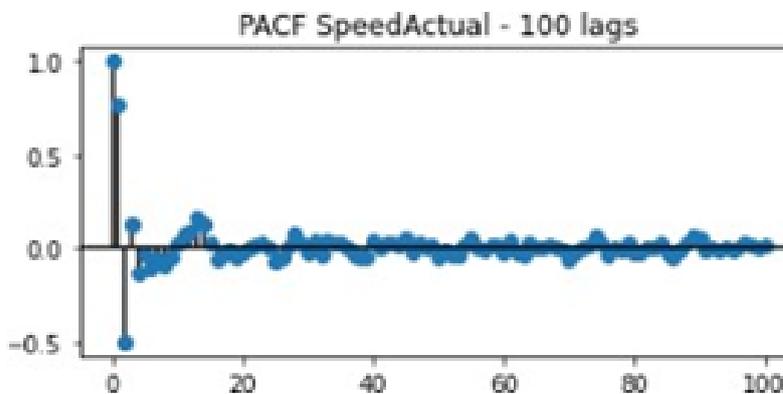


Figura 4.10: Gráfico de autocorrelação parcial de ALS.  
 Fonte: Autoria própria.

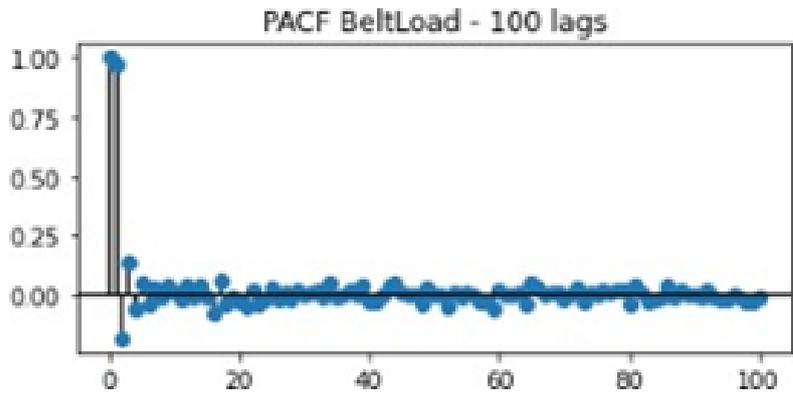


Figura 4.11: Gráfico de autocorrelação parcial de WIT\_1095KS\_2300\_BeltLoad.  
 Fonte: Autoria própria.

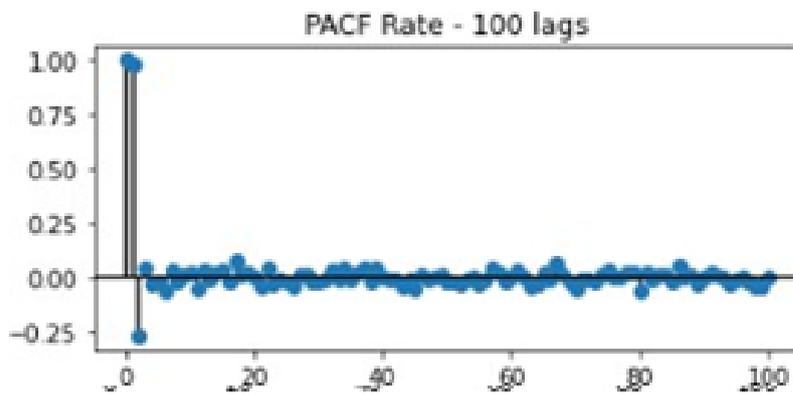


Figura 4.12: Gráfico de autocorrelação parcial de WIT\_1095KS\_2300\_Rate.  
 Fonte: Autoria própria.

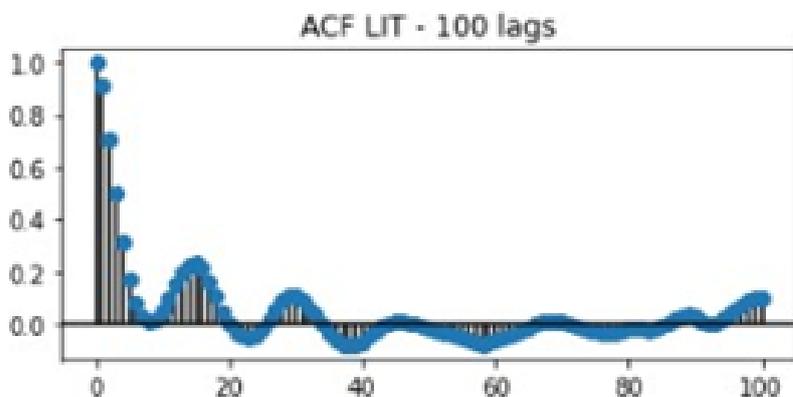


Figura 4.13: Gráfico de autocorrelação de LIT - dados com as falhas.  
 Fonte: Autoria própria.

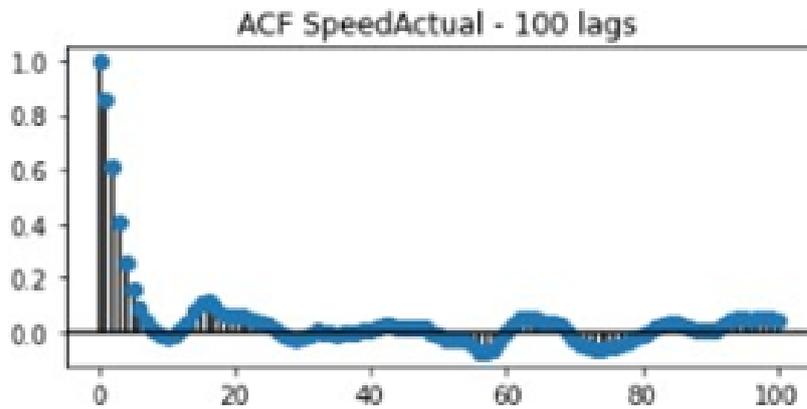


Figura 4.14: Gráfico de autocorrelação de ALS - dados com as falhas.  
 Fonte: Autoria própria.

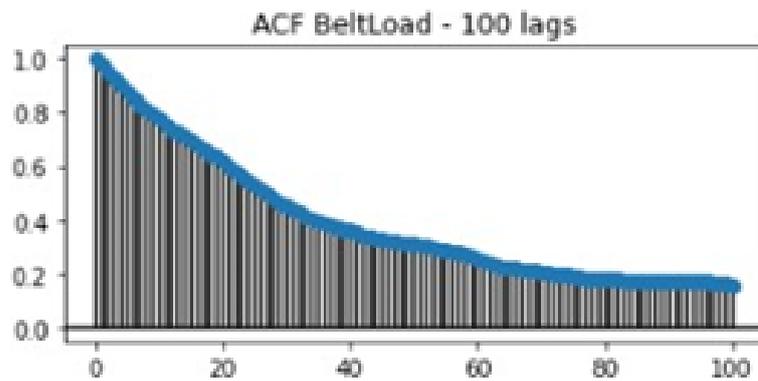


Figura 4.15: Gráfico de autocorrelação de WIT\_1095KS\_2300\_BeltLoad.  
 Fonte: Autoria própria.

