



Universidade Federal de Campina Grande
Centro de Engenharia Elétrica e Informática
Programa de Pós-Graduação em Engenharia Elétrica

VANDILSON RODRIGO DO NASCIMENTO BARBOSA

**ESTIMADOR INTELIGENTE DO MOMENTO ÓTIMO DE
LIMPEZA DE ISOLADORES DE VIDRO A PARTIR DA
MEDIÇÃO DA CORRENTE DE FUGA**

Campina Grande – Paraíba
Abril de 2025

VANDILSON RODRIGO DO NASCIMENTO BARBOSA

**ESTIMADOR INTELIGENTE DO MOMENTO ÓTIMO DE LIMPEZA DE ISOLADORES DE
VIDRO A PARTIR DA MEDIÇÃO DA CORRENTE DE FUGA**

*Tese de doutorado apresentada à Coordenação
do Programa de Pós-Graduação em Engenharia
Elétrica da Universidade Federal de Campina
Grande como parte dos requisitos necessários
para obtenção do grau de doutor em Engenharia
Elétrica.*

Área de Concentração: Processamento de Energia

Orientadores:

Edson Guedes da Costa, D. Sc.

George Rossany Soares de Lira, D. Sc.

Campina Grande – PB

Abril de 2025

VANDILSON RODRIGO DO NASCIMENTO BARBOSA

ESTIMADOR INTELIGENTE DO MOMENTO ÓTIMO DE LIMPEZA DE ISOLADORES DE VIDRO A PARTIR DA MEDIÇÃO DA CORRENTE DE FUGA

Tese de doutorado apresentada à Coordenação do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande como parte dos requisitos necessários para obtenção do grau de doutor em Engenharia Elétrica.

Aprovado(a) em: 31 de março de 2025

Banca Examinadora:

Edson Guedes da Costa, D. Sc., UFCG

Orientador

George Rossany Soares de Lira, D. Sc., UFCG

Coorientador

Karcus Marcelus Colaço Dantas, D. Sc., UFCG

Examinador Interno

Raimundo Carlos Silverio Freire, D. Sc., UFCG

Examinador Interno

Estácio Tavares Wanderley Neto, D. Sc., UNIFEI

Examinador Externo

Pablo Bezerra Vilar, D. Sc., UFCG

Examinador Externo

José Pissolato Filho, D. Sc., UNICAMP

Examinador Externo

Campina Grande – PB

Abril de 2025



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
POS-GRADUACAO EM ENGENHARIA ELETRICA
Rua Aprigio Veloso, 882, - Bairro Universitario, Campina Grande/PB, CEP 58429-900

REGISTRO DE PRESENÇA E ASSINATURAS

- 1 - ATA DA DEFESA PARA CONCESSÃO DO GRAU DE DOUTOR EM CIÊNCIAS, NO DOMÍNIO DA ENGENHARIA ELÉTRICA, REALIZADA EM 31 DE MARÇO DE 2025
(Nº 396)

CANDIDATO(A): **VANDILSON RODRIGO DO NASCIMENTO BARBOSA**. COMISSÃO EXAMINADORA: KARCIOUS MARCELUS COLAÇO DANTAS, D.Sc., UFCG - Presidente da Comissão e Examinador Interno, EDSON GUEDES DA COSTA, D.Sc., UFCG - Orientador, GEORGE ROSSANY SOARES DE LIRA, D.Sc., UFCG – Orientador, RAIMUNDO CARLOS SILVÉRIO FREIRE, Dr. UFCG - Examinador Interno, JOSÉ PISSOLATO FILHO, Dr., UNICAMP - Examinador Externo, ESTÁCIO TAVARES WANDERLEY NETO, Dr., UNIFEI - Examinador Externo, PABLO BEZERRA VILAR, D.Sc., UFCG - Examinador Externo. TÍTULO DA TESE: Estimativa do Tempo Ótimo para Manutenção de Limpeza em Isoladores de Vidro por meio da Aplicação de Inteligência Artificial e Séries Temporais. ÁREA DE CONCENTRAÇÃO: Processamento da Energia. HORA DE INÍCIO: **14h00** – LOCAL: **Sala Virtual, conforme Art. 5º da PORTARIA SEI Nº 01/PRPG/UFCG/GPR, DE 09 DE MAIO DE 2022**. Em sessão pública, após exposição de cerca de 45 minutos, o(a) candidato(a) foi arguido(a) oralmente pelos membros da Comissão Examinadora, tendo demonstrado suficiência de conhecimento e capacidade de sistematização, no tema de sua tese, obtendo conceito **APROVADO** com modificações no texto, de acordo com as exigências da Comissão Examinadora, que deverão ser cumpridas no prazo de 30 dias. Face à aprovação, declara o presidente da Comissão, achar-se o examinado, legalmente habilitado a receber o Grau de Doutor em Ciências, no domínio da Engenharia Elétrica, cabendo a Universidade Federal de Campina Grande, como de direito, providenciar a expedição do Diploma, a que o(a) mesmo(a) faz jus. Na forma regulamentar, foi lavrada a presente ata, que é assinada por mim, Leandro Ferreira de Lima, e os membros da Comissão Examinadora. Campina Grande, 31 de Março de 2025.

LEANDRO FERREIRA DE LIMA

Secretário

KARCIOUS MARCELUS COLAÇO DANTAS, D.Sc., UFCG
Presidente da Comissão e Examinador Interno

EDSON GUEDES DA COSTA, D.Sc., UFCG
Orientador

GEORGE ROSSANY SOARES DE LIRA, D.Sc., UFCG
Orientador

RAIMUNDO CARLOS SILVÉRIO FREIRE, Dr. UFCG
Examinador Externo

JOSÉ PISSOLATO FILHO, Dr., UNICAMP
Examinador Externo

ESTÁCIO TAVARES WANDERLEY NETO, Dr., UNIFEI
Examinador Externo

PABLO BEZERRA VILAR, D.Sc., UFCG
Examinador Externo

VANDILSON RODRIGO DO NASCIMENTO BARBOSA
Candidato

2 - APROVAÇÃO

2.1. Segue a presente Ata de Defesa de Tese de Doutorado do candidato **VANDILSON RODRIGO DO NASCIMENTO BARBOSA**, assinada eletronicamente pela Comissão Examinadora acima identificada.

2.2. No caso de examinadores externos que não possuam credenciamento de usuário externo ativo no SEI, para igual assinatura eletrônica, os examinadores internos signatários **certificam** que os examinadores externos acima identificados participaram da defesa da tese e tomaram conhecimento do teor deste documento.



Documento assinado eletronicamente por **LEANDRO FERREIRA DE LIMA, SECRETÁRIO (A)**, em 03/04/2025, às 09:17, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **KARCIUS MARCELUS COLACO DANTAS, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 03/04/2025, às 09:25, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **EDSON GUEDES DA COSTA, PROFESSOR 3 GRAU**, em 03/04/2025, às 09:43, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **RAIMUNDO CARLOS SILVERIO FREIRE, PROFESSOR 3 GRAU**, em 03/04/2025, às 10:55, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **GEORGE ROSSANY SOARES DE LIRA, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 03/04/2025, às 15:36, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **Vandilson Rodrigo do Nascimento Barbosa, Usuário Externo**, em 03/04/2025, às 22:41, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **PABLO BEZERRA VILAR, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 08/04/2025, às 09:44, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



A autenticidade deste documento pode ser conferida no site <https://sei.ufcg.edu.br/autenticidade>, informando o código verificador **5356069** e o código CRC **025D0DE4**.

B238e

Barbosa, Vandilson Rodrigo do Nascimento.

Estimador inteligente do momento ótimo de limpeza de isoladores de vidro a partir da medição da corrente de fuga / Vandilson Rodrigo do Nascimento – Campina Grande, 2025.

157 f. : il. color.

Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2025.

"Orientação: Prof. Dr. Edson Guedes da Costa, Prof. Dr. George Rossany Soares de Lira."

Referências.

1. Energia Elétrica. 2. Isoladores de Vidro. 3. Estimador Inteligente. 4. Poluição Superficial. 5. Inteligência Artificial. 6. Manutenção de Limpeza. 7. Modelos de Previsão. 8. Series Temporais. I. Costa, Edson Guedes da. II. Lira, George Rossany Soares de. III. Título.

CDU 621(043)

Dedico este trabalho à minha mãe, Vandeilza Barbosa do Nascimento, que, com muito carinho e apoio, não mediu esforços para que eu chegasse até esta etapa de minha vida.

AGRADECIMENTOS

Agradeço, em primeiro lugar, a Deus, por estar comigo em todos os momentos ao longo desta minha jornada, sempre me dando forças nas horas em que pensei em desistir. Pelo dom da vida e por todas as oportunidades que Ele deu para mim.

Agradeço à minha família e aos meus amigos, em especial, à minha mãe, por todo amor, carinho, cuidado e esforço para criar e educar a mim e ao meu irmão, nos proporcionando sempre o melhor que podia.

Agradeço aos meus orientadores e professores Edson Costa e George Lira pela orientação, incentivo e amizade.

Agradeço aos que fazem o LAT, considerando os professores, alunos (graduação e pós-graduação) e técnicos, pela amizade, conhecimentos (técnicos e gerais) e outras experiências compartilhadas durante as conversas no âmbito do laboratório.

Agradeço aos que contribuíram para elaboração deste trabalho, de forma direta ou indireta, com destaque para Matheus Nascimento (aluno de graduação), Giovanny Galdino (aluno de doutorado) e Samuel Nóbrega (aluno de mestrado).

Agradeço aos membros da comissão examinadora, pela disponibilidade em participar na avaliação deste trabalho.

Por fim, agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo suporte financeiro no início da pesquisa.

“Se eu vi mais longe, foi por estar de pé sobre ombros de gigantes.”

Isaac Newton

RESUMO

Nesta tese, propõe-se um estimador inteligente do momento ótimo de limpeza de isoladores de vidro a partir da medição da corrente de fuga. Para tanto, ensaios de poluição ambiente foram realizadas ao ar livre, para registrar os níveis de poluição na superfície dos isoladores de vidro ao longo do tempo. Os níveis de poluição foram realizados de forma sistemática, bem como as informações temporais de cada medição realizada. Com o intuito de simular os níveis de poluição ambiente identificados, ensaios elétricos de poluição artificial foram realizados no Laboratório de Alta Tensão da UFCG, por meio do depósito da solução de poluição sobre os isoladores e cada solução foi diferenciada por meio dos níveis da Densidade de Depósito de Sal Equivalente (DDSE) e Densidade de Depósito Não Solúvel (DDNS). Nos ensaios realizados em laboratório, registros dos níveis da DDSE, da DDNS, dos sinais da corrente de fuga e das descargas superficiais foram realizados, além de informações da umidade e temperatura. E, ainda, ao longo dos ensaios de poluição artificial, valores da DDSE e DDNS associados à ocorrência de descargas superficiais foram determinados, para serem usados como limiares do nível de poluição. A partir dos dados derivados de corrente de fuga, nível de poluição (DDSE e DDNS) e tempo, foi possível estimar o momento em que o nível de poluição estará elevado o suficiente para provocar descargas superficiais nos isoladores de vidro. Modelos de previsão de séries temporais baseados em inteligência artificial foram desenvolvidos para prever níveis de poluição (valores da DDSE e DDNS) e auxiliar na estimativa do momento ótimo para manutenção de limpeza nos isoladores para sistemas de 69 kV.

Palavras-chave: estimativa do momento ótimo; manutenção de limpeza; poluição superficial; inteligência artificial; modelos de previsão; series temporais; isoladores de vidro.

ABSTRACT

In the thesis, an intelligent estimator of the optimal cleaning time for glass insulators is proposed based on the measurement of the leakage current. For this purpose, ambient pollution tests were conducted outdoors to record the pollution levels on the surface of glass insulators and investigate the evolution of these levels over time. The pollution levels were systematically measured, along with the temporal data of each measurement. To simulate the identified ambient pollution levels, artificial pollution electrical tests were performed in a high voltage laboratory. This was done by depositing pollution solutions on the insulators, with each solution differentiated by the levels of Equivalent Salt Deposit Density (ESDD) and Non-Soluble Deposit Density (NSDD). In the laboratory tests, ESDD, NSDD, leakage current, and surface discharge signals were recorded, along with humidity and temperature information. Furthermore, during the artificial pollution tests, ESDD and NSDD values associated with the occurrence of surface discharges were determined to serve as pollution level thresholds. Using the data derived from leakage current, pollution levels (ESDD and NSDD), and time, it was possible to estimate when the pollution level would become high enough to cause surface discharges on the glass insulators. Time series forecasting models based on artificial intelligence were developed to forecast pollution levels (ESDD and NSDD values) and assist in estimating the optimal time for cleaning maintenance of the insulators for 69 kV systems.

Keywords: optimal time estimation; cleaning maintenance; surface pollution; artificial intelligence; forecasting models; time series; glass insulators.

LISTA DE ILUSTRAÇÕES

Figura 2.1:	Projeto de isolador proposto por Locke.....	28
Figura 2.2:	Fotografias de isoladores de (a) porcelana e (b) vidro temperado.....	29
Figura 2.3:	Fotografias de isoladores de porcelana de (a) pino, (b) pedestal e (c) suspensão.....	29
Figura 2.4:	Esquemático das partes constituintes de um isolador de vidro, tipo disco de suspensão.....	30
Figura 2.5:	Sinais da tensão e corrente de fuga para uma cadeia de isoladores limpos e secos.....	33
Figura 2.6:	Sinais da tensão e corrente de fuga para uma cadeia de isoladores limpos e umedecidos.....	34
Figura 2.7:	Sinais da tensão e corrente de fuga de um isolador com presença de bandas secas devido à poluição superficial e umidade.....	35
Figura 2.8:	Isolador de vidro danificado devido ao processo de oxidação.....	36
Figura 2.9:	Níveis de poluição com base nos valores do DDSE e DDNS.....	38
Figura 2.10:	Diagrama ilustrativo para obtenção da massa dos resíduos da poluição.....	39
Figura 2.11:	Disposição dos isoladores para experimento de coleta de poluição (DDSE e DDNS)..	42
Figura 2.12:	Retirada de poluentes da superfície de isoladores.....	43
Figura 2.13:	Etapas do processo de descarga no isolador cerâmico.....	44
Figura 2.14:	Descargas superficiais e disruptivas em cadeias de isoladores de vidro submetidas a condições ambientais adversas (poluição e umidade elevadas).....	45
Figura 2.15:	Transformação dos dados em conhecimento com base no framework CRISP-DM.....	46
Figura 2.16:	Série temporal referente aos valores de produção de energia elétrica e suas componentes de tendência, sazonal e aleatória.....	55
Figura 2.17:	Aplicação do conceito de janela deslizante em uma série temporal.....	57
Figura 2.18:	Ilustração do funcionamento da janela deslizante em uma série temporal.....	57
Figura 2.19:	Hiperplano de separação ótima e seus hiperplanos de suporte.....	63
Figura 2.20:	Ilustração do modelo da SVR, considerando as variáveis de folga e hiperplanos.....	61
Figura 2.21:	Aplicação do procedimento de kernel em um espaço de características.....	63
Figura 2.22:	Arquitetura de um modelo SVR.....	64
Figura 2.23:	Modelo de um neurônio artificial, chamado k	65
Figura 2.24:	Representações das arquiteturas de modelos ANN (a) não recorrente e (b) recorrente.....	68
Figura 2.25:	Esquemático da arquitetura de uma MLP.....	69
Figura 4.1:	Diagrama simplificado dos procedimentos práticos e simulações computacionais.....	93
Figura 4.2:	Representação das marcações realizadas nas cadeias (a) A e (b) B de isoladores de vidro.....	95
Figura 4.3:	Fotografia das cadeias de isoladores de vidro suspensos em uma cruzeta instalada no poste situado próximo ao LAT.....	96
Figura 4.4:	Diagrama da cadeia de isoladores de vidro com as marcações referentes às datas de coleta da poluição.....	98
Figura 4.5:	Níveis de poluição mensal considerando os valores da DDSE e DDNS para as cadeias de isoladores (a) A e (b) B.....	99
Figura 4.6:	Níveis da (a) DDSE e (b) DDNS, considerando a média mensal dos valores desses índices de cada cadeia.....	100

Figura 4.7:	Diagrama dos procedimentos laboratoriais realizados para construção do banco de dados.....	102
Figura 4.8:	Níveis de poluição mensal considerando os valores da DDSE e DDNS, para simulação em laboratório de alta tensão.....	103
Figura 4.9:	Fotografias do (a) isolador higienizado, (b) isolador poluído imediatamente após o depósito da solução salina e (c) isolador após o processo de secagem.....	104
Figura 4.10:	Fotografia das amostras de isoladores utilizados nos ensaios elétricos em laboratório.....	105
Figura 4.11:	Fotografias das partes (a) externa e (b) interna do ambiente de ensaios elétricos.....	106
Figura 4.12:	Esquema do arranjo experimental utilizado nos ensaios elétricos, para simulação de poluição artificial.....	107
Figura 4.13:	Imagens registradas pela câmera UV durante o ensaio de aplicação de tensão.....	109
Figura 4.14:	Fotografia da câmera Daycor II fabricada pela Ofil Systems.....	110
Figura 4.15:	Valores médios dos parâmetros da corrente de fuga obtidos dos ensaios de poluição sem névoa: (a) I_{RMS} , I_{Max} , e I_{1Harm} ; (b) I_{3Harm} , I_{5Harm} e I_{7Harm} ; (c) I_{9Harm} , I_{11Harm} e I_{desv} ; (d) I_{DHT}	112
Figura 4.16:	Valores médios dos parâmetros da corrente de fuga obtidos dos ensaios de poluição com névoa: (a) I_{RMS} , I_{Max} , e I_{1Harm} ; (b) I_{3Harm} , I_{5Harm} e I_{7Harm} ; (c) I_{9Harm} , I_{11Harm} e I_{desv} ; (d) I_{DHT}	112
Figura 4.17:	Matriz de correlação, com coeficiente de Pearson, considerando as informações dos ensaios (a) sem névoa e (b) com névoa.....	113
Figura 4.18:	Matriz de correlação, com coeficiente de Kendall, considerando as informações dos ensaios (a) sem névoa e (b) com névoa.....	114
Figura 4.19:	Curvas obtidas por interpolação e valores médios dos índices (a) DDSE e (b) DDNS.....	116
Figura 4.20:	Curvas obtidas por interpolação, sinais de ruído branco e valores médios dos índices (a) DDSE e (b) DDNS.....	117
Figura 4.21:	Registros dos sinais de corrente de fuga e da câmera UV para poluição leve (a) sem névoa e (b) com névoa.....	119
Figura 4.22:	Registros dos sinais de corrente de fuga e da câmera UV para poluição pesada (a) sem névoa e (b) com névoa.....	119
Figura 4.23:	Estrutura do modelo MLP (modelo A) para estimativa dos índices DDSE e DDNS, sem névoa.....	124
Figura 4.24:	Fluxograma da metodologia proposta para estimar o tempo ótimo para realizar manutenção de limpeza em isoladores.....	130
Figura 5.1:	Valores das métricas obtidos na fase de treinamento dos modelos A, B, C e D: (a) métricas individuais dos índices DDSE e DDNS e (b) média das métricas dos índices DDSE e DDNS.....	133
Figura 5.2:	Valores das métricas obtidas na fase de teste dos modelos A, B, C e D: (a) 15% e (b) 30% da base de dados.....	133
Figura 5.3:	Valores médios das métricas obtidas na fase de teste dos modelos A, B, C e D: (a) 15% e (b) 30% da base de dados.....	133
Figura 5.4:	Previsões realizadas com o modelo A, considerando o DDSE, para (a) treinamento e teste com (b) 15% e (c) 30%.....	134
Figura 5.5:	Previsões realizadas com o modelo A, considerando o DDNS, para (a) treinamento e teste com (b) 15% e (c) 30%.....	134
Figura 5.6:	Previsões realizadas com o modelo B, considerando o DDSE, para (a) treinamento e teste com (b) 15% e (c) 30%.....	135
Figura 5.7:	Previsões realizadas com o modelo B, considerando o DDNS, para (a) treinamento e teste com (b) 15% e (c) 30%.....	135
Figura 5.8:	Previsões realizadas com o modelo C, considerando o DDSE, para (a) treinamento e teste com (b) 15% e (c) 30%.....	136

Figura 5.9:	Previsões realizadas com o modelo C, considerando o DDNS, para (a) treinamento e teste com (b) 15% e (c) 30%.....	136
Figura 5.10:	Previsões realizadas com o modelo D, considerando o DDSE, para (a) treinamento e teste com (b) 15% e (c) 30%.....	137
Figura 5.11:	Previsões realizadas com o modelo D, considerando o DDNS, para (a) treinamento e teste com (b) 15% e (c) 30%.....	137
Figura 5.12:	Registros dos sinais da corrente de fuga e das imagens dos isoladores oriundas da câmera UV, contemplando os doze ensaios de poluição artificial, sem aplicação de névoa.....	141
Figura 5.13:	Registros dos sinais da corrente de fuga e das imagens dos isoladores oriundas da câmera UV, contemplando os doze ensaios de poluição artificial, com aplicação de névoa.....	142
Figura 5.14:	Previsões das séries temporais da (a) DDSE e (b) DDNS realizadas pelo modelo A, para a situação sem névoa.....	144
Figura 5.15:	Previsões das séries temporais da (a) DDSE e (b) DDNS realizadas pelo modelo B, para a situação com névoa.....	144
Figura 5.16:	Fluxograma das etapas para aplicação em campo da metodologia apresentada na tese.....	147
Figura 5.17:	Valores do MAPE obtidos para avaliação da sensibilidade dos modelos (para cada índice DDSE e DDNS), para as situações (a) sem névoa (modelo A) e (b) com névoa (modelo B).....	148
Figura 5.18:	Valores do MAPE obtidos para avaliação da sensibilidade do modelo A (considerando o valor médio dos desvios dos índices DDSE e DDNS), para as situações (a) sem névoa (modelo A) e (b) com névoa (modelo B).....	149
Figura 5.19:	Valores do desvio médio percentual obtidos da comparação das saídas sem alteração e com alteração dos parâmetros da corrente de fuga para avaliação da sensibilidade dos modelos (para cada índice DDSE e DDNS), para as situações (a) sem névoa (modelo A) e (b) com névoa (modelo B).....	150
Figura 5.20	Valores do desvio médio percentual obtidos da comparação das saídas sem alteração e com alteração dos parâmetros da corrente de fuga para avaliação da sensibilidade dos modelos (considerando o valor médio dos desvios dos índices DDSE e DDNS), para as situações (a) sem névoa (modelo A) e (b) com névoa (modelo B).....	150

LISTA DE TABELAS

Tabela 2.1:	Valores equivalentes do grau de poluição artificial do isolador (baseado na DDSE) e condutividade elétrica, considerando o caulim como material inerte.....	41
Tabela 2.2:	Classificação do nível de correlação com base no coeficiente de correlação.....	48
Tabela 2.3:	Classificação do MAPE.....	53
Tabela 3.1:	Comparativo dos trabalhos e suas características/contribuições.....	90
Tabela 4.1:	Características físicas e elétricas dos isoladores de vidro utilizados.....	95
Tabela 4.2:	Estatística descritiva dos valores de tensão, temperatura, umidade e pressão, sem névoa.....	108
Tabela 4.3:	Estatística descritiva dos valores de tensão, temperatura, umidade e pressão, com névoa.....	108
Tabela 4.4:	Configurações dos hiperparâmetros testados e selecionados para o modelo A.....	124
Tabela 4.5:	Configurações dos hiperparâmetros testados e selecionados para o modelo B.....	126
Tabela 4.6:	Configurações dos hiperparâmetros testados e selecionados para o modelo C.....	127
Tabela 4.7:	Configurações dos hiperparâmetros testados e selecionados para o modelo D.....	128
Tabela 5.1:	Valores do coeficiente de determinação dos modelos computacionais A, B, C e D.....	127
Tabela 6.1:	Trabalhos publicados ou em processo de publicação em eventos e/ou periódicos.....	156

LISTA DE ABREVIATURAS E SIGLAS

ADAM - *Adaptive Moment Estimation.*

ANFIS - *Adaptive Neuro-Fuzzy Inference System.*

ANN - *Artificial Neural Networking.*

CA - Corrente Alternada.

CC - Corrente Contínua.

CHESF - Companhia Hidrelétrica do São Francisco.

DDNS - Densidade de Depósito Não Solúvel.

DDSE - Densidade de Depósito de Sal Equivalente.

DHT - Distorção Harmônica Total.

EDA - *Exploratory Data Analysis.*

FFT - *Fast Fourier Transform.*

GMDH - *Group Method of Data Handling.*

KNN - *K-Nearest Neighbors.*

LAT - Laboratório de Alta Tensão.

LBFGS - *Limited-memory Royden–Fletcher–Goldfarb–Shanno.*

LSTM - *Long Short-Term Memory.*

MAE - *Mean Absolute Error.*

MAPE - *Mean Absolute Percentage Error.*

MLP - *Multilayer Perceptron.*

MSE - *Mean Squared Error.*

RMSE - *Root Mean Squared Error.*

NaCl - Cloreto de Sódio.

RBF - *Radial Basis Function.*

ReLU - *Rectified Linear Unit.*

RF - *Random Forest.*

RMS - *Root Mean Square.*

RMSE - *Root Mean Squared Error.*

ROC - *Receiver Operator Characteristic Curve.*

SEP - Sistema Elétrico de Potência.

SGD - *Stochastic Gradient Descent.*

SIN - Sistema Interligado Nacional.

SRM - *Structural Risk Minimization.*

SVM - *Support Vector Machine.*

SVR - *Support Vector Regression.*

UV - Ultra Violeta.

TF - Transformada de Fourier.

TFD - Transformada de Fourier Discreta.

SUMÁRIO

Capítulo 1	21
1.1 Introdução	21
1.2 Objetivos	24
1.2.1 Objetivo Geral	24
1.2.2 Objetivos Específicos	24
1.3 Contribuições	25
1.4 Estrutura Organizacional do Texto.....	25
Capítulo 2	27
Fundamentação Teórica	27
2.1 Isoladores	27
2.1.1 Histórico	28
2.1.2 Corrente de Fuga de Isoladores	32
2.2 Poluição em Isoladores	35
2.2.1 Poluição Natural	39
2.2.2 Poluição Artificial.....	40
2.2.3 Experimento de Coleta de Poluição.....	41
2.3 Descargas em Isoladores de Vidro	43
2.4 Mineração de Dados.....	45
2.5 Séries Temporais.....	53
2.5.1 Preparação dos Dados com <i>Sliding Window</i> (Janela Deslizante)	56
2.6 Modelos de Previsão Baseados em Inteligência Artificial	58
2.6.1 Máquina de Vetores de Suporte - SVM.....	60
2.6.2 Redes Neurais Artificiais - ANN.....	64
2.7 Resumo do Capítulo.....	70
Capítulo 3	71
Revisão Bibliográfica	71
3.1 Estratégias para Mitigar Falhas em Isoladores Devido ao Acúmulo de Poluição Superficial.....	72
3.2 Resumo do Capítulo.....	87
3.2.1 Síntese	87
3.2.2 Quadro Sinóptico.....	89
Capítulo 4	92
Procedimentos Práticos e Simulações Computacionais	92
4.1 Realização de Experimentos de Poluição Superficial em Ambiente Externo	94
4.1.1 Seleção e Tratamento das Amostras de Isoladores	94
4.1.2 Instalação dos Isoladores em Ambiente Externo	96
4.1.3 Medições Sistemáticas dos Níveis de Poluição	97
4.2 Construção das Séries Temporais da DDSE e DDNS dos Níveis de Poluição Superficial	99
4.3 Realização de Ensaios de Poluição Artificial em Laboratório	101

4.3.1	Preparo da Solução de Poluição	102
4.3.2	Seleção e Tratamento das Amostras de Isoladores	104
4.3.3	Ensaios Elétricos de Poluição Artificial	105
4.3.4	Aquisição dos Sinais da Corrente de Fuga e Registros de Descargas Superficiais	107
4.3.5	Extração dos Parâmetros da Corrente de Fuga	110
4.3.6	Análise Exploratória	111
4.4	Povoamento da Base de Dados	115
4.5	Critério Adotado para o Nível Crítico de Poluição Superficial	117
4.6	Modelos de Previsão Baseados em Inteligência Artificial	120
4.6.1	Modelo A	122
4.6.2	Modelo B	124
4.6.3	Modelo C	126
4.6.4	Modelo D	127
4.7	Avaliação de Desempenho dos Modelos de Previsão	128
4.8	Estratégia para estimativa do Momento Ótimo para Realização de Limpeza em Isoladores	129
4.9	Resumo do Capítulo	129
Capítulo 5		131
Resultados e Discussões		131
5.1	Avaliação dos Modelos Computacionais	132
5.2	Crítérios para Previsão do Nível Crítico de Poluição	140
5.3	Previsão do Nível Crítico de Poluição	143
5.4	Proposição de Aplicação em Campo	146
5.5	Influência da Variação da Corrente de Fuga nas Saídas dos Modelos	147
5.6	Resumo do Capítulo	151
Capítulo 6		152
Conclusões		152
6.1	Pesquisas Futuras	154
6.2	Publicações	155
Referências		157

CAPÍTULO 1

1.1 INTRODUÇÃO

O Sistema Elétrico de Potência (SEP) possibilita o fornecimento de energia elétrica por meio dos sistemas de geração, transmissão e distribuição. Nesse cenário, as linhas de transmissão são responsáveis pelo transporte da energia elétrica da geração aos centros consumidores. Para minimizar as perdas, os níveis de tensão nas linhas de transmissão são elevados requerendo a utilização de isoladores de sistemas elétricos. Os isoladores promovem o isolamento elétrico apropriado entre os cabos energizados e entre cabos e a massa aterrada. Os isoladores também são responsáveis pelo suporte mecânico dos cabos condutores (GORUR, 1999; CHERNEY *et al.*, 2015).

As falhas nas linhas de transmissão são uma das principais causas de desligamentos no sistema elétrico brasileiro, representando 76,1% dos desligamentos na rede básica e complementar do Sistema Interligado Nacional (SIN), entre os anos de 2015 e 2016 (FEITOSA NETO *et al.*, 2017). As falhas em equipamentos e componentes representaram 11% do total de desligamentos, sendo disjuntores, unidades capacitivas e isoladores responsáveis por 27,7% dos desligamentos forçados no sistema de transmissão (NOBREGA, 2019).

A ocorrência de falhas nos isolamentos impacta no fornecimento de energia pelo SEP. As falhas podem ocorrer por várias razões, sendo a principal delas a presença de poluição superficial elevada em conjunto com umidade elevada (acima de 90%) (FERREIRA, 2011; ROCHA, 2019; THANH *et al.*, 2021; CASTILLI-SIERRA *et al.*, 2021; SLAMA *et al.*, 2022; ESMAIELI *et al.*, 2023). A combinação desses fatores provoca a elevação da amplitude da corrente de fuga, gerando descargas superficiais e podendo resultar em descargas disruptivas (do inglês *flashover*) (SUDA, 2005; ZHAO *et al.*, 2013; KHAFRAF & EL-HAG, 2017; PALANGAR & MIRZAIE, 2020). Conseqüentemente, o sistema de proteção da linha de transmissão atua e retira a linha de operação, acarretando na interrupção do fornecimento de energia e, em alguns casos, sobrecarga de outras linhas de transmissão.

Embora as empresas do setor elétrico realizem continuamente o monitoramento e controle das condições operacionais dos isoladores, os índices de falhas de isoladores ainda são elevados. No ano de 2017, a Companhia Hidrelétrica do São Francisco (CHESF) identificou que 20,2% das falhas de isoladores, que comprometeram a eficácia e confiabilidade do sistema elétrico, foram causadas pelo acúmulo excessivo de poluição (LINS, 2018; ROCHA, 2019). Em outro estudo de caso, a investigação de um blecaute ocorrido em novembro de 2009, que afetou todas as regiões do Brasil, revelou que a causa do incidente foi um curto-circuito em uma linha de transmissão de 765 kV, tendo como uma das possíveis causas a redução da capacidade de isolamento das cadeias de isoladores submetidas a condições meteorológicas adversas (e.g., poluição pesada e umidade alta) (ONS, 2009). Assim, fica evidente os danos que o excesso de poluição exerce diretamente nos isoladores de vidro, prejudicando o funcionamento do SEP e gerando prejuízos financeiros, sociais e operacionais.

Manutenções e inspeções regulares, com limpezas e detecção de desgaste/danos, são essenciais para prevenir falhas de isoladores por acúmulo de poluição. No entanto, é importante ressaltar que a limpeza é demorada, trabalhosa e potencialmente perigosa. Portanto, adotar uma abordagem proativa, realizando lavagens no momento adequado, não apenas melhora o desempenho do sistema elétrico, mas também reduz custos a longo prazo, evitando gastos financeiros desnecessários para a empresa responsável.

O nível elevado de poluição superficial combinado com umidade alta e névoa salina, influencia negativamente na suportabilidade dos isoladores, provocando o aumento da amplitude da corrente de fuga e o surgimento de descargas superficiais e, nas situações mais críticas, descargas disruptivas (KARADY & AMARH, 1999; SALEM *et al.*, 2020; ZHAO *et al.*, 2013). Como a corrente de fuga do isolador é sensível a esses fatores ambientais, parâmetros dessa grandeza são relevantes para prever condições críticas de poluição, que podem resultar em descargas superficiais, e auxiliar na estimativa do momento ótimo de limpeza, para prevenir o acúmulo de poluição e contaminantes (LI *et al.*, 2010; ZHANG *et al.*, 2016; SALEM *et al.*, 2020).

Vários trabalhos foram desenvolvidos com o intuito de diagnosticar o nível de poluição superficial de isoladores usando, principalmente, parâmetros derivados do sinal da corrente de fuga, nos domínios do tempo e da frequência, tendo em vista a elevada correlação entre esses parâmetros e a poluição superficial, representada pela Densidade de Depósito de Sal Equivalente (DDSE) e Densidade de Depósito não Solúvel (DDNS) (FERNANDO & GUBANSKI, 1999; LI *et al.*, 2010; KUMAGAI & YOSHIMA, 2010;

MUNIRAJ & CHANDRASEKAR, 2011; FERREIRA, 2011; PYLARINOS *et al.*, 2012; MARAABA, AL-HAMOUZ & AL-DUWAISH, 2014; ZHAO *et al.*, 2013; ZHANG *et al.*, 2016; MAVRIKAKIS, MIKROPOULOS & SIDERAKIS, 2017; KHAFRAF & EL-HAG, 2017; GAO *et al.*, 2018; ROCHA, 2019; SALEM *et al.*, 2020; THANH, CHO & DA, 2021; CASTILLO-SIERRA *et al.*, 2021; SOPELSA NETO *et al.*, 2022; ESMAIELI *et al.*, 2023; LIN & KUO, 2024). As técnicas baseadas nos parâmetros da corrente de fuga são as mais confiáveis para estimar o nível de poluição, visto que uma pequena variação da poluição proporciona uma variação proporcional e direta do sinal da corrente de fuga. Nesse sentido, vários trabalhos que se baseiam na corrente de fuga verificaram que um aumento da amplitude da corrente de fuga do isolador está associado a uma redução da sua capacidade de isolamento.

Alguns trabalhos reportados na literatura utilizam parâmetros da corrente de fuga e técnicas de inteligência artificial para estimar o nível de poluição e reduzir ao máximo a subjetividade na tomada de decisão (LI *et al.*, 2010; MUNIRAJ & CHANDRASEKAR, 2011; PYLARINOS *et al.*, 2012; KHAFRAF & EL-HAG, 2017; GAO *et al.*, 2018; SOPELSA NETO *et al.*, 2022; LIN & KUO, 2024). Os resultados fornecidos pelos modelos permitiram prever o grau de poluição de acordo com os níveis da DDSE previstos em norma (IEC 60815-1, 2008). Apesar que a maioria das estratégias propostas pelos estudos possam diagnosticar o nível de poluição com base nos parâmetros da corrente de fuga, elas não permitem estimar o momento ideal para a realização de limpezas periódicas na superfície dos isoladores, tampouco estabelecem limiares baseados nos índices da DDSE e DDNS, que indiquem níveis críticos de poluição, os quais podem conduzir à ocorrência de descargas disruptivas

As descargas disruptivas (*flashover*) são fenômenos que podem afetar o desempenho dos isoladores, diminuindo a vida útil desses componentes (KARADY & AMARH, 1999; ZHAO *et al.*, 2013; SALEM *et al.*, 2020; PALANGAR & MIRZAIE, 2020; SLAMA *et al.*, 2022; LIN & KUO, 2024). A ocorrência da descarga disruptiva vai depender, principalmente, do nível de poluição na superfície do isolador, da umidade e da tensão. Como a corrente de fuga do isolador é sensível a esses fatores ambientais, parâmetros dessa grandeza foram utilizados por diversos trabalhos para desenvolverem estratégias destinadas para prever condições que possam culminar na ocorrência de descargas disruptivas. Os trabalhos alcançaram resultados que podem auxiliar na prevenção de descargas disruptivas em isoladores. Entretanto, ainda não é possível determinar o momento de ocorrência das descargas

disruptivas, uma vez que medições sistemáticas ao longo do tempo dos níveis de poluição devem ser realizadas, para ser viável a estimativa de níveis futuros de poluição (usando combinações da DDSE e DDNS).

Apesar dos avanços na previsão das condições que levam às descargas disruptivas, ainda não há consenso em relação à proposição de uma estratégia, técnica ou metodologia objetiva, eficiente e inteligente, que possibilite estimar o momento ótimo para realizar limpeza em isoladores de vidro nas linhas de transmissão, para reduzir o nível de poluição superficial desses componentes, a fim de evitar que ocorra indisponibilidade de energia elétrica devido a falhas de isoladores ocasionadas pelo excesso de poluição.

1.2 OBJETIVOS

1.2.1 OBJETIVO GERAL

O objetivo geral desta tese consiste em estimar o momento ótimo para realização de limpeza em isoladores de vidro utilizando parâmetros da corrente de fuga, DDSE, DDNS e tempo.

1.2.2 OBJETIVOS ESPECÍFICOS

Para alcançar o objetivo geral desta pesquisa, os objetivos específicos apresentados a seguir foram definidos para ser atingidos ao longo do desenvolvimento da Tese.

- Construção de séries temporais do nível de poluição (DDSE e DDNS) superficial de isoladores, utilizando dados obtidos de experimentos de exposição de cadeia de isoladores à poluição ambiente.
- Construção de uma base de dados com informações dos sinais da corrente de fuga obtido em laboratório e associados aos níveis de poluição identificados com os experimentos de poluição ambiente (representados pelas séries temporais dos índices DDSE e DDNS).
- Determinação de valores limiares da DDSE e DDNS, que indiquem a iminência de descargas superficiais, a partir de ensaios de poluição

artificial, para serem utilizados como critério na estimativa do nível crítico de poluição superficial.

- Determinação dos parâmetros da corrente de fuga que mais se correlacionam ao nível de poluição dos isoladores avaliados, por meio de critérios estatísticos, para serem usados no desenvolvimento de modelos computacionais otimizados baseados em inteligência artificial, para prever a poluição superficial (DDSE e DDNS) dos isoladores de vidro ao longo do tempo.
- Estimação do momento necessário para alcançar o nível crítico de poluição em isoladores de vidro poluídos.

1.3 CONTRIBUIÇÕES

As principais contribuições desta tese são listadas a seguir.

- Metodologia capaz de estimar o momento ótimo para realizar limpeza em isoladores de vidro, utilizando inteligência artificial, informações da corrente de fuga e séries temporais dos índices DDSE e DDNS.
- Critérios para identificação de descargas superficiais na superfície dos isoladores de vidro empregados neste trabalho, com base nos valores dos índices de poluição solúvel (DDSE) e não solúvel (DDNS), considerando ensaios a seco e com névoa, para evitar a ocorrência de condições mais críticas (e.g., descargas disruptivas).
- Modelos computacionais otimizados baseados em inteligência artificial capazes de prever séries temporais dos índices da DDSE e DDNS de isoladores de vidro, para as situações a seco e com névoa.

1.4 ESTRUTURA ORGANIZACIONAL DO TEXTO

Este trabalho está organizado em seis capítulos, conforme a estrutura apresentada a seguir.

No Capítulo 2, a fundamentação teórica é apresentada, que serve como base para o desenvolvimento e entendimento do trabalho. Os assuntos do capítulo são referentes

aos isoladores de vidro, considerando aspectos como: histórico, tipos, conceitos teóricos, concepção estrutural, efeitos danosos da poluição superficial, características dos ensaios de poluição (artificial e natural) e procedimento para coleta de poluição. As etapas até culminar em descargas disruptivas também são apresentadas detalhadamente. Além disso, os conceitos pertencentes à ciência de dados também são apresentados, abrangendo métodos estatísticos e modelos de previsão de séries temporais baseados em inteligência artificial.

No Capítulo 3, a revisão bibliográfica é apresentada, na qual são abordadas análises dos trabalhos correlatos com o tema desta pesquisa, com foco nos trabalhos que propõem o monitoramento, diagnóstico e/ou prognóstico de isoladores de vidro com base no nível de poluição superficial, considerando as técnicas de classificação e previsão dos níveis de poluição (DDSE e/ou DDNS), como também os trabalhos que se destinaram a prever a tensão (associada ao nível de poluição) de descarga disruptiva. No final do capítulo é apresentada uma tabela, na qual são abordadas as contribuições de cada trabalho e o diferencial desta pesquisa em relação aos demais trabalhos analisados.

No Capítulo 4, os procedimentos práticos e computacionais são apresentados, com ênfase nas descrições dos ensaios de poluição ambiente realizados ao ar livre, dos ensaios de poluição artificial, bem como das implementações dos modelos computacionais.

No Capítulo 5, os resultados que foram obtidos para o trabalho desta tese e suas respectivas análises são apresentados.

Por fim, no Capítulo 6, as conclusões obtidas com o desenvolvimento da tese e sugestões de trabalhos futuras são apresentadas. Além disso, ainda no Capítulo 6 também são apresentados os trabalhos publicados (ou em processo de publicação) em periódicos e anais.

CAPÍTULO 2

FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os principais conceitos que servem de base para o desenvolvimento e entendimento deste trabalho. O capítulo está estruturado em seis seções. Na seção 2.1, os isoladores de vidro são apresentados, com foco no histórico dos isoladores, as suas partes constituintes, as suas vantagens e desvantagens, além das características da corrente de fuga. Na seção 2.2, conceitos e procedimentos relacionados à poluição em isoladores de vidro são apresentados. Na seção 2.3, conceitos relacionados ao fenômeno de descargas em isoladores são apresentados. Na seção 2.4, conceitos relacionados à mineração de dados também são abordados, a fim de facilitar o entendimento das definições relativas à ciência de dados. Na seção 2.5, é realizada uma contextualização acerca de séries temporais, para auxiliar, principalmente, no entendimento das séries temporais referentes aos índices de poluição (DDSE e DDNS). Na seção 2.6, os principais modelos estatísticos e algoritmos baseados em inteligência artificial são apresentados, com foco maior nos algoritmos aplicados neste trabalho.

2.1 ISOLADORES

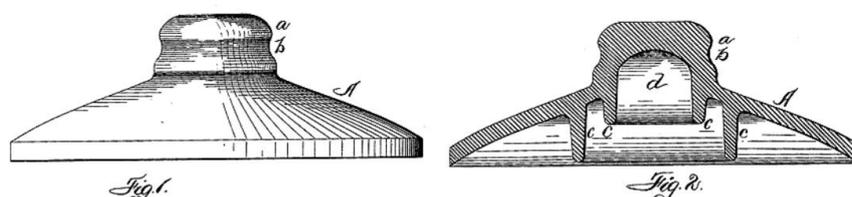
Nas linhas de transmissão, três tipos de isoladores comumente são encontrados: os isoladores de porcelana, de vidro temperado e poliméricos (KIM *et al.*, 1992; FERREIRA, 2011). Os isoladores possuem as funções de suportar mecanicamente condutores e isolar regiões de potenciais elétricos distintos (GORUR, CHERLEY & BURNHAM, 1999). Essas funções são associadas principalmente aos materiais dielétricos e ferragens metálicas que compõem os isoladores. Historicamente, vários modelos de isoladores foram desenvolvidos, contemplando vários formatos e diferentes materiais dielétricos, conforme apresentado no histórico a seguir.

2.1.1 HISTÓRICO

A necessidade de materiais que assegurassem isolamento elétrico começou em 1830, com as primeiras redes telegráficas, quando materiais como madeira, vidro e ebonite foram experimentados, destacando-se o vidro pelas suas excelentes propriedades elétricas e mecânicas (LIEBERMANN, 2000). Na década de 1840, surgiram os isoladores de pino para linhas de distribuição, inicialmente fixados com buchas e, posteriormente, com rosca interna (padrão a partir de 1865) (CAUVET, 1865; ROCHA, 2019). Com o desenvolvimento das linhas de transmissão de energia por volta de 1880, as tensões subiram de 1 kV para dezenas ou centenas de quilovolts, o que exigiu a adaptação dos isoladores, que foram projetados em tamanhos maiores para lidar com as altas tensões, passando a adotar a porcelana devido aos desafios de produção de grandes peças de vidro (FASSBINDER, 2003; BERRY, 2008).

O processo de fabricação de cerâmica idealizado por Fred M. Locke garantiu isoladores de alta tensão com menos bolhas de ar e maior resistência a intempéries, sendo aplicado em uma linha de 40 kV em 1896, nos Estados Unidos (FASSBINDER, 2003; GISH, 1994). Em 1910, Arthur Austin introduziu o isolador de suspensão, similar ao modelo atual, conforme pode ser observado na Figura 2.1. Nas décadas de 1950 e 1960, avanços nas técnicas de fabricação consolidaram os isoladores de vidro e porcelana como opções robustas e confiáveis. Desde então, os isoladores de porcelana e vidro têm formatos e processos de montagem semelhantes, com variações que atendem a diferentes exigências de desempenho e confiabilidade. Fotografias de isoladores cerâmicos podem ser observados na Figura 2.2.

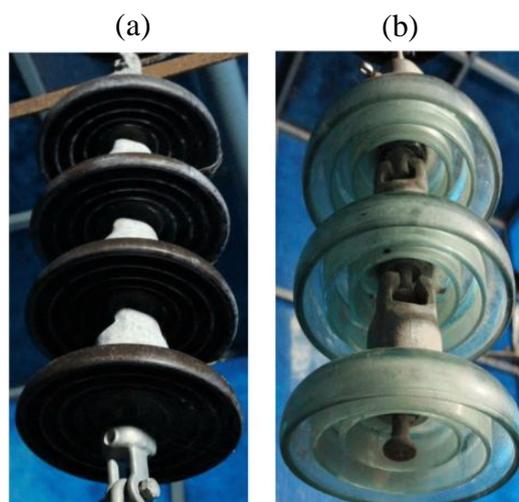
Figura 2.1 – Projeto de isolador proposto por Locke.



Fonte: adaptado de Gish (1994).

Os principais tipos de isoladores cerâmicos usados no sistema elétrico são feitos de porcelana e vidro temperado. Entre os isoladores de porcelana, destacam-se os de pino, suspensão e pedestal, cada um com estrutura específica para diferentes aplicações, conforme pode ser verificado na Figura 2.3 (KUFFEL, KUFFEL & ZAENGL, 2000). Os isoladores de porcelana, por sua alta resistência a produtos químicos, ácidos e substâncias

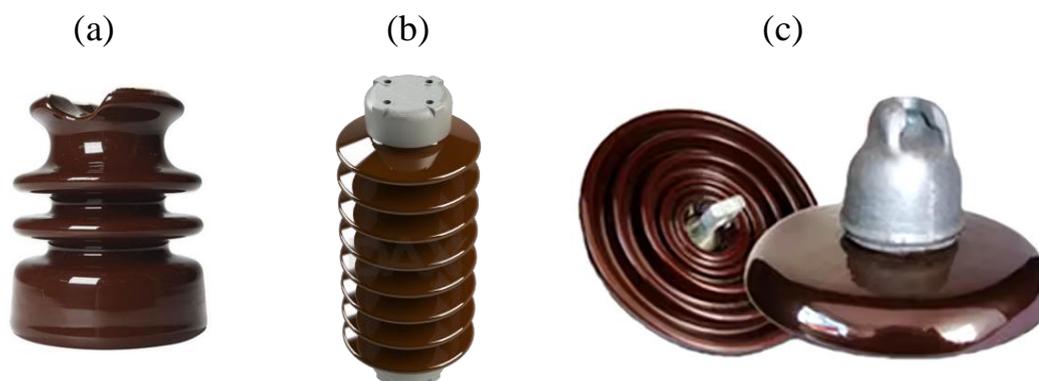
Figura 2.2 – Fotografias de isoladores de (a) porcelana e (b) vidro temperado.



Fonte: adaptado de Chakraborty (2017).

alcalinas, mantêm suas características originais mesmo sob condições climáticas adversas. No entanto, a superfície desse tipo de isolador é áspera, o que o torna propenso a acumular poeira e partículas, um problema que em alguns casos é minimizado por um processo de esmaltagem, que cria uma superfície lisa e impermeável, facilitando a limpeza natural pela chuva ou durante a manutenção. A sujeira acumulada nos isoladores de porcelana pode aumentar a corrente de fuga e reduzir a tensão de descarga disruptiva, além de causar problemas devido à distribuição irregular do potencial elétrico tanto em cadeias de isoladores quanto em diferentes pontos de um mesmo isolador.

Figura 2.3 – Fotografias de isoladores de porcelana de (a) pino, (b) pedestal e (c) suspensão.

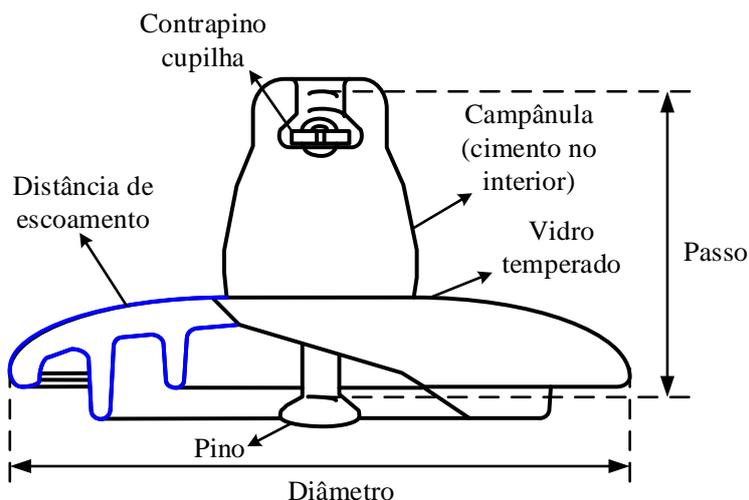


Fonte: autor (2025).

Os isoladores de vidro mais empregados são do tipo de suspensão. Esses isoladores são caracterizados por possuírem: contrapino cupilha, campânula, cimento, vidro temperado e pino. Esses itens podem ser observados na Figura 2.4. O dielétrico de vidro temperado no formato de disco é a peça que possibilita a isolação elétrica do componente. A campânula e o pino possuem a função de prover a sustentação ao isolador

e, conseqüentemente, à cadeia em que ele se encontra. O pino é fabricado em aço forjado ou usinado, encaixado na campânula do isolador, que é situado imediatamente na parte inferior da cadeia. O contrapino cupilha propicia o travamento contra a separação das unidades da cadeia de isoladores durante o manuseio e o uso. O cimento é de elevada resistência mecânica e com variação mínima de volume devido à mudança de temperatura e ao envelhecimento (KUFFEL, KUFFEL & ZAENGL, 2000).

Figura 2.4 – Esquemático das partes constituintes de um isolador de vidro, tipo disco de suspensão.



Fonte: adaptado de Kuffel, Kuffel & Zaengl (2000).

Isoladores de vidro e porcelana apresentam diferenças considerando, sobretudo, o quesito de aplicação: o vidro é mais resistente a contaminações e oferece inspeção visual mais fácil por sua transparência, enquanto a porcelana, opaca e mais porosa, exige mais manutenção em ambientes poluídos. O vidro possui alta resistência mecânica, mas é vulnerável a choques térmicos, enquanto a porcelana tem resistência geral confiável, sendo menos suscetível a fraturas. Em termos de durabilidade, o vidro envelhece melhor, mantendo suas propriedades dielétricas, e costuma ter um custo menor comparado à porcelana, cujo processo de produção é mais complexo.

De modo geral, as vantagens dos isoladores do vidro temperado estão associadas às características de resistir à degradação natural, ser inerte para grande parte dos compostos químicos e possuir elevada resistência ao calor oriundo de arcos elétricos enquanto estiver em operação. Além disso, outras vantagens dos isoladores de vidro são apresentadas a seguir:

- os isoladores de vidro possuem vida útil mais longa em relação aos isoladores poliméricos;

- os isoladores de vidro apresentam flexibilidade de tamanho da cadeia, podendo o mesmo isolador ser utilizado para compor cadeias de isoladores para sistemas elétricos de níveis distintos de tensão;
- se um dos discos da cadeia for danificado, não provoca ineficiência dos demais discos;
- o isolador de vidro absorve a maior parte das vibrações mecânicas dos cabos;
- para aumentar a capacidade de isolamento, basta aumentar o número de discos e não trocar a cadeia inteira;
- comparado com os materiais cerâmicos, os isoladores de vidro possuem material dielétrico mais resistente;
- devido à sua transparência, impurezas e bolhas podem ser facilmente detectadas no isolador de vidro.

Embora as vantagens de utilizar isoladores de vidro nas linhas de transmissão justifiquem seu uso, esses componentes apresentam algumas desvantagens. A umidade pode se condensar facilmente na superfície do vidro, que pode resultar na formação de película de água em condições de alta umidade. O excesso de poluição em conjunto com umidade elevada afeta o desempenho dos isoladores de vidro, por formar uma camada condutora superficial. Assim, pode ocorrer a elevação da amplitude da corrente de fuga e, conseqüentemente, aumentar as perdas. Ademais, os isoladores de vidro estão mais vulneráveis aos danos causados pelo vandalismo, em função do seu tipo de dielétrico.

Na década de 1950, isoladores com revestimento constituído por material polimérico foram propostos, com aprimoramentos nas características hidrofóbicas e redução da massa física do componente, para facilitar a realização da instalação nas torres, além de serem mais resistentes ao vandalismo. Entretanto, diante de condições ambientais severas, isoladores poliméricos estão mais vulneráveis à degradação precoce, devido à exposição à radiação ultravioleta proveniente do sol, que pode causar degradação dos materiais poliméricos ao longo do tempo; maior propensão ao acúmulo de sujeira, poeira, partículas poluentes e umidade, levando à formação de camadas condutoras superficiais; menor resistência a incêndios, visto que podem derreter e queimar mais facilmente que os isoladores cerâmicos. Outra desvantagem dos isoladores poliméricos é a menor resistência mecânica em relação aos isoladores cerâmicos (FERREIRA, 2011).

Considerando isso, muitas empresas recorrem aos isoladores de vidro, uma vez que eles apresentam vida útil mais longa em relação aos isoladores de polímero;

apresentam flexibilidade de tamanho da cadeia; se um dos discos da cadeia for danificado, não provoca ineficiência dos demais discos (SALEM *et al.*, 2020; DIAS, 2017; VOSLOO, MACEY & TOURREIL, 2008).

2.1.2 CORRENTE DE FUGA DE ISOLADORES

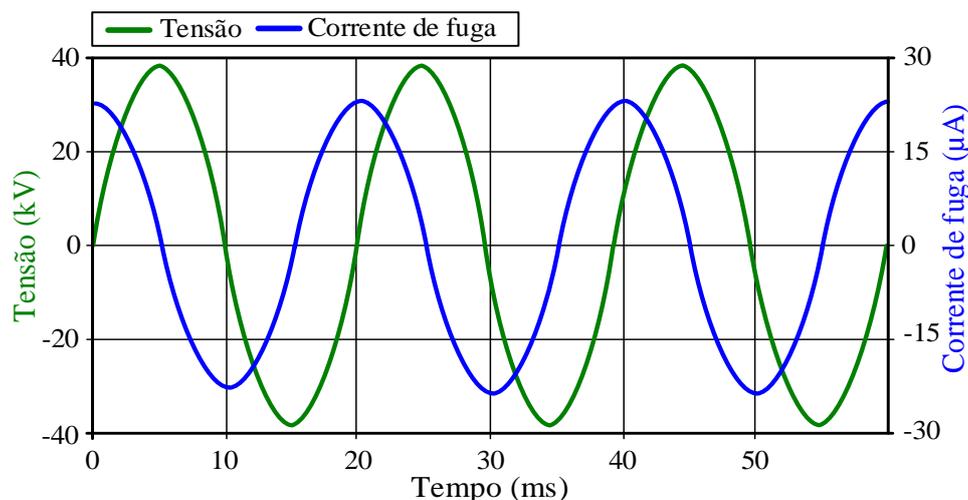
A corrente de fuga é a corrente elétrica que percorre a superfície de um isolador devido à presença de contaminantes e umidade, os quais reduzem a resistência superficial e formam um caminho condutivo que facilita o movimento de cargas elétricas ao longo da superfície. No isolador, em geral, a corrente de fuga surge quando esse componente está submetido a uma diferença de potencial. O aumento da corrente de fuga pode estar associado a uma redução das características isolantes do componente, o que pode ocasionar descargas superficiais e, nas situações mais severas, descargas disruptivas (*flashover*). A corrente de fuga possui uma forte correlação com a poluição depositada na superfície do isolador (RAMIREZ, HERNADEZ & MONTOYA, 2012). A poluição superficial do isolador pode ser dissolvida quando é associada à umidade, gerando cargas livres (íons e elétrons) que diminuem a resistividade elétrica do material na superfície. Os poluentes podem ser poeiras, cinzas, fumaça, pó de argila, produtos químicos de indústrias próximas ou névoa salina em áreas costeiras (ROCHA, 2019).

Diversos fenômenos estão envolvidos na formação da corrente de fuga nos isoladores. Devido a isso, o sinal de corrente possui diversas componentes, o que faz necessária a utilização de técnicas de processamento de sinais para extrair informações sobre o risco de descargas disruptivas nos isoladores. As componentes harmônicas presentes na corrente de fuga podem ocorrer devido a diversos fatores relacionados a não linearidades no sistema elétrico e condições de operação. Os principais motivos que podem estar relacionados às causas da presença de harmônicos na corrente são: presença de contaminantes e sujeira superficial; não linearidade inerente aos materiais dielétricos diante da aplicação da tensão (e.g., vidro e ar); distribuição de campo elétrico não uniforme devido à geometria do sistema.

A corrente de fuga em isoladores limpos e secos é predominantemente capacitiva, visto que o isolador atua como um capacitor entre o condutor energizado e o ambiente; além disso, a alta resistência do material isolante minimiza a corrente resistiva, fazendo com que a corrente de fuga seja dominada pelo carregamento e descarregamento capacitivo. Na Figura 2.5 é apresentado a corrente de fuga adianta aproximadamente 90%

em relação ao sinal da tensão. Essa diferença de fase entre os sinais de tensão e corrente pode ser verificada em isoladores com diferentes materiais dielétricos (materiais cerâmicos e poliméricos, por exemplo) (METWALLY *et al.*, 2006). O nível de corrente de fuga vai variar, podendo ser influenciado principalmente pelos seguintes fatores: umidade relativa, nível e tipo de poluição, tensão aplicada, material constituinte do isolador e distância de escoamento. Nas condições que o isolador está limpo e seco, os sinais de corrente de fuga são consideravelmente baixos, com amplitudes de algumas dezenas de microampères (μA) (METWALLY *et al.*, 2006; OLIVEIRA, 2008).

Figura 2.5 – Sinais da tensão e corrente de fuga para uma cadeia de isoladores limpos e secos.

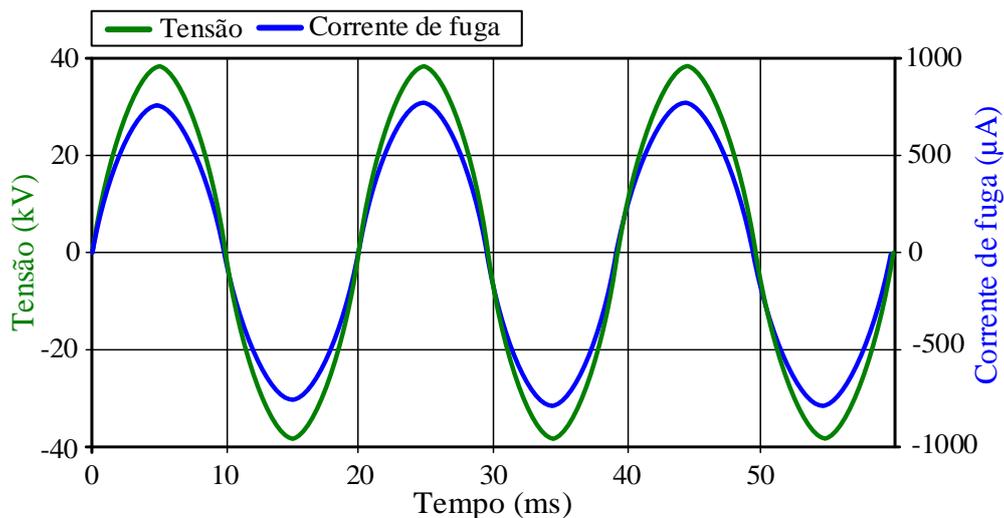


Fonte: adaptado de Metwally *et al.* (2006).

As características da corrente de fuga nos isoladores podem mudar de acordo com as condições ambientais, sobretudo em função da umidade. Essa mudança pode ser verificada na forma de onda da corrente de fuga apresentada na Figura 2.6, que representa a corrente de fuga de um isolador de material cerâmico (porcelana) exposto a um ambiente com umidade relativa de 100%. Uma fina camada de água formou-se sobre a superfície do isolador, criando uma camada condutiva. Assim, a corrente de fuga mudou suas características, aumentando sua amplitude consideravelmente, quando comparado à situação do isolador seco e limpo, e apresentando fase bastante próxima à fase do sinal de tensão. Em isoladores de material polimérico e de vidro, também há mudança similar nas características da corrente de fuga, podendo a corrente do isolador com umidade apresentar crescimento de até 50 vezes maior do que o isolador quando estava seco (METWALLY *et al.*, 2006).

As bandas secas são regiões localizadas na superfície de um isolador em que a umidade foi evaporada devido ao aquecimento provocado pela passagem de corrente de

Figura 2.6 – Sinais da tensão e corrente de fuga para uma cadeia de isoladores limpos e umedecidos.



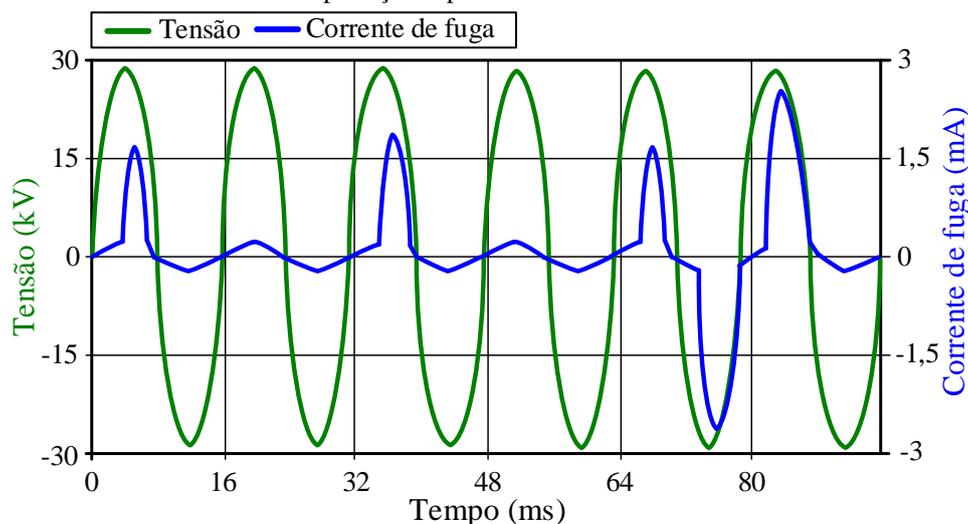
Fonte: adaptado de Metwally *et al.* (2006).

fuga em uma camada condutiva de poluição. Essas áreas formam pequenas regiões isolantes (dielétricas) cercadas por áreas condutoras, o que facilita o surgimento de descargas superficiais. Nos isoladores com poluição superficial e expostos a alta umidade, ocorre a formação de bandas secas, resultando em descargas superficiais. O campo elétrico intenso aplicado às bandas secas ultrapassa a rigidez dielétrica do ar, provocando descargas ao longo da superfície do isolador. Como consequência, ocorrem pulsos intermitentes, com duração de aproximadamente meio ciclo, na corrente de fuga, resultando em uma forma de onda de baixa intensidade e aproximadamente senoidal, porém marcada por pulsos intermitentes. Comparado aos sinais de corrente de isoladores secos ou apenas úmidos, essa configuração apresenta um aumento significativo na amplitude da corrente de fuga, conforme ilustrado na Figura 2.7.

Em geral, a corrente de fuga apresenta pulsos intermitentes quando os isoladores estão com poluição alta em conjunto com umidade elevada (METWALLY *et al.*, 2006; OLIVEIRA, 2008). A amplitude do sinal de corrente (componente senoidal) possui geralmente algumas unidades de miliampères e os pulsos de corrente são sincronizados com os instantes de valores máximos e mínimos do sinal de tensão. Para níveis severos de poluição e em instantes próximos da ocorrência de descargas disruptivas, a componente senoidal da corrente de fuga se mantém próxima de algumas dezenas de miliampères, em situações mais críticas.

Vários estudos realizaram análises da corrente de fuga dos isoladores no domínio da frequência, por meio da extração das componentes harmônicas (KARADY & AMARH, 1999; SUDA, 2001; SUDA, 2005; KHAFRAF & EL-HAG, 2017;

Figura 2.7 – Sinais da tensão e corrente de fuga de um isolador com presença de bandas secas devido à poluição superficial e umidade.



Fonte: adaptado de Metwally *et al.* (2006).

SALEM *et al.*, 2020). Nesse sentido, o espectro da corrente de fuga foi investigado até 400 kHz, com variações acentuadas até a frequência de 1 kHz, para isoladores com diferentes níveis de poluição e umidade. As componentes ímpares da corrente de fuga até 350 Hz foram as mais sensíveis às diferentes condições ambientais nos quais os isoladores foram expostos. Em alguns trabalhos presentes na literatura, descargas superficiais foram identificadas a partir da análise da intensidade da corrente de fuga, como também por meio da investigação espectral do sinal de corrente (SUDA, 2001; SUDA 2005). Dentre as componentes harmônicas estudadas para os diferentes níveis de tensão, a terceira componente harmônica foi empregada como critério para prever a ocorrência de descargas disruptivas.

2.2 POLUIÇÃO EM ISOLADORES

A poluição superficial é um problema recorrente no sistema elétrico, sendo considerada uma das principais causas de falhas no isolamento externo (ZHAO *et al.*, 2013; LINS, 2018; THANH *et al.*, 2021). O acúmulo de poluição superficial afeta negativamente o desempenho dos isoladores, principalmente devido à formação de uma camada superficial condutora em ambientes úmidos, o que pode provocar aumento da corrente de fuga (CIGRÉ, 2000; NOBREGA, 2019). Assim, pode acarretar no surgimento de descargas elétricas superficiais e parciais. Arcos elétricos na superfície do isolador podem culminar na degradação do isolador, por diversos motivos,

sendo os principais: trilhamento elétrico superficial e corrosão das ferragens por causa da liberação de ozônio pelo arco elétrico.

Como os isoladores são instalados e operam em ambientes externos, eles estão sujeitos às intempéries climáticas, tais como chuvas, ventos e oscilações de temperatura. Outras fontes de poluição incluem dejetos de animais, produtos químicos agropecuários, poluição industrial, poeira e maresia. Nas regiões costeiras, os isoladores são expostos ao depósito de partículas solúveis, como o cloreto de sódio (NaCl).

Um das possíveis consequências devido ao excesso de poluição combinado com umidade elevada nos isoladores é a oxidação de elementos metálicos existentes nas terminações do isolador (CHERNEY *et al.*, 2015). Fotografias de isoladores danificados devido à oxidação das suas partes metálicas ocasionada pelo excesso de poluição superficial e umidade elevada são apresentadas na Figura 2.8.

Figura 2.8 – Isolador de vidro danificado devido ao processo de oxidação.



Fonte: adaptado de Cherney *et al.* (2014).

A oxidação das partes metálicas de isoladores de vidro em condições de alto nível de poluição e umidade elevada ocorre devido à corrosão eletroquímica (CHERNEY *et al.*, 2015). Os isoladores geralmente têm partes metálicas, como grampos, pinos e suportes, que são usados para fixar o isolador à estrutura de suporte. Quando essas partes metálicas entram em contato com poluentes atmosféricos e umidade, podem ocorrer reações químicas que levam à oxidação. A poluição ambiente pode incluir compostos corrosivos, como dióxido de enxofre (SO₂) e óxidos de nitrogênio (NO_x), que estão presentes na atmosfera devido à poluição industrial e veicular (CUENCA, 2005). Esses poluentes podem se depositar nas superfícies metálicas dos isoladores e em conjunto com a umidade presente no ambiente iniciar reações eletroquímicas que levam à formação de produtos de corrosão, como óxidos metálicos. Esses produtos de corrosão podem desgastar as partes metálicas e comprometer a integridade do isolador.

A poluição pode ser categorizada em dois tipos, de acordo com a norma IEC 60815-1 (2008): A e B. A poluição do tipo A é composta principalmente por partículas sólidas não solúveis, que se tornam condutivas quando em contato com a umidade presente na superfície do isolador. Esse tipo de poluição é comum em regiões interioranas, desérticas ou com poluição natural. A poluição A pode ser dividida em duas partes: a parcela solúvel, composta por sais, que forma a camada condutora quando umidificada e pode ser quantificada através da medição da DDSE em mg/cm^2 . E a parcela não solúvel é composta por partículas sólidas inertes (óleo, argila, poeira etc.), que pode ser quantificada pela medição da DDNS em mg/cm^2 .

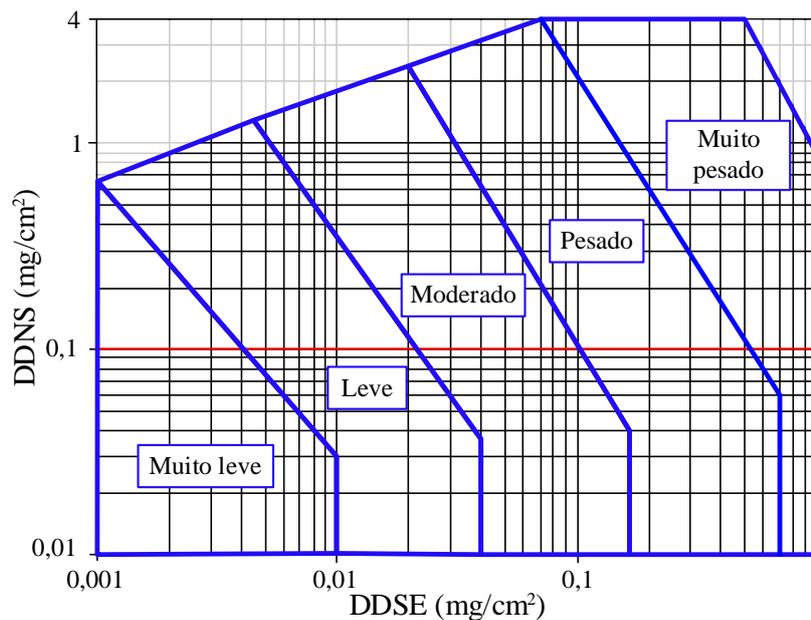
A poluição classificada como tipo B é composta em grande parte por eletrólitos líquidos e partículas solúveis. Esse tipo de poluição é associado a áreas costeiras, com presença de maresia (ou névoa condutiva) e em regiões com presença de névoa química, pulverização de culturas e chuva ácida. Uma das formas de quantificar o nível desse tipo de poluição é por meio da medição da condutância.

Os índices DDSE e DDNS são geralmente aplicados para monitoramento da agressividade da poluição local em isoladores. A medição desses índices é realizada em isoladores desenergizados, embora eles possam estar energizados durante período de depósito de poluição, com base em procedimentos definidos em normas (IEC 60815-1, 2008). A poluição local é categorizada a partir da determinação dos índices DDSE e DDNS. Os dois índices estão relacionados de acordo com a ilustração apresentada na Figura 2.9.

Para mensurar a poluição do ambiente, os índices DDSE e DDNS são determinados por meio de uma lavagem do componente exposto à poluição. Para isso, a condutividade da água utilizada no processo de lavagem é medida. Existem dois tipos de técnicas sugeridas em norma para realizar a coleta da poluição (IEC 60507, 2013; 60815-1, 2008). Uma delas consiste em, inicialmente, preparar um recipiente com água destilada, para umidificar um algodão. É necessário que a condutividade da água com algodão seja menor que $0,001 \text{ S/m}$. Com isso, utilizando-se o algodão, esfrega-se o isolador até remover toda a camada de poluição, armazenando o líquido da lavagem em outro recipiente. O algodão empregado na limpeza deve ser novamente inserido no recipiente, contendo água com a poluição derivada da superfície do isolador. Após isso, a medição da condutividade é realizada.

O cálculo da DDSE é realizado considerando os valores da área, da condutividade e da temperatura, tendo em vista que esse índice se refere a uma concentração de poluição

Figura 2.9 – Níveis de poluição com base nos valores da DDSE e DDNS.



Fonte: adaptado de IEC 60815-1 (2008).

sobre determinada área. Sabe-se que a condutividade da solução depende da sua concentração (e esta depende da temperatura ambiente). Assim, de acordo com IEC 60507 (2013), é necessário aplicar um fator de correção caso a temperatura seja diferente de 20 °C, conforme (2.1) e (2.2).

$$\sigma_{20} = \sigma_{\theta} \cdot [1 - b(\theta - 20)], \quad (2.1)$$

$b = -3200 \cdot 10^{-8} \cdot \theta^3 + 1032 \cdot 10^{-5} \cdot \theta^2 - 8272 \cdot 10^{-4} \cdot \theta + 3544 \cdot 10^{-2}$, (2.2) sabendo que θ é a temperatura (°C) da solução, σ_{θ} e σ_{20} são as condutividades volumétricas das soluções nas temperaturas θ e 20 °C, nessa ordem; e b é um fator dependente da temperatura θ . Assim, pode-se obter o valor do DDSE por meio de (2.3) e (2.4).

$$S_a = (5,7 \cdot \sigma_{20})^{1,03}, \quad (2.3)$$

$$DDSE = S_a \cdot \frac{V}{A}, \quad (2.4)$$

em que S_a é a salinidade em kg/m³, V é o volume total de água destilada (cm³) e A é a área da superfície (cm²) do isolador utilizado para coleta de poluição. Para isoladores com um nível elevado de poluição acumulada, o volume de água a ser considerado no cálculo da DDSE deve ser maior.

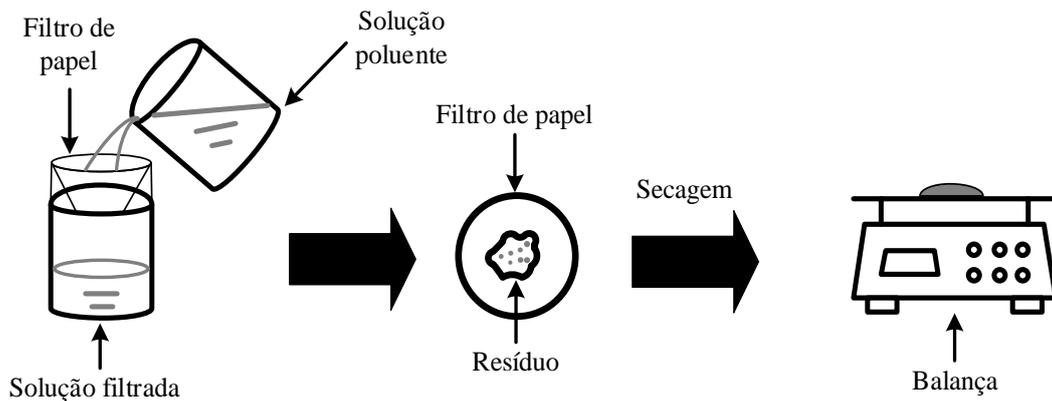
Para o cálculo da DDNS, inicialmente deve ser filtrada a água contendo poluição, utilizando um filtro de graduação GF/A 1,6 µm, ou equivalente. Na sequência, a umidade do filtro deve ser retirada e a massa (g) dos resíduos deve ser obtida. O procedimento para

obter a massa dos resíduos é ilustrado no diagrama apresentado na Figura 2.10. Com a informação da massa obtida, deve-se utilizar (2.5) para calcular a DDNS.

$$DDNS = \frac{1000 \cdot (m_f - m_i)}{A}, \quad (2.5)$$

em que m_f é a massa do filtro de papel poluído (g), m_i é a massa do filtro de papel limpo e A é a área da superfície (cm^2) do isolador usado para coleta de poluição.

Figura 2.10 – Diagrama ilustrativo para obtenção da massa dos resíduos da poluição.



Fonte: adaptado de IEC 60815-1 (2008).

2.2.1 POLUIÇÃO NATURAL

A poluição natural é composta por duas partes, a parte ativa (condutora) e a parte não ativa (inerte). A parcela ativa pode possuir dois tipos básicos de componentes. O primeiro tipo apresenta característica condutiva sem a necessidade de água. Exemplos de poluição ativa com o primeiro componente: maresia, excrementos de aves, elementos metálicos (magnetita) e gases (e.g., dióxido de enxofre - SO_2). Em relação ao segundo componente, é necessária a adição de água para que a camada se torne condutiva. Para a poluição ativa com o segundo componente, alguns exemplos são: cimento, cinza volante (derivado da queima do carvão mineral) e sais iônicos (NaCl). Nesse contexto, a medição do DDSE representa melhor o quantitativo da poluição ativa total da camada, por representar a concentração de poluentes em uma área específica.

A parcela inerte que constitui a camada da poluição influencia indiretamente na diminuição da tensão suportável do isolador, por exemplo, cerâmico (MATSUOKA *et al.*, 1996). A medição do DDNS é utilizada para quantificar a parcela inerte da poluição. Quando há acúmulo de poluição, ocorre a retenção de líquido sobre a superfície, constituindo uma película contínua de água, que diminui a capacidade de

isolação esperada do componente. Dessa forma, há diminuição da tensão suportável do isolador, devido ao acúmulo de poluição inerte (NAITO *et al.*, 1994).

2.2.2 POLUIÇÃO ARTIFICIAL

A poluição artificial, de modo semelhante à poluição natural, é constituída pelas partes ativa e inerte, as quais são associadas aos materiais que exercem cada uma dessas funções. Para representar o material inerte, utiliza-se o caulim ou a diatomita (IEC 60507, 2013). No tocante ao material da parte ativa da solução, deve ser utilizado cloreto de sódio (NaCl), denominado popularmente como sal de cozinha.

Para a preparação da solução de poluição utilizando caulim, deve-se adicionar 40 g de caulim para cada litro de água, para se ter $0,1 \text{ mg/cm}^2$ referente ao índice DDNS (valor destacado no gráfico dos níveis de poluição da Figura 2.9) (IEC 60507, 2013). A quantidade NaCl varia de acordo com o nível de condutividade desejado. Já para a preparação usando diatomita, deve-se adicionar 100 g de diatomita e 10 g de dióxido de silício altamente disperso, para cada 1 litro de água (ABNT NBR 10621, 2005).