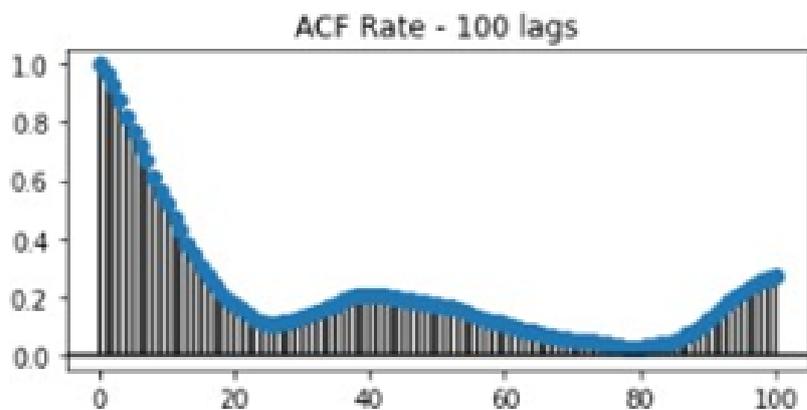


Figura 4.16: Gráfico de autocorrelação de WIT\_1095KS\_2300\_Rate - dados com as falhas.  
 Fonte: Autoria própria.

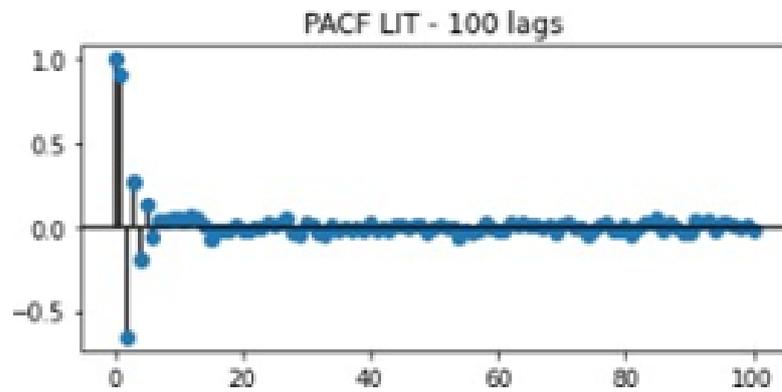


Figura 4.17: Gráfico de autocorrelação parcial de LIT - dados com as falhas.  
 Fonte: Autoria própria.

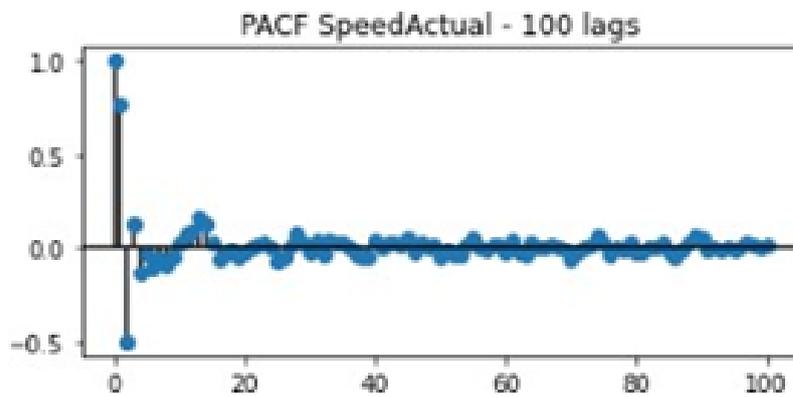


Figura 4.18: Gráfico de autocorrelação parcial de ALS - dados com as falhas.  
 Fonte: Autoria própria.

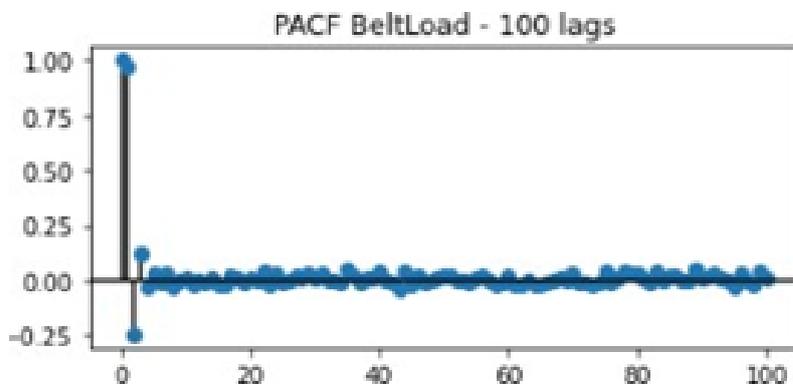


Figura 4.19: Gráfico de autocorrelação parcial de WIT\_1095KS\_2300\_BeltLoad - dados com as falhas.

Fonte: Autoria própria.

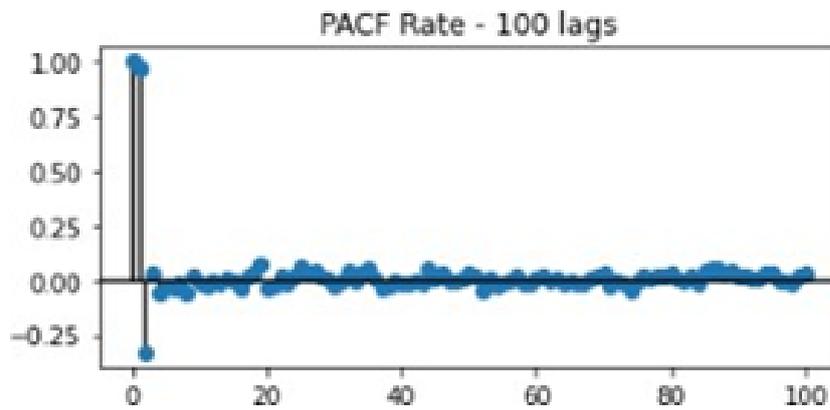


Figura 4.20: Gráfico de autocorrelação parcial de WIT\_1095KS\_2300\_Rate - dados com as falhas.

Fonte: Autoria própria.

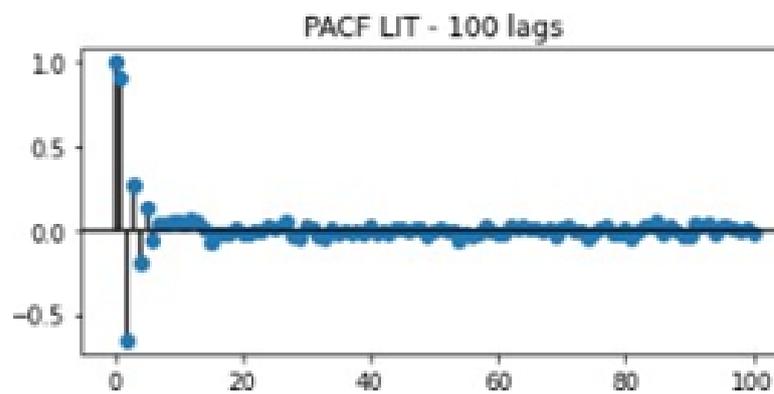


Figura 4.21: Gráfico de correlação cruzada de LIT - dados com as falhas.

Fonte: Autoria própria.