A preparação da solução de poluição artificial deve ser realizada após ser determinado a condutividade volumétrica desejada da poluição. Inicialmente, a solução de poluição é preparada com água e material inerte; em seguida, é adicionado NaCl conforme o nível de condutividade desejado. Apesar disso, o nível de poluição não deve ser definido com base na condutividade, pois devem ser utilizados os índices DDSE e DDNS como critérios de classificação da poluição artificial. Considerando isso, utiliza-se a Tabela 2.1 para correlacionar o grau de poluição (DDSE e DDNS, dados em mg/cm^2) e a condutividade da solução (S/m) (IEC 60507, 2013). Caso a proporção do caulim (40 g para cada litro de água) seja constante durante a preparação da solução, o valor do DDNS deve ser de $0,1 \text{ mg/cm}^2$, para todos os valores apresentados na Tabela 2.1. Assim, é possível fazer a correspondência entre a condutividade da solução poluente com o nível de poluição na superfície do isolador.

Tabela 2.1 – Valores equivalentes do grau de poluição artificial do isolador (baseado na DDSE) e condutividade elétrica, considerando o caulim como material inerte.

DDSE (mg/cm ²)	Condutividade elétrica da solução (mS/cm)
0,012	5
0,018	7
0,025	10
0,035	14
0,050	20
0,070	28
0,100	40
0,140	56
0,200	80
0,280	112
0,400	160

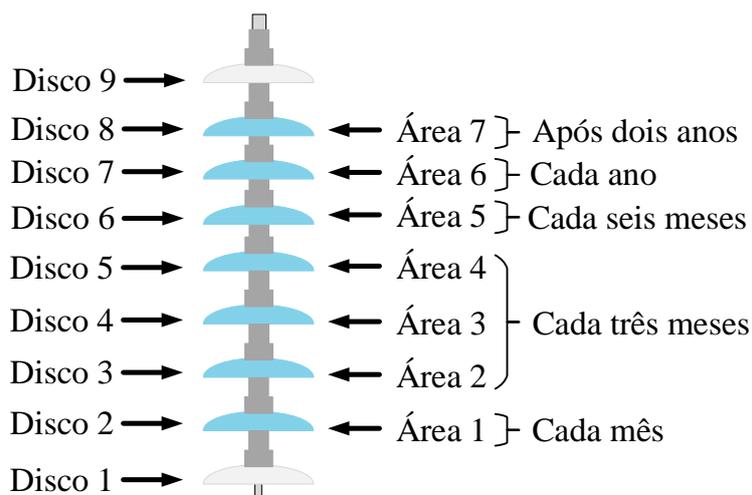
Fonte: adaptado de IEC 60507 (2013).

2.2.3 EXPERIMENTO DE COLETA DE POLUIÇÃO

A seleção adequada de isoladores para sistemas elétricos depende de uma análise criteriosa dos requisitos do sistema e das condições ambientais, incluindo a severidade local da poluição. Para estimar essa severidade, é necessário realizar medições da DDSE e DDNS, que ajudam a caracterizar o nível de poluição local e determinam os valores mínimos de distância de escoamento dos isoladores. Esse processo requer um período mínimo de um ano para garantir que sejam capturadas as variações sazonais e climáticas que podem influenciar a severidade da poluição na região em estudo.

Recomenda-se que a cadeia seja composta por nove isoladores de vidro temperado do tipo suspensão, desenergizada e posicionada em uma altura próxima aos isoladores da linha ou do barramento, conforme as necessidades das análises. A coleta de poluição para medição da DDSE e DDNS deve seguir os procedimentos determinados na norma IEC 60815-1 (2008), sendo realizada em regiões específicas da cadeia de isoladores e em intervalos de tempo predefinidos, de acordo análises desejadas. A norma exemplifica o procedimento com uma cadeia de nove (9) isoladores, conforme apresentado na Figura 2.11, sendo os isoladores marcados como 1 e 9 adotados apenas como suportes e os

Figura 2.11 – Disposição dos isoladores para experimento de coleta de poluição (DDSE e DDNS).



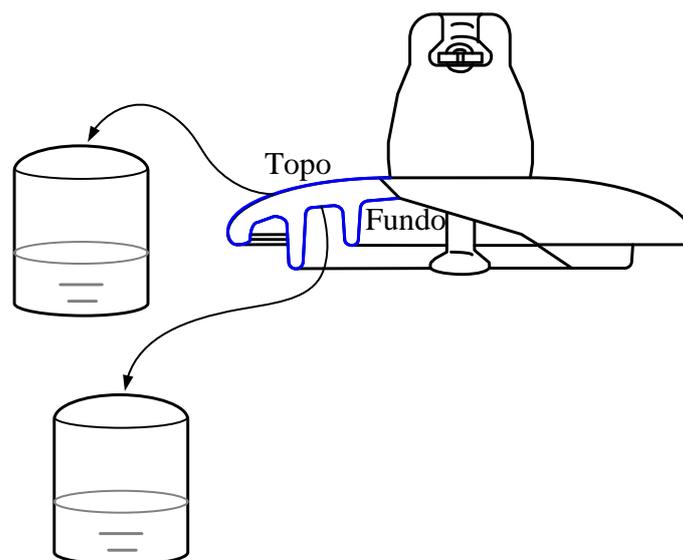
Fonte: adaptado de IEC 60815-1 (2008).

demais utilizados para coleta da poluição superficial. Nesse contexto, o isolador 2 é destinado para coleta mensal; os isoladores 3, 4 e 5 são para coleta trimestral; o isolador 6 para coleta semestral; o isolador 7 para coleta anual; e o isolador 8 para coleta a cada 2 anos.

A coleta da poluição nos intervalos e regiões indicados na Figura 2.11 pode ser realizada diretamente na cadeia suspensa ou com a remoção do isolador a ser monitorado, sempre evitando o contato com a superfície do isolador para prevenir perda de poluição, utilizando luvas cirúrgicas limpas. A coleta deve ser realizada separadamente nas partes superior e inferior do isolador, empregando 300 ml de água destilada ou desmineralizada para cada parte. Os poluentes são removidos da superfície, excluindo ferragens e materiais de montagem, esfregando-se algodão que, após ser impregnado com o líquido, será espremido e colocado no recipiente etiquetado. Os poluentes serão dissolvidos na água, espremendo e agitando o algodão no líquido.

O algodão deve ser esfregado nas superfícies do isolador até que todos os poluentes sejam removidos. Se, após várias tentativas, o poluente permanecer aderido à superfície, ele deve ser retirado com uma espátula e colocado na água dentro do recipiente etiquetado. O operador deve ter cuidado para evitar a perda de volume de água durante a medição, garantindo que a quantidade de água não varie significativamente antes e após a coleta dos poluentes. O procedimento para a remoção dos poluentes das superfícies dos isoladores está ilustrado na Figura 2.12, sabendo que a coleta deve ser realizada contemplando toda a superfície superior e inferior.

Figura 2.12 – Retirada de poluentes da superfície de isoladores.



Fonte: adaptado de IEC 60815-1 (2008).

Após a coleta das amostras de poluição, procede-se com as medições da DDSE e DDNS, conforme os procedimentos normativos supracitados, de modo a caracterizar a severidade da poluição na área estudada. Essas medições permitem obter dados representativos do nível de deposição de poluentes sobre os isoladores, contribuindo para uma análise detalhada da severidade local e para a determinação dos valores mínimos de distância de escoamento adequados ao ambiente. A aplicação criteriosa desses procedimentos assegura que os dados obtidos reflitam as condições reais da instalação, orientando a escolha e o dimensionamento dos isoladores de forma adequada e conforme as necessidades específicas do sistema elétrico.

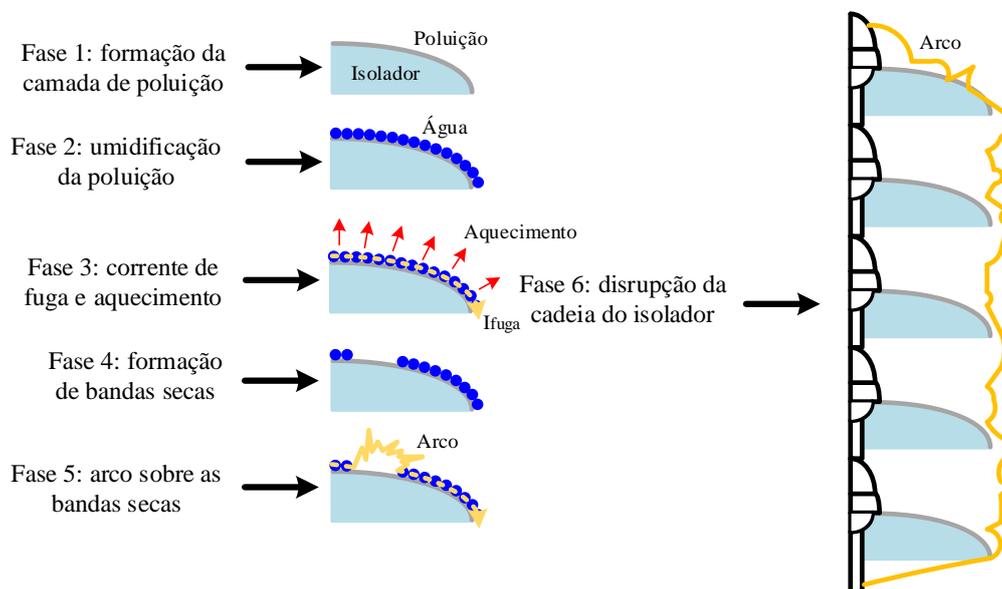
2.3 DESCARGAS EM ISOLADORES DE VIDRO

A ocorrência de descargas em isoladores depende de vários fatores, sendo os mais recorrentes: tipo e nível de poluição superficial; presença de umidade relativa elevada (acima de 90%); esforços mecânicos; e envelhecimento do vidro temperado (ZELLER, 1987; IEC 60815-1, 2008; CHERNEY *et al.*, 2015; LIU *et al.*, 2021). Os diferentes tipos de descargas (descargas superficiais e disruptivas) são eventos indesejados, pois podem levar à falha do isolador e comprometer a segurança e o desempenho do sistema elétrico.

As descargas superficiais em isoladores provocam o envelhecimento precoce do isolador e danos permanentes em sua estrutura. Os danos são resultados do fluxo de corrente de fuga no isolador e dos seus efeitos, tais como, por exemplo, aquecimento devido ao efeito Joule, formação de caminhos condutores e processos químicos (ZELLER, 1987). Ademais, as descargas superficiais provocam luz, ruído audível e ozônio, ao passo que originam outros efeitos danosos aos isoladores, como radiação ultravioleta.

Na Figura 2.13, pode ser observada uma ilustração da evolução do processo de descargas na superfície de um isolador de vidro submetido ao efeito da poluição tipo A (com partículas não solúveis) e presença de umidade. A primeira fase do processo de descarga na superfície do isolador com poluição do tipo A é caracterizada por uma superfície poluída e seca. A segunda etapa ocorre quando há umidade na superfície do isolador, podendo ocorrer nessa fase, chuva forte e, conseqüentemente, provocando a lavagem da superfície do isolador, que contribui para a remoção parcial da poluição superficial. E, ainda, devido à precipitação, é possível que ocorra descarga direta por causa do encurtamento da distância entre as saias.

Figura 2.13 – Etapas do processo de descarga no isolador cerâmico.



Fonte: adaptado de Rocha (2019).

Na terceira etapa, o isolador está coberto por uma camada condutiva e devido a isso, ocorre o aumento da corrente de fuga, que provoca aquecimento em determinadas partes da superfície do isolador. Nesse momento, há formação de bandas secas sobre a superfície nas regiões de maior densidade de corrente, por causa da evaporação da umidade em regiões pontuais na superfície, interrompendo o fluxo de corrente nas partes

que existem bandas secas. Assim, o campo elétrico intenso aplicado às bandas secas ultrapassa a rigidez dielétrica do material, provocando uma descarga superficial no isolador. Para a camada de poluição dentro de limites aceitáveis, o surgimento das descargas superficiais acontece de forma isolada, de modo a não causar danos severos ao isolamento da cadeia de isoladores. Entretanto, para camadas de poluição com níveis elevados, combinado com umidade alta, múltiplas bandas secas irão surgir, provocando descargas superficiais em diversas partes da cadeia. Caso os poluentes não forem removidos e a deposição evoluir, pode ocorrer um *flashover* em toda a cadeia de isoladores, como apresentado na Figura 2.14.

Figura 2.14 – Descargas superficiais e disruptivas em cadeias de isoladores de vidro submetidas a condições ambientais adversas (poluição e umidade elevadas).



Fonte: adaptado de Liu *et al.* (2021).

Em alguns casos, é possível que o isolador seja submetido à poluição do tipo B, caracterizada pela presença de névoa condutiva (maresia ou de origem industrial) ou fezes de aves. Quando isso acontece, o depósito sobre a superfície ocorre de forma rápida e centelhamentos surgem. Entretanto, após cerca de 1 h do evento, o isolador retorna à condição anterior quando o evento finaliza. A situação descrita contempla as fases avançadas em relação à poluição do tipo A, começando já na terceira fase e alcançando rapidamente a última fase. Para o caso de dejetos de aves nos isoladores, há a formação de um caminho de elevada condutividade, diminuindo a distância de isolamento e contribuindo para o surgimento de descarga disruptiva.

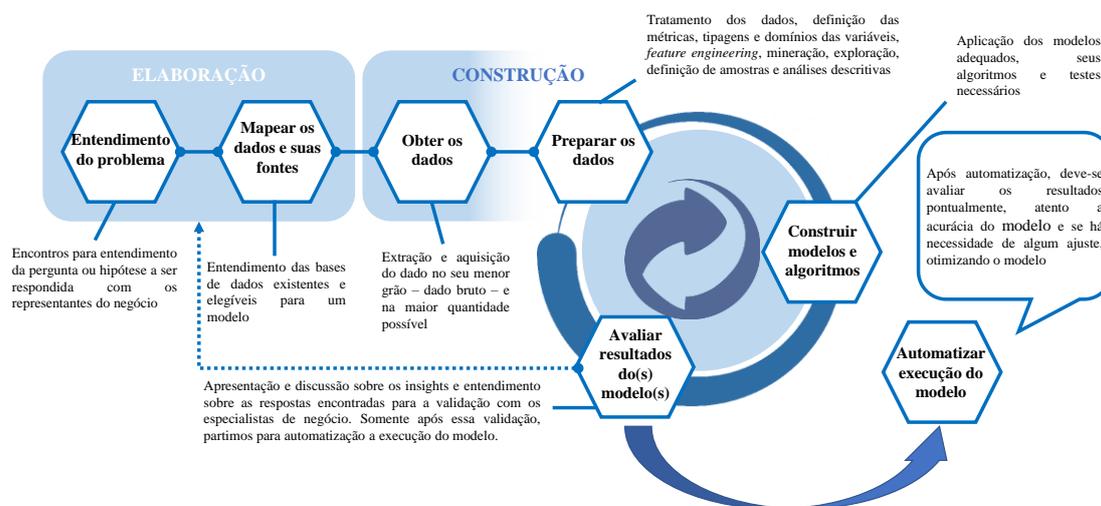
2.4 MINERAÇÃO DE DADOS

Mineração de dados é o processo de extrair informações úteis e conhecimentos relevantes a partir de grandes conjuntos de dados, utilizando técnicas de análise estatística e inteligência artificial (SONG, ZHOU & ZHU, 2013; BISHNU *et al.*, 2019). A finalidade

da mineração de dados é identificar padrões, tendências e relações que possam ser usados para fazer previsões, melhorar a tomada de decisão e a eficiência de processos. Ela pode ser aplicada em diversas áreas, como setor elétrico, *marketing*, finanças, saúde, ciência, entre outras.

O processo de extração de conhecimento a partir de dados segue um fluxo estruturado que guia desde a compreensão do problema até a implementação de modelos inteligentes. Na Figura 2.15, são apresentadas as principais etapas desse fluxo, que incluem a compreensão do negócio e problema, a exploração e preparação dos dados, a modelagem, a avaliação e a implantação. Na indústria, geralmente todas as etapas são realizadas, porém no contexto acadêmico, a implantação/automação não é uma regra, pois diversos trabalhos encerram o fluxo até a etapa de avaliação de resultados. O processo que representa todo o fluxo é conhecido como CRISP-DM (*Cross Industry Standard Process for Data Mining*), um dos *frameworks* mais utilizados para projetos de mineração de dados e aprendizado de máquina (WIRTH; HIPPE, 2000).

Figura 2.15 – Transformação dos dados em conhecimento com base no *framework* CRISP-DM.



Fonte: adaptado de Wirth & Hipp (2000).

Na compreensão do negócio, define-se o objetivo do projeto de mineração de dados com base nas necessidades e desafios da organização ou clientes da área de negócio. É essencial compreender o problema a ser resolvido e identificar as métricas de sucesso, garantindo que a solução proposta tenha impacto real. Isso envolve reuniões com stakeholders, análise do contexto e levantamento das restrições do projeto.

Após definir o objetivo, realiza-se a seleção/coleta inicial dos dados disponíveis. A seleção deve ser cuidadosa para garantir que os dados selecionados sejam relevantes e representativos o suficiente para os objetivos da análise. Para a seleção dos dados, é

necessário definir os objetivos que devem ser alcançados com a mineração de dados. Os dados selecionados devem apresentar qualidade satisfatória para o projeto em desenvolvimento, considerando aspectos como completude, consistência, singularidade e aplicabilidade.

A preparação de dados, ou pré-processamento de dados, é uma das etapas fundamentais na mineração de dados. Essa etapa consiste em tratar os dados brutos, tornando-os adequados para a análise, removendo erros, inconsistências e dados duplicados, além de tratar valores faltantes. A preparação de dados é importante porque a qualidade dos dados é essencial para que as análises e modelos gerados sejam confiáveis e representativos. Se os dados não forem tratados adequadamente, as análises realizadas podem levar a conclusões errôneas ou enviesadas. Nesse sentido, realiza-se também a transformação de dados, que envolve a modificação dos dados brutos e permite a sua análise e interpretação de forma sistêmica, possibilitando o desenvolvimento de modelos de aprendizado de máquina (*machine learning*). A transformação de dados pode incluir várias técnicas diferentes, como redução de dimensionalidade, padronização e normalização de dados.

Para ajudar a compreender a estrutura, distribuição e características dos dados, geralmente é realizada a análise exploratória dos dados (EDA, do inglês *Exploratory Data Analysis*) antes da modelagem. Durante essa fase, é essencial selecionar os atributos mais relevantes, o que ajuda a reduzir a complexidade do modelo e melhora o seu desempenho. Essa seleção é baseada em critérios estatísticos que analisam a relação entre as variáveis (variáveis explicativas e variável resposta), como coeficientes de correlação – Pearson para correlações lineares, Spearman para associações monotônicas e Kendall para relações não lineares. Esses coeficientes fornecem *insights* sobre a força e a direção da relação entre variáveis, permitindo priorizar atributos que são mais relevantes para prever o alvo do modelo.

O coeficiente de correlação de Pearson, r_p , possibilita quantificar a força e a direção da relação linear entre duas variáveis. O valor de r_p varia de -1 a 1, em que $r_p = 1$ indica uma correlação positiva perfeita; $r_p = -1$ indica uma correlação negativa perfeita, e $r_p = 0$ indica ausência de correlação linear. Esse coeficiente é definido em (2.6).

$$r_p = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}, \quad (2.6)$$

x_i e y_i são os valores das duas variáveis; \bar{x} e \bar{y} são as médias das variáveis x e y ; e n é o número de observações. A correlação pode ser classificada de acordo com a Tabela 2.2 (MONTGOMERY & RUNGER, 2018; LOPES, 2016).

Tabela 2.2 – Classificação do nível de correlação com base no coeficiente de correlação.

Correlação	Coeficiente
Perfeita negativa	$r_p = -1$
Negativa	$-1 < r_p < 0$
Nula	$r_p = 0$
Positiva	$0 < r_p < 1$
Perfeita positiva	$r_p = 1$
Muito fraca*	$0 < r_p < 0,19$
Fraca*	$0,2 < r_p < 0,39$
Moderada*	$0,4 < r_p < 0,69$
Forte*	$0,7 \leq r_p \leq 0,89$
Muito forte*	$0,9 \leq r_p < 1$

*Possui o mesmo significado para os casos negativos ou positivos.

Fonte: adaptado de Montgomery & Runger (2018).

O coeficiente de Spearman, r_s , mede a relação monotônica entre duas variáveis, ou seja, se uma variável aumenta ou diminui consistentemente com a outra. Diferente do coeficiente de correlação de Pearson, o coeficiente de Spearman é uma correlação não paramétrica (não faz pressupostos sobre a distribuição dos dados ou sobre a relação entre as variáveis serem lineares) e pode capturar relações que não sejam necessariamente lineares, desde que sejam monotônicas. Uma correlação monotônica descreve uma relação entre duas variáveis em que, à medida que uma aumenta ou diminui, a outra sempre se move em uma única direção (aumenta ou diminui), mas não necessariamente de forma constante ou linear. Esse coeficiente é calculado com base nas posições (ou *rankings*) dos dados em vez de seus valores originais. O cálculo de r_s envolve duas etapas principais: o ranqueamento dos dados e o cálculo da correlação das posições (ou *ranks*). Para cada variável, substitui-se os valores originais pelas posições desses valores na lista ordenada. Se houver valores iguais (empates), atribui-se a média das posições que esses valores ocupariam. Se não houver empates nas posições, usa-se (2.7) para calcular r_s . Quando há empates, calcula-se r_s como a correlação de Pearson entre as posições das duas variáveis.

$$r_s = 1 - \frac{6 \cdot \sum_{i=1}^n d_i^2}{n \cdot (n^2 - 1)}, \quad (2.7)$$

n é o número de pares de dados; d_i é a diferença entre os *ranks* de cada par de dados (para cada i , $d_i = Rank(x_i) - Rank(y_i)$). O valor de r_s varia de -1 a 1, em que $r_s = 1$ indica uma correlação monotônica positiva perfeita (quando uma variável aumenta, a outra

também aumenta de forma consistente); $r_S = -1$ uma correlação monotônica negativa perfeita (quando uma variável aumenta, a outra diminui de forma consistente); e $r_S = 0$ indica ausência de correlação monotônica.

O coeficiente de Kendall, r_K , é uma medida não paramétrica de associação entre duas variáveis ordinais, usada para avaliar a concordância entre os *ranks* dessas variáveis. Assim como o coeficiente de Spearman, o coeficiente r_K é utilizado para medir relações monotônicas, mas é calculado com base nas concordâncias e discordâncias entre pares de observações, oferecendo uma interpretação ligeiramente diferente. Para calcular o coeficiente de Kendall, considera-se todos os pares possíveis de observações (x_i, y_i) e (x_j, y_j) com $i \neq j$, e podem ser classificados em concordantes ou discordantes. Um par é concordante se, ao comparar duas observações, ambas as variáveis aumentam ou ambas diminuem, ou seja, se $(x_i - x_j) \cdot (y_i - y_j) > 0$. Um par é discordante se uma das variáveis aumenta enquanto a outra diminui, ou seja, se $(x_i - x_j) \cdot (y_i - y_j) < 0$. Se os valores de uma ou ambas as variáveis são iguais para o par (i, j) , o par é considerado empatado e não é incluído na contagem. A definição matemática de r_K é apresentada em (2.8).

$$r_K = \frac{N_c - N_d}{\frac{n(n-1)}{2}}, \quad (2.8)$$

em que N_c é o número de pares concordantes; N_d é o número de pares discordantes; e n é o número total de observações. Alternativamente, em casos de empates, o coeficiente r_K pode ser ajustado para levar em conta os empates nas duas variáveis. O valor de r_K varia de -1 a 1, em que $r_K = 1$ indica uma concordância perfeita, em que todas as variáveis aumentam ou diminuem juntas; $r_K = -1$ uma discordância perfeita, onde, ao comparar pares, uma variável aumenta enquanto a outra diminui em todos os casos; e $r_K = 0$ indica ausência de correlação monotônica.

A inteligência artificial é uma área da ciência da computação dedicada ao desenvolvimento de sistemas e/ou algoritmos que podem realizar tarefas que normalmente requerem inteligência humana, como percepção, aprendizado, raciocínio e tomada de decisão. Dentro dessa área, o aprendizado de máquina (*machine learning*) se destaca como um campo em que algoritmos são treinados para identificar padrões e fazer previsões a partir de dados. No aprendizado supervisionado, o algoritmo recebe um conjunto de dados rotulado, ou seja, dados para os quais já se conhecem os resultados desejados. Isso permite que o modelo aprenda a associar entradas às saídas específicas e, assim, faça previsões ou classificações sobre novos dados com base nesses padrões

conhecidos. Em contraste, o aprendizado não supervisionado trabalha com dados não rotulados, buscando identificar estruturas ou agrupamentos intrínsecos nos dados sem nenhuma orientação prévia. Esse tipo de aprendizado é útil para explorar e descobrir padrões ocultos nos dados, especialmente em casos onde não há uma resposta previamente definida.

A modelagem envolve a seleção e aplicação de diferentes métodos estatísticos e algoritmos de inteligência artificial (e.g., aprendizado de máquina, aprendizado profundo, processamento de linguagem natural etc.) para extrair informações úteis dos dados. Na modelagem, torna-se necessário que os dados estejam em um formato adequado para aplicação dos algoritmos. Após a realização do tratamento dos dados, deve ser criado um modelo preditivo ou descritivo adaptado a fazer previsões, classificar novos dados ou entender melhor os padrões presentes nos dados. Os modelos são construídos a partir de um conjunto de dados de treinamento, que é usado para configurar os hiperparâmetros do modelo de modo a minimizar o erro, adotando métodos para evitar o sobreajuste (*overfitting*). Os modelos de *machine learning* são exemplos que podem ser citados, os quais possuem vários hiperparâmetros que precisam ser ajustados para o funcionamento satisfatório, de acordo com a necessidade do negócio. Uma vez que o modelo tenha sido desenvolvido, ele deve ser avaliado para determinar a qualidade do seu desempenho. Para tanto, usa-se um conjunto de dados de teste, que é separado do conjunto de dados de treinamento e usado para avaliar o desempenho do modelo diante de dados desconhecidos.

A busca por hiperparâmetros é uma etapa crucial no treinamento de modelos de *machine learning* e *deep learning*, pois os hiperparâmetros influenciam significativamente o desempenho do modelo. Dentre os métodos existentes (*random search*, *grid search*, *bayesian optimization*, algoritmos genéticos etc.), o *grid search* vem sendo largamente aplicado (HAYKIN, 2008; GÉRON, 2019). O *grid search* é uma técnica sistemática para a busca de hiperparâmetros em modelos de aprendizado de máquina. Ela funciona ao definir um conjunto de valores possíveis para cada hiperparâmetro e, em seguida, gerar todas as combinações possíveis entre eles, formando uma grade (*grid*). Cada configuração é avaliada de forma independente, geralmente utilizando validação cruzada, para determinar seu desempenho no modelo.

Para identificar e controlar o *overfitting* em modelos de *machine learning* e *deep learning*, diversos métodos podem ser utilizados (HAYKIN, 2008; GÉRON, 2019). A validação cruzada (*cross-validation*) é uma técnica que divide os dados em várias

partições (*folds*), avaliando o modelo em cada uma delas e ajudando a verificar se o desempenho é consistente, o que reduz o risco de ajuste excessivo a um conjunto específico. Comparar o erro de treinamento com o de validação/teste também é útil: uma diferença significativa entre esses erros sugere que o modelo está capturando características específicas do conjunto de treinamento. Avaliar o modelo em um conjunto de teste independente é essencial para garantir que ele generalize bem em dados novos. Além disso, técnicas de regularização como L_1 e L_2 adicionam penalidades para reduzir a complexidade, enquanto o *early stopping* interrompe o treinamento assim que o erro de validação começa a aumentar, evitando o *overfitting*. As curvas de aprendizado (*learning curves*) permitem monitorar o erro de treinamento e de validação ao longo das épocas; um aumento no erro de validação enquanto o erro de treinamento diminui indica um possível sobreajuste. Para redes neurais, o *dropout* (com redes neurais artificiais) desativa neurônios aleatórios durante o treinamento, dificultando que o modelo dependa excessivamente de neurônios específicos e promovendo uma aprendizagem mais robusta e generalizável. Essas abordagens ajudam a monitorar e otimizar o modelo para que ele generalize bem, mesmo diante de novos dados.

Uma vez que o *overfitting* seja mitigado, a avaliação do desempenho do modelo na fase de teste é essencial para garantir que ele generalize bem para novos dados. Nessa etapa, o modelo treinado é aplicado a um conjunto de teste independente, que não foi utilizado no treinamento. O objetivo é verificar se os padrões aprendidos durante o treinamento se mantêm em dados ainda não apresentados ao modelo. O desempenho do modelo pode ser avaliado por meio de métricas estatísticas.

Diferentes métricas de desempenho podem ser adotadas a depender do problema (GÉRON, 2019). Para problemas de classificação, as métricas mais usadas são: precisão (*precision*), revocação (*recall*), *f1-score*, seguindo as definições apresentadas em (2.9), (2.10) e (2.11). Para abordagens de regressão (previsão), é comum a utilização do Erro Médio Absoluto (MAE, do inglês *Mean Absolute Error*), Raiz Quadrada do Erro Médio (RMSE, do inglês *Root Mean Squared Error*), Média Percentual Absoluta do Erro (MAPE, do inglês *Mean Absolute Percentage Error*) e coeficiente de determinação, considerando as definições apresentadas (2.12), (2.13), (2.14) e (2.15). E para problemas de agrupamentos (*clustering*), normalmente é utilizado o coeficiente Silhouette para mensurar a qualidade dos agrupamentos realizados, com a definição matemática apresentada em (2.16).

$$precisão = \frac{verdaderos\ positivos\ (TP)}{verdaderos\ positivos\ (TP) + falsos\ positivos\ (FP)}, \quad (2.9)$$

$$revocação = \frac{verdaderos\ positivos\ (TP)}{verdaderos\ positivos\ (TP) + falsos\ negativos\ (FN)}, \quad (2.10)$$

$$f1 - score = 2 \cdot \frac{precisão \cdot revocação}{precisão + revocação}, \quad (2.11)$$

em que a precisão quantifica a proporção de previsões positivas corretas entre todas as previsões positivas. É especialmente útil em casos onde o custo de falsos positivos é alto. A revocação indica a proporção de instâncias verdadeiramente positivas que foram corretamente identificadas pelo modelo. É relevante quando o custo de falsos negativos é alto. A métrica *f1-score* é a média harmônica entre precisão e revocação, sendo útil quando é importante equilibrar ambas as métricas.

$$MAE = \frac{1}{n} \cdot \sum_{i=1}^n |\hat{y}_i - y_i|, \quad (2.12)$$

$$MAPE = \frac{1}{n} \cdot \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \cdot 100\%, \quad (2.13)$$

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}}, \quad (2.14)$$

$$R^2 = 1 - \frac{SSE}{SST},$$

$$SSE = \sum_{i=1}^n (\hat{y}_i - y_i)^2, \quad (2.15)$$

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2,$$

em que n representa o número dos valores para treinamento e teste, y_i representa os valores medidos e \hat{y}_i refere-se aos valores estimados pelo modelo para treinamento ou/e teste. SSE é a soma dos erros quadráticos, que representa a variação total do que não foi possível se ajustar aos valores medidos, e SST representa a soma total dos quadrados, que consiste na variação total de y_i em relação à sua média.

$$Silhouette = \frac{a-b}{\max(a,b)}, \quad (2.16)$$

em que a é a média da distância entre a amostra e todas as outras amostras do mesmo cluster e b é a média da distância entre a amostra e todas as amostras do grupo (*cluster*) mais próximo. O coeficiente Silhouette avalia a qualidade dos grupos formados, medindo a proximidade entre as amostras dentro do mesmo grupo e a distância entre os grupos. O valor varia de -1 a 1; quanto maior, melhor a definição dos grupos.

Como forma de interpretação do MAE, MAPE e RMSE, quanto menor o valor do erro, mais confiáveis são as previsões do modelo, sendo o RMSE caracterizado como uma métrica que penaliza os maiores erros. Geralmente é utilizado a Tabela 2.3 como

referência para classificar o desempenho do modelo em função do valor obtido do MAPE (SLAMA *et al.*, 2022). O coeficiente de determinação comumente é usado para avaliar a qualidade do ajuste do modelo em relação aos valores medidos que são destinados para treinamento. A faixa de variação possível do R^2 geralmente é definida por (2.17), sabendo que quanto maior o valor desse coeficiente, melhor é o ajuste do modelo aos dados.

$$0 \leq R^2 \leq 1. \quad (2.17)$$

Tabela 2.3 – Classificação do MAPE.

MAPE	Acurácia
$MAPE \leq 10$	Muito alta
$10 < MAPE \leq 20$	Alta
$20 < MAPE \leq 50$	Média
$MAPE > 50$	Baixa

Fonte: adaptado de Slama *et al.* (2022).

2.5 SÉRIES TEMPORAIS

Em diversas áreas, como estatística, matemática aplicada e processamento de sinais, uma série temporal é composta por observações sequenciais de um fenômeno ou variável ao longo do tempo (HYNDMAN & ATHANASOPOULOS, 2018). Para analisar esse conjunto de dados, são aplicados conceitos e modelos estatísticos que vão desde abordagens clássicas até técnicas avançadas baseadas em inteligência artificial, como aprendizado de máquina e redes neurais artificiais, visando modelar e compreender a dependência entre os dados que compõem a série (HYNDMAN & ATHANASOPOULOS, 2018; NIELSEN, 2019).

As séries temporais podem ser divididas em discretas e contínuas (MORETTIN & TOLOI, 2006). Uma série discreta ocorre quando as observações são feitas em instantes específicos no tempo, normalmente espaçadas por intervalos constantes durante um período definido. Já uma série contínua é associada a uma variável contínua, que pode assumir um número infinito de valores dentro de um intervalo, permitindo registrar medições que variam de maneira ininterrupta ao longo do tempo.

A modelagem de séries temporais visa identificar o modelo que melhor se ajusta aos dados observados, possibilitando a realização de previsões. A análise dessas séries

pode ser conduzida em dois domínios distintos: o domínio do tempo (análise temporal) e o domínio da frequência (análise espectral) (MORETTIN & TOLOI, 2006).

Na análise temporal, o foco reside na observação da magnitude do fenômeno em momentos específicos e nas relações de dependência entre as observações que se sucedem no tempo. Em abordagens estatísticas clássicas, a Função de Autocorrelação (FAC) é uma ferramenta fundamental para investigar essas relações. Em contraste, a análise no domínio da frequência busca identificar as frequências características que compõem a série temporal e que podem estar associadas a eventos específicos. Para facilitar essa análise espectral, a Transformada Rápida de Fourier (FFT, do inglês *Fast Fourier Transform*) é uma técnica amplamente empregada.

A análise clássica de séries temporais, de forma resumida, consiste em decompor a série em três componentes principais: tendência, sazonalidade e aleatória (também chamada de irregular ou residual) (METCALFE & COWPERTWAIT, 2009; HYNDMAN & ATHANASOPOULOS, 2018; MILLS, 2019). A definição matemática que representa a série, considerando a análise clássica, é expressa em (2.18). Na Figura 2.16 é apresentado um exemplo de série temporal em conjunto com as suas três componentes.

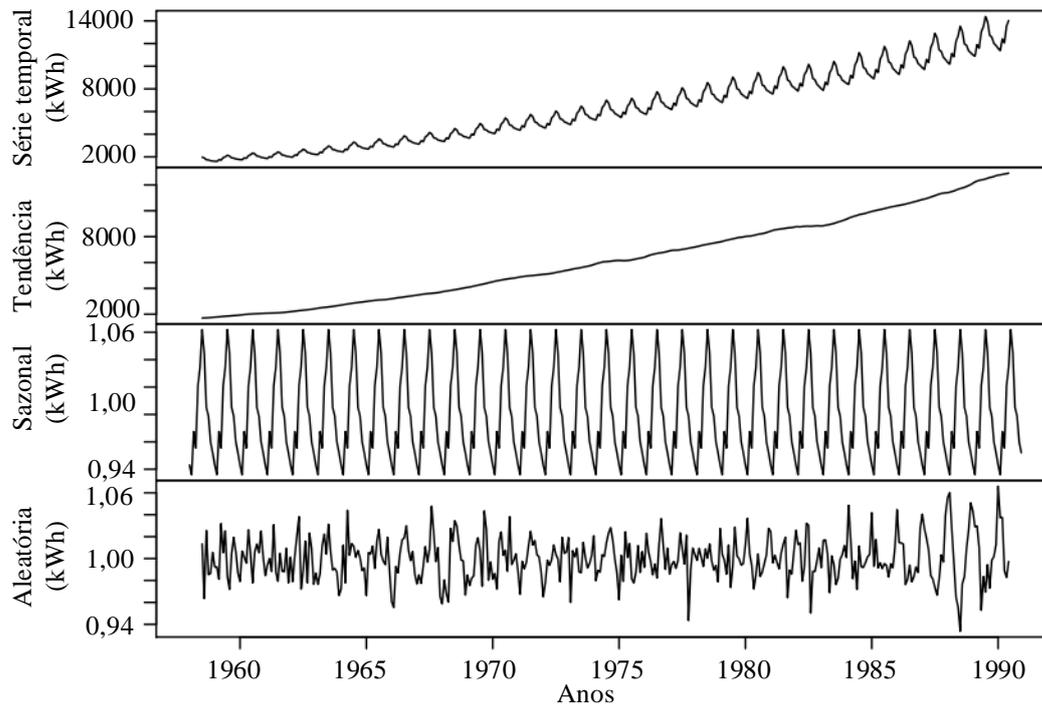
$$Y_t = T_t + S_t + A_t, \quad (2.18)$$

em que Y_t é a série temporal, T_t é a componente de tendência, S_t é a componente sazonal e A_t é a componente aleatória.

Com relação a cada uma dessas componentes, a tendência é a componente da série que descreve se ela é crescente ou decrescente. A determinação dessa componente pode ser realizada como o ajuste de uma função do tempo, como um polinômio, uma exponencial ou outra função suave do tempo (MORETTIN & TOLOI, 2006). Além disso, também é possível determinar a componente de tendência por meio da filtragem dos valores da série ao redor de um ponto, para estimar a tendência nesse ponto. E também é realizado a suavização dos valores da série por meio de sucessivos ajustes de retas usando mínimos quadrados ponderados, como outra forma de determinar a tendência da série.

Outra componente importante na constituição da série temporal é a componente sazonal. Essa componente descreve a característica periódica da série. Para determinação dessa componente, utiliza-se (2.19), dado que a série possui período $N = 2q + 1$, se N for ímpar, ou $N = 2q$, se N for par, e o número de observações da série é dado por n , enquanto q representa um contador numérico, iniciando de zero até o número de observações (BROCKWELL & DAVIS, 2002).

Figura 2.16 – Série temporal referente aos valores de produção de energia elétrica e suas componentes de tendência, sazonal e aleatória.



Fonte: Adaptada de Metcalfe & Cowpertwait (2009).

Outra componente importante na constituição da série temporal é a componente sazonal. Essa componente descreve a característica periódica da série. Para determinação dessa componente, utiliza-se (2.19), dado que a série possui período $N = 2q + 1$, se N for ímpar, ou $N = 2q$, se N for par, e o número de observações da série é dado por n , enquanto q representa um contador numérico, iniciando de zero até o número de observações (BROCKWELL & DAVIS, 2002).

$$S_k = w_k - \frac{1}{N} \cdot \sum_{i=1}^N w_i, \quad k = 1, \dots, N, \quad (2.19)$$

em que, para cada índice k , w_k é a média dos desvios, calculados por meio de (2.20).

$$w_k = \frac{1}{m} (Y_{k+jN} - T_{k+jN}), \quad q < k + jN \leq n - q, \quad (2.20)$$

sabendo que Y_{k+jN} é a série temporal observada, T_{k+jN} é a tendência associada à mesma fase sazonal, e o somatório é realizado para todas as ocorrências da posição k dentro do período N . A quantidade de termos m no somatório depende da quantidade de observações disponíveis que atendem à condição $q < k + jN \leq n - q$. Com isso, S_k é obtido ao remover a média dos valores de w_k , conforme dado em (2.19), garantindo que a componente sazonal tenha média zero.