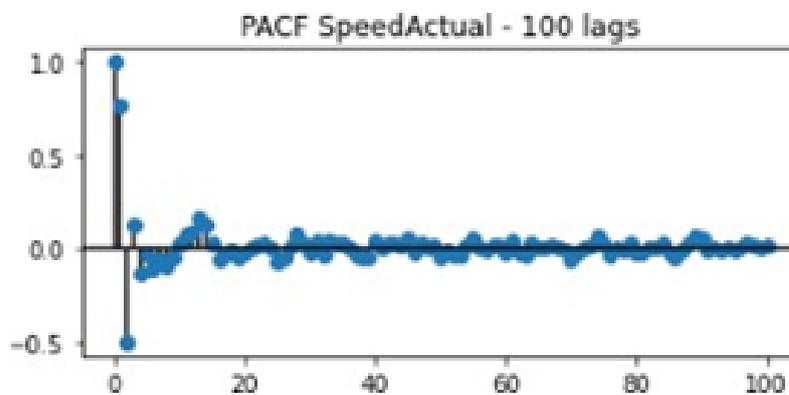


Figura 4.22: Gráfico de autocorrelação parcial de ALS - dados com as falhas.

Fonte: Autoria própria.

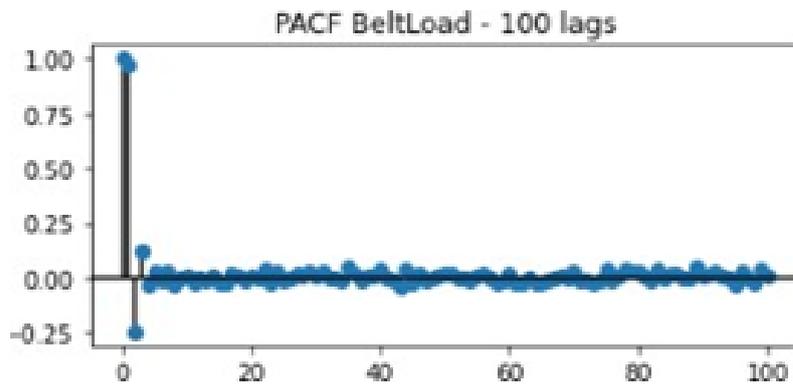


Figura 4.23: Gráfico de correlação cruzada de WIT\_1095KS\_2300\_BeltLoad - dados com as falhas.

Fonte: Autoria própria.

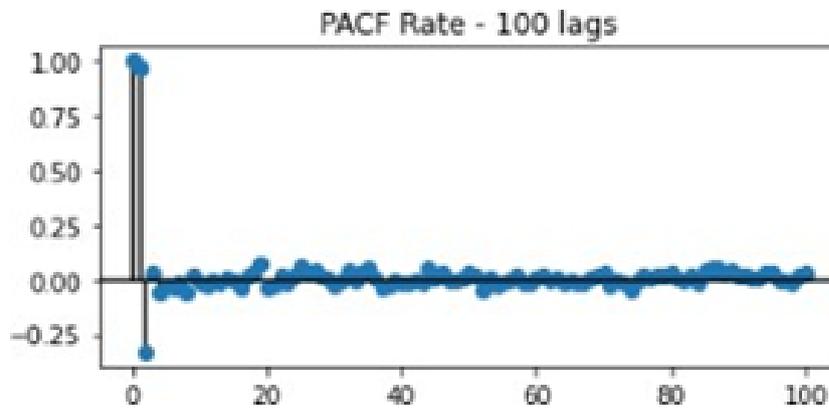


Figura 4.24: Gráfico de autocorrelação parcial de WIT\_1095KS\_2300\_Rate - dados com as falhas.

Fonte: Autoria própria.

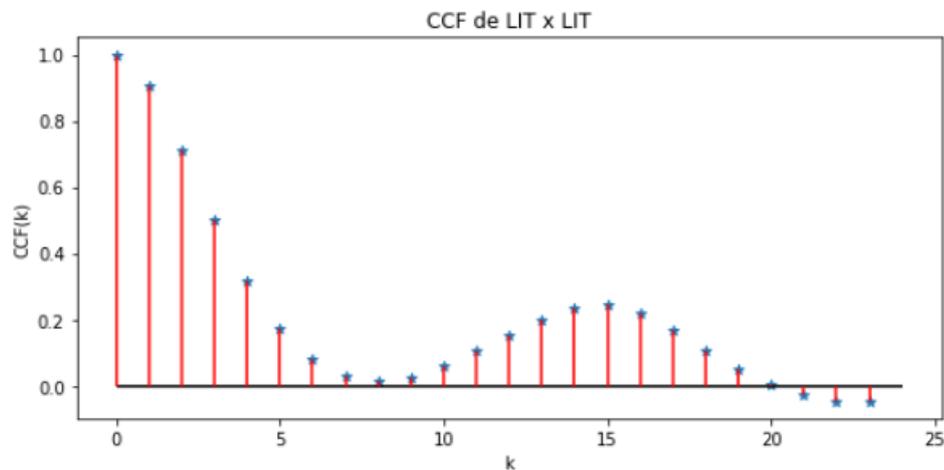


Figura 4.25: Gráfico de correlação cruzada de LIT o próprio LIT.

Fonte: Autoria própria.

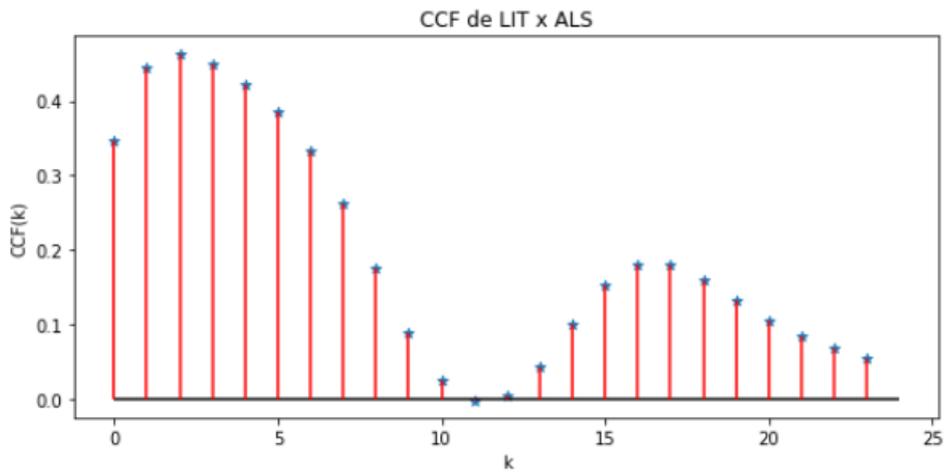


Figura 4.26: Gráfico de correlação cruzada de ALS com LIT.  
Fonte: Autoria própria.

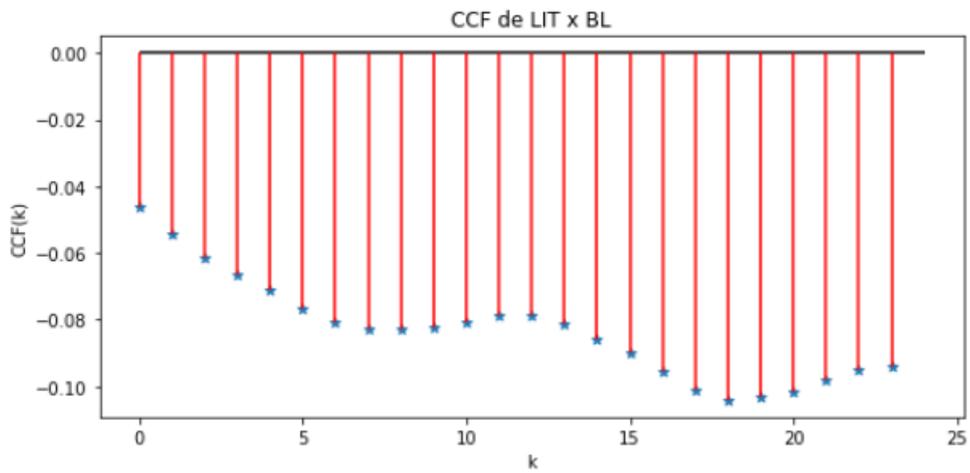


Figura 4.27: Gráfico de correlação cruzada de BL com LIT.  
Fonte: Autoria própria.