No tocante à componente aleatória, A_t , sua determinação é realizada por meio da subtração entre as componentes T_t e S_t da série original, conforme expresso em (2.21) (MILLS, 2019). Devido à característica aleatória de A_t , supõe-se que ela seja um processo estocástico, com média zero e variância constante (HYNDMAN & ATHANASOPOULOS, 2018).

$$A_t = Y_t - T_t - S_t. \quad (2.21)$$

2.5.1 PREPARAÇÃO DOS DADOS COM *SLIDING WINDOW* (JANELA DESLIZANTE)

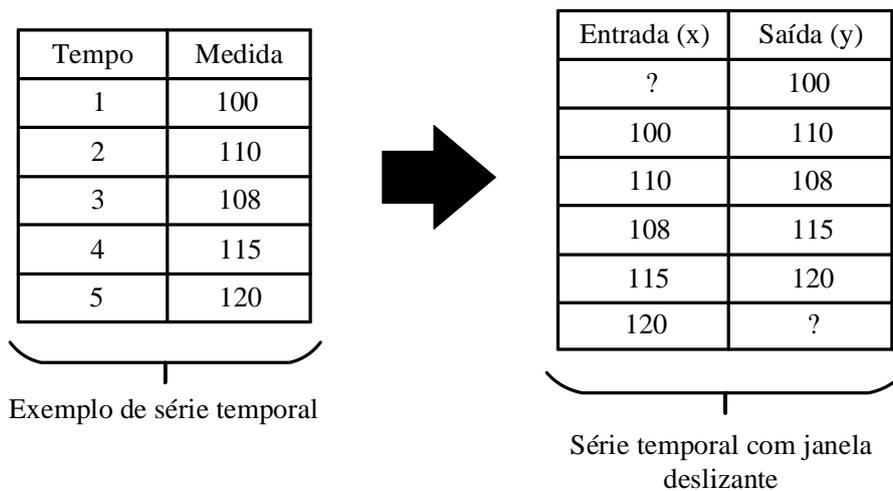
Na aplicação de modelos de aprendizado de máquina à análise de séries temporais, a preparação dos dados desempenha um papel essencial para o sucesso da modelagem. Esse processo envolve diversos aspectos, desde a formatação dos conjuntos temporais até o uso adequado de janelas temporais e a adaptação dos dados para capturar a dependência temporal (BOX *et al.*, 2015; MARTINS, 2024). Compreender essas etapas de preparação é fundamental para explorar todo o potencial dos modelos de previsão, estabelecendo uma base sólida para as próximas fases de desenvolvimento e fornecendo *insights* valiosos sobre a manipulação dos dados e a maximização do desempenho dos modelos.

Nas aplicações de aprendizado de máquina supervisionado, para o caso univariado, variáveis de entrada são utilizadas para identificar padrões da variável de saída. O objetivo é aproximar esse mapeamento real subjacente de forma que, ao receber novos dados de entrada, seja possível prever a variável de saída correspondente a esses dados.

A modelagem com aprendizagem supervisionada consiste em um processo de treinamento no qual o algoritmo realiza previsões iterativas, ajustando seus parâmetros para otimizar uma função objetivo a partir de dados rotulados. O treinamento continua até que o modelo atinja um nível satisfatório de desempenho. Esse tipo de aprendizado divide-se em problemas de classificação (a variável de saída é uma categoria, como, por exemplo, o nível de poluição), e de regressão (a saída é um valor real, como o valor da amplitude da corrente de fuga). Na aplicação de aprendizado de máquina em séries temporais, é necessário adaptar a estrutura dos dados para que o problema se enquadre em regressão ou classificação. Esse processo busca organizar os dados de forma que o modelo consiga capturar padrões temporais (NIELSEN, 2019; MARTINS, 2024).

A previsão de séries temporais pode ser tratada como um problema de aprendizado supervisionado. Com uma sequência temporal de dados, é possível reorganizá-la para atender a essa abordagem, utilizando dados passados como variáveis de entrada (*input*) e dados consecutivos como variável de saída (*output*). Assim, o conjunto de dados apresentado na Figura 2.17 pode ser reestruturado para prever o valor consecutivo no tempo com base no valor da etapa anterior. A disposição dos dados reestruturados para esse fim também é ilustrada na mesma figura, utilizando o conceito de janela deslizante.

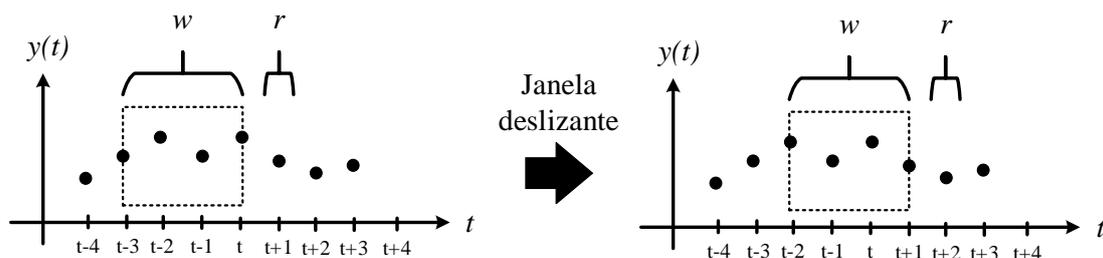
Figura 2.17 – Aplicação do conceito de janela deslizante em uma série temporal.



Fonte: adaptado de Martins (2024).

Com o intuito ainda de ilustrar o conceito de janela deslizante, na Figura 2.18 é apresentado o procedimento da janela deslizante com uma janela de tamanho w fixa, definida como 4. Isso significa que o modelo usará as informações contidas nessas janelas para fazer previsões no instante $t + 1$. Neste exemplo, adota-se $r = 1$ para simplificar a visualização, o que configura o modelo para prever apenas uma etapa à frente em $t + 1$, em vez de múltiplas etapas futuras (como $t + 2$, $t + 3$ etc.), focando exclusivamente no próximo ponto após a janela de entrada.

Figura 2.18 – Ilustração do funcionamento da janela deslizante em uma série temporal.



Fonte: adaptado de Martins (2024).

Ao ajustar o conjunto de dados de séries temporais aplicando o conceito de janela deslizante, observam-se algumas características: a etapa anterior torna-se a entrada x e a próxima etapa, a saída y , configurando o problema como uma análise de aprendizado supervisionado; a ordem entre as observações é mantida e deve ser preservada durante o treinamento do modelo. O primeiro valor da sequência geralmente é descartado, pois não há valores anteriores para usá-lo na previsão; e, da mesma forma, o último valor é excluído do treinamento supervisionado, pois não possui um próximo valor conhecido para ser previsto.

O método da janela deslizante, ou método de latência, transforma séries temporais em problemas de aprendizado supervisionado ao utilizar etapas anteriores (histórico de dado), conhecidas como largura da janela ou tamanho do atraso (NIELSEN, 2019; MARTINS, 2024). Essa abordagem permite converter a previsão de séries temporais em um problema de regressão, por exemplo, possibilitando o uso de algoritmos de aprendizado de máquina, desde que a ordem das linhas seja preservada. A técnica é expansível para incluir mais histórico de dados e também pode ser aplicada em séries temporais multivariadas, quando se deseja prever os valores de uma saída, y , em função de dados históricos considerando mais de um tipo de informação/atributo.

Devido à dependência temporal nas séries, os valores passados influenciam diretamente os futuros. Para prever o valor em um instante t , utiliza-se uma janela de valores imediatamente anteriores (*lags*), que possui maior autocorrelação com o ponto previsto e reduz o tempo de treinamento. Na ilustração da Figura 2.18 é considerado o uso de 4 *lags* para prever o próximo instante, reestruturando a sequência em pares de entrada e saída (x, y), onde x representa os valores passados e y o valor a ser previsto.

2.6 MODELOS DE PREVISÃO BASEADOS EM INTELIGÊNCIA ARTIFICIAL

A modelagem possui como intuito principal descrever a dinâmica da variável resposta dos dados (e.g., sinal eletromagnético) e realizar previsões, buscando minimizar os erros entre os valores estimados e os observados. Para que essa modelagem seja realizada, comumente é necessário especificar uma função perda (e.g., MSE - *Mean Squared Error*), além do tipo de modelo de previsão, que pode ser baseado em estatística

ou inteligência artificial (GÉRON, 2019; HYNDMAN & ATHANASOPOULOS, 2018). Para compor essa modelagem, é necessária a utilização de variáveis explicativas do fenômeno que se deseja modelar. As variáveis explicativas selecionadas para a modelagem geralmente possuem uma correlação forte com a variável resposta, a fim de que as variáveis selecionadas possam explicar uma grande parte da variável resposta e, por consequência, a modelagem forneça resultados mais exatos.

Os modelos de previsão baseados em inteligência artificial têm sido amplamente utilizados devido à sua capacidade de adaptação a dados complexos e dinâmicos. Entre os mais aplicados, destacam-se (KO & LEE, 2013; CHEN *et al.*, 2017; HONG, 2018; DHIMAN, DEB & GUERRERO, 2019; KHAN *et al.*, 2019): Redes Neurais Artificiais (ANN, do inglês *Artificial Neural Networking*), Máquina de Vetores de Suporte (SVM, do inglês *Support Vector Machine*), Árvore de Decisão (DT, do inglês *Decision Tree*), Floresta Aleatória (RF, do inglês *Random Forest*), Impulso Extremo do Gradiente (XGBoost, do inglês *Extreme Gradient Boosting*), Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS, do inglês *Adaptive Neuro-Fuzzy Inference System*), Memória Longa de Curto Prazo (LSTM, do inglês *Long Short-Term Memory*) e Algoritmo Genético (GA, do inglês *Genetic Algorithm*). Esses modelos se destacam pela capacidade de aprender padrões complexos e podem ser continuamente realimentados com novos dados, ajustando-se a diferentes cenários. Embora apresentem alta complexidade, sua aplicação é essencial em problemas que exigem flexibilidade e robustez na modelagem.

Os modelos de previsão baseados em ANN, como o Perceptron de Multicamadas (MLP, do inglês *Multilayer Perceptron*), e em Máquinas de Vetores de Suporte (SVM), com sua variante para regressão (SVR, do inglês *Support Vector Regression*), têm sido amplamente empregados devido ao desempenho superior que apresentam no processo de previsão em comparação com outros métodos de inteligência artificial (HAYKIN, 2008; KO & LEE, 2013; CHEN *et al.*, 2017; DHIMAN, DEB & GUERRERO, 2019; POURDARYAEI *et al.*, 2019; GÉRON, 2019; SOPELSA NETO *et al.*, 2021). Esses modelos foram selecionados para serem estudados, implementados, avaliados e comparados, a fim de selecionar o modelo que apresenta o melhor desempenho para auxiliar na modelagem da poluição artificial e possibilitar a previsão do nível crítico de poluição (ocorrência de descargas superficiais) e estimar o momento necessário para essa condição ser alcançada. Para melhor entendimento do funcionamento dos algoritmos mencionados, eles serão descritos de forma mais meticulosa a seguir.

2.6.1 MÁQUINA DE VETORES DE SUPORTE - SVM

O SVM é um algoritmo de aprendizado de máquina que tem como objetivo criar um hiperplano que separe duas classes de padrões, maximizando a margem de separação entre elas (HAYKIN, 2008; GÉRON, 2019). Ou seja, esse algoritmo busca maximizar a distância entre os exemplos mais próximos de cada classe e, assim, garantir uma melhor generalização do modelo para novos dados. Embora a SVM seja aplicada para classificação de dados, ela também é utilizada para resolver problemas de regressão (ou previsão) não linear, empregando a SVM adaptada, passando a ser denominada de Regressão por Vetores de Suporte (SVR, do inglês *Support Vector Regression*). Para adaptar a SVM para se tornar uma SVR, basta reverter o objetivo. Em vez de segmentar ao máximo as duas ou mais classes de interesse, o foco da SVR deve ser tentar preencher com instâncias, o máximo possível, a margem definida pelos vetores de suporte.

Um modelo baseado em SVR busca o menor erro de treinamento por meio do princípio de Minimização do Risco Estrutural (SRM, do inglês *Structural Risk Minimization*) (GÉRON, 2019). Esse princípio reside na minimização de um limite superior para o erro de generalização do modelo de previsão. Nesse sentido, o intuito da SVR é construir uma função, $f(\mathbf{x})$, definida em (2.22), que descreve um hiperplano, com desvio máximo, ε , dos dados de treinamento.

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b, \quad (2.22)$$

em que $f(\mathbf{x})$ é a função que descreve o hiperplano, \mathbf{w} é o vetor de pesos do modelo, \mathbf{x} é o vetor de entrada, T é a transposta e b é denominado de bias.

Como forma de otimizar os resultados obtidos pela SVR, algumas amostras de treinamento são criteriosamente escolhidas para serem denominadas de vetores de suporte, as quais se situam na região de fronteira em duas classes. Para que esses vetores sejam separados de forma ótima, constrói-se um hiperplano. Apresenta-se, na Figura 2.19, um exemplo de hiperplano com separação ótima.

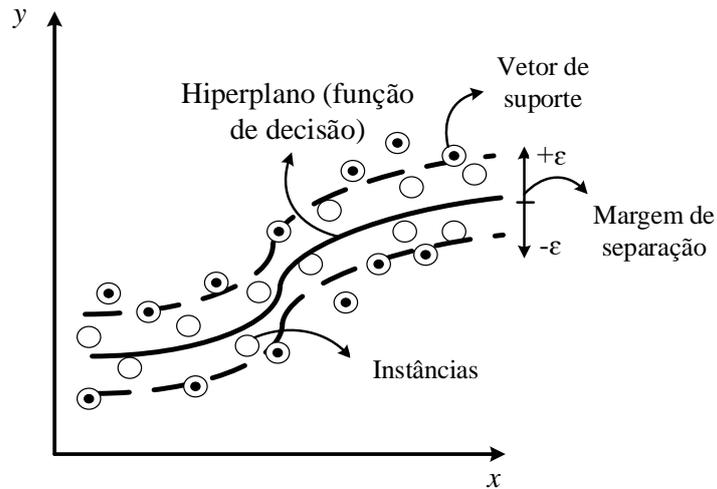
Para generalização do modelo de regressão, $f(\mathbf{x})$, minimiza-se a norma euclidiana de \mathbf{w} , gerando um problema de programação quadrática, em que (2.23) deve ser minimizado, considerando as restrições apresentadas em (2.24) e (2.25).

$$\min \frac{1}{2} \|\mathbf{w}\|^2, \quad (2.23)$$

$$y_i - f(\mathbf{x}_i) \leq \varepsilon, \quad (2.24)$$

$$f(\mathbf{x}_i) - y_i \leq \varepsilon. \quad (2.25)$$

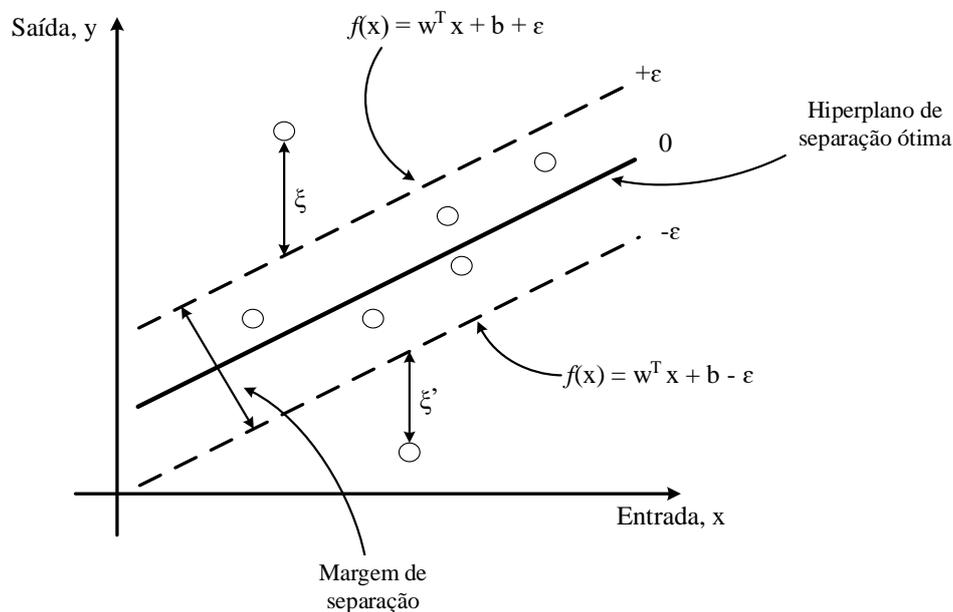
Figura 2.19 – Hiperplano de separação ótima e seus hiperplanos de suporte.



Fonte: adaptada de Haykin (2008).

Para lidar com problemas de ruído nos dados de entrada, as variáveis de folga, ξ_i e ξ'_i , são utilizadas, a fim de que alguns valores fiquem fora da região delimitada por $-\varepsilon$ e $+\varepsilon$, conforme ilustrado na Figura 2.20. Dessa forma, o objetivo da SVR é encontrar valores para w e b que minimizem (2.26), respeitando as restrições (2.27), (2.28) e (2.29).

Figura 2.20 – Ilustração do modelo da SVR, considerando as variáveis de folga e hiperplanos.



Fonte: adaptada de Haykin (2008).

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N (\xi_i + \xi'_i), \quad (2.26)$$

$$y - f(\mathbf{x}) \leq \varepsilon + \xi_i, \quad (2.27)$$

$$f(\mathbf{x}) - y_i \leq \varepsilon + \xi'_i, \quad (2.28)$$

$$\xi_i, \xi'_i \geq 0, \quad (2.29)$$

para $i = 1, 2, \dots, N$; C é a constante de regularização (também denominada de *box constraint*), que é responsável por regular o desvio máximo da previsão fora da banda definida por ε . Um valor alto de C resulta em previsões mais exatas. Contudo, o modelo será mais complexo e terá menor capacidade de generalização do que um modelo com valor de C inferior. Essa constante deve sempre ser maior que zero.

Para resolver o problema de otimização apresentado em (2.27), deve-se construir uma função objetivo, L , com a introdução dos Multiplicadores de Lagrange α_i , α'_i , η_i e η'_i , conforme apresentado em (2.30). Essa função também deve ser minimizada, considerando as restrições apresentadas em (2.31) e (2.32). Isso é alcançado garantindo que as derivadas parciais das variáveis primárias sejam iguais a zero, como apresentado em (2.33), (2.34) e (2.35).

$$L = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N (\xi_i + \xi'_i) - \sum_{i=1}^N \alpha_i (-y + d_i + \varepsilon + \xi_i) - \sum_{i=1}^N \alpha'_i (y_i - d_i + \varepsilon + \xi'_i) - \sum_{i=1}^N (\eta_i \xi_i + \eta'_i \xi'_i), \quad (2.30)$$

$$\eta_i, \eta'_i \geq 0, \quad (2.31)$$

$$\alpha_i, \alpha'_i \geq 0, \quad (2.32)$$

$$\frac{\partial L}{\partial b} = \sum_{i=1}^N (\alpha_i - \alpha'_i) = 0, \quad (2.33)$$

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^N (\alpha_i - \alpha'_i) \mathbf{x} = 0, \quad \mathbf{w} = \sum_{i=1}^N (\alpha_i - \alpha'_i) \mathbf{x}, \quad (2.34)$$

$$\frac{\partial L}{\partial \xi'_i} = C - \alpha'_i - \eta'_i, \quad \eta'_i = C - \alpha'_i, \quad (2.35)$$

O problema de otimização com as restrições pode ser modificado seguindo o problema de otimização dual a partir da substituição de (2.33), (2.34) e (2.35) em (2.30). Assim, pode-se obter (2.36) com as restrições (2.37) e (2.38).

$$L(\alpha) = \sum_{i=1}^N (\alpha_i - \alpha'_i) - \varepsilon \sum_{i=1}^N (\alpha_i + \alpha'_i) - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha'_i) (\alpha_i - \alpha'_i) \langle \mathbf{x}_i, \mathbf{x}_j \rangle, \quad (2.36)$$

$$\sum_{i=1}^N (\alpha_i - \alpha'_i) = 0, \quad (2.37)$$

$$0 \leq \alpha_i, \alpha'_i \leq C. \quad (2.38)$$

Após a solução dos problemas de otimização que foram descritos, o modelo SVR é representado de acordo com (2.39).

$$\hat{f}(\mathbf{x}) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) \langle \mathbf{x}, \mathbf{x}_i \rangle + b, \quad (2.39)$$

em que $\hat{f}(\mathbf{x})$ representa o valor a ser estimado pelo modelo SVR para uma nova entrada \mathbf{x} . Os modelos de previsão baseados em SVR mapeiam os dados de entrada, \mathbf{x}_i , em um

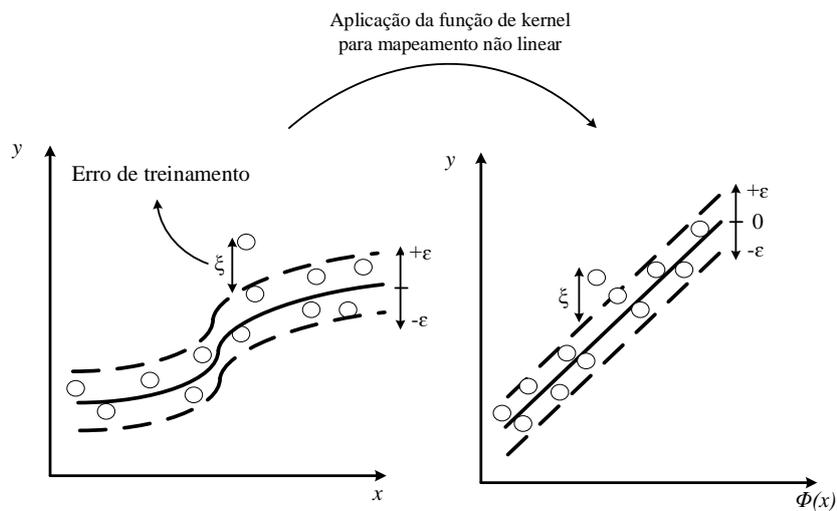
espaço de maior dimensão (espaço de características), usando, para isso, um mapeamento não linear. Após esse aumento de dimensionalidade, busca-se resolver um problema de regressão linear nesse novo espaço. As ferramentas que possibilitam que os dados de entrada sejam mapeados em espaços de dimensões mais elevadas são chamadas de funções *kernel* (HAYKIN, 2008; KO & LEE, 2013). A forma geral da função *kernel* é definida em (2.40). Para cada tipo de problema há uma função *kernel* apropriada, sendo as principais: Linear, Polinomial e Gaussiana. O mapeamento não linear dos dados de entrada ocorre conforme apresentado em (2.41), matematicamente, e na Figura 2.21, graficamente. A arquitetura de um modelo SVR é apresentada na Figura 2.22.

$$k(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j), \quad (2.40)$$

$$\hat{f}(\mathbf{x}) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) k(\mathbf{x}, \mathbf{x}_i) + b, \quad (2.41)$$

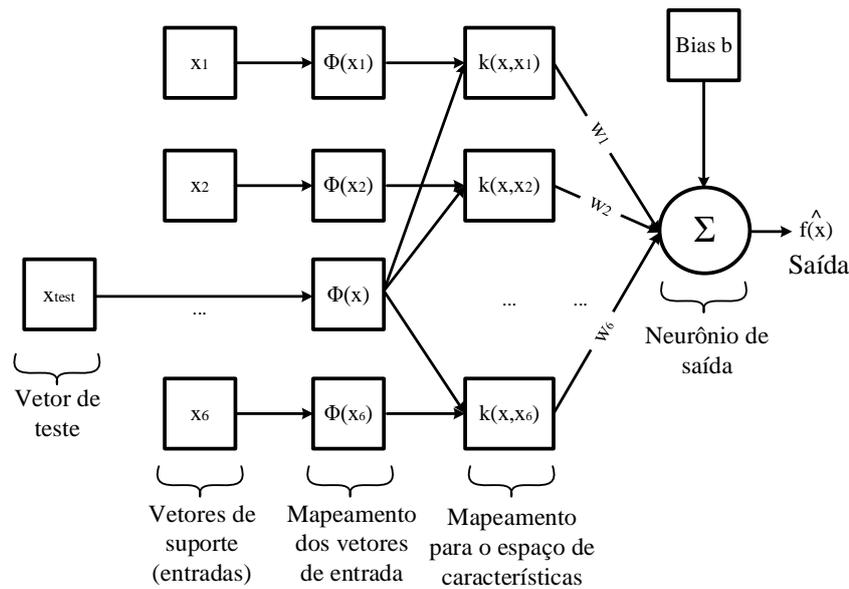
em que $(\alpha_i - \alpha_i^*)$ representa um conjunto de multiplicadores de Lagrange e $k(\mathbf{x}, \mathbf{x}_i)$ é uma função *kernel*.

Figura 2.21 – Aplicação do procedimento de *kernel* em um espaço de características.



Fonte: adaptado de Géron (2019).

Figura 2.22 – Arquitetura de um modelo SVR.



Fonte: autor (2025).

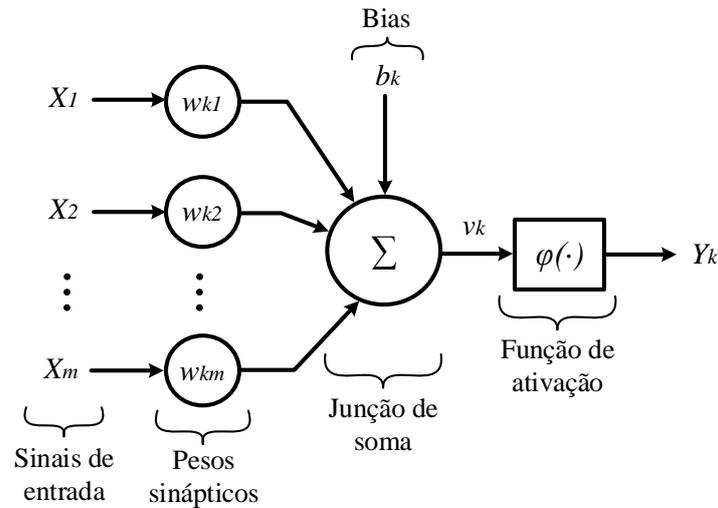
2.6.2 REDES NEURAIAS ARTIFICIAIS - ANN

A ANN é um modelo matemático cujo funcionamento é inspirado no sistema nervoso biológico. Assim, esse tipo de modelo pode ser compreendido como um conjunto de unidades de processamento, as quais são denominadas de neurônios artificiais e são capazes de armazenar conhecimento pela experiência (HAYKIN, 2008; GÉRON, 2019).

Uma representação de um neurônio artificial é apresentada na Figura 2.23, na qual são apresentados os seus elementos básicos: conexões (ou sinapses), um somador e uma função de ativação. As sinapses ligam as entradas x_1, x_2, \dots, x_m ao neurônio, multiplicando-as pelos pesos $w_{k1}, w_{k2}, \dots, w_{km}$, nessa sequência. O somador realiza a soma dos sinais de entrada ponderados pelos pesos sinápticos, para realizar a combinação linear dos sinais de entrada. A função de ativação possui como finalidade limitar a amplitude de saída. Além disso, o neurônio artificial também possui um bias, b_k , que realiza o aumento ou diminuição da entrada da função de ativação, podendo variar entre valores positivos e negativos. A saída do modelo, y_k , é representada matematicamente por meio de (2.42) e a saída do neurônio, v_k , é dada por (2.43).

$$y_k = \varphi(v_k), \quad (2.42)$$

$$v_k = \sum_{j=1}^m w_{kj}x_j + b_k. \quad (2.43)$$

Figura 2.23 – Modelo de um neurônio artificial, chamado k .

Fonte: adaptado de Haykin (2008).

em que x_1, x_2, \dots, x_m são os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos; u_k é a saída do combinador linear dos sinais de entrada; b_k é o bias; $\varphi(v_k)$ é a função de ativação; e y_k é o sinal de saída do neurônio.

As funções de ativação constituem uma parte essencial das redes neurais artificiais, pois elas são responsáveis por introduzir não linearidade nas saídas das camadas da rede, permitindo que a rede aprenda a representar funções complexas. Existem diversas funções de ativação disponíveis, cada uma com suas vantagens e desvantagens. As funções mais aplicadas na literatura são: linear (ou identidade), sigmoide (ou logística), tangente hiperbólica, radial (ou gaussiana) e unidade retificada linear. A escolha da função de ativação vai depender das características da variável resposta do problema a ser resolvido.

A função de ativação identidade ou linear é uma função simples que retorna a entrada sem aplicar qualquer transformação não linear. A função é bastante utilizada no neurônio localizado na camada de saída da rede, quando é desejado que a saída não seja saturada. Em geral, ela é aplicada em problemas de regressão (ou previsão), em que a saída deve ser um valor contínuo, dentro do intervalo real. Matematicamente, a função de ativação linear é representada por meio de (2.44).

$$\varphi(v) = av, \quad (2.44)$$

em que v é a entrada da função de ativação e a é o coeficiente de inclinação da função linear, que geralmente é igual ao valor unitário se for aplicado na camada de saída da rede.

A função degrau é uma função de ativação discreta que retorna um valor constante de 0 ou 1, dependendo do valor de entrada em relação a um limiar. Essa função recebe esse nome porque a sua forma gráfica se assemelha a um degrau, com uma mudança brusca no valor de saída quando o valor de entrada ultrapassa um determinado limiar. Matematicamente, a função degrau é obtida por meio de (2.45). Essa função retorna 1 se o valor de entrada v for maior ou igual a zero e 0 se v for menor que zero. O limiar (*threshold*) da função é zero, o que significa que o ponto de mudança brusca ocorre em $v = 0$.

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0, \\ 0, & \text{se } v < 0. \end{cases} \quad (2.45)$$

A função degrau é usada principalmente para tarefas de classificação binária simples. No entanto, a sua natureza discreta pode tornar o processo de treinamento da rede neural mais difícil, especialmente quando o algoritmo de otimização depende de gradientes contínuos para ajustar os pesos da rede. Além disso, a função degrau não é diferenciável em $v = 0$, o que torna impossível calcular a sua derivada nesse ponto. Como alternativa à função degrau, outras funções de ativação foram propostas, como, por exemplo, a função sigmoide, a função tangente hiperbólica, a função ReLU e suas variantes, que são diferenciáveis em todos os pontos.

A função sigmoide ou logística é uma das funções mais utilizadas em redes neurais. Essa função aplica uma transformação não linear na entrada, apresentando na saída um valor entre 0 e 1. Essa função é amplamente utilizada em redes neurais antigas, mas foi perdendo popularidade em redes mais modernas devido a algumas desvantagens, como o problema de gradiente desvanecido. A função sigmoide é frequentemente usada na camada de saída de uma rede neural para problemas de classificação binária, onde a saída da rede deve ser um valor entre 0 e 1 representando a probabilidade de pertencer a uma das duas classes. Essa função é representada matematicamente por meio de (2.46).

$$\varphi(v) = \frac{1}{1+e^{-av}}, \quad a > 0 \quad (2.46)$$

em que v é a entrada da função de ativação e a é o parâmetro de inclinação da função sigmoide.

A função tangente hiperbólica, também conhecida como *tanh*, é uma função de ativação não linear que mapeia uma entrada para um valor entre -1 e 1. A função é semelhante à função sigmoide, mas tem uma saída simétrica em torno de zero. É comum o uso dessa função na camada oculta de uma rede neural. A equação que representa essa função é apresentada em (2.47).

$$\varphi(v) = \tanh(av), \quad a > 0 \quad (2.47)$$

em que v é a entrada da função de ativação e a é o parâmetro de inclinação da função \tanh .

A função \tanh é frequentemente usada em redes neurais devido à sua propriedade de saída simétrica, o que pode ser útil para normalizar a entrada em torno de zero. Ela também é menos propensa a saturação do que a função sigmoide, pois sua saída varia de -1 a 1, o que permite que a rede possa gerar saídas mais diversas. No entanto, assim como a função sigmoide, a função \tanh também pode ter problemas em redes mais profundas devido ao problema de gradiente desvanecido, quando os gradientes das camadas iniciais se tornam extremamente pequenos durante o treinamento, dificultando a atualização dos pesos do método de *backpropagation* (PASCANU, MIKOLOV & BENGIO, 2013).

A função radial ou gaussiana é uma função de ativação não linear e é baseada na distribuição normal ou gaussiana, sendo simétrica em torno do centro. Essa função é comumente usada em redes neurais para problemas de regressão (ou previsão), para mapear a entrada para a saída desejada. Em geral, a função radial é especialmente útil em situações onde a entrada está em um espaço multidimensional e a relação entre a entrada e a saída é complexa e não linear. Matematicamente, ela é representada por meio de (2.48).

$$\varphi(v) = e^{-(av)^2}, \quad (2.48)$$

em que v é a entrada da função de ativação e a é o parâmetro influencia no quão rápido a função se aproxima de zero à medida que v se afasta de zero.

Além das funções de ativação apresentadas, há também a função de Unidade Linear Retificada (ReLU, do inglês *Rectified Linear Unit*), que é uma função não linear e amplamente utilizada em redes neurais profundas. A função ReLU retorna zero para todas as entradas negativas e retorna a entrada original para todas as entradas positivas. Essa função é definida em (2.49).

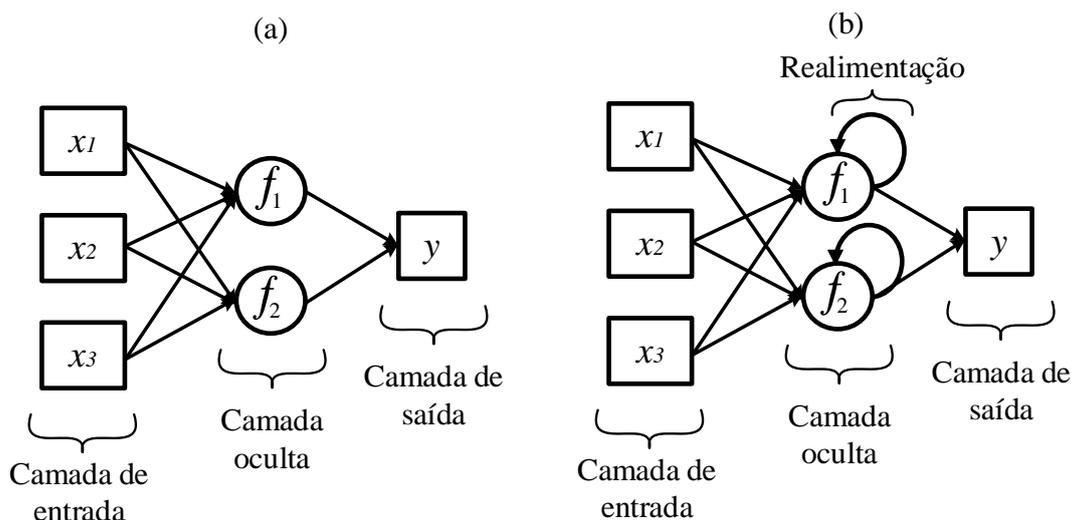
$$\varphi(v) = \max(0, v), \quad (2.49)$$

em que v é a entrada da função de ativação. A função ReLU é popular em redes neurais profundas porque é simples e eficiente. Ela permite que a rede seja treinada mais rápida do que outras funções de ativação como a tangente hiperbólica ou a função sigmoide. A função ReLU também pode ajudar a resolver o problema de gradiente desvanecido, que pode ocorrer em redes com o nível de profundidade elevado.

A forma como os neurônios e as conexões da rede são arranjados define a sua arquitetura (ou topologia), influenciado na sua capacidade de processamento. A arquitetura de uma ANN pode ser de dois tipos: recorrente (do inglês *feedback*) e não recorrente (do inglês *feedforward*). Uma arquitetura do tipo recorrente possui uma realimentação, caracterizando um circuito fechado. A realimentação pode ser direta (denominada também de autorrecorrência) para os casos em que os neurônios são conectados a si mesmos; ou indireta, quando os neurônios têm suas saídas conectadas aos neurônios de camadas anteriores (HAYKIN, 2008; GÉRON, 2019).

No tocante à arquitetura não recorrente, as camadas são divididas em: uma camada de entrada, uma camada de saída e uma ou mais (multicamadas) camadas ocultas (ou camadas de processamento). Nesse tipo de arquitetura, as conexões só são realizadas para os neurônios da camada seguinte (KRIESEL, 2007), conforme ilustrado na Figura 2.24.

Figura 2.24 – Representações das arquiteturas de modelos ANN (a) não recorrente e (b) recorrente.

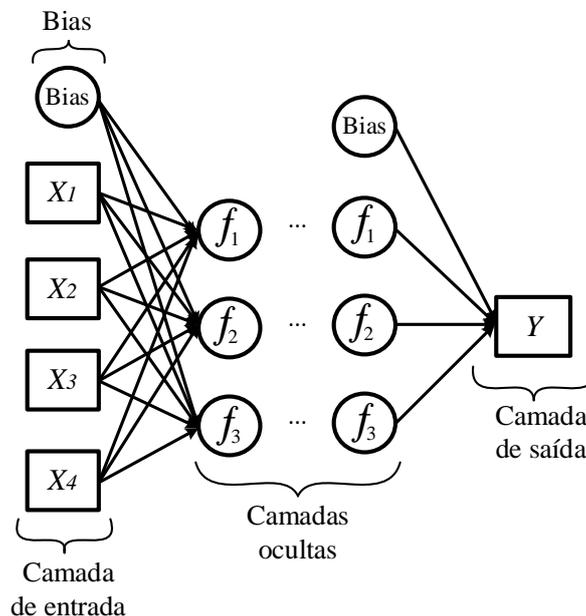


Fonte: adaptado de Haykin (2008).

A rede Perceptron Multicamadas (MLP do inglês, *Multilayer Perceptron*) é um tipo de rede neural utilizada para problemas de regressão e classificação de dados. A MLP é caracterizada por possuir uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Em problemas de regressão, o objetivo da MLP é encontrar uma relação não linear entre as variáveis de entrada (variáveis explicativas) e a variável de saída (variável resposta). Para isso, a MLP utiliza um algoritmo de aprendizado supervisionado, como o algoritmo de retropropagação de erro (BP, do inglês como *backpropagation*), para ajustar os pesos sinápticos da rede de forma a minimizar a diferença entre as previsões do modelo e os valores reais dos dados de treinamento (HAYKIN, 2008). Na

Figura 2.25, apresenta-se um exemplo de arquitetura da MLP com uma camada de entrada, três camadas ocultas (cada camada com três neurônios) e uma camada de saída.

Figura 2.25 – Esquemático da arquitetura de uma MLP.



Fonte: adaptado de Haykin (2008).

O algoritmo de retropropagação possui a finalidade de ajustar os pesos sinápticos da MLP, com o objetivo de minimizar o erro associado à previsão. Inicialmente, os dados de entrada são propagados pela rede, camada por camada, até que a saída da rede seja gerada. O erro entre a saída da rede e o valor real dos dados de treinamento é calculado. Geralmente, utiliza-se uma função de perda, como o MSE, para calcular o erro. O erro é propagado pela rede, camada por camada, a partir da camada de saída até a camada de entrada. Durante a retropropagação, o erro em cada neurônio é distribuído para os neurônios conectados a ele, proporcionalmente aos pesos sinápticos dessas conexões. Os pesos sinápticos da rede são atualizados de acordo com a magnitude do erro retropropagado e com uma taxa de aprendizado pré-definida. A taxa de aprendizado é um hiperparâmetro que controla o tamanho do ajuste dos pesos em cada iteração do algoritmo. Essas etapas são repetidas para vários ciclos (ou épocas) de treinamento, até que a MLP atinja um nível satisfatório de desempenho.