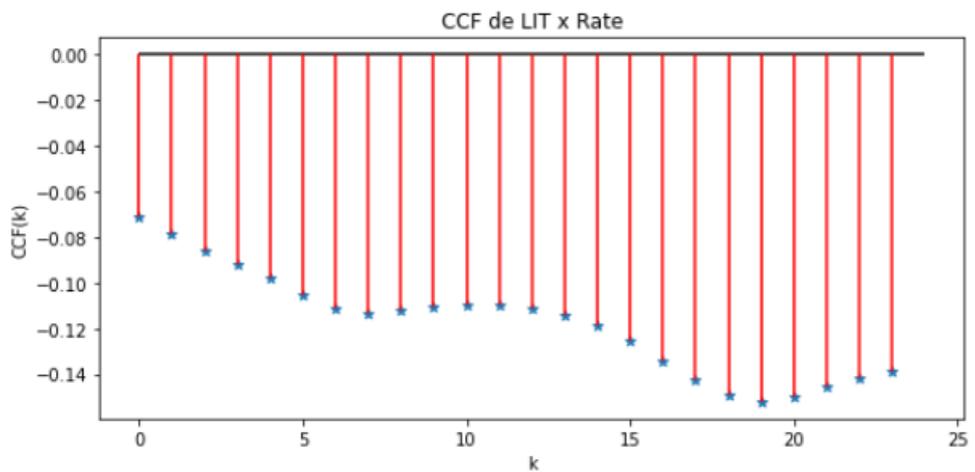


Figura 4.28: Gráfico de correlação cruzada de Rate e com LIT.  
Fonte: Autoria própria.

## 5 Resultados e Discussão

Na metodologia do classificador proposto no Capítulo 3, serão apresentados os resultados obtidos com a classificação com o XGBoost com muitos lags e a junção do XGBoost com as matrizes de *LHS* e *RHS* obtidas nos modelos da *PWFTS*. A base de dados utilizada para ambos os casos será a mesma.

De acordo com as análises de ACF e PACF apresentadas para no capítulo 4, nota-se que a utilização de 4 ‘lags’ seria suficiente para realizar técnicas de classificação. Conforme descrito anteriormente, serão apresentados resultados utilizando um total de 8 ‘lags’ (100% a mais) nas análises.

Para *PWFTS*, em uma representação gráfica do modelo obtido para um dos sets de dados (100 amostras) e os pesos das regras aplicadas para 10 conjuntos nebulosos (DE LIMA *et al.*, 2019), sendo uma representação gráfica dos modelos obtidos pelo algoritmo da *PWFTS*. Para os últimos 100 valores de cada variável, obtivemos os seguintes modelos para as variáveis avaliadas, apresentadas nas Figuras 5.1, 5.2, 5.3 e 5.4.

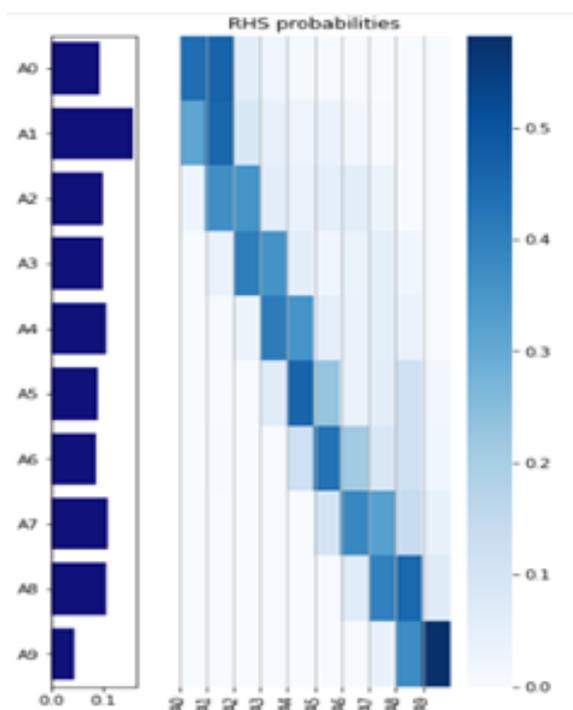


Figura 5.1: Gráfico do modelo da *PWFT* de LIT.  
Fonte: Autoria própria.

Os modelos obtidos graficamente, apresentam um modelo descritivo das regras para a transição entre os conjuntos nebulosos. estes modelos são descritos em (DE LIMA *et al.*, 2019). Para cada variável, em cada janela de dados de 100 elementos foi gerado um modelo com os pesos e probabilidades para cada conjunto nebuloso. Além disso, para a variável endógena, o modelo obtido para as últimas 100 amostras, apresentadas no formato  $[[LHS][RHS]]$  e apresentado na matriz 5.1, foi:

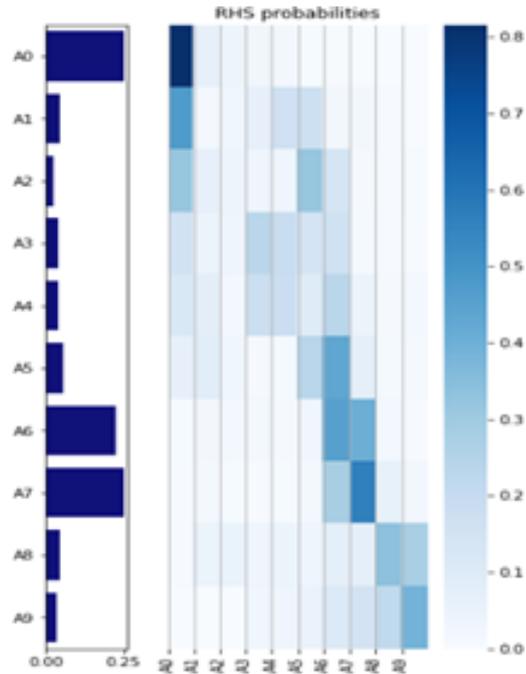


Figura 5.2: Gráfico do modelo da *PWFTS* de ALS.  
 Fonte: Autoria própria.

$$\begin{bmatrix} 0,095 \\ 0,159 \\ 0,1 \\ 0,102 \\ 0,107 \\ 0,09 \\ 0,088 \\ 0,109 \\ 0,108 \\ 0,043 \end{bmatrix} \times \begin{bmatrix} 0,441 & 0,464 & 0,057 & 0,022 & 0,01 & 0,004 & 0 & 0 & 0 & 0 \\ 0,316 & 0,459 & 0,087 & 0,045 & 0,031 & 0,04 & 0,019 & 0,002 & 0 & 0 \\ 0,029 & 0,37 & 0,356 & 0,058 & 0,041 & 0,054 & 0,059 & 0,032 & 0 & 0 \\ 0 & 0,04 & 0,408 & 0,358 & 0,059 & 0,022 & 0,035 & 0,054 & 0,022 & 0 \\ 0 & 0,003 & 0,034 & 0,413 & 0,357 & 0,055 & 0,039 & 0,055 & 0,04 & 0,002 \\ 0 & 0,001 & 0,002 & 0,067 & 0,463 & 0,23 & 0,037 & 0,061 & 0,12 & 0,019 \\ 0,002 & 0,002 & 0 & 0,001 & 0,122 & 0,43 & 0,213 & 0,089 & 0,12 & 0,022 \\ 0 & 0 & 0 & 0 & 0,001 & 0,099 & 0,385 & 0,329 & 0,14 & 0,045 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0,068 & 0,401 & 0,456 & 0,075 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0,402 & 0,376 & 0,582 \end{bmatrix} \quad (5.1)$$

Para as variáveis exógenas, os modelos obtidos para as últimas 100 amostras, no formato  $[[LHS][RHS]]$ . Para ALS foi obtido a matriz 5.2:

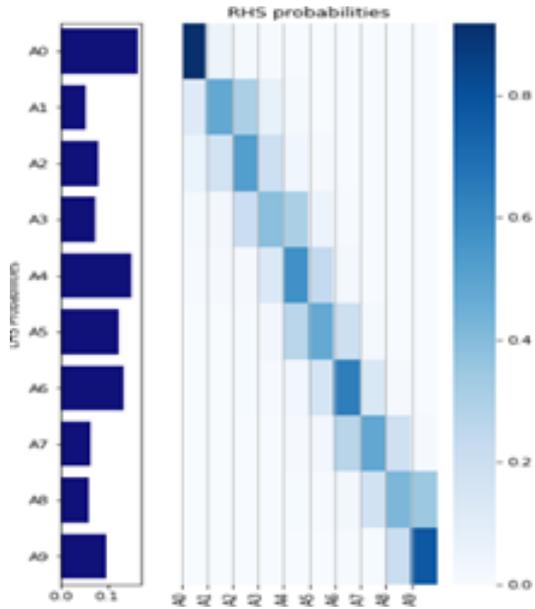


Figura 5.3: Gráfico do modelo da *PWFTS* de *WIT\_1095KS\_2300\_BeltLoad*  
 Fonte: Autoria própria.

$$\begin{bmatrix} 0,249 \\ 0,042 \\ 0,026 \\ 0,036 \\ 0,037 \\ 0,056 \\ 0,225 \\ 0,248 \\ 0,046 \\ 0,036 \end{bmatrix} \times \begin{bmatrix} 0,815 & 0,07 & 0,042 & 0,034 & 0,025 & 0,009 & 0,004 & 0,001 & 0 & 0 \\ 0,478 & 0,021 & 0,034 & 0,069 & 0,167 & 0,174 & 0,029 & 0,024 & 0,004 & 0 \\ 0,321 & 0,068 & 0,043 & 0,04 & 0,041 & 0,032 & 0,142 & 0,013 & 0,004 & 0,008 \\ 0,159 & 0,048 & 0,036 & 0,238 & 0,193 & 0,143 & 0,161 & 0,013 & 0,004 & 0,006 \\ 0,124 & 0,083 & 0,021 & 0,18 & 0,184 & 0,096 & 0,233 & 0,046 & 0,012 & 0,002 \\ 0,069 & 0,09 & 0,033 & 0,012 & 0,014 & 0,236 & 0,437 & 0,079 & 0,15 & 0,016 \\ 0,008 & 0,024 & 0,018 & 0,017 & 0,011 & 0,034 & 0,458 & 0,406 & 0,02 & 0,005 \\ 0,005 & 0,017 & 0,009 & 0,006 & 0,009 & 0,02 & 0,282 & 0,564 & 0,065 & 0,024 \\ 0,006 & 0,049 & 0,054 & 0,038 & 0,045 & 0,039 & 0,075 & 0,077 & 0,34 & 0,279 \\ 0 & 0 & 0,001 & 0,03 & 0,04 & 0,055 & 0,113 & 0,15 & 0,22 & 0,391 \end{bmatrix} \quad (5.2)$$

Para BL, tem-se a matriz 5.3:

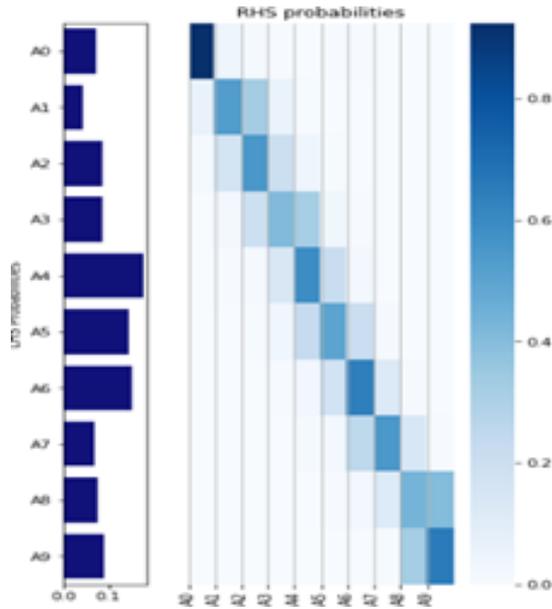


Figura 5.4: Gráfico do modelo da *PWFTS* de *WIT\_1095KS\_2300\_Rate*  
 Fonte: Autoria própria.

$$\begin{bmatrix} 0,071 \\ 0,044 \\ 0,086 \\ 0,088 \\ 0,178 \\ 0,146 \\ 0,153 \\ 0,069 \\ 0,075 \\ 0,091 \end{bmatrix} \times \begin{bmatrix} 0,924 & 0,043 & 0,017 & 0,004 & 0,002 & 0,005 & 0,005 & 0 & 0 & 0 \\ 0,068 & 0,523 & 0,329 & 0,06 & 0,01 & 0,001 & 0 & 0 & 0 & 0 \\ 0,018 & 0,169 & 0,555 & 0,205 & 0,042 & 0,009 & 0,002 & 0 & 0 & 0 \\ 0,003 & 0,021 & 0,196 & 0,412 & 0,323 & 0,037 & 0,005 & 0 & 0 & 0,001 \\ 0,003 & 0,006 & 0,017 & 0,142 & 0,593 & 0,218 & 0,019 & 0,001 & 0 & 0,001 \\ 0 & 0,001 & 0,008 & 0,033 & 0,233 & 0,504 & 0,208 & 0,012 & 0,002 & 0 \\ 0 & 0,001 & 0,003 & 0,007 & 0,03 & 0,175 & 0,643 & 0,128 & 0,013 & 0 \\ 0 & 0 & 0,001 & 0,001 & 0,016 & 0,024 & 0,256 & 0,551 & 0,145 & 0,006 \\ 0 & 0 & 0,002 & 0,001 & 0,002 & 0,005 & 0,024 & 0,122 & 0,438 & 0,407 \\ 0 & 0 & 0,002 & 0,002 & 0,002 & 0,001 & 0,001 & 0,008 & 0,327 & 0,658 \end{bmatrix} \quad (5.3)$$