2.7 RESUMO DO CAPÍTULO

Neste capítulo de fundamentação teórica, foram apresentados os principais temas que servem de suporte para compreensão do que propõe esta pesquisa. Inicialmente, os isoladores foram detalhadamente descritos, com foco principal nos seus aspectos construtivos e suas vantagens e desvantagens. Além desses aspectos referentes aos isoladores, conceitos sobre poluição superficial em isoladores foram abordados, explanando sua constituição física, os tipos, os métodos de quantificação e a influência no processo de descargas superficiais e disruptivas. Na sequência, alguns conceitos pertinentes de ciência de dados foram apresentados, com destaque para as etapas de mineração de dados, contemplando desde o tratamento dos dados até a avaliação dos modelos preditivos. Nos tópicos posteriores, conceitos referentes ao tratamento e análise de séries temporais foram abordados. Por fim, modelos de previsão baseados nos algoritmos MLP e SVR foram descritos de forma minuciosa.

No capítulo seguinte, a revisão bibliográfica dos trabalhos correlatos a esta pesquisa será apresentada, a fim de conhecer o estado da arte referentes às técnicas de monitoramento, diagnóstico e prognóstico de isoladores elétricos, destinados a mitigar falhas devido ao acúmulo de poluição, utilizando informações da corrente de fuga.

CAPÍTULO 3

REVISÃO BIBLIOGRÁFICA

Diversos trabalhos foram desenvolvidos com o intuito de investigar falhas ocorridas em isoladores, com foco nos casos relacionados ao nível de poluição superficial, usando informações derivadas da corrente de fuga. Inicialmente, estudos foram realizados para conhecer o comportamento da corrente de fuga diante de diferentes níveis de poluição, com análises no domínio do tempo e da frequência (KARADY & AMARH, 1999; FERNANDO & GUBANSKI, 1999; SUDA, 2001; KUMAGAI & YOSHIMURA, 2004; SUDA, 2005; PALANGAR & MIRZAIE, 2020; SALEM *et al.*, 2020). Uma vez conhecida a correlação entre a poluição superficial e a corrente de fuga de isoladores, algumas pesquisas investigaram os parâmetros da corrente mais fortemente correlacionados com a poluição, para que apenas eles fossem foco de análise em tomadas de decisão quanto à realização de manutenção ou substituição dos isoladores.

Em paralelo a esses estudos, investigações foram realizadas para construção de modelos estatísticos capazes de prever a tensão responsável pela ocorrência de *flashovers* em isoladores (ZHAO *et al.*, 2013; SLAMA *et al.*, 2022). Os trabalhos demonstram que a ocorrência de descargas disruptivas depende, principalmente, do nível de poluição na superfície do isolador (DDSE e DDNS) e da umidade.

Com a popularização dos algoritmos de aprendizado de máquina e redes neurais artificiais, vários trabalhos passaram a integrar esse tipo de inteligência nas metodologias (JIANYUAN, YUN & XIN, 2008; LI *et al.*, 2010; FERREIRA, 2011; MUNIRAJ & CHANDRASEKAR, 2011; PYLARINOS *et al.*, 2012; KHAFRAF & EL-HAG, 2017; GAO *et al.*, 2018; ROCHA, 2019; THANH, CHO & DA, 2021; SOPELSA NETO *et al.*, 2022; ESMAIELI *et al.*, 2023; LIN & KUO, 2024). Alguns desses trabalhos utilizaram modelos de regressão (e.g., redes neurais artificiais, regressão por vetores de suporte, árvore de decisão etc.) para prever parâmetros da corrente de fuga (e.g., valor eficaz, valor de pico, amplitude das harmônicas ímpares, distorção harmônica total etc.), utilizando grandezas ambientais (poluição, umidade, temperatura etc.), dada a forte

correlação entre essas grandezas (KHAFAF & EL-HAG, 2017; GAO *et al.*, 2018; THANH, CHO & DA, 2021; SOPELSA NETO *et al.*, 2022; LIN & KUO, 2024). Outras pesquisas utilizaram modelos de classificação para diagnóstico de isoladores, contemplando diferentes condições operacionais (com e sem poluição superficial) (FERREIRA, 2011; PYLARINOS *et al.*, 2012; ROCHA, 2019; ESMAIELI *et al.*, 2023). Além disso, alguns trabalhos, em uma quantidade menor, propuseram prever níveis de poluição (DDSE) usando informações da corrente de fuga e algoritmos de aprendizado de máquina (JIANYUAN, YUN & XIN, 2008; LI *et al.*, 2010; MUNIRAJ & CHANDRASEKAR, 2011). Nesse mesmo sentido ainda, alguns trabalhos buscaram otimizar os ciclos de lavagens de isoladores, reduzindo a quantidade de manutenções, com base nas informações somente da corrente de fuga (CASTILLO-SIERRA *et al.*, 2021).

Vários trabalhos que discutem técnicas, estratégias e metodologias para mitigar falhas em isoladores devido ao acúmulo de poluição, com base na corrente de fuga, foram selecionados para o levantamento do estado da arte deste trabalho de tese. Esses trabalhos foram estudados individualmente e serão apresentados a seguir.

3.1 ESTRATÉGIAS PARA MITIGAR FALHAS EM ISOLADORES DEVIDO AO ACÚMULO DE POLUIÇÃO SUPERFICIAL

O trabalho realizado por Karady & Amarh (1999) propõe utilizar análise espectral para estudar sinais da corrente de fuga de isoladores poluídos. Os autores utilizaram técnicas estatísticas (e.g., periodograma, correlograma etc.) para obter informações da corrente no domínio da frequência. Para construção da base de dados, ensaios foram realizados com isoladores poluídos artificialmente e registros foram feitos com os sinais da corrente de fuga continuamente ao longo de 30 (trinta) minutos. Eles constataram que esse tempo era suficiente para a ocorrência de descargas disruptivas (*flashover*). Com base na Densidade Espectral de Potência (PSD, do inglês *Power Spectral Density*) e energia dissipada, verificou-se que as componentes harmônicas ímpares da corrente de fuga aumentaram em função do surgimento de descargas superficiais geradas por bandas secas, devido ao aumento de umidade combinada com poluição. Dentre as componentes analisadas, eles constataram que a PSD da terceira componente harmônica da corrente foi

a mais sensível ao aumento da umidade combinada com poluição, que foi simulada ao longo do ensaio, uma vez que teve aumento de aproximadamente 20% acima da PSD da componente fundamental, considerando inicialmente uma condição normal de operação (apenas com poluição e umidade ambiente) até um nível crítico de poluição combinada com umidade elevada. Com base nessa análise, a energia dissipada devido à corrente de fuga foi analisada, com foco nas suas componentes harmônicas. Assim, os autores constataram que a terceira componente harmônica é a mais sensível, e relatam que a energia dissipada devido a essa componente ultrapassa a energia da componente fundamental da corrente, à medida que os níveis de poluição e umidade aumentam. Com base nos resultados, os autores constataram que há ocorrência de descarga disruptiva quando a razão entre as energias da terceira harmônica e fundamental da corrente de fuga (E_{I3Harm}/E_{I1Harm}) for igual ao valor unitário.

No seu artigo, Fernando & Gubanski (1999) propuseram um estudo baseado na análise da corrente de fuga de isoladores poliméricos, para identificar padrões da corrente de fuga associados aos isoladores de forma natural (nível de poluição pesada) e artificialmente. Para obtenção dos resultados, foram utilizados cinco conjuntos de seis isoladores, para sistema elétrico de 33 kV. Dentre esses conjuntos, três deles foram envelhecidos naturalmente por mais de três anos, sendo cada um deles instalados em localizações geográficas diferentes. E os demais conjuntos foram envelhecidos artificialmente em laboratório. As cadeias de isoladores foram submetidas a estresse elétrico (com poluição e umidade constante) e poluição superficial (com tensão aplicada constante). Os níveis de poluição simulados em laboratório foram medidos de acordo com os valores da DDSE. A identificação dos padrões de corrente de fuga foi realizada por meio de modelos de classificação baseados no algoritmo Quantização de Vetores de Aprendizado (LVQ, o inglês *Learning Vector Quantization*). Dois modelos foram desenvolvidos, sendo um deles utilizado para classificar quatro condições operacionais diferentes de acordo com os valores das componentes harmônicas de 3ª e 5ª ordem, tendo em vista que essas condições são influenciadas pelo nível de poluição. O outro modelo foi desenvolvido para classificar três condições operacionais diferentes conforme os valores médios de sinais da corrente de fuga, considerando que essas categorias contemplam os sinais no formato senoidal, não linear (presença de *spikes* de baixa amplitude) e com diferentes tipos de descargas. É importante destacar que as entradas foram normalizadas, a fim de evitar erros derivados da ordem de medida das grandezas. Os autores afirmam que os resultados obtidos foram suficientes para classificar a

condição operacional influenciada pelo nível de poluição dos isoladores, utilizando as formas de onda dos sinais da corrente de fuga, bem como as componentes harmônicas adotadas.

Suda (2001) apresenta um estudo investigativo das características do sinal da corrente de fuga e o seu conteúdo harmônico (até 400 kHz). A pesquisa tem o objetivo de obter indicadores sensíveis ao nível de poluição a serem utilizados no monitoramento de isoladores. Para obtenção dos indicadores, ensaios elétricos nos isoladores foram realizados em laboratório e por meio da simulação de poluição superficial baseada nos índices DDSE e DDNS, além da aplicação da tensão sobre a amostra do isolador. Os níveis de poluição foram aumentados gradualmente, com variação da umidade e névoa salina, até a ocorrência de descarga disruptiva. Em cada experimento, a tensão aplicada foi aumentada. Tendo em vista isso, três condições foram consideradas: condição de operação normal, com descargas superficiais (presença de bandas secas) e sem descargas superficiais (posterior a ocorrência das descargas superficiais). Os ensaios permitiram verificar que apenas as componentes harmônicas ímpares abaixo de 1 kHz aumentam em função do nível de poluição. Com base nessa faixa de frequência, as componentes que mais aumentaram consistem nas componentes harmônicas fundamental e de 3ª ordem, como também foi verificado por Karady & Amarh (1999) e Fernando & Gubanski (1999). Ainda durante os ensaios, foram observados seis estágios até a ocorrência de *flashover* na superfície do isolador, desde o instante em que o nível de poluição estava baixo até o momento na iminência de um *flashover*. Nesses estágios, além das componentes supracitadas, também foi constatado o crescimento da componente harmônica de 5ª ordem. Para análise dos resultados obtidos, de modo geral, o autor também selecionou a componente harmônica de 7ª ordem da corrente de fuga, considerando que ela também apresentou crescimento expressivo nas análises espectrais. As componentes foram normalizadas pela fundamental e avaliadas para diferentes níveis de poluição. Com isso, o autor pôde determinar valores das relações harmônicas que indicassem a ocorrência de descargas disruptivas. Para o caso da componente harmônica de 3ª ordem da corrente, definiu-se como limiar o valor de 50% em relação à componente fundamental (I_{3Harm}/I_{1Harm}), que é um forte indicativo da ocorrência de *flashover*.

Kumagai & Yoshimura (2004) desenvolveram um estudo focado em extrair informações no domínio da frequência da corrente de fuga da superfície de isoladores poliméricos e cerâmicos, por meio da aplicação da Transformada de Wavelet. Para obtenção dos dados, testes de poluição artificial foram realizados em isoladores,

considerando variações do DDSE e DDNS, sabendo que a corrente foi extraída nas seguintes condições: formato senoidal, com arco local e transitórios. Para o formato senoidal (ou componente senoidal), os isoladores foram submetidos à solução salina, porém sem formação de descargas superficiais. Para a situação com descargas superficiais, a solução de poluição foi aplicada com nível mais elevado, capaz de provocar distorção no sinal da corrente e predominância da componente resistiva da corrente de fuga, permanecendo com características semelhantes à situação de componente senoidal e em fase com a tensão aplicada. Já na componente transitória, há presenças de várias descargas superficiais, provocando distorção significativa no sinal de corrente e surgimentos de *spikes* nas regiões de crista e vale do sinal. Por meio da Transformada wevelet, os autores extraíram informações no domínio da frequência para caracterizar as condições supracitadas e distingui-las, a fim de auxiliar no diagnóstico da condição da superfície de isoladores. A razão entre a 3ª componente harmônica e a fundamental da corrente de fuga (I_{3Harm}/I_{1Harm}) foi extraída para ser utilizada como indicador da condição da superfície do isolador, por ter sido verificado a sensibilidade desse indicador em função da poluição na superfície dos isoladores poliméricos e cerâmicos.

Suda (2005) propõe uma técnica de monitoramento da ocorrência de *flashover* em uma cadeia de isoladores cerâmicos (constituída por cinco unidades de isoladores), por meio de informações extraídas do sinal da corrente de fuga e de suas componentes harmônicas ímpares. Para validação da técnica, foram utilizados registros de sinais da corrente de fuga obtidos em laboratório por meio de ensaios de poluição artificial, como também de testes realizados em campo. Diante dos experimentos realizados, os autores constataram que o surgimento de descargas locais intensas está correlacionado diretamente com o aumento das componentes harmônicas fundamental, 3ª e 5ª da corrente de fuga, haja vista que a forma de onda do sinal de corrente de fuga tende a ficar simétrica. Para auxiliar na previsão de *flashover* e usar em sistemas de monitoramento da condição operacional de isoladores, limiares foram propostos, com base no valor de pico da corrente de fuga e nas componentes harmônicas supracitadas. Para valores de pico da corrente de fuga acima de 50 mA, teve ocorrência de *flashover* para os isoladores ensaiados. E para a 3ª componente harmônica da corrente de fuga, os autores definiram como limiar o valor de 60% em relação à componente fundamental (I_{3Harm}/I_{1Harm}), semelhante ao resultado apresentado na pesquisa de Suda (2001).

O trabalho proposto por Jianyuan, Yun & Xin (2008) teve como intuito propor uma técnica, baseada em modelos preditivos, que permita estimar a probabilidade de

ocorrência de *flashover* em isoladores contaminados, com base na análise de séries temporais da DDSE e fatores ambientais (temperatura, umidade, precipitação e velocidade do vento). Para desenvolvimento dos modelos computacionais, uma base de dados é construída, contendo informações da DDSE e variáveis ambientais, tais como temperatura, umidade, precipitação e velocidade do vento. Essa base possui informações obtidas de experimentos de poluição ambiente (*outdoor*), com 36 cadeias de isoladores, com 9 unidades cada uma delas, as quais foram utilizadas para armazenar o depósito de poluição ambiente ao longo de 180 dias, sendo usadas duas cadeias a cada 10 dias, para análise do acúmulo de poluição com base apenas no índice da DDSE. Além desse tipo de experimento, também foram realizados ensaios elétricos usando uma cadeia poluída artificialmente com o nível de poluição referente ao acúmulo de 180 dias, com o intuito de registrar a tensão responsável pelo *flashover*, iniciando com aplicação de 50% da tensão máxima suportada pelo isolador e fazendo variar para mais ou menos até identificar a tensão responsável pelo evento de *flashover*. Com os dados obtidos, um modelo de previsão de valores futuros da DDSE foi desenvolvido usando o algoritmo MLP, com 17 amostras para treinamento e apenas 1 amostra para teste, com erro percentual de 4,66%. Usando a saída (DDSE previsto) desse modelo como entrada em outro modelo preditivo e a tensão aplicada no isolador, implementou-se um modelo para prever a probabilidade de ocorrência de *flashover*, com erro máximo de 12,73%.

Li *et al.* (2010) apresentaram um estudo para prever o nível de poluição superficial (DDSE) de cadeias de isoladores. Para construção da base de dados, cinco níveis de poluição foram simulados em laboratório, com aplicação de névoa ao longo dos experimentos. Para cada um dos níveis de poluição, vários registros dos sinais de corrente de fuga foram realizados, a fim de extrair parâmetros e adotá-los como variáveis explicativas para uso na modelagem da poluição superficial presente nas cadeias de isoladores ensaiadas. Com base em testes estatísticos, os autores definiram os parâmetros da corrente de fuga, valor médio, valor de pico e desvio padrão do Valor Quadrático Médio (RMS, do inglês *Root Mean Square*), como os mais explicativos (correlação forte). Para povoamento dos dados para modelagem, equações matemáticas de regressão foram definidas, com o intuito de aumentar a base de dados, mantendo as características originais das informações obtidos ao longo dos experimentos em laboratório. A partir dos parâmetros extraídos dos sinais da corrente de fuga, em conjunto com informações da umidade e tensão de operação, associados aos níveis de poluição simulados, um modelo de previsão foi desenvolvido, para estimar valores da DDSE utilizando informações da

corrente de fuga. O modelo desenvolvido pelos autores foi baseado na MLP usando como algoritmo de treinamento o *backpropagation*, com uma camada de entrada, a qual foi responsável por receber os valores dos parâmetros da corrente de fuga selecionados, umidade e tensão de operação; a camada oculta, com doze neurônios; e a camada de saída, que fornece uma estimativa para o DDSE. O desempenho obtido para o modelo nas estimativas realizados para o DDSE foi mensurado a partir de erros absolutos, que pode ser representado por meio da métrica MAPE igual a 22,79%, considerando os valores previstos e observados, podendo, assim, impactar nas tomadas de decisão. Esse impacto pode refletir na realização de manutenção ou substituição atrasada, propiciando o acúmulo de poluição e consequências derivadas dessa situação.

Muniraj & Chandrasekar (2011) propuseram uma técnica para prever o nível de poluição (DDSE) de isoladores poliméricos usando um modelo baseado no algoritmo híbrido ANFIS (combinação da Lógica Fuzzy com rede neural artificial). Para tanto, ensaios de poluição artificial em um isolador polimérico de suspensão foram realizados em laboratório, com aplicação de cinco níveis de poluição sobre a superfície do isolador, como também foi injetado névoa no ambiente de ensaio. Os valores do DDSE simulados contemplaram níveis de poluição leve, médio e pesado (com variação de 0,01 até 0,25 mg/cm²). Durante os testes realizados, os sinais da corrente de fuga foram registrados, 50 amostras de sinais da corrente de fuga para cada valor da DDSE, totalizando 250 amostras, a fim de ser realizada a extração dos parâmetros que foram utilizados para construção do modelo baseado no algoritmo ANFIS. Informações do domínio do tempo e da frequência da corrente de fuga foram utilizados, especificamente os parâmetros: valor de pico, valor médio, desvio padrão do valor eficaz e DHT. Segundo os autores, esses parâmetros estão fortemente correlacionados com o nível de poluição, motivo pelo qual eles foram utilizados no estudo proposto. O modelo proposto foi comparado com outro modelo baseado no algoritmo MLP, utilizando métricas de desempenho, como o RMSE e coeficiente de determinação. Os autores relataram que o modelo baseado no sistema de inferência ANFIS apresentou desempenho superior com RMSE igual a 0,00323 e coeficiente de determinação igual a 0,998; enquanto o modelo MLP obteve 0,02524 para o RMSE e 0,943 para o coeficiente de determinação. Embora o desempenho do modelo baseado no algoritmo ANFIS tenha sido melhor, a complexidade da modelagem aumenta de forma considerável, como também o esforço computacional, uma vez que regras *fuzzy* devem ser definidas e as etapas de inferência precisam ser realizadas nas etapas de treinamento e teste, para fazer estimativas dos valores da DDSE.

O trabalho desenvolvido por Ferreira (2011) desenvolveu uma técnica de estimação da poluição em isoladores, utilizando ruído ultrassônico emitido pelos isoladores quando energizados. A metodologia do trabalho inclui a realização de ensaios laboratoriais onde sinais ultrassônicos foram capturados e processados para extração de atributos. Para isso, foi desenvolvido o algoritmo Vetores de Energia dos Centróides das Sub-bandas Espectrais (VECSE), que permitiu selecionar as bandas de frequência mais significativas do ruído. Os dados extraídos da aplicação do VECSE foram organizados em uma base de treinamento, alimentando uma rede MLP, treinada para classificar os isoladores em diferentes níveis de poluição, possibilitando distinguir entre um isolador mais poluído de outro menos poluído. Posteriormente, foram conduzidas campanhas de medição em campo, registrando ruídos ultrassônicos em equipamentos de uma subestação real para validação da abordagem. Os resultados demonstraram que a técnica proposta obteve taxas de acerto superiores a 80% na distinção entre isoladores limpos e poluídos.

O trabalho desenvolvido por Pylarinos *et al.* (2012) apresenta um estudo para diagnosticar a condição da superfície de isoladores utilizando informações da corrente de fuga e algoritmo de classificação baseado em *machine learning*. A condição da superfície do isolador é dependente do nível de poluição superficial e está relacionada com a forma de onda da corrente de fuga, de modo que suas características podem ser úteis no processo de diagnóstico. A construção da base de dados para desenvolvimento da pesquisa foi realizada por meio de registros periódicos de sinais da corrente de fuga realizados em campo. Um sistema de medição foi usado para registrar os sinais da corrente de fuga ao longo de seis anos em duas subestações, contemplando 18 isoladores de porcelana, os quais foram submetidos a intensos níveis de poluição, haja vista que as subestações estavam localizadas em regiões com elevado nível de salinidade. Os sinais de corrente de fuga foram utilizados para extração de informações no domínio do tempo (dez parâmetros) e da frequência (dez parâmetros). As condições operacionais da superfície foram segmentadas em duas classes, sendo uma delas correspondente a formas de onda da corrente de fuga com presença de *spikes* contemplando até quatro semiciclos em uma janela de tempo contendo oito períodos; e a outra classe correspondente a sinais de corrente de fuga com *spikes* contemplando mais de quatro semiciclos e podendo ultrapassar 50 mA, causando maior dano à superfície dos isoladores e representando o nível de poluição mais crítico dentre as duas classes previstas. Uma vez que os parâmetros dos sinais da corrente de fuga foram extraídos e as classes definidas, os autores desenvolveram três modelos de classificação baseados em algoritmos de *machine*

learning: SVM, KNN (do inglês *K-Nearest Neighbors*) e Naive Bayes. Com base nas variáveis explicativas (parâmetros extraídos da corrente de fuga), foram desenvolvidos modelos capazes de classificar se a superfície do isolador (ou cadeia de isoladores) vai estar submetida a descargas prolongadas e intensas (com valores de pico podendo ultrapassar 50 mA), para a condição da segunda classe prevista; ou caso contrário, para a condição associada à primeira classe. Com base na taxa de acerto obtida para cada um dos modelos desenvolvidos, o algoritmo SVM apresentou o melhor desempenho nos testes realizados, com a maior taxa (acima de 82% em todos os cenários).

O trabalho proposto por Zhao *et al.* (2013) apresenta uma técnica para prever a tensão associada à ocorrência de *flashover* devido ao acúmulo de poluição superficial, utilizando parâmetros da corrente de fuga. Os parâmetros da corrente de fuga foram obtidos a partir de análise do sinal no domínio do tempo. Esses parâmetros apresentaram alta correlação com o nível de poluição da superfície de isoladores. Para construção da base de dados, ensaios em laboratório foram realizados para simular níveis de poluição artificial em cadeias de isoladores. Nos ensaios de poluição, seis níveis de DDSE e cinco níveis de DDNS foram simulados, resultando em 30 combinações de soluções de poluição diferentes, com aplicação de névoa no ambiente de ensaio. Para cada um desses experimentos, a tensão foi aumentada gradualmente até ocorrer *flashover* e amostras da tensão responsável por esse fenômeno foram registradas, para extração do valor RMS, a fim de determinar a média aritmética considerando 50% da tensão associada à ocorrência da *flashover*, bem como o desvio padrão. Além da tensão, a corrente de fuga também foi analisada para os níveis de poluição simulados, para auxiliar na identificação do *flashover* e outros tipos de descargas. Os autores relataram que a partir dos ensaios realizados, parâmetros da corrente de fuga foram extraídos, tais como: entropia da amplitude do pulso (S), que reflete a complexidade (e uniformidade) da amplitude do pulso da corrente, sendo quanto maior o grau de poluição, menor é o valor de S ; amplitude do pulso máximo (I_h), que reflete a intensidade de uma descarga na superfície do isolador; relação da energia ($S = E_L/E_H$), a qual consiste no grau de distorção da forma de onda da corrente de fuga causada pela extinção e reinício de um arco parcial; e a energia ($E = E_L + E_H$) associada à corrente de fuga, para representar sua variação total, contemplando até a frequência de 1000 Hz. Com base nos parâmetros obtidos derivados da corrente de fuga e os valores da tensão aplicada na cadeia de isoladores, um modelo baseado no algoritmo SVR e otimizado com algoritmo genético foi desenvolvido para prever a tensão associada à

ocorrência de *flashover*. Para as previsões realizadas, os erros relativos percentuais foram abaixo de 13%, sabendo que as previsões contemplaram todos os níveis de DDNS.

Khafaf & El-Hag (2017) desenvolveram um estudo focado na estimação de parâmetros da corrente de fuga, a fim de serem utilizados no diagnóstico do nível de poluição superficial de isoladores. Uma base de dados foi construída em laboratório, com a realização de ensaios de poluição artificial no interior de uma câmara de névoa, a fim de simular poluição na superfície de isoladores e fazer registros de sinais da corrente de fuga. Para tanto, nos experimentos foram simulados diferentes níveis de poluição, contemplando os níveis leve, moderado e pesado, totalizando 14 valores de DDSE diferentes, com variações também da tensão aplicada sobre as amostras de isoladores. Para cada nível de poluição, foram registradas quantidades diferentes de sinais de corrente de fuga por valor de DDSE. Nas modelagens computacionais, três modelos foram desenvolvidos para previsão das componentes fundamental e terceira harmônica da corrente de fuga. O primeiro modelo foi desenvolvido para prever valores da componente fundamental ou terceira harmônica usando como entradas valores passados da variável prevista. O segundo modelo também foi desenvolvido para prever valores das componentes supracitadas, adotando como entradas os valores da componente fundamental para prever valores da terceira componente harmônica; e usando como entradas os valores da terceira componente harmônica para prever os valores da fundamental da corrente de fuga. Finalmente, o terceiro modelo usa como entradas os valores passados da componente a prever e da outra componente (e.g., os valores da componente fundamental e terceira componente harmônica são usados para prever os valores da fundamental). Todos os modelos propostos pelos autores foram baseados na rede MLP e otimizados com a aplicação da regularização bayesiana. Para as previsões com 13 amostras (entradas e saídas), o maior erro percentual verificado foi de 9%, considerando cada uma das previsões. Quando os autores analisaram as previsões, com 48 amostras, os erros percentuais variaram entre 24% e 192%.

O trabalho proposto por Gao *et al.* (2018) apresenta uma técnica para previsão da dinâmica da corrente de fuga de isoladores, utilizando uma rede baseada no algoritmo MLP e informações ambientais como variáveis explicativas no processo de modelagem. A construção do banco de dados foi realizada por meio de registros feitos usando um sistema de aquisição de dados, tanto da corrente de fuga, como também de grandezas ambientais. Nesse sentido, os autores adotaram como variáveis de entrada para o modelo computacional, as informações ambientais, tais como: umidade relativa, diferença de

temperatura (valores máximo e mínimo da temperatura em um dia), condição de precipitação (se ocorreu precipitação ou não) e informações de poluição. Como variável resposta, os autores adotaram o valor máximo da corrente de fuga registrado ao longo do dia, sendo esse o mesmo dia de registro das variáveis ambientais. O intervalo de tempo para registro das informações, para treinamento, contemplou os meses de março, abril e maio dos anos de 2015 e 2016; e para teste do modelo, algumas informações desse intervalo temporal foram usadas, sendo total de oito valores previsto para o valor máximo da corrente de fuga. Os autores relatam que o modelo foi desenvolvido com base na MLP otimizada com o método Quase-Newton para ajustar os pesos da rede neural na fase de treinamento. Para treinamento, o valor do coeficiente de determinação foi de 0,935; e para teste, os erros percentuais variaram entre 0% até 400%, tendo em vista que os maiores erros são associados às previsões para os menores valores da corrente de fuga.

O trabalho desenvolvido por Rocha (2019) propõe uma metodologia para prever o nível de poluição superficial, com base na DDSE, da superfície de isoladores poliméricos, usando sinais de radiofrequência (RF) irradiado pelos isoladores. Para o desenvolvimento desse trabalho, uma base de dados foi criada por meio de medições de RF realizadas ao longo de 12 meses em isoladores de vidro e poliméricos instalados em campo, para obter dados representativos das variações dos níveis de poluição. Além dos experimentos em campo, medições laboratoriais com poluição artificial também foram realizadas para correlacionar dados obtidos em campo com os dados nos experimentos laboratoriais, além de povoar a base de dados com amostras obtidas para diferentes níveis de poluição. Uma vez a base de dados construída, com dados de campo e laboratoriais, realizou-se a extração de parâmetros estatísticos dos sinais de RF originais e derivados da Transformada Wavelet, que foram utilizados para o desenvolvimento de um modelo de classificação do nível de poluição da superfície dos isoladores, em três níveis: leve, médio e pesado. O modelo de classificação foi construído com base no algoritmo MLP, treinado com 70% dos dados e validado/testado com 30% restante dos dados. Os resultados apresentados pelo autor mostraram que para as medições em campo, a faixa de frequência com mais acertos foi de 1,6 GHz a 1,8 GHz, apresentando 86% e 84% de acertos para os isoladores de vidro e polimérico, respectivamente. Já com relação aos resultados obtidos pela matriz de confusão, o método obteve 100% de acertos na identificação de isoladores com poluição pesada.

Palangar & Mirzaie (2020) desenvolveram um estudo para determinar e validar um indicador derivado da corrente de fuga e sensível à poluição superficial e que possa

ser utilizado para prever a ocorrência de *flashover*. Esse indicador foi obtido por meio do ângulo de fase da corrente de fuga, sendo obtido por meio do cosseno desse ângulo e representado em termos percentuais. Para tanto, uma base de dados foi construída por meio de experimentos realizados em laboratório, com registros dos sinais da corrente de fuga, considerando o ambiente de ensaio sem névoa (umidade ambiente) e com névoa (umidade relativa 100%). Nos ensaios realizados, os autores utilizaram quatro amostras diferentes de isoladores, sendo três de porcelana e um de vidro temperado. Além disso, quatro níveis diferentes de poluição foram simulados, contemplando os níveis leve, moderado, pesado e muito pesado. A umidade relativa também foi considerada como variável, com testes realizados considerando a umidade ambiente, 77%, 85% e 91%. Para cada uma das combinações, registros da corrente de fuga foram realizados por meio de um sistema de medição, a fim de extrair o percentual do cosseno do ângulo de fase de cada sinal. Com base nos resultados obtidos, os autores verificaram que para o nível de poluição leve e umidade ambiente, o indicador manteve-se abaixo de 30%; já para as condições mais severas de poluição (moderada, pesada e muito pesada) e umidade relativa igual ou maior que 77%, constatou-se que o indicador apresentou valor igual ou maior a 60% em todas essas condições. Embora testes tenham sido realizados, não é explicitado de forma precisa o quantitativo do nível de poluição que o indicador começa a ultrapassar 30%, tendo em vista que esse é o limiar proposto pelos autores para indicar condição severa e propícia para provocar *flashover*.

Os autores Salem *et al.* (2020) apresentaram uma pesquisa focada na proposição de um novo indicador baseado na corrente de fuga e sensível ao nível de poluição superficial de isoladores. Esse indicador é definido por meio de uma relação usando as componentes harmônicas 3^a, 5^a e 7^a da corrente de fuga, representado por $R_{hi} = I_3 / (I_5 + I_7)$. Para construção da base de dados para obtenção, análise e validação do indicador, duas cadeias de isoladores de vidro foram utilizadas, cada uma delas com condições operacionais diferentes. A base de dados foi construída por meio da realização de ensaios de poluição artificial, com variação do nível de poluição contemplando quatro níveis diferentes, com variação do DDSE entre 0,003 mg/cm² (poluição leve) até 0,24 mg/cm² (poluição pesada). Para cada nível de poluição, testes com variação da tensão foram realizados, com taxa de 3 kV/s, até a ocorrência de *flashover*. Os testes foram realizados quatro vezes para as cadeias de isoladores submetidas nas mesmas condições de poluição e umidade, para tratamento estatístico dos parâmetros extraídos dos sinais da corrente de fuga. A partir dos resultados obtidos, os autores relataram que as 3^a, 5^a e 7^a componentes

harmônicas são sensíveis à variação da poluição e umidade, sendo a 3ª componente mais sensível à presença de descargas superficiais na superfície dos isoladores e essa componente pode alcançar aproximadamente 40% da componente fundamental, conforme análises verificadas pelos autores. Nesse sentido, o indicador proposto também demonstrou ser sensível e apresentou alta correlação com o nível de poluição. Na pesquisa, métodos estatísticos foram aplicados para analisar a distribuição da densidade de probabilidade do indicador em função do nível de poluição. As funções obtidas apresentaram diferenças nítidas, de modo a ser possível distinguir os níveis de poluição simulados. E quanto maior o valor de R_{hi} , maior é a probabilidade da ocorrência de *flashover* devido ao acesso de poluição combinado com umidade elevada.

Thanh, Cho & Da (2021) desenvolveram um sistema de monitoramento para identificar isoladores em condições críticas de poluição, a partir de previsões realizadas da corrente de fuga. A base de dados para desenvolvimento do trabalho foi construída por meio de um sistema de telemetria de aquisição e transmissão de dados, tendo em vista que as informações utilizadas foram informações climáticas, contendo dados de umidade relativa, temperatura, ponto de orvalho, precipitação, irradiância e direção e velocidade do vento. Esse sistema embarcado de telemetria foi destinado para funcionar em tempo real, de modo que ele foi instalado em linhas de transmissão de 69 kV e 161 kV. Além dessas informações, também foram realizados registros de sinais da corrente de fuga, para que parâmetros fossem extraídos e utilizados nas modelagens computacionais. Com a base de dados construída, modelos de previsão foram desenvolvidos para estimativa da corrente de fuga utilizando informações meteorológicas. Os autores desenvolveram três modelos, sendo baseados nos seguintes algoritmos: MLP otimizada com Enxame de Partículas (do inglês *Particle Swarm Optimization*), MLP e SVR. As entradas para o desenvolvimento dos modelos foram informações meteorológicas supracitadas e *status* da ocorrência de descargas parciais na superfície dos isoladores considerados para a construção da base de dados. No total, foram mais de seis modelos de previsão, sendo três modelos com diferentes entradas para cada algoritmo de *machine learning* considerado no trabalho. Os autores relataram que para o modelo baseado em MLP otimizada com Enxame de Partículas, valores obtidos para o MAPE ficaram abaixo de 5%; e para os demais modelos, o MAPE apresentou variação entre valores acima de 5% e abaixo de 23%. Dessa forma, o modelo com MLP otimizada com Enxame de Partículas apresentou o melhor desempenho para estimativa da corrente de fuga.

A pesquisa desenvolvida por Castillo-Sierra *et al.* (2021) apresenta um método para monitorar e prever a corrente de fuga para determinar ciclos de lavagem adequados para isoladores em ambientes de alta poluição (por exemplo, zonas costeiras e industriais), visando otimizar o planejamento de manutenção em subestações expostas a poluentes, reduzindo as lavagens nos isoladores, por serem julgadas como desnecessárias. Para o desenvolvimento e validação do método, experimentos foram realizados em uma subestação na costa norte da Colômbia (local com níveis elevados de poluição), em que sinais de corrente de fuga foram registrados usando um amperímetro de garra em isoladores cerâmicos. Dados de temperatura e umidade foram coletados a cada minuto por uma estação meteorológica, possibilitando modelar a corrente de fuga em função do tempo e variáveis climáticas. Para modelar a corrente de fuga, o estudo aplicou uma regressão quadrática ajustada para períodos diurnos e noturnos, corrigida por um modelo autorregressivo para lidar com a dependência temporal. Um gráfico de controle baseado na Média Móvel Ponderada Exponencial (EWMA, do inglês *Exponentially Weighted Moving Average*) foi implementado para monitorar variações e auxiliar na escolha da quantidade de lavagens necessárias por ciclo, usando os valores de pico da corrente de fuga, com parâmetros otimizados via Metodologia de Superfície de Resposta (RSM, do inglês *Response Surface Methodology*) e análise de variância (ANOVA, do inglês *Analysis of Variance*). Comparado ao método adotado como referência, o modelo proposto demonstrou melhor desempenho, dado que um menor valor do MAPE foi obtido na fase de teste, e reduziu lavagens julgadas como desnecessárias, uma vez que o modelo preditivo desenvolvido propõe menos intervenções de lavagem em comparação ao modelo do método de referência.

O trabalho proposto por Slama *et al.* (2022) apresenta um estudo para investigar os efeitos de materiais não solúveis (DDNS) nas características da tensão de *flashover* para analisar a influência desse tipo de poluição na formação de arcos de banda seca, usando modelagens matemáticas da tensão de *flashover* em função do nível de poluição. Os autores explicaram que a construção da base de dados é realizada em laboratório por meio de ensaios de poluição artificial, com variação dos tipos de poluição DDSE e DDNS, para análises experimentais e obtenção de dados para determinação dos parâmetros dos modelos computacionais. Nas soluções preparadas, os autores fizeram uso de cloreto de sódio (NaCl) como poluente solúvel (DDSE) e caulim como poluente não solúvel (DDNS). Amostras de isoladores de material polimérico foram selecionadas para o estudo desenvolvido. As amostras foram pré-condicionadas e poluídas de acordo com as

especificações apresentadas na norma pertinente (IEC 60507, 2013). Além disso, a técnica de rampa de tensão CA (com taxa de 6,5 kV/min.) foi usada para alcançar a tensão de *flashover* com diferentes níveis de poluição, variando-se os índices DDSE e DDNS. Slama *et al.* (2022) também analisaram os fenômenos das descargas de banda seca utilizando termografias, a fim de identificar os pontos com temperaturas mais elevadas na superfície do isolador. Como também realizaram registros fotográficos ao longo dos experimentos, para visualização das descargas de banda seca. Os resultados dos testes mostraram que a tensão de *flashover* do isolador de material polimérico diminuiu substancialmente com o aumento dos valores DDSE e DDNS, considerando que a variação da tensão de *flashover* com o DDSE já tinha sido investigada e identificada a relação diretamente proporcional e não linear. Os autores também identificaram que a partir dos resultados os arcos de banda seca foram consideravelmente influenciados pelos níveis DDSE e DDNS. Com base nos resultados que foram obtidos, um modelo matemático para estimar a tensão de *flashover* foi proposto, levando em consideração o efeito tanto da DDSE quanto do DDNS.

O trabalho proposto por Sopelsa Neto *et al.* (2022) teve como intuito aprimorar a previsão de falhas em isoladores poluídos com base na corrente de fuga, por meio da aplicação de modelos de previsão baseados em inteligência artificial, para antecipar as falhas elétricas que podem ocorrer antes de uma descarga disruptiva. Para tanto, ensaios elétricos de poluição artificial foram realizados em laboratório, a fim de simular o acúmulo de poluição superficial nos isoladores ao longo do tempo e avaliar o efeito na corrente de fuga, desde níveis de poluição leve até níveis suficientes para ocorrer descargas disruptivas. Nos ensaios, 6 isoladores (tipo pino com material de porcelana) foram configurados em paralelo dentro de uma câmara de névoa, com aplicação de poluição artificial sobre a superfície dos isoladores, fazendo-se registros dos sinais da corrente de fuga para todos os níveis de poluição simulados, considerando que o nível de tensão aplicado foi de 8,66 kV. Desses 6 isoladores, apenas 4 deles sofreram descargas disruptivas e os dados referentes a esses isoladores foram utilizados para desenvolvimento dos modelos de previsão. Os ensaios duraram 12 dias, sendo esse o tempo suficiente para ocorrer das descargas disruptivas, para o acúmulo de poluição obtido, embora não seja informado o nível de poluição salina associado à descarga. Com a construção da base de dados, modelos baseados em inteligência artificial (*machine learning* e *deep learning*) foram desenvolvidos, com aplicação dos algoritmos LSTM, *Group Method of Data Handling* (GMDH), ANFIS, além de modelos de *ensemble*

learning (aprendizado conjunto), como *bagging*, *boosting*, *random subspace* e *stacking*. Cada modelo foi configurado e otimizado com diferentes hiperparâmetros para determinar a estrutura mais apropriada para a previsão dos valores de pico da corrente de fuga. Esses modelos foram avaliados por meio de métricas estatísticas, tais como: R^2 , RMSE, MAPE e MAE. Os testes mostraram que o modelo ANFIS com aplicação da Transformada Wavelet apresentou o melhor desempenho, por apresentar os menores valores dos erros (MAE, MAPE e RMSE), destacando-se como o mais exato e robusto nas previsões realizadas. O *ensemble bagging* também obteve bons resultados, embora com valores de erros ligeiramente superiores e maior variabilidade em relação ao ANFIS. A aplicação da Transformada Wavelet contribuiu significativamente para a redução de ruído nos dados, melhorando o desempenho da maioria dos modelos, exceto da LSTM que apresentou desempenho inferior em comparação com abordagens mais adaptativas, como o GMDH e o ANFIS.