Para Rate, tem se a matriz 5.4:

$$\begin{bmatrix} 0,165 \\ 0,053 \\ 0,081 \\ 0,072 \\ 0,152 \\ 0,124 \\ 0,135 \\ 0,063 \\ 0,059 \\ 0,097 \end{bmatrix} \times \begin{bmatrix} 0,918 & 0,053 & 0,016 & 0,005 & 0,003 & 0,003 & 0,002 & 0 & 0 & 0 \\ 0,118 & 0,484 & 0,307 & 0,075 & 0,015 & 0,002 & 0 & 0 & 0 & 0 \\ 0,055 & 0,175 & 0,526 & 0,194 & 0,035 & 0,013 & 0,003 & 0,001 & 0 & 0 \\ 0,015 & 0,026 & 0,205 & 0,387 & 0,306 & 0,054 & 0,004 & 0,001 & 0 & 0,002 \\ 0,006 & 0,014 & 0,013 & 0,131 & 0,577 & 0,236 & 0,02 & 0,001 & 0 & 0,002 \\ 0,002 & 0,003 & 0,01 & 0,027 & 0,267 & 0,478 & 0,195 & 0,016 & 0,002 & 0 \\ 0,002 & 0,002 & 0,01 & 0,005 & 0,028 & 0,157 & 0,645 & 0,139 & 0,013 & 0 \\ 0 & 0 & 0 & 0 & 0,012 & 0,026 & 0,271 & 0,485 & 0,193 & 0,013 \\ 0,003 & 0,001 & 0 & 0,001 & 0,008 & 0,006 & 0,031 & 0,179 & 0,421 & 0,351 \\ 0,002 & 0,001 & 0 & 0 & 0 & 0 & 0,005 & 0,009 & 0,208 & 0,776 \end{bmatrix} \quad (5.4)$$

Nas Tabelas 5.1 e 5.2 é possível observar a diferença entre o número de observações existentes nas mesmas. Isso se deve ao processo de geração dos exemplos de treinamento e teste para cada avaliação. Na Tabela 5.1 foram utilizadas amostras de 8 elementos, já na Tabela 5.2 foram utilizadas janelas de 100 elementos.

Tabela 5.1: Matriz de Confusão XGBoost

Parâmetro	Positivo	Negativo
Verdadeiro	281	197
Falso	65	721

Fonte: Autoria própria.

A partir dos resultados obtidos nas matrizes de confusão, foram calculados índices dos processos de classificação como sensibilidade, taxas de falsos positivos e negativos, especificidade, acurácia, precisão e F-Score mostrados na Tabela 5.3.

Em ambos os casos foi possível perceber um desempenho melhor com a metodologia sugerida. Para a acurácia, tivemos um aumento de 37,8% para 51,6%. Nos demais casos citados, os valores apresentaram aumento, o que representa uma melhora de desempenho de classificação com o novo algoritmo adotado.

É possível observar uma redução de falsos positivos e falsos negativos em ambos os casos. Para os falsos positivos, no modelo apenas com o XGBoost obtivemos uma taxa de 7,1% e com a adição do modelo da *PWFTS*, passamos para uma taxa de 2,3%. Em relação aos falsos negativos, a taxa para o modelo do XGBoost foi de 208,4% e com a nova metodologia proposta,

Tabela 5.2: Matriz de Confusão XGBoost + *PWFTS*

Parâmetro	Positivo	Negativo
Verdadeiro	47	0
Falso	1	43

Fonte: Autoria própria.

Tabela 5.3: Comparativo de Métricas

Parâmetro	XGBoost	XGBoost + PWFTS
Sensibilidade	0,812	0,979
Taxa de Falso Positivo	0,071	0,023
Taxa de Falso Negativo	2,084	0,896
Especificidade	0,215	0,000
Acurácia	0,378	0,516
Precisão	0,812	0,979
F Score	0,812	0,979

Fonte: Autoria própria.

o resultado obtido foi de 89,6%. Indicações que sinalizam que a metodologia proposta apresenta um menor índice de erros ao fazer as suas classificações.

## 6 Conclusão

Conforme apresentado ao longo do trabalho, é notório os ganhos associados a adoção de práticas de inteligência artificial aos processos indústrias, seja na detecção de falhas ou melhoria de algum processo existente. Os ganhos em termos de redução de tempos de parada ou melhoria de qualidade de produção são de grande escala.

A adoção de técnicas de inteligência artificial faz com que o processo de manutenção seja melhorado, evoluindo num sentido da manutenção preditiva, em detrimento as manutenções corretivas e emergenciais do sistema. Pois com a adição de técnicas que visão prever falhas e não simplesmente atuar na reação, com a parada do sistema, caracteriza uma manutenção preditiva em que se usa um sistema inteligente para suportar o processo de manutenção.

A pesquisa apresentou a primeira etapa de implementação de um modelo de série temporal fuzzy para realizar detecção de falhas com o uso de classificações. Avaliou seu desempenho com a adição de técnicas de FTS do modelo *PWFTS* a um classificador clássico da literatura (XGBoost). O modelo probabilístico proposto alcançou bons resultados quando comparados ao método clássico, conforme descritos anteriormente com maior acurácia e menor índice de falsos positivos, apresentado nas matrizes de confusão. Isso demonstra o potencial das previsões probabilísticas, sendo estes competitivos com os métodos mais avançados existentes na atualidade.

## 7 Trabalhos Futuros

Como trabalhos futuros, tem-se a definição de um número ótimo de conjuntos nebulosos a ser utilizado na obtenção do modelo de regras da *PWFTS* e também a definição da melhor função de pertinência para a obtenção do modelo. Além destes pontos, salienta-se a adoção da metodologia no sentido de se realizar a predição da falha e dos tipos distintos de falha existentes. Este trabalho aplicou as técnicas de inteligência artificial para detecção de falhas de sensoriamento de nível dos silos de minério, sendo que a expansão para outros tipos de sensoriamento, como medidores de tensão e corrente, encoders ou sensores para proteção do circuito (rip-cord) também se destaca como um interessante trabalho futuro.

## Referências Bibliográficas

- ALIM, M., YE, G.-H., GUAN, P., et al.. “**Comparison of ARIMA model and XGBoost model for prediction of human brucellosis in mainland China: a time-series study**”, *BMJ open*, v. 10, n. 12, pp. e039676, 2020. doi: 10.1136/bmjopen-2020-039676. Disponível em: <<https://bmjopen.bmj.com/content/10/12/e039676.abstract>>. Acessado em 2 de junho de 2022.
- AMMICHE, M., KOUADRI, A., BAKDI, A. “**A combined monitoring scheme with fuzzy logic filter for plant-wide Tennessee Eastman Process fault detection**”, *Chemical Engineering Science*, v. 187, pp. 269–279, 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0009250918302926>>. Acessado em 10 de agosto de 2022.
- BENNER JR, L. “**Rating accident models and investigation methodologies**”, *Journal of safety research*, v. 16, n. 3, pp. 105–126, 1985. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/0022437585900386>>. Acessado em 10 de junho de 2022.
- BROCKWELL, P. J., DAVIS, R. A. *Introduction to time series and forecasting*. New York, NY, Springer, New York, 2002. ISBN: 978-0-387-21657-7. doi: [https://doi.org/10.1007/0-387-21657-X\\_8](https://doi.org/10.1007/0-387-21657-X_8).
- CAPACI, F., VANHATALO, E., KULAHCI, M., et al.. “**The revised Tennessee Eastman process simulator as testbed for SPC and DoE methods**”, *Quality Engineering*, v. 31, n. 2, pp. 212–229, 2019. doi: 10.1080/08982112.2018.1461905. Disponível em: <<https://doi.org/10.1080/08982112.2018.1461905>>. Acessado em 16 de novembro de 2022.
- CHEN, M.-Y. “**A high-order fuzzy time series forecasting model for internet stock trading**”, *Future Generation Computer Systems*, v. 37, pp. 461–467, 2014. ISSN: 0167-739X. doi: <https://doi.org/10.1016/j.future.2013.09.025>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0167739X13002045>>. Special Section: Innovative Methods and Algorithms for Advanced Data-Intensive Computing Special Section: Semantics, Intelligent pro-

cessing and services for big data Special Section: Advances in Data-Intensive Modelling and Simulation Special Section: Hybrid Intelligence for Growing Internet and its Applications. Acessado em 15 de Abril de 2022.