A pesquisa desenvolvida por Esmieli *et al.* (2023) propôs e validou critérios para auxiliar na avaliação da condição de isoladores de material polimérico considerando os impactos de envelhecimento assimétrico, envelhecimento completo, poluição e umidade sobre as características da corrente de fuga, além de também desenvolver um modelo de ajuste para previsão de falhas com base nos critérios propostos. Para o desenvolvimento do trabalho, vários testes experimentais e análises de dados foram realizadas, a fim de avaliar o desempenho de isoladores sob diferentes condições de envelhecimento, poluição e umidade. Nesse sentido, três tipos de isoladores (novos, com envelhecimento assimétrico e totalmente envelhecidos) foram expostos a condições controladas de poluição e umidade. A corrente de fuga foi medida com um osciloscópio digital e analisada através da FFT para decomposição em componentes harmônicos de primeira, terceira e quinta ordens. Modelos de ajuste iterativo, com base no método dos mínimos quadrados, foram utilizados para prever variações nas harmônicas em função dos níveis de poluição e envelhecimento. Critérios para auxiliar no diagnóstico, como a razão entre as terceira e quinta componentes harmônicas e o ângulo de fase da corrente de fuga, foram propostos para diferenciar os estados de envelhecimento e condições de poluição dos isoladores. Os autores constataram que a amplitude da corrente de fuga e suas harmônicas aumentam com o grau de poluição e umidade, sendo o efeito mais pronunciado nos isoladores totalmente envelhecidos. E, ainda, o envelhecimento dos isoladores provocou aumento da terceira componente harmônica e redução da quinta, tornando a relação I_{t3}/I_{t5} um critério eficaz para classificar isoladores novos (de 0 até 0,5), envelhecidos

assimetricamente (acima de 0,5 e até 0,9) e totalmente envelhecidos (acima de 0,9). O ângulo de fase (dado em %) também indicou condições de poluição, com valores abaixo de 15% para isoladores limpos e acima de 15% para poluídos, possibilitando a definição de critério que podem ser utilizados no diagnóstico de isoladores.

Os autores Lin & Kuo (2024) propuseram um sistema de previsão da corrente de fuga de isoladores cerâmicos com base em parâmetros ambientais, tais como temperatura, umidade relativa, pressão, velocidade do vento e radiação ultravioleta), utilizando algoritmos baseados em inteligência artificial. Para tanto, uma base de dados foi construída por meio de coletas de dados ambientais e sinais da corrente de fuga, dentro do contexto de uma área localizada na região costeira altamente poluída de Taiwan, usando sensores para monitorar variáveis como temperatura, umidade relativa, pressão atmosférica, velocidade do vento e radiação UV ao longo de 30 meses. Os sinais da corrente de fuga dos isoladores foram registrados continuamente para capturar os efeitos das variações climáticas e de poluição. Utilizando esses dados, três modelos foram desenvolvidos com base em diferentes algoritmos de inteligência artificial - SVR, *Gradiente Boosting Regression* (GBR) e LSTM, para prever a corrente de fuga dos isoladores com base nas condições ambientais. Cada modelo foi avaliado com métricas de desempenho, como MSE, MAE e escore de variância explicada (EVS, do inglês *Explained Variance Score*), com o objetivo de selecionar o modelo que apresentasse previsões mais exatas (menores valores de erros). O modelo LSTM demonstrou de forma consistente o melhor desempenho em comparação com SVR e GBR. A implementação do modelo com melhor desempenho foi integrada a uma plataforma de monitoramento em nuvem para permitir a análise em tempo real e a emissão de alertas de manutenção, categorizando os níveis de contaminação e risco dos isoladores.

3.2 RESUMO DO CAPÍTULO

3.2.1 SÍNTESE

Mediante o levantamento do estado da arte realizado, verifica-se a existência de diversos trabalhos envolvendo monitoramento, diagnóstico e prognóstico de isoladores, com base no nível de poluição superficial. Alguns desses trabalhos propuseram critérios/limiares associados à ocorrência de descargas disruptivas nos isoladores, tanto

de material cerâmico como também de polimérico, com base no conteúdo harmônico da corrente de fuga, sobretudo as componentes harmônicas fundamental, terceira, quinta e sétima, além de relações derivadas dessas componentes (KARADY & AMARH, 1999; SUDA, 2001; KUMAGAI & YOSHIMURA, 2004; SUDA, 2005; PALANGAR & MIRZAIE, 2020; ESMAIELI *et al.*, 2023).

Também foram analisados trabalhos destinados a realizar estimação e monitoramento do nível de poluição superficial (DDSE) do isolador usando também os parâmetros supracitados e outros extraídos do sinal da corrente de fuga, além de grandezas ambientais (LI *et al.*, 2010; MUNIRAJ & CHANDRASEKAR, 2011; PYLARINOS *et al.*, 2012). Alguns trabalhos que se baseiam em prever a classe do nível de poluição (baseado apenas na DDSE) também foram analisados, seja usando ruídos ultrassônicos ou sinais de rádio frequência (FERREIRA, 2011; ROCHA, 2019). E ainda foi constatada a presença de pesquisas focadas em estimar parâmetros da corrente de fuga, haja vista a forte correlação com a poluição superficial do isolador (FERNANDO & GUBANSKI, 1999; KHAFAF & EL-HAG, 2017; GAO *et al.*, 2018; THANH, CHO & DA, 2021; SOPELSA NETO *et al.*, 2022; LIN & KUO, 2024). Ainda referente aos trabalhos que adotam as decisões baseadas na corrente de fuga, um dos trabalhos analisados buscou otimizar os ciclos de lavagens de isoladores (CASTILLO-SIERRA *et al.*, 2021). Pesquisas também foram realizadas para investigar a relação da tensão de *flashover* com o nível de poluição, considerando os tipos de poluição solúvel (DDSE) e não solúvel (DDNS) (JIANYUAN, YUN & XIN, 2008; ZHAO *et al.*, 2013; SLAMA *et al.*, 2022; SOPELSA NETO *et al.*, 2022).

Os trabalhos analisados possuem limitações práticas ou técnicas para aplicação da otimização nos processos de manutenção de limpeza em isoladores, de forma preditiva, uma vez que não possibilitam prever o nível de poluição, contemplando os índices DDSE e DDNS, diretamente ao longo do tempo. Os trabalhos que buscam fazer monitoramento, diagnóstico ou prognóstico com base apenas nos parâmetros da corrente de fuga (incluindo também os trabalhos que propõem limiares/critérios) podem ser influenciados, principalmente, por oscilações de tensão e umidade relativa, podendo gerar tomadas de decisão equivocadas. Além disso, com o estudo dos trabalhos não foi possível constatar a realização de registros sistemáticos dos níveis de poluição natural (DDSE e DDNS), respeitando intervalos de tempo adequados para aplicações práticas, de modo a inviabilizar realização de manutenções (e.g., lavagens) preditivas mais eficientes. Embora um dos trabalhos avaliados busque otimizar os ciclos de lavagens dos isoladores, ainda

não é possível estimar o momento que será necessário a limpeza nos isoladores, de forma objetiva e prática. E, ainda, esse trabalho propõe uma estratégia baseada apenas na corrente de fuga, podendo acarretar no cenário mencionado anteriormente. Além do mais, o uso de estatística clássica, regressão quadrática, pode não identificar variações mais complexas dos valores de pico da corrente de fuga diante de fenômenos intempestivos.

3.2.2 QUADRO SINÓPTICO

Diante da revisão bibliográfica apresentada, a temática abordada neste trabalho já vem sendo estudada por vários anos, embora ainda existam oportunidades para explorar novas perspectivas e soluções. Com o intuito de sintetizar as principais características das pesquisas apresentadas no levantamento do estado da arte, na Tabela 3.1 são apresentadas as contribuições de cada trabalho desenvolvido, como também desta pesquisa.

Com base na Tabela 3.1, verifica-se que o trabalho proposto contempla todas as características supracitadas e algumas características são exclusivas do trabalho desenvolvido (características G e H), por possuir como objetivo principal estimar o momento ótimo para manutenção de limpeza em isoladores de vidro, utilizando modelo de previsão de séries temporais baseado em inteligência artificial para representar a poluição superficial (DDSE e DDNS) ao longo do tempo. Essa abordagem visa solucionar problemas críticos, como a ocorrência de alarmes falsos e omissões de lavagem, que comprometem a eficiência do planejamento de manutenção. Além disso, ao representar a evolução da poluição superficial ao longo do tempo, a metodologia proposta permite prever o momento exato para intervenção e realização de limpeza, reduzindo riscos operacionais, como a ocorrência de descargas disruptivas, devido ao acúmulo de poluição superficial. Com o trabalho proposto sendo aplicado ao contexto de alta contaminação atmosférica, pode-se ter uma alternativa prática para minimizar custos elevados de manutenção, reduzir a necessidade de intervenções frequentes e evitar sobrecargas na alocação de equipes e materiais.

Os benefícios esperados dessa abordagem incluem um planejamento de manutenção mais eficiente, realizado de forma proativa, de modo a melhorar a confiabilidade e o desempenho do sistema elétrico. Em ambientes com elevados níveis de poluição, como regiões costeiras e áreas industriais, com modelos baseados em inteligência artificial é possível prever de maneira confiável os níveis críticos de poluição superficial nos isoladores, antecipando o risco de falhas antes da ocorrência de descargas

disruptivas. Assim, a metodologia desenvolvida e proposta na tese contribui para otimizar a frequência das limpezas e diminuir os custos operacionais, ao mesmo tempo que promove maior segurança e durabilidade dos equipamentos (isoladores e materiais utilizados na manutenção).

Ademais, a metodologia proposta oferece vantagens sobre lavagens periódicas (com cronograma fixo de lavagens e geralmente não considera o acúmulo real da poluição superficial) ao estimar o momento ótimo para limpeza dos isoladores de vidro, evitando intervenções prematuras ou tardias e otimizando tempo e recursos. Ao modelar a dinâmica da poluição, reduz alarmes falsos e omissões, tornando a manutenção mais eficiente e confiável, além de diminuir significativamente os custos com equipes e materiais em lavagens desnecessárias.

Tabela 3.1 – Comparativo dos trabalhos e suas características/contribuições.

Pesquisa	Características/contribuições								
	A	B	C	D	E	F	G	H	I
Karady & Amarh (1999)		•		•	•				
Fernando & Gubanski (1999)		•		•	•				
Suda (2001)		•		•	•				
Kumagai & Yoshimura (2004)		•		•	•				
Suda (2005)		•		•	•				
Jianyuan, Yun & Xin (2008)	•			•		•			•
Li <i>et al.</i> (2010)	•		•	•	•				
Muniraj & Chandrasekar (2011)	•		•	•	•				
Ferreira (2011)	•								•
Pylarinos <i>et al.</i> (2012)		•	•		•				
Zhao <i>et al.</i> (2013)				•	•				•
Khafaf & El-Hag (2017)					•				•
Gao <i>et al.</i> (2018)					•				•
Rocha (2019)	•								•
Palangar & Mirzaie (2020)		•			•				•
Salem <i>et al.</i> (2020)		•		•	•				
Castillo-Sierra <i>et al.</i> (2021)				•	•				•
Thanh, Cho & Da (2021)				•	•				•

Slama <i>et al.</i> (2022)	•		•	•					
Sopelsa Neto <i>et al.</i> (2022)		•	•	•					•
Esmaili <i>et al.</i> (2023)				•	•				•
Lin & Kuo (2024)				•	•				•
Esta pesquisa	•	•	•	•	•	•	•	•	•

Descrição das características/contribuições

- A. Estimativa do nível de poluição superficial (DDSE e/ou DDNS) usando modelos de regressão/previsão.
- B. Apresentação de limiares/critérios da DDSE e/ou DDNS (ou indicadores baseados na corrente de fuga) que indiquem níveis críticos de poluição (iminência de descargas superficiais).
- C. Utilização de parâmetros da corrente de fuga para modelagem (com inteligência artificial ou abordagem estatística clássica) da poluição superficial de isoladores.
- D. Investigação de condições severas de poluição superficial suficientes para provocar descargas superficiais (iminência de descarga disruptiva).
- E. Monitoramento, diagnóstico ou prognóstico de isoladores baseado na análise de parâmetros da corrente de fuga.
- F. Construção de série temporal representativa da poluição natural presente na superfície de isoladores de vidro.
- G. Associação do nível de poluição, parâmetros da corrente de fuga, variáveis ambientais e tempo, para implementação de modelo de previsão de séries temporais dos índices de poluição (DDSE e/ou DDNS).
- H. Proposição de uma metodologia para estimar o momento ótimo para limpeza em isoladores, com base em previsões do nível de poluição, utilizando informações históricas da corrente de fuga, variáveis ambientais e DDSE e/ou DDNS.
- I. Otimização do gerenciamento dos isoladores de vidro, para limpeza serem realizadas de acordo com os *insights* extraídos das previsões.

Fonte: autor (2025).

CAPÍTULO 4

PROCEDIMENTOS PRÁTICOS E SIMULAÇÕES

COMPUTACIONAIS

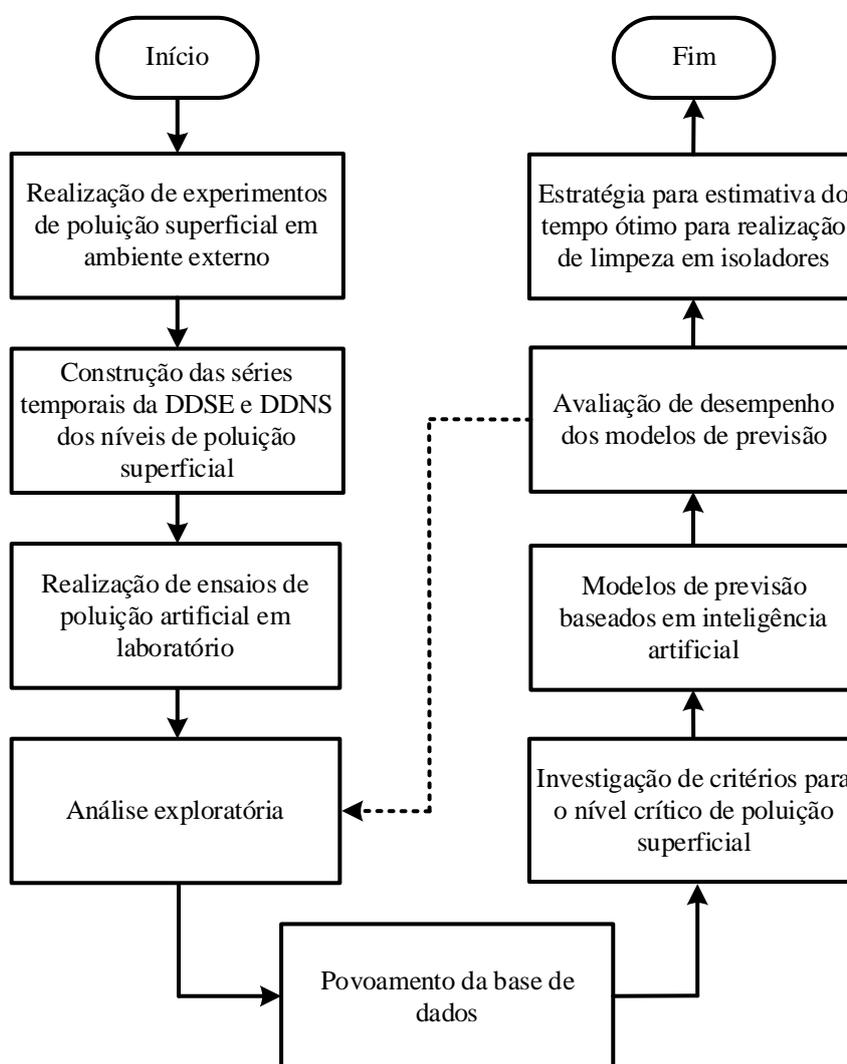
O momento ótimo para realização de manutenção de limpeza em isoladores de vidro foi estimado por meio de modelagens computacionais baseadas em inteligência artificial, utilizando parâmetros da corrente de fuga e séries temporais representativas da poluição (valores dos índices DDSE e DDNS representados ao longo do tempo). Na Figura 4.1 é apresentado um diagrama sumarizado dos procedimentos práticos e simulações computacionais das atividades realizadas para a tese.

Os procedimentos práticos e simulações computacionais contemplaram a construção de séries temporais representativas da poluição (DDSE e DDNS) utilizando dados obtidos de experimentos de exposição de cadeia de isoladores à poluição ambiente. Uma vez identificados os níveis de poluição com os experimentos de poluição ambiente, esses níveis foram simulados em laboratório por meio de ensaios de poluição artificial, a fim de fazer análise da corrente de fuga para os níveis simulados e definir o horizonte temporal das previsões das séries temporais representativas dos índices da DDSE e DDNS. Ainda nos ensaios em laboratório, valores limiares da DDSE e DDNS, que indicassem a iminência de descargas superficiais, foram determinados por meio de análises da corrente de fuga e identificação de radiação ultravioleta emitida pelas descargas, a fim de estimar o nível crítico de poluição superficial.

A partir das informações da corrente de fuga obtidas em laboratório, investigações foram realizadas para verificar os parâmetros da corrente de fuga que mais se correlacionam ao nível de poluição dos isoladores avaliados, por meio de critérios estatísticos. Assim, os parâmetros mais adequados para o processo de modelagem computacional foram definidos, para que modelos baseados em inteligência artificial fossem desenvolvidos e capazes de prever as séries temporais representativas da DDSE e DDNS dos isoladores de vidro. Com os modelos desenvolvidos, métricas estatísticas foram adotadas para avaliação do desempenho, de modo a ser possível selecionar o

modelo com o melhor desempenho, considerando a base de dados construída. Antes de seguir adiante, em uma possível replicação das etapas, é possível que haja necessidade de retornar à análise exploratória, para verificar a necessidade de incluir novos atributos para melhoria do desempenho dos modelos. Uma vez que os modelos tenham sido avaliados e selecionados, aplica-se à estratégia para estimativa do momento ótimo para manutenção de limpeza nos isolados. A realização de todos esses procedimentos possibilitou estimar o momento que a superfície do isolador estará com nível crítico de poluição, na iminência de descargas superficiais. Nas seções seguintes, cada um dos procedimentos será detalhado.

Figura 4.1 – Diagrama simplificado dos procedimentos práticos e simulações computacionais.



Fonte: autor (2025).

4.1 REALIZAÇÃO DE EXPERIMENTOS DE POLUIÇÃO

SUPERFICIAL EM AMBIENTE EXTERNO

A realização de experimentos de poluição superficial em ambiente externo permite entender e acompanhar a evolução do nível de poluição ao longo do tempo, considerando as características geográficas e meteorológicas da região selecionada para os experimentos. Tendo em vista que a poluição ambiental pode ser representada por meio dos índices DDSE e DDNS, eles foram monitorados e coletados durante o período de doze (12) meses, a fim de construir séries temporais e simular os níveis de poluição em laboratório. As etapas executadas de forma ordenadas foram: seleção e tratamento das amostras de isoladores; instalação dos isoladores em ambiente externo; e medições sistemáticas dos níveis de poluição.

4.1.1 SELEÇÃO E TRATAMENTO DAS AMOSTRAS DE ISOLADORES

Para realização dos experimentos em ambiente externo, foram adotados como objetos de teste duas cadeias de isoladores, tipo suspensão, com quatorze¹ isoladores cada uma delas. Esses isoladores são do mesmo fabricante, de vidro temperado e mesmas dimensões físicas, seguindo as características físicas e elétricas apresentadas na Tabela 4.1.

Os isoladores de vidro selecionados para este trabalho não eram novos e todos eles possuíam tempo de operação aproximado, tendo em vista que o tempo exato de operação é desconhecido, visto que eles foram doados por uma empresa de geração e transmissão do setor elétrico. Embora eles não fossem novos, estavam em bom estado de conservação, não apresentando defeitos visuais. Os isoladores foram higienizados, com aplicação de detergente neutro, com o intuito de garantir a remoção completa de impurezas que poderiam estar presentes na superfície dos isoladores.

Após a higienização de todos os isoladores, eles foram numerados para garantir a rastreabilidade e organização durante os experimentos de poluição superficial em

¹ Os quatorze isoladores foram utilizados para possibilitar o depósito de poluição ao longo de doze meses no experimento de poluição ambiente, tendo em vista que dois desses isoladores foram utilizados nas extremidades da cadeia de isoladores para atender uma das exigências da norma (60815-1, 2008).

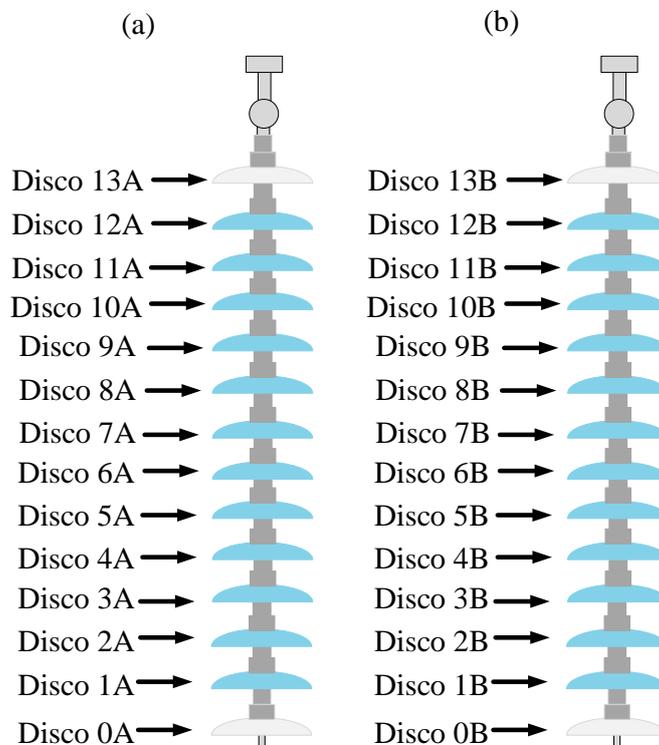
Tabela 4.1 – Características físicas e elétricas dos isoladores de vidro utilizados.

Características físicas		Características elétricas	
Resistência eletromecânica combinada	70 kN	Tensão disruptiva em frequência industrial a seco	80 kV
Resistência ao impacto	45 kN	Tensão disruptiva em frequência industrial sob chuva	50 kV
Distância de escoamento	320 mm	Tensão crítica de impulso atmosférico (positivo)	125 kV
Diâmetro	255 mm	Tensão crítica de impulso atmosférico (negativo)	130 kV
Passo	146 mm	Tensão de perfuração na frequência industrial	130 kV

Fonte: autor (2025).

ambiente externo. As marcações foram realizadas com uso de caneta de tinta permanente, registrando o número de identificação de cada um dos isoladores na região da campânula, para não interferir na funcionalidade da superfície dos isoladores. Durante as marcações, luvas de proteção foram utilizadas para evitar transferência de óleos ou sujeira das mãos para os isoladores. As marcações realizadas nos isoladores seguem uma ordem e formato conforme apresentado na Figura 4.2.

Figura 4.2 – Representação das marcações realizadas nas cadeias (a) A e (b) B de isoladores de vidro.

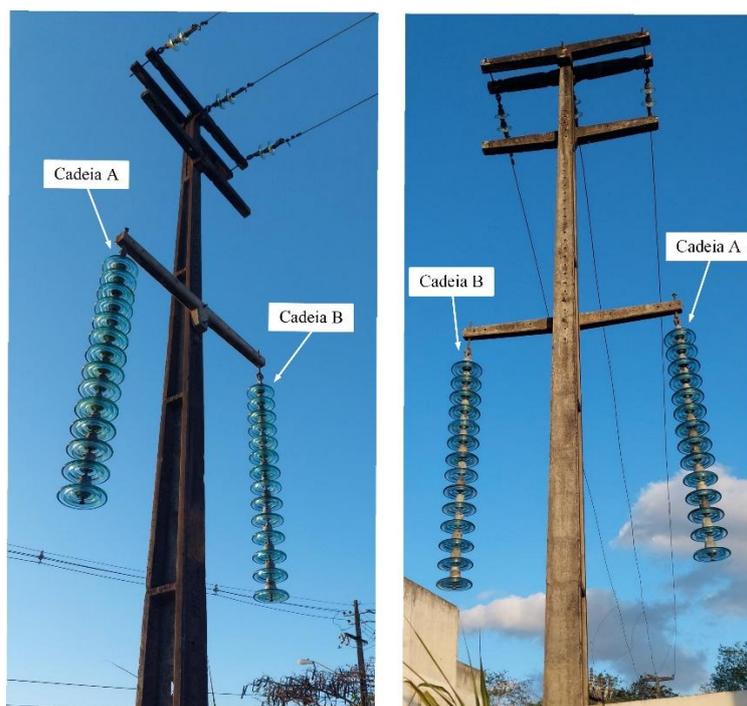


Fonte: autor (2025).

4.1.2 INSTALAÇÃO DOS ISOLADORES EM AMBIENTE EXTERNO

Duas cadeias de isoladores de vidro foram suspensas em uma cruzeta instalada em um poste de concreto armado, em ambiente externo, nas proximidades do Laboratório de Alta Tensão (LAT) pertencente à Universidade Federal de Campina Grande, na cidade de Campina Grande, Paraíba. Uma fotografia das cadeias de isoladores pode ser visualizada na Figura 4.3. Essas cadeias foram instaladas em locais vulneráveis a condições de poluição do ar, por estarem sujeitas a diversas fontes de poluição, incluindo emissões de veículos e atividades industriais próximas, que podem contribuir para a deposição de contaminantes atmosféricos sobre os isoladores. Ainda nas proximidades do local do experimento, há um açude (Açude de Bodocongó) que sofre degradação em virtude de ações antrópicas, provocando também a degradação do ambiente e aumentando a quantidade de contaminantes atmosféricos.

Figura 4.3 – Fotografia das cadeias de isoladores de vidro suspensas em uma cruzeta instalada no poste situado próximo ao LAT.



Fonte: autor (2025).

A instalação das cadeias de isoladores foi cuidadosamente projetada para replicar condições similares às encontradas em sistemas de transmissão de energia, embora os isoladores não tenham sido energizados ao longo da exposição ao ar livre. As cadeias foram posicionadas a uma altura adequada para simular a exposição típica aos ventos, chuvas e variações de temperatura. Além disso, a orientação das cadeias foi escolhida

para maximizar a exposição aos principais fluxos de poluentes. Os isoladores foram espaçados de maneira a evitar interferências mútuas e permitir a livre circulação do ar ao redor, garantindo uma deposição uniforme dos contaminantes. A cruzeta em que as cadeias foram suspensas foi fabricada em material resistente às intempéries, assegurando a integridade estrutural ao longo de todo o período experimental.

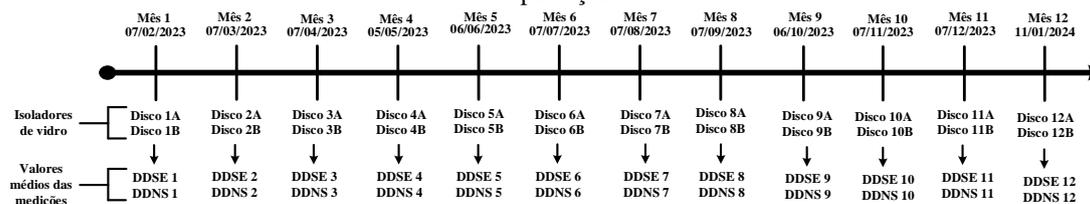
4.1.3 MEDIÇÕES SISTEMÁTICAS DOS NÍVEIS DE POLUIÇÃO

A estratégia adotada para o monitoramento do nível de poluição superficial dos isoladores de vidro ao longo do tempo seguiu as diretrizes estabelecidas na norma IEC 60815-1 (2008). Essa norma fornece procedimentos específicos para avaliar a poluição em termos dos índices DDSE e DDNS, permitindo uma análise detalhada de como esses contaminantes se acumulam na superfície dos isoladores em diferentes condições ambientais ao longo do tempo. A utilização desta norma garantiu que as medições fossem realizadas de forma sistemática e comparável ao longo do tempo, possibilitando a construção de um banco de dados que reflete a evolução da poluição nos isoladores ao longo de 12 meses de estudo.

As medições dos índices de DDSE e DDNS foram realizadas mensalmente durante o período de 12 meses, iniciando a instalação das cadeias de isoladores em 7 de janeiro de 2023 e finalizando em 11 de janeiro de 2024. Para cada um dos meses, foi realizada uma coleta dos depósitos acumulados nos isoladores das duas cadeias usadas nos experimentos. Os isoladores numerados de 1 a 12 foram submetidos a medições em intervalos de 1 a 12 meses, respectivamente, garantindo uma cobertura temporal completa ao longo dos doze meses de experimentos. Os registros foram realizados nas datas conforme apresentado no diagrama da Figura 4.4, sendo a primeira coleta de poluição realizada no dia 7 de fevereiro de 2023, com a retirada dos isoladores numerados como 1A e 1B. Nesse sentido, as demais coletas de poluição superficial dos isoladores restantes foram realizadas de forma análoga, seguindo também as datas apresentadas na Figura 4.4. Dessa forma, ao final do período experimental, foram registradas 12 medições (dos índices DDSE e DDNS) para cada cadeia, permitindo uma análise temporal dos valores médios dos níveis da poluição superficial, considerando as condições ambientais do local utilizado para realização dos experimentos.

Para a coleta dos depósitos de poluição nos isoladores de vidro, seguiu-se os procedimentos padronizados, conforme orientado pelas normas IEC 60815-1 (2008) e

Figura 4.4 – Diagrama da cadeia de isoladores de vidro com as marcações referentes às datas de coleta da poluição.



Fonte: autor (2025).

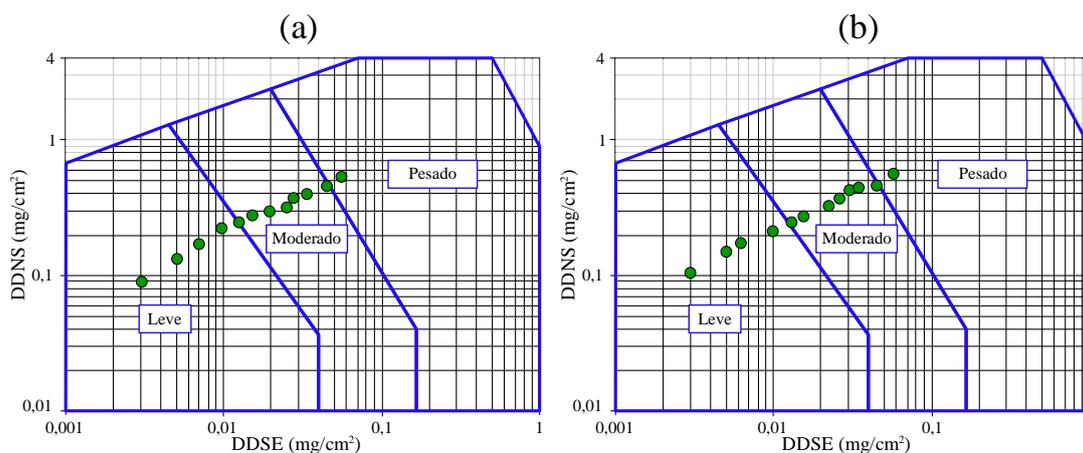
IEC 60507 (2013). As características da poluição ambiente a ser considerada, referente ao local do ambiente no qual foram realizados os experimentos, está mais próxima do tipo A, pois é composta principalmente por partículas sólidas não solúveis e o município que foram realizados os experimentos está situado a mais de 100 km de distância do litoral.

Para mensurar os níveis de poluição ambiente, os índices DDSE e DDNS foram determinados por meio da lavagem de cada um dos isoladores expostos à poluição. Para isso, a condutividade da água utilizada no processo de lavagem foi medida. Para realizar a coleta de poluição, utilizou-se um recipiente com 300 ml de água destilada (com condutividade menor que 0,001 S/m), para umidificar um algodão. Assim, utilizando-se o algodão, esfregou-se o isolador até remover toda a camada de poluição, armazenando o líquido da lavagem em outro recipiente. O algodão empregado na limpeza foi inserido repetidas vezes no recipiente, contendo água com a poluição derivada da superfície do isolador. Depois disso, a medição da condutividade foi realizada, para possibilitar o cálculo da DDSE. O cálculo desse índice foi realizado considerando os valores da área do disco do isolador (superfície do vidro temperado), da condutividade e da temperatura, tendo em vista que a DDSE se refere a uma concentração de poluição sobre determinada área. Para o cálculo da DDNS, inicialmente a água contendo poluição foi filtrada, utilizando um filtro de graduação equivalente a GF/A 1,6 μm . Em seguida, a umidade do filtro foi retirada e a massa (g) dos resíduos foi obtida.

A norma IEC 60815-1 (2008) propõe cinco níveis de poluição, sendo eles: muito leve, leve, médio, pesado e muito pesado. Em virtude de aspectos práticos, a classificação foi reduzida para três níveis, considerando apenas os níveis de poluição leve (junção de muito leve e leve), moderado e pesado (junção de pesado e muito pesado). Considerando essa adaptação e dado que as medições dos níveis de poluição (DDSE e DDNS) foram realizadas, as quais foram resultantes da poluição natural, os dados foram processados e representados graficamente, em função dos níveis dos índices DDSE e DDNS. Os valores da DDSE e DDNS foram inseridos no plano cartesiano logarítmico para identificar o nível

de poluição, considerando o gráfico apresentado em norma, conforme apresentado na Figura 4.5. Os pontos apresentados nos gráficos são referentes a intervalos de meses diferentes, que cresce da esquerda para direita, já que foi verificado o crescimento do nível de poluição ao longo do tempo. Para obtenção dos valores dos indicadores DDSE e DDNS, as equações (2.1), (2.2), (2.3), (2.4) e (2.5) apresentadas no Capítulo 2 e definidas na norma IEC 60815-1 (2008) foram utilizadas, de modo que foi possível verificar o aumento da poluição ao longo dos meses, para as cadeias de isoladores A e B.

Figura 4.5 – Níveis de poluição mensal considerando os valores da DDSE e DDNS para as cadeias de isoladores (a) A e (b) B.



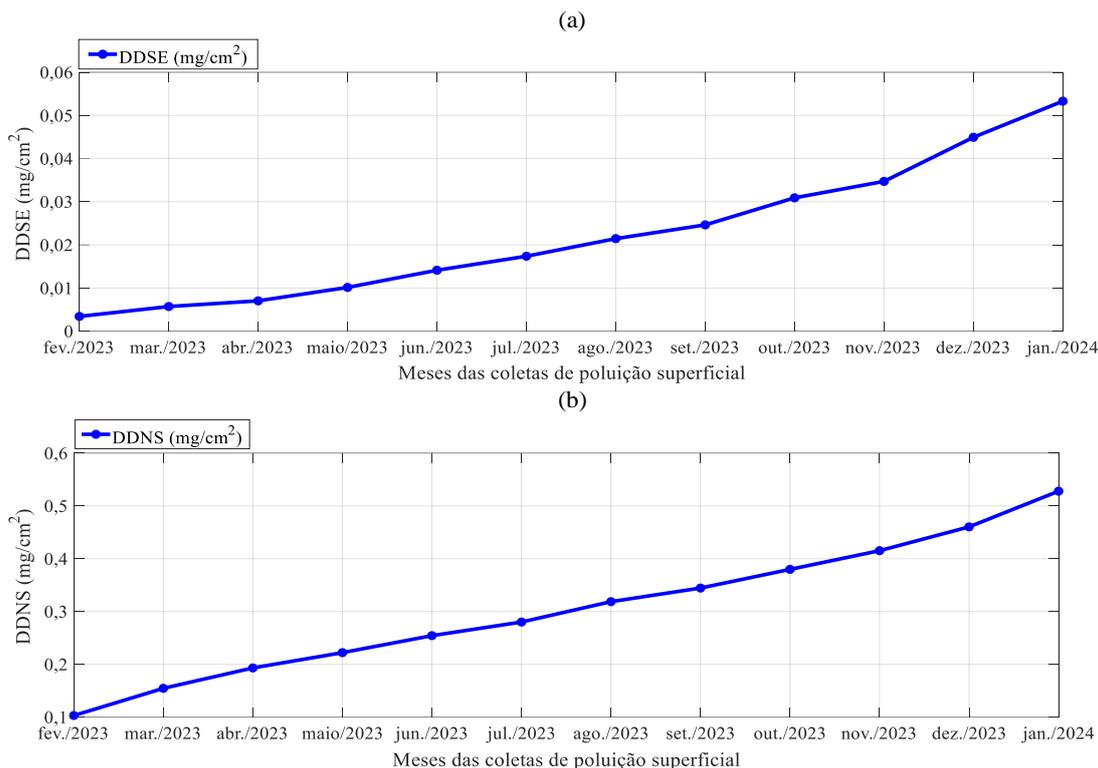
Fonte: autor (2025).

4.2 CONSTRUÇÃO DAS SÉRIES TEMPORAIS DA DDSE E DDNS DOS NÍVEIS DE POLUIÇÃO SUPERFICIAL

A estratégia para a construção das séries temporais dos índices DDSE e DDNS foi fundamentada em medições mensais acumulativas, realizadas ao longo de 12 meses. Cada isolador da cadeia foi submetido a um período específico de exposição à poluição antes da medição, refletindo diferentes intervalos de acúmulo. Por exemplo, as medições dos níveis de poluição dos isoladores A1 e B1 foram feitas após um mês de exposição, enquanto as medições referentes aos isoladores A2 e B2 ocorreram no segundo mês, refletindo a poluição acumulada ao longo de dois meses, e assim por diante até a realização das coletas de poluição nos isoladores A12 e B12, que acumularam a poluição ao longo de 12 meses. Os valores dos índices de poluição mensal das duas cadeias de isoladores foram utilizados para determinar os valores médios dos índices da DDSE e DDNS, para constituir as séries temporais da DDSE e DDNS. A estratégia adotada

permitiu a construção de séries temporais que representassem a evolução dos níveis de poluição ao longo do tempo, fornecendo 12 níveis de poluição distintos medidos, mês a mês, de janeiro de 2023 até janeiro de 2024. Assim, obteve-se um panorama detalhado da variação dos índices DDSE e DDNS em resposta às condições ambientais e sazonais. As séries temporais representativas dos níveis de poluição superficial (DDSE e DDNS) são apresentadas na Figura 4.6.

Figura 4.6 – Níveis da (a) DDSE e (b) DDNS, considerando a média mensal dos valores desses índices de cada cadeia.



Fonte: autor (2025).

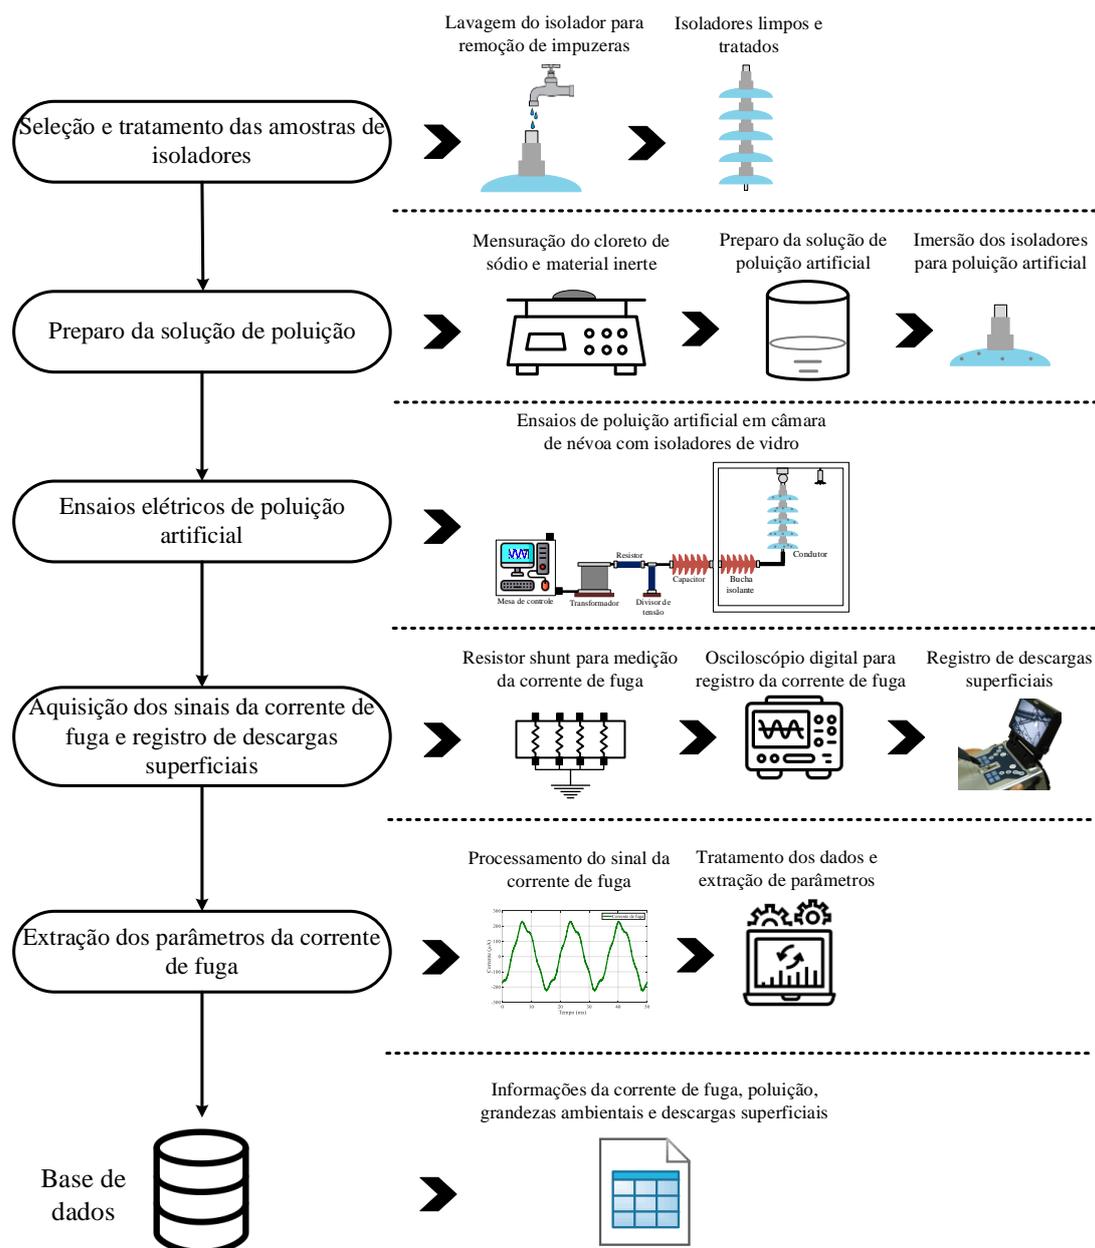
O objetivo principal da construção das séries temporais dos índices DDSE e DDNS é fornecer dados que possam ser utilizados como referência para os ensaios subsequentes em laboratório, permitindo a replicação controlada das condições de poluição observadas ao longo dos experimentos que contemplaram 12 meses. As séries temporais são capazes de representar as flutuações e os picos de poluição ao longo do tempo, fornecendo informações úteis para análises do efeito da poluição nos isoladores. Ao entender como os níveis de DDSE e DDNS variam mensalmente, foi possível realizar ensaios em laboratório para refletir as condições reais enfrentadas pelos isoladores, possibilitando que os resultados dos ensaios fossem representativos e aplicáveis ao mundo real.

Embora a construção das séries temporais ao longo de 12 meses forneça uma visão abrangente das variações de poluição em um ano, essa abordagem possui limitações. A análise de apenas um ciclo anual não permite a identificação de padrões sazonais robustos, pois a sazonalidade só pode ser confirmada com dados de pelo menos dois anos. No entanto, mesmo com essa limitação, as séries temporais abrangem todas as estações do ano e variações climáticas, fatores cruciais que afetam os níveis de poluição superficial nos isoladores. Nesse sentido, uma gama completa de condições ambientais é contemplada, de modo possibilitar uma análise detalhada do impacto dessas variações sazonais sobre os níveis de poluição. Isso permite identificar tendências e padrões específicos para cada estação, contribuindo para a compreensão de como diferentes condições climáticas influenciam a acumulação de poluentes. Além disso, essas séries temporais, em conjunto com outras informações referentes à corrente de fuga, fornecem informações valiosas, que podem ser utilizados para prever a dinâmica da poluição superficial de isoladores em cenários futuros, tornando-se um recurso de grande valia para estratégias de manutenção de limpeza.

4.3 REALIZAÇÃO DE ENSAIOS DE POLUIÇÃO ARTIFICIAL EM LABORATÓRIO

Os ensaios de poluição artificial foram realizados em laboratório de alta tensão, com o intuito de construir uma base de dados, que permitisse simular os níveis de poluição identificados ao longo dos 12 meses considerados nos experimentos de poluição ambiente. Para cada nível de poluição, ensaios elétricos foram realizados, possibilitando realizar registros de sinais da corrente de fuga, níveis de tensão aplicada sobre a cadeia de isoladores e informações de grandezas ambientais. A construção da base de dados contemplou uma sequência de procedimentos, os quais são ilustrados no diagrama da Figura 4.7 e todas as etapas são descritas a seguir.

Figura 4.7 – Diagrama dos procedimentos laboratoriais realizados para construção do banco de dados.



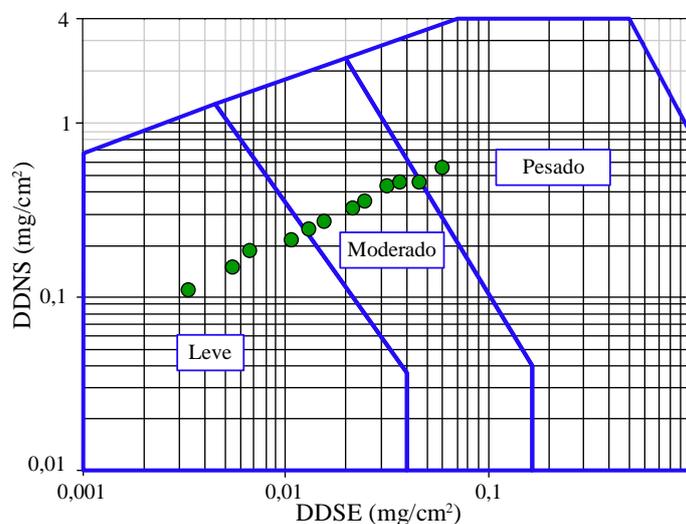
Fonte: autor (2025).

4.3.1 PREPARO DA SOLUÇÃO DE POLUIÇÃO

Para simular de forma artificial os níveis de poluição superficial registrados ao longo dos 12 meses, que foram identificados no gráfico logarítmico apresentado na Figura 4.8, fez-se necessário preparar uma solução de poluição seguindo as instruções apresentadas nas normas pertinentes (IEC 60815-1, 2008; IEC 60507, 2013), considerando a aplicação dos índices DDSE e DDNS, bem como a associação do primeiro

índice com a condutividade elétrica. A combinação desses índices determina o nível de poluição local, o qual os isoladores estão submetidos.

Figura 4.8 – Níveis de poluição mensal considerando os valores da DDSE e DDNS, para simulação em laboratório de alta tensão.



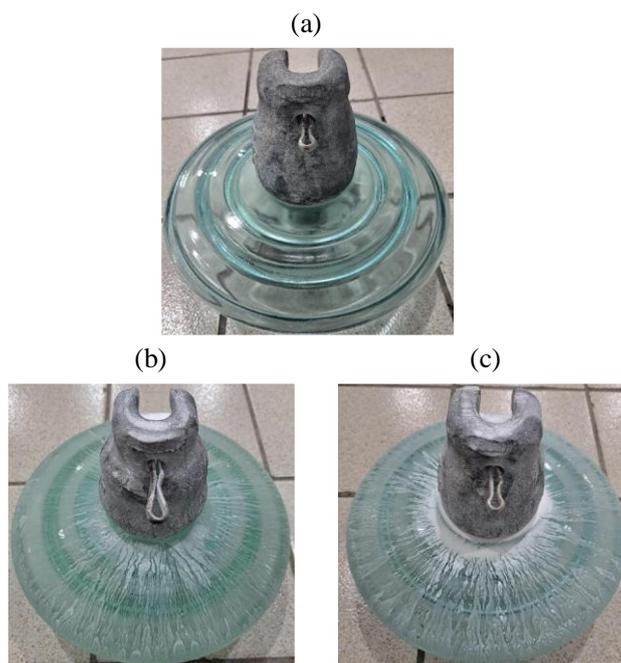
Fonte: autor (2025).

O preparo da poluição artificial foi baseado na norma IEC 60507 (2013), que trata, dentre outros tópicos, sobre a execução de testes em isoladores com poluição artificial. Para isso, iniciou-se com a preparação da solução salina, constituída por água, material inerte e sal de cozinha. Como material inerte, usou-se o caulim, sendo a quantidade variável de acordo com o nível de DDNS a ser simulado e considerando a relação entre caulim e DDNS determinada em norma, dado que para alcançar $DDNS = 0,1 \text{ mg/cm}^2$ é preciso ter 40 gramas de caulim para cada litro; já a quantidade de cloreto de sódio variou conforme o nível da condutividade elétrica desejada para solução, expresso em mS/cm, tendo em vista que a norma apresenta uma tabela (Tabela 2.1) contendo as relações aproximadas entre a condutividade e a DDSE (IEC 60507, 2013). Para ambos os índices, buscou-se alcançar os valores da DDSE e DDNS registrados ao longo dos experimentos de 12 meses em ambiente externo. Dessa forma, as soluções de poluição artificial foram preparadas, considerando a variação dos índices DDSE e DDNS.

Uma vez preparadas as soluções salinas para todos os níveis simulados de poluição, contemplando os 12 registros realizados ao longo de 12 meses e as faixas de poluição baixa, média e pesada, elas foram aplicadas na superfície do isolador por meio da imersão de cada um deles na solução. Para o processo de secagem das amostras de isoladores, esperaram-se 24 horas para o início da realização do ensaio com as amostras de isoladores, para garantir a secagem da superfície de cada um dos isoladores ensaiados.

A forma de aplicação da solução da poluição se deu por meio da imersão do isolador na solução, a fim de se obter uma distribuição uniforme da solução salina. É importante destacar que antes de cada aplicação da solução de poluição, os isoladores foram higienizados, com aplicação de detergente neutro, com o intuito de garantir a remoção completa de impurezas que poderiam estar presentes na superfície do isolador. Na Figura 4.9 são apresentadas amostras de isoladores higienizadas, poluídas imediatamente após o depósito da solução salina e após o processo de secagem.

Figura 4.9 – Fotografias do (a) isolador higienizado, (b) isolador poluído imediatamente após o depósito da solução salina e (c) isolador após o processo de secagem.



Fonte: autor (2025).

4.3.2 SELEÇÃO E TRATAMENTO DAS AMOSTRAS DE ISOLADORES

Para a realização dos ensaios, foram adotados como objetos de teste cinco isoladores de vidro, tipo suspensão, para compor uma cadeia dimensionada para um sistema de 69 kV. Esses isoladores são do mesmo fabricante, de vidro temperado e mesmas dimensões físicas, seguindo as características físicas e elétricas apresentadas na Tabela 4.1. Na Figura 4.10, são apresentadas as amostras dos isoladores empregados para o desenvolvimento do trabalho, antes do depósito de poluição.

Os isoladores de vidro selecionados para este trabalho foram ensaiados, para investigação das características elétricas do sinal da corrente de fuga. Esses isoladores não eram novos e todos eles possuíam tempo de operação aproximado, tendo em vista

que o tempo exato de operação é desconhecido, visto que eles foram doados por uma empresa de geração e transmissão do setor elétrico. Embora eles não fossem novos, estavam em bom estado de conservação, não apresentando defeitos visuais, conforme pode ser verificado na Figura 4.10.

Figura 4.10 – Fotografia das amostras de isoladores utilizados nos ensaios elétricos em laboratório.

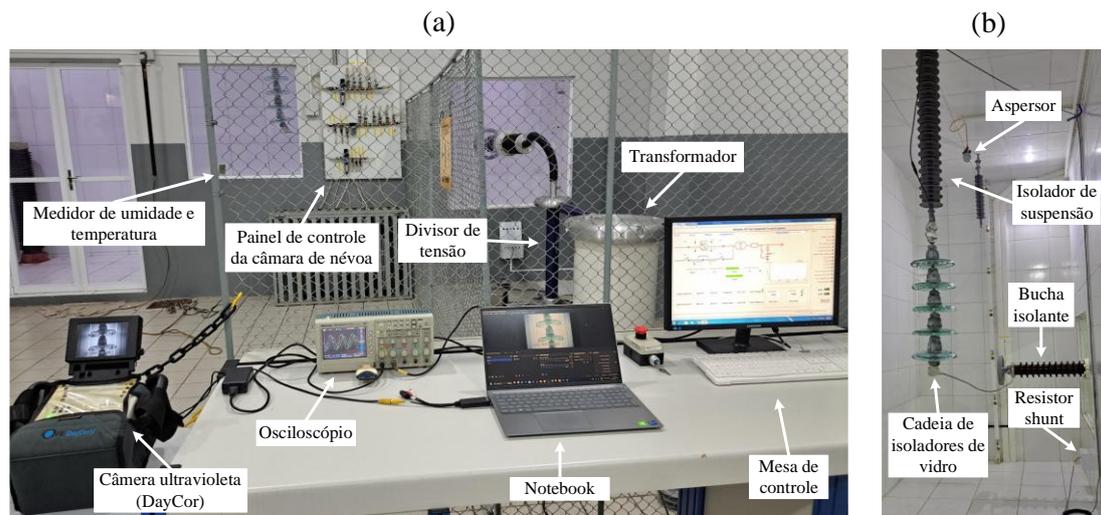


Fonte: autor (2025).

4.3.3 ENSAIOS ELÉTRICOS DE POLUIÇÃO ARTIFICIAL

Para a realização dos ensaios, os isoladores foram instalados no interior de uma câmara de névoa com o intuito de simular os níveis de poluição registrados ao longo dos experimentos com poluição ambiente. As dimensões da câmara de névoa são 6,5 m x 2,0 m x 4,0 m e possibilita minimizar os efeitos da temperatura e da umidade ambiente, possibilitando que essas grandezas se mantenham praticamente constantes ao longo dos ensaios. Na Figura 4.11, são apresentadas fotografias do arranjo experimental utilizado para monitoramento da corrente de fuga e descargas superficiais, considerando as partes interna e externa do ambiente de ensaios.

Figura 4.11 – Fotografias das partes (a) externa e (b) interna do ambiente de ensaios elétricos.



Fonte: autor (2025).

Os ensaios foram divididos em duas partes, sem aplicação de névoa e com aplicação de névoa, para o mesmo nível de poluição depositada na superfície dos isoladores ensaiados. Cada ensaio sem aplicação de névoa foi realizado com tempo de ensaio de duas horas. Esse tempo é necessário para o isolador entrar em estado de operação verossímil à situação de campo, sobretudo em relação a estabilização térmica. Após esse intervalo de tempo, dez medições dos sinais da corrente de fuga e tensão aplicada na cadeia de isoladores foram realizadas, além dos registros das grandezas ambientais.

Nos ensaios com névoa, um aspersor foi utilizado para geração da névoa no interior do ambiente da câmara de névoa, tendo o cuidado para evitar a incidência direta da névoa sobre a cadeia de isoladores. A névoa foi gerada com baixa intensidade com o intuito de tornar a camada de poluição condutiva. A pressão do ar e no reservatório de água foi de 400 kPa. A condutividade da água utilizada para gerar a névoa durante os ensaios foi de 0,35 mS/cm. A névoa foi aplicada previamente por um período de 10 minutos antes da energização, a fim de proporcionar o umedecimento da superfície dos isoladores (umidade no ambiente de ensaio atingir 100%) e permitir que a umidade se estabilizasse. Esse intervalo de tempo foi o suficiente para a camada de poluição sobre a superfície dos isoladores atingir a condutividade máxima, haja vista que foi constatada a estabilidade do crescimento da corrente de fuga.

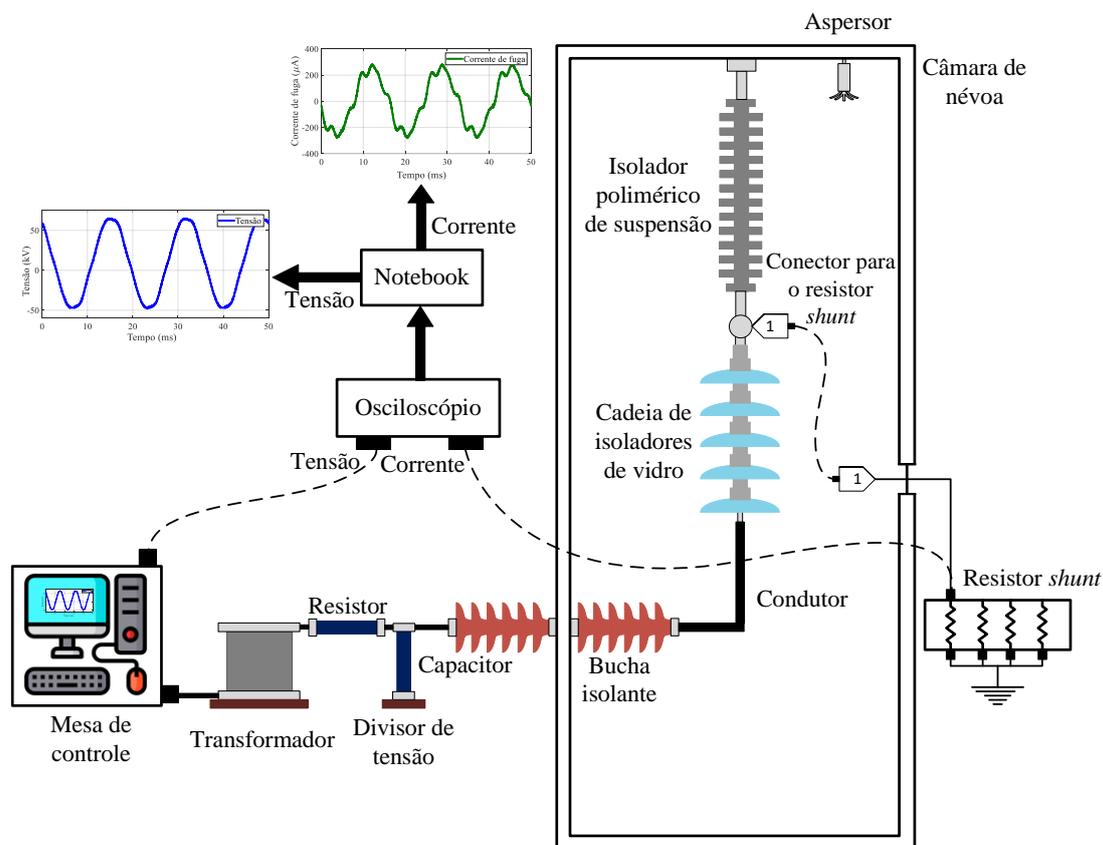
Uma vez os isoladores umedecidos, a cadeia de isoladores foi energizada, com aplicação de tensão alternada na frequência industrial, durante um período de 30 minutos, com aplicação de névoa, antes de registrar os sinais da corrente de fuga e tensão aplicada.

Esse intervalo de tempo foi o suficiente para que a corrente de fuga se estabilizasse, nas condições do ensaio elétrico realizado. Esse tempo não deve ser adotado de modo absoluto, pois esse tempo depende de vários fatores, como a temperatura ambiente, a umidade relativa, a condutividade da névoa e as características do isolador.

4.3.4 AQUISIÇÃO DOS SINAIS DA CORRENTE DE FUGA E REGISTROS DE DESCARGAS SUPERFICIAIS

A aquisição dos sinais da corrente de fuga foi realizada a partir do arranjo experimental apresentado na Figura 4.12. O arranjo é composto por uma mesa de controle, um transformador elevador de tensão (220V/100 kV, 15 kVA), um divisor de tensão capacitivo (relação de transformação de 30000:1), o objeto de teste (cadeia de isoladores de vidro temperado) em série com resistor *shunt* de resistência de 1 k Ω e osciloscópio digital.

Figura 4.12 – Esquema do arranjo experimental utilizado nos ensaios elétricos, para simulação de poluição artificial.



Fonte: autor (2025).

Os sinais de corrente de fuga foram obtidos indiretamente por meio da medição da tensão sobre o resistor *shunt*. As formas de onda da corrente e tensão foram digitalizadas por meio de um osciloscópio digital, para que pudessem ser armazenadas em um computador. Para cada nível de poluição, foram realizados dez registros de sinais de corrente de fuga.

Ao longo dos ensaios de poluição artificial, a tensão permaneceu praticamente constante, com valores médios de 41,8 kV e 41,5 kV, para ensaios sem névoa e com névoa, respectivamente. Os valores de temperatura e umidade relativa também foram registrados, sabendo que os seus valores médios ao longo dos ensaios foram de 25,9 °C e 71,7%, nessa ordem, para os ensaios sem névoa; e 25,6 °C e 100,0%, respectivamente, para os ensaios com névoa. Os dados das estatísticas descritivas dos ensaios sem névoa e com névoa são apresentados nas Tabelas 4.2 e 4.3, respectivamente, considerando os valores da tensão eficaz (RMS) e dos parâmetros ambientais.

Tabela 4.2 – Estatística descritiva dos valores de tensão, temperatura, umidade e pressão, sem névoa.

Parâmetros estatísticos	Tensão RMS	Temperatura	Umidade
Número de amostras	120	12	12
Média	41,8 kV	25,9 °C	71,7%
Mediana	41,5 kV	25,8 °C	72,0%
Desvio padrão	0,2 kV	0,5 °C	0,9%
Mínimo	41,2 kV	25,1 °C	70,0%
Máximo	41,7 kV	26,9 °C	73,0%

Fonte: autor (2025).

Tabela 4.3 – Estatística descritiva dos valores de tensão, temperatura, umidade e pressão, com névoa.

Parâmetros estatísticos	Tensão RMS	Temperatura	Umidade
Número de amostras	120	12	12
Média	41,5 kV	25,6 °C	100,1%
Mediana	41,7 kV	25,5 °C	100,0%
Desvio padrão	0,4 kV	0,5 °C	0,0%
Mínimo	40,7 kV	24,9 °C	100,0%
Máximo	42,2 kV	26,7 °C	100,0%

Fonte: autor (2025).

As descargas superficiais foram registradas por meio da análise dos sinais da corrente de fuga e registros de vídeos realizados por meio de uma câmera sensível às emissões na faixa de frequência do ultravioleta. As imagens foram registradas durante os ensaios de aplicação de tensão nominal sobre a cadeia de isoladores adotada como objeto de teste, para todas as condições de poluição superficial simuladas, considerando as

situações sem névoa e com névoa. As imagens foram captadas na faixa de luz visível (para registro do isolador) e na faixa da radiação ultravioleta (para registro da manifestação UV), conforme apresentado na Figura 4.13.

Figura 4.13 – Imagens registradas pela câmera UV durante o ensaio de aplicação de tensão.



Fonte: autor (2025).

A câmera UV para a registro de imagens e vídeos durante os ensaios elétricos é do modelo Daycor II, fabricada pela Ofil Systems. A câmera possui uma resolução temporal de aproximadamente 30 FPS. Para a realização de registros de vídeos em um computador portátil, foi necessário a utilização de uma placa de captura de vídeo. O registro dos quadros foi realizado no sistema colorido RGB. O registro das imagens ou quadros foi realizado no sistema colorido RGB (resolução de bits de 24 bits) e resolução espacial de 720×480 . Na Figura 4.14, uma fotografia da câmera utilizada é apresentada.

Figura 4.14 – Fotografia da câmera Daycor II fabricada pela Ofil Systems.



Fonte: autor (2025).

4.3.5 EXTRAÇÃO DOS PARÂMETROS DA CORRENTE DE FUGA

Uma vez que os sinais de corrente de fuga foram registrados, os seus parâmetros foram determinados. Os parâmetros foram determinados por meio da utilização de uma ferramenta computacional com capacidade de resolver problemas numéricos. Como grande parte desses parâmetros são componentes harmônicas da corrente de fuga, a FFT foi empregada para extração dessas componentes, devido a sua eficiência computacional para calcular a Transformada de Fourier Discreta (TFD). Para cada sinal de corrente de fuga registrado, foram utilizadas 2500 amostras para aplicar a FFT, contemplando uma janela de tempo de três ciclos.

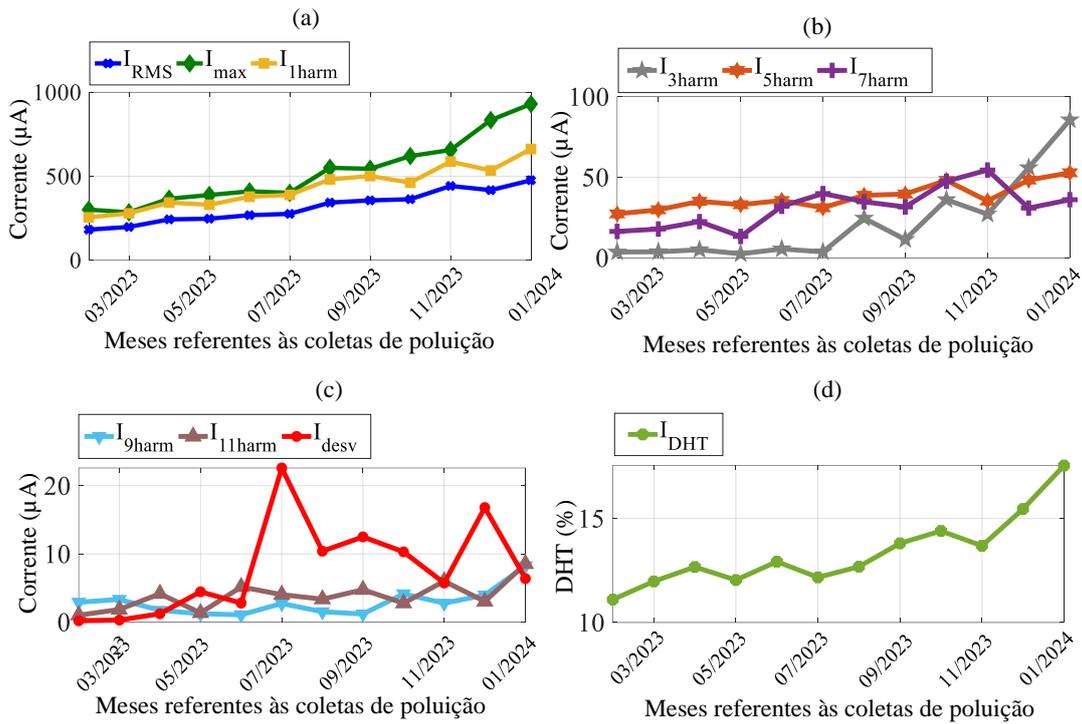
Os parâmetros extraídos dos sinais de corrente de fuga foram: valor eficaz (I_{RMS}), valor de pico (I_{pico}), Distorção Harmônica Total (DHT) (I_{DHT}), nível CC (I_{CC}), componente fundamental (I_{1Harm}), 3ª componente harmônica (I_{3Harm}), 5ª componente harmônica (I_{5Harm}), 7ª componente harmônica (I_{7Harm}), 9ª componente harmônica (I_{9Harm}) e 11ª componente harmônica (I_{11Harm}). Uma vez que as componentes harmônicas foram obtidas, a DHT percentual foi obtida, a fim de analisar sua relação com o nível de poluição. Já em relação aos valores de pico e eficaz da corrente de fuga, o primeiro foi obtido a partir do valor máximo do sinal de corrente de fuga e o valor eficaz por meio do RMS.

4.3.6 ANÁLISE EXPLORATÓRIA

Para a análise exploratória dos dados, fez-se necessário a realização da estatística descritiva dos parâmetros da corrente de fuga, tensão e grandezas ambientais. Para os parâmetros derivados da corrente de fuga, obtiveram-se os dados e foram ilustrados graficamente nas Figuras 4.15 e 4.16, para os ensaios sem névoa e com névoa, nessa ordem; enquanto para os dados referentes às grandezas ambientais e tensão aplicada ao longo dos ensaios foram obtidos os dados apresentados nas Tabelas 4.2 e 4.3.

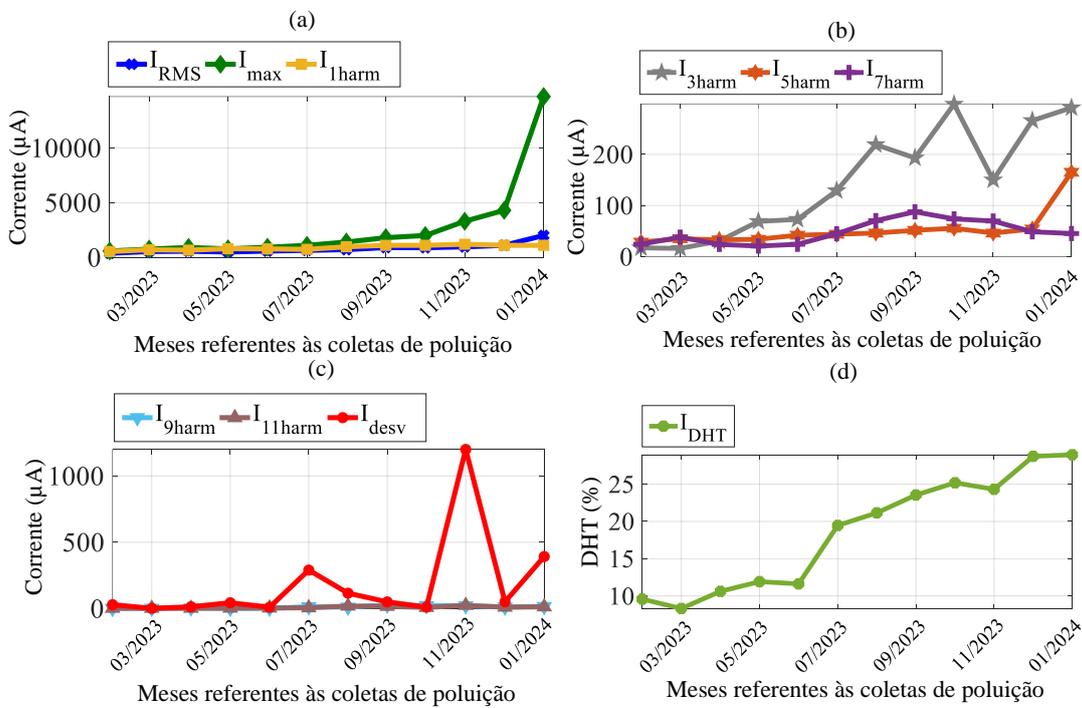
Os valores dos parâmetros da corrente de fuga ilustrados graficamente nas Figuras 4.15 e 4.16 foram usados para construir as matrizes de correlação baseadas nos coeficientes de correlação de Pearson e de Kendall. Esses coeficientes possibilitam medir o grau da correlação (e a direção dessa correlação – se positiva ou negativa) entre duas variáveis. As matrizes obtidas são apresentadas nas Figuras 4.17 (considerando o coeficiente de Pearson) e 4.18 (considerando o coeficiente de Spearman), as quais possibilitam verificar os parâmetros que mais se correlacionam com o índice DDSE e DDNS, para as situações sem névoa e com névoa. Considerando as matrizes com os coeficientes de Pearson e Spearman, para as situações sem névoa e com névoa, os parâmetros da corrente de fuga com correlação forte e muito forte, de acordo com a Tabela 2.2, foram: o valor eficaz da corrente de fuga, o seu valor pico, a sua componente harmônica fundamental, as suas 3^a e 5^a componentes harmônicas e a sua DHT. Os parâmetros apresentaram correlação forte e muito forte, pois os coeficientes obtidos para os parâmetros estão dentro da faixa definida por $0,7 \leq \text{correlação} < 1$.

Figura 4.15 – Valores médios dos parâmetros da corrente de fuga obtidos dos ensaios de poluição sem névoa: (a) I_{RMS} , I_{Max} , e I_{1Harm} ; (b) I_{3Harm} , I_{5Harm} e I_{7Harm} ; (c) I_{9Harm} , I_{11Harm} e I_{desv} ; (d) I_{DHT} .



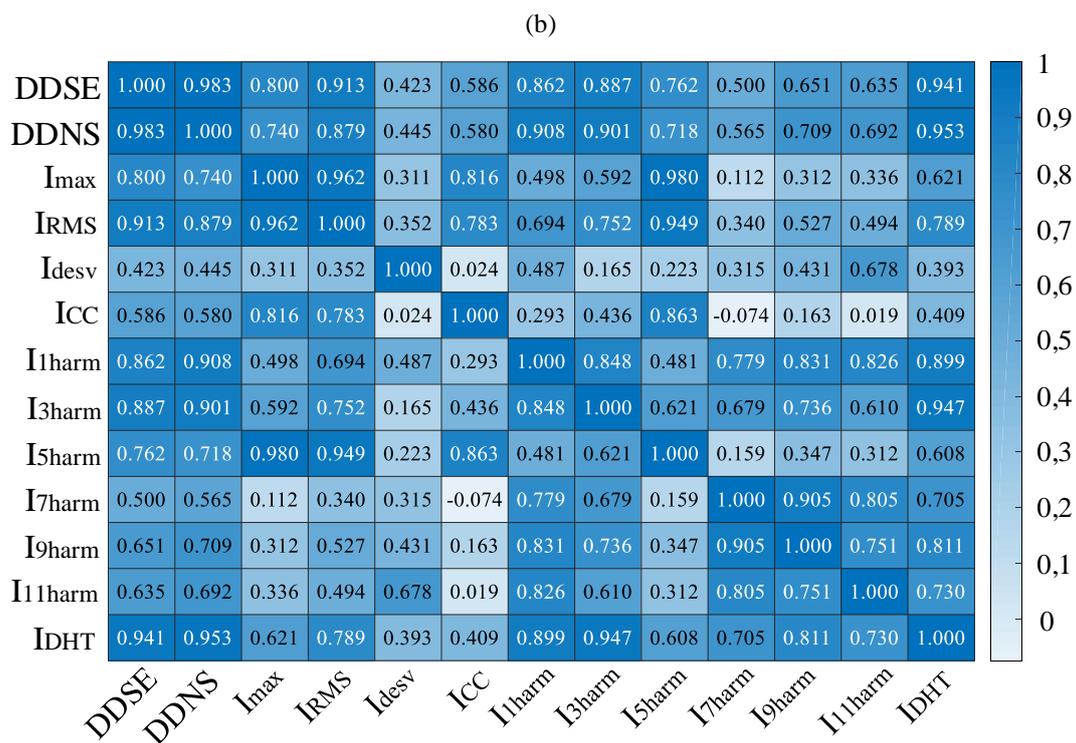
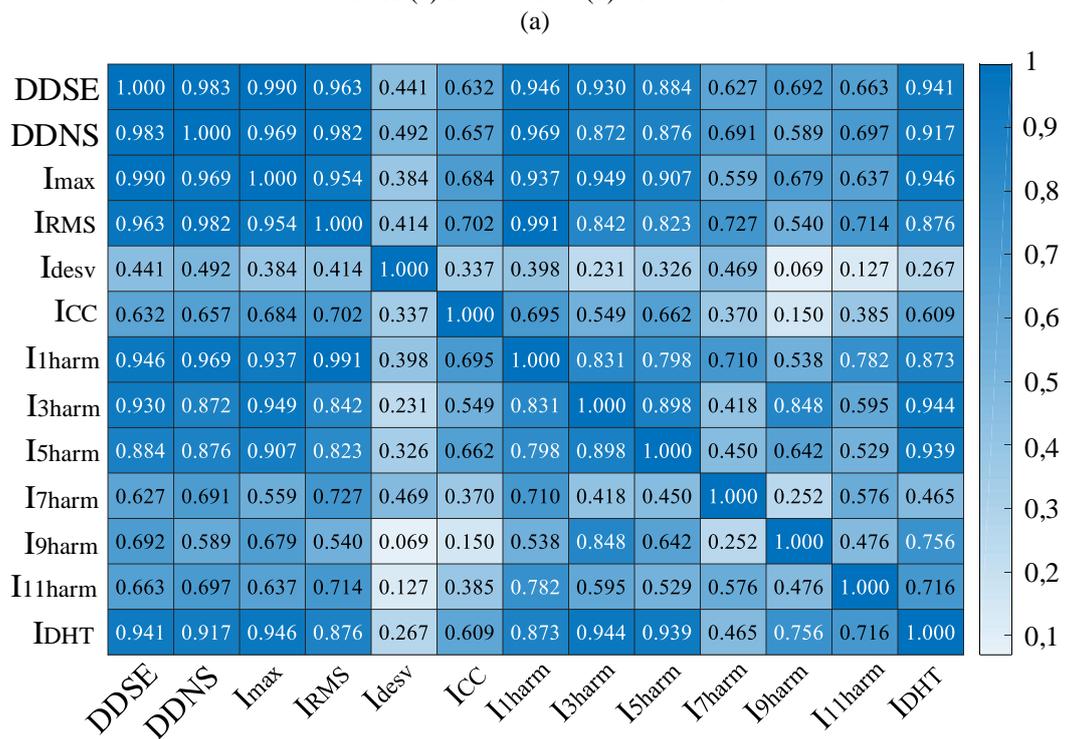
Fonte: autor (2025).

Figura 4.16 – Valores médios dos parâmetros da corrente de fuga obtidos dos ensaios de poluição com névoa: (a) I_{RMS} , I_{Max} , e I_{1Harm} ; (b) I_{3Harm} , I_{5Harm} e I_{7Harm} ; (c) I_{9Harm} , I_{11Harm} e I_{desv} ; (d) I_{DHT} .