CHEN, S.-M. “**Forecasting enrollments based on fuzzy time series**”, *Fuzzy Sets and Systems*, v. 81, n. 3, pp. 311–319, 1996. ISSN: 0165-0114. doi: [https://doi.org/10.1016/0165-0114\(95\)00220-0](https://doi.org/10.1016/0165-0114(95)00220-0). Disponível em: <<https://www.sciencedirect.com/science/article/pii/0165011495002200>>. Acessado em 07 de setembro de 2022.

CHEN, T., GUESTRIN, C. “**Xgboost: A scalable tree boosting system**”. Em: *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pp. 785–794, 2016. Disponível em: <<https://dl.acm.org/doi/abs/10.1145/2939672.2939785>>. Acessado em 18 de junho de 2022.

CHENG, C.-H., CHANG, J.-R., YEH, C.-A. “**Entropy-based and trapezoid fuzzification-based fuzzy time series approaches for forecasting IT project cost**”, *Technological Forecasting and Social Change*, v. 73, n. 5, pp. 524–542, 2006. ISSN: 0040-1625. doi: <https://doi.org/10.1016/j.techfore.2005.07.004>. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0040162505001125>>. Acessado em 23 de junho de 2022.

DE LIMA, P. C., OTHERS. *Scalable models for probabilistic forecasting with fuzzy time series*. Tese de Doutorado, Universidade Federal de Minas Gerais, 2019. Disponível em: <<http://hdl.handle.net/1843/30040>>. Acessado em 18 de novembro de 2022.

DEMIR, V., ZONTUL, M., YELMEN, İ. “**Drug Sales Prediction with ACF and PACF Supported ARIMA Method**”. Em: *2020 5th International Conference on Computer Science and Engineering (UBMK)*, pp. 243–247. IEEE, 2020. doi: 10.1109/UBMK50275.2020.9219448. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/9219448>>. Acessado em 27 de junho de 2022.

DENIG, M. R. D. S. “**Análise Hierárquica Bayesiana com Aplicação à Qualidade da Água do Rio dos Sinos**”, *XXX Salão de Iniciação Científica Universidade Federal do Rio Grande do Sul*, 2016. Disponível em: <<https://www.lume.ufrgs.br/handle/10183/153750>>. Acessado em 18 de novembro de 2022.

DICKEY, D. A., FULLER, W. A. “**Distribution of the estimators for autoregressive time series with a unit root**”, *Journal of the American statistical association*, v. 74, n. 366a, pp. 427–431, 1979. doi: 10.1080/01621459.1979.10482531. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/01621459.1979.10482531>>. Acessado em 27 de junho de 2022.

- ESLAMLOUEYAN, R. “**Designing a hierarchical neural network based on fuzzy clustering for fault diagnosis of the Tennessee–Eastman process**”, *Applied soft computing*, v. 11, n. 1, pp. 1407–1415, 2011. ISSN: 1568-4946. doi: <https://doi.org/10.1016/j.asoc.2010.04.012>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1568494610000888>>. Acessado em 22 de maio de 2022.
- HART, P. E., STORK, D. G., DUDA, R. O. *Pattern classification*. California, United States, Wiley Hoboken, 2000.
- HATTORI, L. T., BENITEZ, C. M. V., GUTOSKI, M., et al.. “**A novel approach to protein folding prediction based on long short-term memory networks: a preliminary investigation and analysis**”. Em: *2018 International Joint Conference on Neural Networks (IJCNN)*, pp. 1–8. IEEE, 2018. doi: 10.1109/IJCNN.2018.8489514. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/8489514>>. Acessado em 18 de novembro de 2022.
- HOEL, P. G., PORT, S. C., STONE, C. J. *Introduction to stochastic processes*. Illinois, United States, Waveland Press, 1986.
- HUARNG, K. “**Heuristic models of fuzzy time series for forecasting**”, *Fuzzy Sets and Systems*, v. 123, n. 3, pp. 369–386, 2001a. ISSN: 0165-0114. doi: [https://doi.org/10.1016/S0165-0114\(00\)00093-2](https://doi.org/10.1016/S0165-0114(00)00093-2). Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0165011400000932>>. Acessado em 12 de junho de 2022.
- HUARNG, K. “**Effective lengths of intervals to improve forecasting in fuzzy time series**”, *Fuzzy sets and systems*, v. 123, n. 3, pp. 387–394, 2001b. ISSN: 0165-0114. doi: [https://doi.org/10.1016/S0165-0114\(00\)00057-9](https://doi.org/10.1016/S0165-0114(00)00057-9). Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0165011400000579>>. Acessado em 12 de agosto de 2022.
- HUGHES-OLIVER, J. M. “**Population and empirical PR curves for assessment of ranking algorithms**”, *arXiv preprint arXiv:1810.08635*, 2018. doi: <https://doi.org/10.48550/arXiv.1810.08635>. Disponível em: <<https://arxiv.org/abs/1810.08635>>. Acessado em 10 de novembro de 2022.
- HUMPHREYS, D., OTHERS. *The remaking of the mining industry*. London, England, Palgrave Macmillan London, 2015. ISBN: 978-1-137-44201-7. doi: <https://doi.org/10.1057/9781137442017>.
- HWANG, J.-R., CHEN, S.-M., LEE, C.-H. “**Handling forecasting problems using fuzzy time series**”, *Fuzzy sets and systems*, v. 100, n. 1-3, pp. 217–228, 1998.

ISSN: 0165-0114. doi: [https://doi.org/10.1016/S0165-0114\(97\)00121-8](https://doi.org/10.1016/S0165-0114(97)00121-8). Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0165011497001218>>. Acessado em 16 de novembro de 2022.

ISMAIL, Z., EFENDI, R. “**Enrollment forecasting based on modified weight fuzzy time series**”, *Journal of Artificial Intelligence*, v. 4, n. 1, pp. 110–118, 2011. ISSN: 1994-5450. doi: 10.3923/jai.2011.110.118. Disponível em: <[https://d1wqtxts1xzle7.cloudfront.net/30972173/110-118-with-cover-page-v2.pdf?Expires=1668801425&Signature=H3CgaJ2i0gVp~9rEMynY~M4vS2N--6Q05MPi0GnVsTyG4q21AV4S0zVQD58oPsqFz0uSq452~J\\_&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA](https://d1wqtxts1xzle7.cloudfront.net/30972173/110-118-with-cover-page-v2.pdf?Expires=1668801425&Signature=H3CgaJ2i0gVp~9rEMynY~M4vS2N--6Q05MPi0GnVsTyG4q21AV4S0zVQD58oPsqFz0uSq452~J_&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA)>. Acessado em 27 de junho de 2022.

JAHANSHAHI, E., SIVALINGAM, S., SCHOFIELD, J. B. “**Industrial test setup for autotuning of PID controllers in large-scale processes: Applied to Tennessee Eastman process – Funding for this research was provided by SIEMENS AS**”, *IFAC-PapersOnLine*, v. 48, n. 8, pp. 469–476, 2015. ISSN: 2405-8963. doi: <https://doi.org/10.1016/j.ifacol.2015.09.012>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2405896315010939>>. Acessado em 27 de junho de 2022.

KARDEC, A., NASCIF, J. *Manutenção Função Estratégica, 2a edição*. Rua José Augusto, 64 - sl. 101 - Jacarepaguá - Rio de Janeiro, RJ, Qualitymark Editora Ltda, 2001.

LEBUKAN, D. E., WARDANA, A. N., EFFENDY, N. “**Implementation of plant-wide PI-fuzzy controller in tennessee eastman process**”. Em: *2019 International Seminar on Application for Technology of Information and Communication (iSemantic)*, pp. 450–454. IEEE, 2019. doi: 10.1109/ISEMANTIC.2019.8884301. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/8884301>>. Acessado em 18 de agosto de 2022.

LEVENE, H. “**Robust tests for equality of variances in contribution to probability and Statistics,(Ed) 1**”, *Olkin: Stanford Univ. Press, Palo Alto, CA*, pp. 278–292, 1960.

MONARD, M. C., BARANAUSKAS, J. A. “**Conceitos sobre aprendizado de máquina**”, *Sistemas inteligentes-Fundamentos e aplicações*, v. 1, n. 1, pp. 32, 2003. Disponível em: <<https://dcm.ffclrp.usp.br/~augusto/publications/2003-sistemas-inteligentes-cap4.pdf>>. Acessado em 16 de novembro de 2022.

MONTGOMERY, D. C., JENNINGS, C. L., KULAHCI, M. *Introduction to time series analysis and forecasting*. New Jersey, United States, John Wiley & Sons, 2015.

- MORETTI, P. *Análise de séries temporais: Modelos lineares univariados*. Rua Pedroso Alvarenga, 1245, 4º andar - São Paulo-SP, Editora Blucher. ABE - Projeto Fisher, 2004.
- OLIVEIRA, D. F. N. *Interpretabilidade de modelos de aprendizado profundo aplicados ao diagnóstico e prognóstico não supervisionado de falhas*. Tese de Doutorado, Universidade de São Paulo, 2020. Disponível em: <<https://www.teses.usp.br/teses/disponiveis/3/3141/tde-08032021-102116/en.php>>. Acessado em 20 de junho de 2022.
- QI, C.-C. “**Big data management in the mining industry**”, *International Journal of Minerals, Metallurgy and Materials*, v. 27, n. 2, pp. 131–139, 2020. doi: <https://doi.org/10.1007/s12613-019-1937-z>. Disponível em: <<https://link.springer.com/article/10.1007/s12613-019-1937-z#citeas>>. Acessado em 06 de junho de 2022.
- SAHIN, E. K. “**Assessing the predictive capability of ensemble tree methods for landslide susceptibility mapping using XGBoost, gradient boosting machine, and random forest**”, *SN Applied Sciences*, v. 2, n. 7, pp. 1–17, 2020. Disponível em: <<https://link.springer.com/article/10.1007/s42452-020-3060-1>>. Acessado em 25 de junho de 2022.
- SATYANARAYANAN, M., BAHL, P., CACERES, R., et al.. “**The case for vm-based cloudlets in mobile computing**”, *IEEE pervasive Computing*, v. 8, n. 4, pp. 14–23, 2009. doi: 10.1109/MPRV.2009.82. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/5280678>>. Acessado em 28 de julho de 2022.
- SCHWAB, K. *The fourth industrial revolution*. New York, United States, Currency, 2017.
- SILVA, P. C., LUCAS, P., SADAELI, H., et al.. “**pyfts: Fuzzy time series for python**”, *Belo Horizonte*, 2018. doi: <https://doi.org/10.5281/zenodo.597359>. Disponível em: <<https://pyfts.github.io/pyFts/build/html/index.html>>. Acessado em 14 de agosto de 2022.
- SILVEIRA, A., MATTOS, V., NAKAMURA, L., et al.. “**Análise do Valor p Determinado pela Estatística  $\tau$  na Aplicação do Teste de Dickey-Fuller Aumentado**”, *Trends in Computational and Applied Mathematics*, v. 23, n. 2, pp. 283–298, 2022. ISSN: 2676-0029. doi: 10.5540/tcam.2022.023.02.00283. Disponível em: <<https://tema.sbmec.org.br/tema/article/view/1599>>. Acessado em 18 de novembro de 2022.
- SONG, Q., CHISSOM, B. S. “**Fuzzy time series and its models**”, *Fuzzy sets and systems*, v. 54, n. 3, pp. 269–277, 1993. ISSN: 0165-0114. doi: <https://doi.org/10.1016/>

0165-0114(93)90372-O. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0165011493903720>>. Acessado em 11 de outubro de 2022.

VALADÃO, G., ARAUJO, A. *Introdução ao Tratamento de Minérios*. Av. Antônio Carlos, 6627 CAD 2 Bloco 3 Campus 901 - Pampulha, Belo Horizonte - MG, Editora UFMG, 2012.

XU, Z. “**High distributed control system, with security, introduced in China:** four advantages of the ABB DCS Extended Automation V6 were highlighted in a Control Engineering China interview with Tobias Becker, global head of Abb Control Technology Business Unit, and Anne Yang, an ABB group vice president”, *Control Engineering*, v. 61, n. 8, pp. 24–26, 2014. Disponível em: <<https://go.gale.com/ps/i.do?id=GALE%7CA382656236&sid=googleScholar&v=2.1&it=r&linkaccess=abs&iissn=00108049&p=AONE&sw=w&userGroupName=anon%7E914165a0>>. Acessado em 17 de novembro de 2022.

ZADEH, L. “**Fuzzy sets**”, *Information and Control*, v. 8, n. 3, pp. 338–353, 1965. ISSN: 0019-9958. doi: [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X). Disponível em: <<https://www.sciencedirect.com/science/article/pii/S001999586590241X>>. Acessado em 27 de junho de 2022.

ZOU, W., XIA, Y., LI, H. “**Fault Diagnosis of Tennessee-Eastman Process Using Orthogonal Incremental Extreme Learning Machine Based on Driving Amount**”, *IEEE Transactions on Cybernetics*, v. 48, n. 12, pp. 3403–3410, 2018. doi: [10.1109/TCYB.2018.2830338](https://doi.org/10.1109/TCYB.2018.2830338). Disponível em: <<https://ieeexplore.ieee.org/abstract/document/8361786>>. Acessado em 27 de junho de 2022.

# **Apêndice A: Formulação do algoritmo computacional usado no tratamento dos dados**

Por motivos de economia de espaço, o código utilizado nos testes está disponibilizado no link: <https://github.com/gabrielvini02/ExperimentsMultivariate>