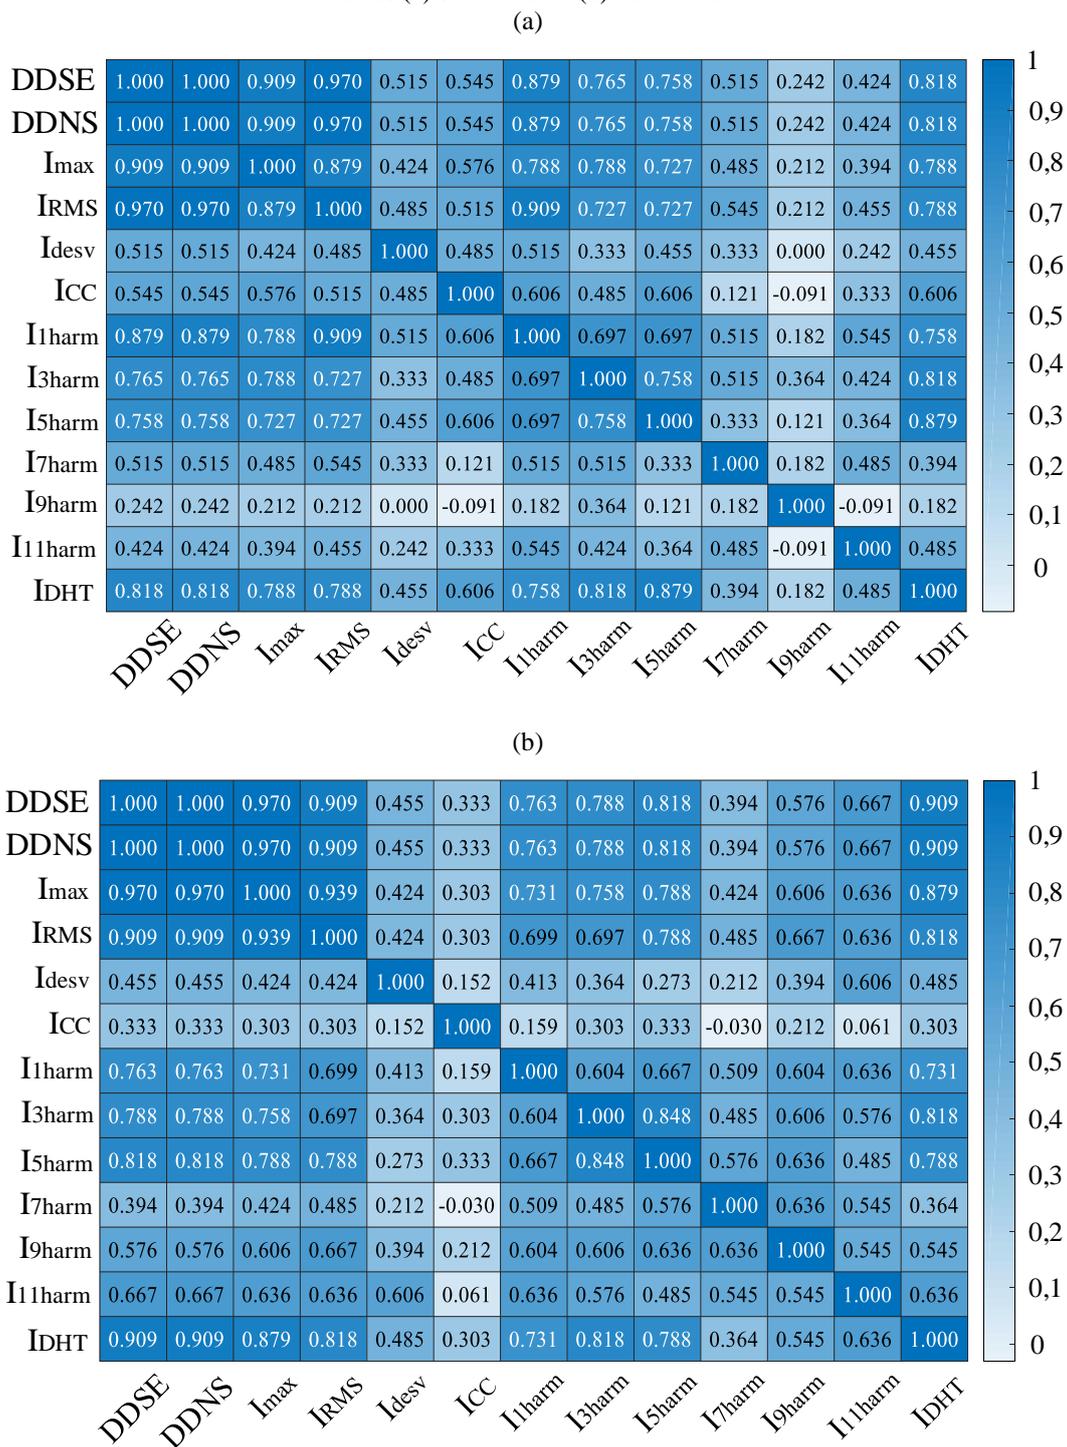
Fonte: autor (2025).

Figura 4.17 – Matriz de correlação, com coeficiente de Pearson, considerando as informações dos ensaios (a) sem névoa e (b) com névoa.



Fonte: autor (2025).

Figura 4.18 – Matriz de correlação, com coeficiente de Kendall, considerando as informações dos ensaios (a) sem névoa e (b) com névoa.



Fonte: autor (2025).

4.4 POVOAMENTO DA BASE DE DADOS

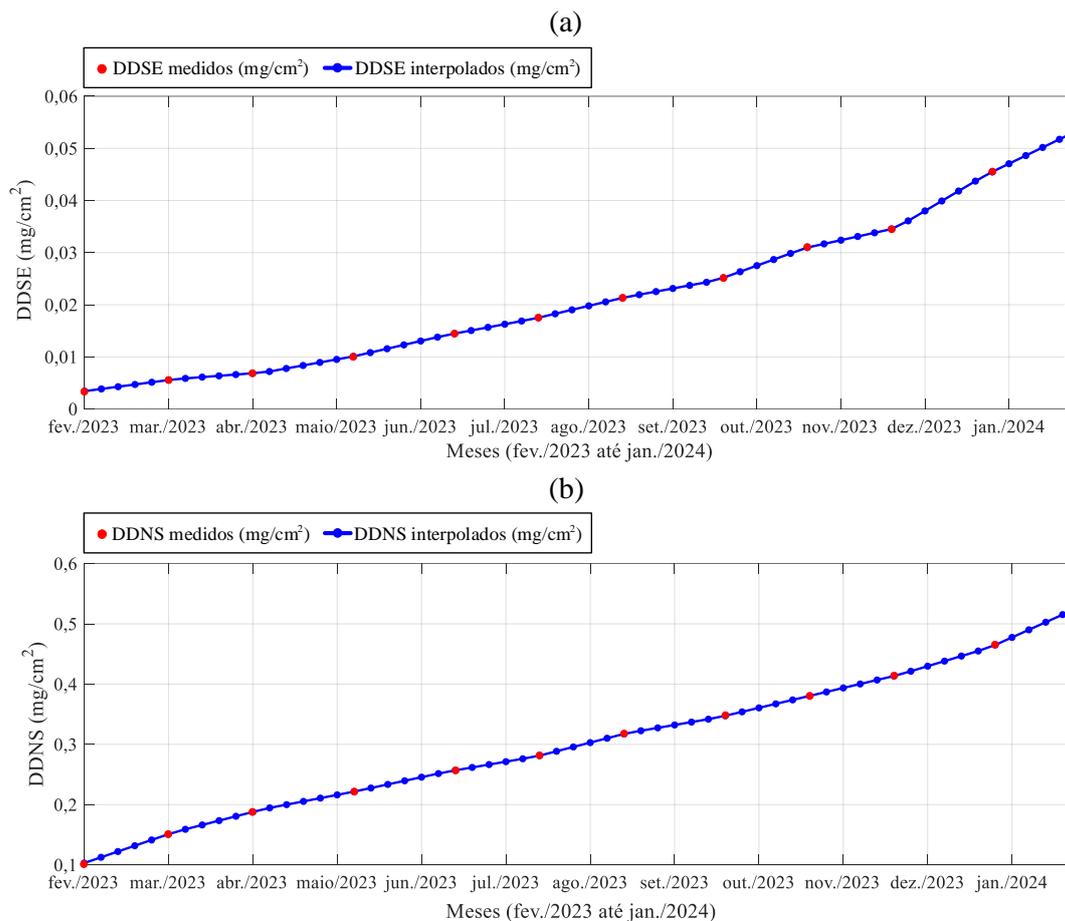
Para garantir a robustez das modelagens de previsão de séries temporais utilizando algoritmos de *machine learning*, foi necessário realizar o povoamento dos dados originais. Essa etapa é fundamental, pois o aumento da quantidade de dados melhora o desempenho e a capacidade de generalização dos algoritmos, especialmente em problemas de previsão de séries temporais. Para tanto, os dados medidos referentes aos índices de poluição DDSE e DDNS, juntamente com os parâmetros de corrente de fuga, temperatura e umidade, foram empregados como base para povoamento. O uso de dados povoados, ao ampliar a amostra e capturar mais nuances da dinâmica dos parâmetros ao longo do tempo, contribui para que os modelos de aprendizado de máquina identifiquem padrões mais complexos, podendo aumentar a acurácia das previsões e aprimorando a capacidade do sistema em generalizar os resultados para novas situações. Isso é particularmente vantajoso na manutenção preditiva e no planejamento das ações de inspeção, uma vez que sistemas mais bem treinados conseguem antecipar eventuais falhas e degradações com maior eficiência.

A partir das amostras referentes às entradas (parâmetros históricos da corrente de fuga, DDSE e DDNS) e saídas (DDSE e DDNS), realizou-se o povoamento dos dados, para aumentar a quantidade de amostras dentro do intervalo de tempo de medições. Para tanto, foram realizadas interpolações usando os valores médios das entradas e saídas constituintes da base de dados, com aplicação da biblioteca *scipy* (1.10.0) da linguagem Python 3.11.1, com módulo *scipy.interpolate* e classe *interp1d*. A interpolação possibilitou a ampliação do banco de dados para 60 amostras de entradas e saídas, correspondentes a medições semanais, entre as datas de fevereiro de 2023 e janeiro de 2024, como pode ser visualizado na Figura 4.19, as curvas obtidas por interpolações e os valores medidos referentes aos índices de poluição DDSE e DDNS. De forma semelhante foi realizado para os parâmetros da corrente de fuga.

Para agregar mais informações das medições realizadas ao longo dos experimentos em laboratório e ambiente externo às amostras obtidas da interpolação, adicionou-se um sinal de ruído branco com distribuição uniforme para cada parâmetro de entrada e saída para representar os efeitos de eventuais fenômenos intempestivos que podem ocorrer ao longo do tempo de operação do isolador e em diferentes regiões geográficas, tais como chuvas intensas, ventos fortes carregados de contaminantes,

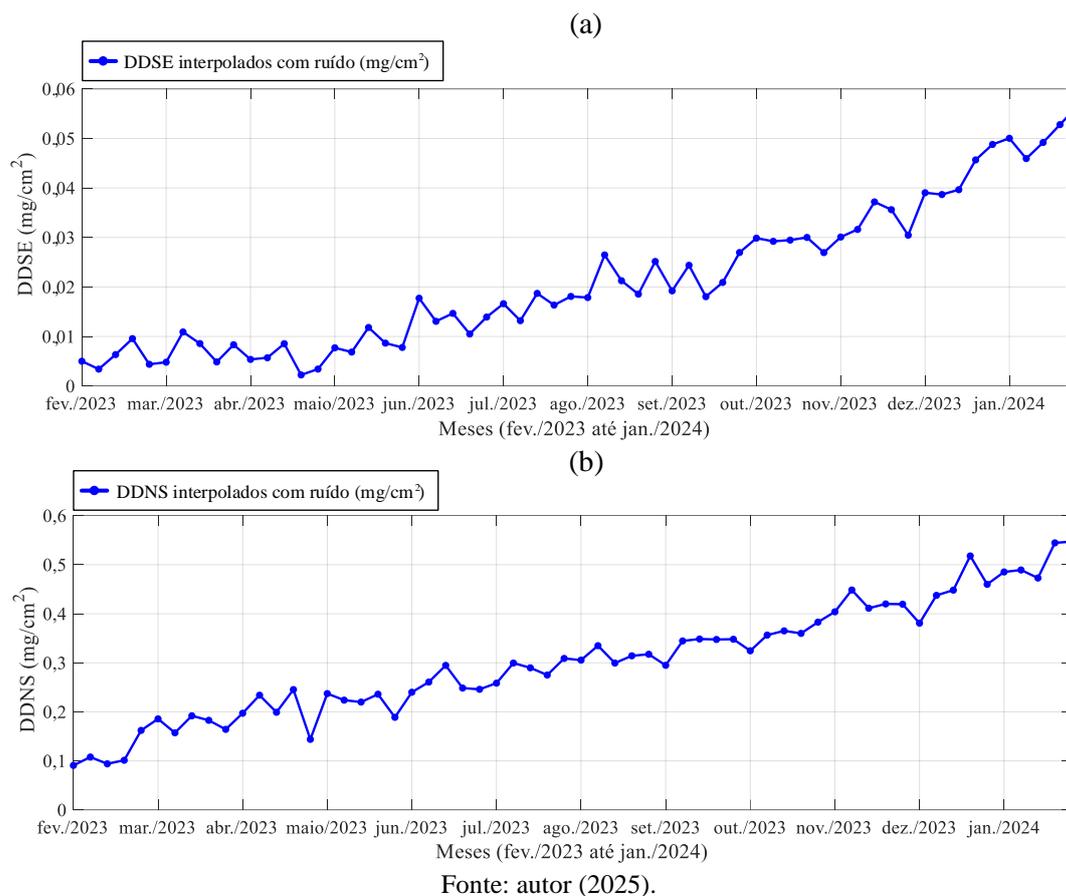
neblina salina, dejetos de animais, atividades industriais etc. Os níveis máximo e mínimo do ruído branco foram limitados pelo valor da média ponderada obtida por meio dos valores de desvio padrão associados a cada conjunto de medições, de acordo com cada parâmetro de entrada e saída. Para os índices DDSE e DDNS, as séries temporais construídas com os 60 valores obtidos da interpolação somada aos valores do ruído branco são apresentadas na Figura 4.20.

Figura 4.19 – Curvas obtidas por interpolação e valores médios dos índices (a) DDSE e (b) DDNS.



Fonte: autor (2025).

Figura 4.20 – Curvas obtidas por interpolação, sinais de ruído branco e valores médios dos índices (a) DDSE e (b) DDNS.



4.5 CRITÉRIO ADOTADO PARA O NÍVEL CRÍTICO DE POLUIÇÃO SUPERFICIAL

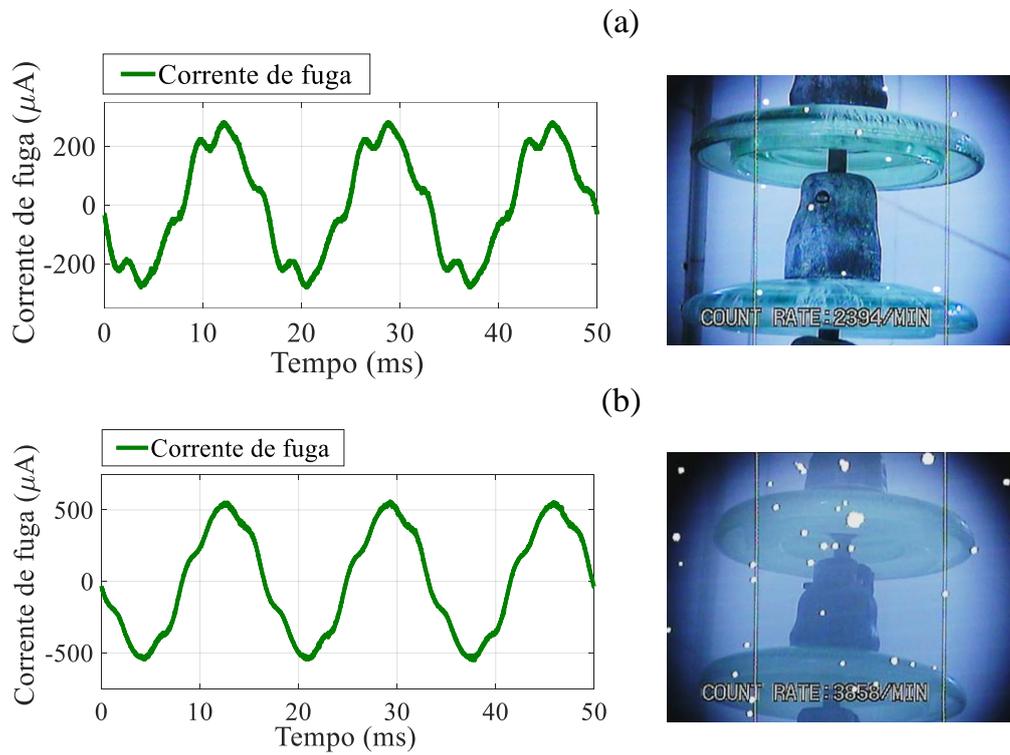
A determinação de critérios associados ao nível crítico de poluição superficial foi realizada por meio dos ensaios de poluição artificial. Para isso, ao longo dos ensaios de poluição artificial foram registrados os sinais da corrente de fuga e os valores dos índices DDSE e DDNS. O nível crítico de poluição foi associado à presença de descargas superficiais nos isoladores. Uma das formas de identificar a presença de descargas superficiais nos isoladores é por meio da análise da corrente de fuga, conforme constatado em vários trabalhos (SUDA, 2005; KUMAGI & YOSHIMURA, 2004; LI *et al.*, 2010; PYLARINOS *et al.*, 2012; ZHANG *et al.*, 2016; SALEM *et al.*, 2020; ZHANG *et al.*, 2016; SALEM *et al.*, 2020). Caso haja *spikes* nos locais de vale e crista do sinal da corrente de fuga, isso é um forte indício da ocorrência de descargas

superficiais. Os *spikes* tendem a aumentar com o acúmulo de poluição superficial, podendo resultar em descargas disruptivas (SALEM *et al.*, 2020; ZHANG *et al.*, 2016; LI *et al.*, 2010).

Uma outra maneira, neste trabalho adotada como complementar e para fundamentar ainda mais os critérios adotados, para identificar a presença de descargas superficiais é a utilização de câmera UV, pois as descargas superficiais emitem um alto nível de radiação ultravioleta. Por meio da câmera UV é possível visualizar o isolador em operação, a intensidade e contagem de descargas. A câmera possui um sistema de *count rate* (do inglês taxa de contagem), que é apresentado em número de fótons por minuto. O *count rate* contabiliza os pontos luminosos correspondente à manifestação UV na imagem. O valor do *count rate* pode ser consultado diretamente na interface da câmera UV, permitindo fazer o monitoramento das descargas para diferentes níveis de poluição superficial e validar as constatações realizadas com base nas análises dos sinais de corrente de fuga.

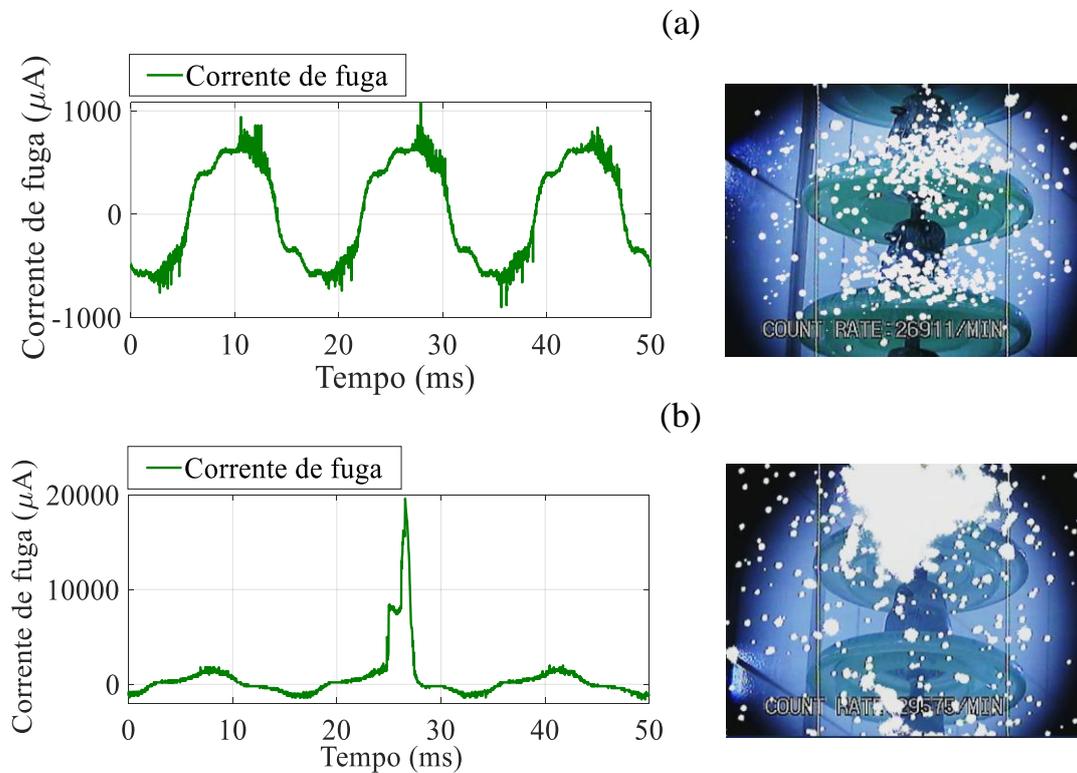
Na Figura 4.21 e 4.22 são apresentados sinais da corrente de fuga e imagens registradas por meio da câmera UV para níveis de poluição diferentes, sem névoa e com névoa, respectivamente. Ao longo dos registros dos sinais de corrente, a tensão manteve-se praticamente constante, com valores médios de 41,8 kV e 41,5 kV para os ensaios sem névoa e com névoa, nessa ordem, conforme apresentado nas Tabelas 4.2 e 4.3. A comparação dos sinais da corrente de fuga e registros das imagens registradas pela câmera UV foi a forma adotada para validar a ocorrência de descargas superficiais nos isoladores, a fim de determinar limiares dos índices DDSE e DDNS que indiquem a ocorrência de descargas superficiais. Assim, a condição crítica de poluição foi adotada como critério para auxiliar na estimativa do momento ótimo para realizar manutenção de limpeza em isoladores.

Figura 4.21 – Registros dos sinais de corrente de fuga e da câmera UV para poluição leve (a) sem névoa e (b) com névoa.



Fonte: autor (2025).

Figura 4.22 – Registros dos sinais de corrente de fuga e da câmera UV para poluição pesada (a) sem névoa e (b) com névoa.



Fonte: autor (2025).

4.6 MODELOS DE PREVISÃO BASEADOS EM INTELIGÊNCIA ARTIFICIAL

Os algoritmos MLP e SVR foram usados para modelar a poluição superficial (DDSE e DDNS) da cadeia de isoladores de vidro, sem névoa e com névoa, a fim de analisar o desempenho de cada um dos modelos e selecionar o melhor com base nas métricas estatísticas adotadas. Os modelos que apresentarem maior acurácia serão utilizados para fazer previsão dos índices DDSE e DDNS, que representam os níveis de poluição, a fim de estimar o momento ótimo de manutenção de limpeza dos isoladores, dado que os índices tenham alcançado níveis críticos de poluição. Dentre os algoritmos de aprendizado de máquina usados na literatura, os modelos MLP e SVR têm mostrado bons resultados para problemas complexos regressão/previsão de séries temporais (HAYKIN, 2008; MUNIRAJ & CHANDRASEKAR, 2011; SOPELSA NETO *et al.*, 2021; LIRA & COSTA, 2013; GAO *et al.*, 2018; GÉRON, 2019; Barbosa *et al.*, 2021; Barbosa *et al.*, 2024).

A escolha dos algoritmos de aprendizado de máquina MLP e SVR para a modelagem e previsão das séries temporais dos níveis de poluição superficial (DDSE e DDNS) oferece vantagens em relação a métodos estatísticos mais básicos, como, por exemplo, regressão por ajuste de curva para extrapolação e média móvel (GÉRON, 2019; Barbosa *et al.*, 2021). Enquanto o ajuste de curva assume uma forma funcional predefinida para representar a evolução da série temporal, limitando sua capacidade de capturar relações não lineares e mudanças de regime, os algoritmos MLP e o SVR são capazes de aprender padrões complexos diretamente dos dados, sem a necessidade de especificar explicitamente essas relações matemáticas (GILAT & SUBRAMANIAM, 2013; GÉRON, 2019). A média móvel, embora útil para suavizar oscilações e identificar tendências de curto prazo, possui capacidade de previsão limitada, pois se baseia apenas em uma janela fixa de dados passados e não modela a dinâmica subjacente da série (e.g., aleatoriedade e sazonalidade) (GILAT & SUBRAMANIAM, 2013). Em contraste, os algoritmos MLP e o SVR podem incorporar múltiplas variáveis de entrada, aprender dependências temporais complexas através de suas arquiteturas e fornecer previsões mais exatas, sobretudo em séries temporais com comportamento não linear, sazonalidade complexa e influenciadas por múltiplos fatores, como é o caso da poluição superficial em isoladores sujeitos a diversas condições ambientais.

Os modelos foram desenvolvidos utilizando os parâmetros derivados da corrente de fuga com correlação forte e muito forte com a DDSE e DDNS, além dos índices de poluição. As bases referentes aos ensaios sem e com névoa, que passaram por povoamento de dados e adição de ruído branco, foram utilizadas para a realização das modelagens. Os modelos foram implementados na linguagem Python 3.11.1 por meio, principalmente, das bibliotecas *scikit-learn* (1.0.2), *numpy* (1.22.3) e *pandas* (2.0.3), e foram submetidos às fases de treinamento (ajuste dos modelos aos dados destinados para treinamento) e teste (apresentação de novos dados aos modelos). Os dados históricos de entrada (DDSE, DDNS, I_{Pico} , I_{RMS} , I_{1Harm} , I_{3Harm} , I_{5Harm} , I_{DHT}) e saída (DDSE e DDNS) foram divididos para essas duas fases, em que para treinamento foram utilizados 70% dos dados e para teste, 15% e 30%, a fim de avaliar o desempenho dos modelos para diferentes intervalos de horizonte temporal.

Na construção dos modelos de previsão temporal dos índices DDSE e DDNS, empregou-se o conceito de janelamento temporal para organizar os dados de forma adequada ao treinamento dos modelos MLP e SVR. Os dados históricos foram divididos em múltiplas subsequências (janelas), cada uma contendo 18 amostras passadas (*lags*) dos índices DDSE, DDNS e parâmetros da corrente de fuga como entrada. Para a previsão, utilizou-se uma abordagem iterativa: cada modelo previu o próximo valor, que foi então incorporado como uma nova entrada para prever o valor subsequente, e assim por diante. A definição da quantidade de *lags* foi baseada no horizonte temporal desejado para realizar previsão e alcançar o valor crítico de poluição (caracterizado pela presença de descargas superficiais), de modo a contemplar 30% da base de dados. À medida que o treinamento avançava, essa janela era deslocada no tempo de forma iterativa, de modo que o modelo fosse capaz de aprender padrões e tendências a partir de diferentes segmentos dos dados históricos, sabendo que essa janela passava a contemplar também os dados previstos. Após a fase de treinamento, o mesmo processo de janelamento foi aplicado aos dados de teste, possibilitando a geração de previsões para os períodos futuros correspondentes aos 15% e 30% dos dados mais recentes, considerando o intervalo do histórico para o desenvolvimento desta pesquisa.

Para melhor desempenho dos algoritmos, o método de padronização é adotado para os dados de entrada, que é definido matematicamente por (4.1) e usado por meio do módulo *sklearn.preprocessing* e classe *StandardScaler*. Esse método possui a vantagem de mapear a saída para uma faixa não saturada da função de ativação, pois os valores são deslocados e redimensionados. A utilização do método ajuda a melhorar o desempenho

dos algoritmos de aprendizado de máquina nas fases de treinamento e nas previsões diante de novas entradas, como constatado na literatura (GÉRON, 2019; KAKIHATA, 2017; BISHOP, 2006).

$$x_{Novo} = \frac{x - \mu}{\sigma}, \quad (4.1)$$

em que x_{Novo} é o valor padronizado, x é a variável antes do escalonamento, μ é a média aritmética das amostras e σ é o desvio padrão.

Para cada tipo de algoritmo (MLP e SVR), dois modelos foram desenvolvidos, considerando as situações dos ensaios sem névoa e com névoa, totalizando quatro modelos computacionais. A descrição dos modelos e suas peculiaridades serão apresentadas a seguir.

4.6.1 MODELO A

O modelo A foi desenvolvido com base no algoritmo MLP (módulo *sklearn.neural_network* e classe *MLPRegressor*), com o intuito de estimar valores futuros dos índices DDSE e DDNS, utilizando os dados obtidos dos experimentos com poluição artificial sem névoa, além das informações temporais. As entradas para treinamento do modelo foram dados históricos referentes aos parâmetros da corrente de fuga com correlação forte e muito forte com os índices de poluição DDSE e DDNS, além dos índices DDSE e DDNS. Os dados foram padronizados com base na média aritmética e desvio padrão das informações históricas selecionadas para desenvolvimento do modelo, para que o modelo fosse treinado de modo adequado. A fase de treinamento foi constituída pela seleção dos melhores hiperparâmetros e definição da estrutura do modelo usando a arquitetura de rede não recorrente.

Os hiperparâmetros (função de ativação, algoritmo de otimização, parâmetro de regularização, número de camadas ocultas, número de iterações e número de neurônios por camada oculta) do modelo A foram selecionados por meio do método *grid Search* (módulo *sklearn.model_selection* e classe *GridSearchCV*). Esse método envolve a definição de um conjunto de valores possíveis para cada hiperparâmetro selecionado para configurar. Uma vez as listas de hiperparâmetros definidas, a combinação de todos os valores possíveis é realizada, para treino e avaliação do modelo com cada combinação, usando métrica de desempenho, como o MSE, para determinar a configuração de hiperparâmetros que produz o melhor resultado.

A validação cruzada (do inglês *cross-validation*) é aplicada em conjunto com o *grid search* para evitar o *overfitting* e obter uma estimativa mais robusta do desempenho dos modelos. Nesse processo, o conjunto de dados é dividido em k subconjuntos (*k-folds*), e o *grid search* realiza k iterações. Para o trabalho desenvolvido, foram usados cinco subconjuntos. Em cada iteração, um dos subconjuntos é usado como conjunto de validação e os restantes são usados para treinamento do modelo. A métrica de desempenho é calculada para cada iteração e, ao final do processo, é obtida uma média das métricas de desempenho para as diferentes divisões do conjunto de dados. O conjunto de hiperparâmetros que alcança a melhor média de desempenho na validação cruzada é selecionado como a configuração mais adequada para o modelo MLP.

Para desenvolvimento do modelo, a função de ativação utilizada nas camadas ocultas foi a tangente hiperbólica e o algoritmo de otimização foi o Broyden–Fletcher–Goldfarb–Shanno Memória Limitada² (LBFGS, do inglês *Limited-memory Royden–Fletcher–Goldfarb–Shanno*), o qual possibilitou a minimização da função de perda e uma convergência mais rápida, permitindo atingir o mínimo global de maneira mais eficiente, como pode ser observado na Tabela 4.4. Além disso, verificou-se que o melhor desempenho foi obtido para a estrutura com duas camadas ocultas e cada uma dessas camadas com quatro neurônios, conforme a estrutura apresentada na Figura 4.23. Os pesos da rede do modelo A foram atualizados ao longo de 100 iterações até alcançar a convergência, isto é, minimização da função de perda e estabilização dos pesos. Com a utilização do parâmetro de regularização (α)³ de forma adequada, é possível evitar *overfitting*, melhorando a capacidade de generalização do modelo. Em geral, quanto maior é o valor de α , mais simplificado é o modelo e o sua acurácia pode ser afetada diante de problemas não lineares e com elevada complexidade. Essas configurações foram utilizadas considerando a semente aleatória (*random seed*)⁴ igual a 42.

² O algoritmo de otimização LBFGS é discutido de forma mais aprofundada nas referências Nocedal & Wright (2006) e Haykin (2008).

³ O parâmetro de regularização (α) controla a complexidade do modelo, penalizando os pesos da rede para reduzir sua sensibilidade a variações nos dados de treinamento. Em geral, valores baixos podem levar ao *overfitting*, comprometendo a generalização, enquanto valores altos podem causar *underfitting*, limitando a captura de padrões complexos (GÉRON, 2019).

⁴ A semente aleatória define o estado inicial do gerador de números aleatórios no treinamento do MLP, garantindo reprodutibilidade nos resultados (GÉRON, 2019). Ele assegura que, por exemplo, a inicialização dos pesos e a divisão dos dados em treino e teste sejam consistentes entre diferentes execuções, permitindo comparações justas entre experimentos e ajustes de hiperparâmetros.

Tabela 4.4 – Configurações dos hiperparâmetros testados e selecionados para o modelo A.

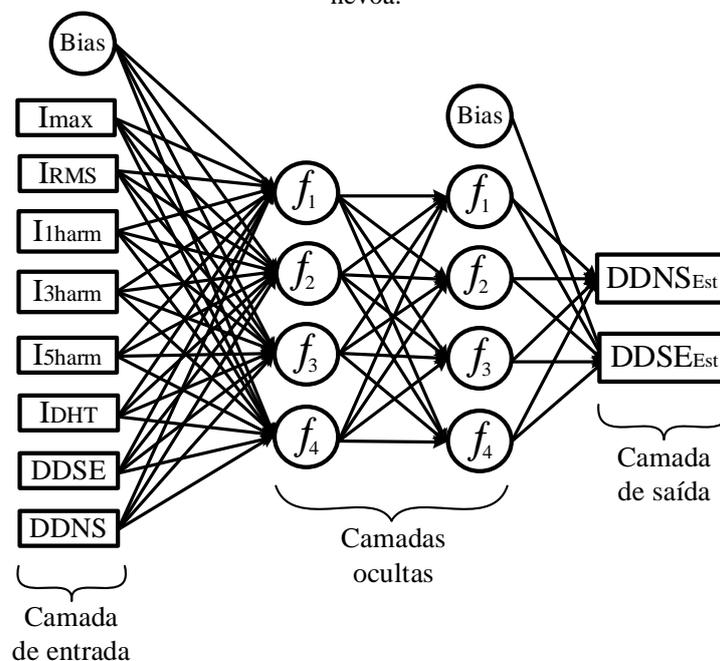
Hiperparâmetros	Configurações	Selecionados
Função de ativação*	<i>identity</i> , <i>logistic</i> , <i>tanh</i> e <i>relu</i>	<i>tanh</i>
Algoritmo de otimização**	<i>lbfgs</i> ; <i>sgd</i> ; <i>adam</i>	<i>lbfgs</i>
α	5×10^{-5} ; 5×10^{-4} ; 5×10^{-3}	5×10^{-5}
Número de camadas ocultas	1; 2; 3	2
Número de iterações	100; 500; 1000; 1500	100
Número de neurónicos por camada oculta	3; 4; 5; 6	4

*Função de ativação: *identity* (identidade); *logistic* (sigmóide); *tanh* (tangente hiperbólica); e *relu* (unidade linear retificada).

**Algoritmo de otimização: *lbfgs*; *sgd* (do inglês *Stochastic Gradient Descent*); *adam* (do inglês *Adaptive Moment Estimation*).

Fonte: autor (2025).

Figura 4.23 – Estrutura do modelo MLP (modelo A) para estimativa dos índices DDSE e DDNS, sem névoa.



Fonte: autor (2025).

4.6.2 MODELO B

O modelo B foi desenvolvido com base no algoritmo de SVR (módulo *sklearn.svm* e classe *SVR*), com a finalidade de estimar valores futuros dos índices DDSE e DDNS, utilizando os dados obtidos dos experimentos com poluição artificial sem névoa, como também as informações temporais. As entradas para treinamento do modelo foram dados históricos referentes aos parâmetros da corrente de fuga com correlação forte e

muito forte com os índices de poluição DDSE e DDNS, além dos índices DDSE e DDNS. Os dados foram padronizados com base na média aritmética e desvio padrão das informações históricas selecionadas para desenvolvimento do modelo, para que o modelo fosse treinado de modo adequado. Na fase de treinamento, os hiperparâmetros foram selecionados e a estrutura da definição do modelo foi realizada.

Durante a fase de treinamento do modelo B, buscou-se selecionar os seus hiperparâmetros (*kernel*, constante de regularização, *gamma*, margem insensível, *shrinking*) utilizando o método *grid search* em conjunto com o modelo de validação cruzada, a fim de desenvolver um modelo com as melhores configurações possíveis, para alcançar o melhor desempenho para o conjunto de dados utilizado, sem acarretar em *overfitting*. Além disso, os índices DDSE e DDNS foram modelados de forma independente por meio de um método fornecido pela biblioteca *scikit-learn* (módulo *sklearn.multioutput* e classe *MultiOutputRegressor*), que se trata de uma alternativa para ser possível prever múltiplas saídas, já que o modelo SVR originalmente não possibilita isso.

O modelo foi desenvolvido utilizando a função *kernel* Gaussiana (também denominada de Função de Base Radial – RBF do inglês *Radial Basis Function*), possibilitando o mapeamento de relações não lineares entre as variáveis de entrada e saída. Outras funções foram testadas, tais como: linear, polinomial e sigmoide. A constante de regularização, C , é responsável por controlar o ajuste aos dados de treinamento, podendo ocasionar *overfitting*, para valores maiores de C ; já para valores menores de C , a capacidade de generalização do modelo aumenta. O parâmetro do *kernel* (γ) também vai influenciar no ajuste do modelo aos dados de treinamento, com interpretação análoga à constante de regularização. A margem insensível (ϵ) determina a largura da zona de tolerância em torno da linha de regressão (hiperplano ótimo). Valores maiores dessa margem permitem maior tolerância aos erros, tornando o modelo mais flexível e capaz de lidar com ruídos e *outliers* nos dados; enquanto valores menores da margem resultam em uma superfície de regressão mais ajustada aos dados de treinamento. Os hiperparâmetros utilizados no *grid search* e selecionados para desenvolvimento do modelo B são apresentados na Tabela 4.5.

Tabela 4.5 – Configurações dos hiperparâmetros testados e selecionados para o modelo B.

Hiperparâmetros	Configurações	Selecionados
<i>Kernel</i> *	<i>linear</i> ; <i>poly</i> ; <i>sigmoid</i> ; <i>rbf</i>	<i>rbf</i>
<i>C</i>	0,1; 1; 10; 100; 1000	100
<i>Gamma</i> (γ)	<i>scale</i> ; <i>auto</i> ; 0,001; 0,01; 0,1; 1	0,0001
<i>Epsilon</i> (ϵ)	0,0001; 0,001; 0,01; 0,1; 1; 10	0,0001
<i>Shrinking</i> **	<i>True</i> ; <i>False</i>	<i>True</i>

**Kernel*: *linear* (linear); *poly* (polinomial); *sigmoid* (sigmóide); e *rbf* (função de base radial).

**Hiperparâmetro responsável por controlar a ativação do mecanismo de redução de margens para amostras que estão fora da margem (*shrinking*).

Fonte: autor (2025).

4.6.3 MODELO C

O modelo C foi desenvolvido com base no algoritmo de MLP, para estimar valores futuros dos índices DDSE e DDNS, utilizando os dados obtidos dos experimentos com poluição artificial com névoa. As entradas para treinamento do modelo também foram dados históricos referentes aos parâmetros da corrente de fuga com correlação forte e muito forte com os índices de poluição DDSE e DDNS, além dos índices DDSE e DDNS. Os dados também foram padronizados com base na média aritmética e desvio padrão das informações históricas selecionadas para desenvolvimento do modelo, para que o modelo fosse treinado de modo adequado. Na fase de treinamento, os hiperparâmetros foram selecionados e a estrutura da definição do modelo foi realizada.

Durante a fase de treinamento do modelo C, buscou-se selecionar os seus hiperparâmetros utilizando o método *grid search* em conjunto com o modelo de validação cruzada, com o intuito de desenvolver um modelo com as melhores configurações possíveis, para alcançar o melhor desempenho para o conjunto de dados utilizado, sem acarretar no *overfitting*.

O desenvolvimento do modelo foi baseado na utilização da função de ativação sigmóide e o algoritmo de otimização foi o LBFGS. Ademais, verificou-se que o melhor desempenho foi obtido para a estrutura com uma camada oculta e cada uma dessas camadas com quatro neurônios, seguindo também a estrutura apresentada na Figura 4.23. Para o treinamento do modelo, o mínimo global da função custo foi alcançado com 100 iterações. Essas configurações foram utilizadas considerando a semente aleatória igual a

42. Os hiperparâmetros utilizados no *grid search* e selecionados para desenvolvimento do modelo C são apresentados na Tabela 4.6.

Tabela 4.6 – Configurações dos hiperparâmetros testados e selecionados para o modelo C.

Hiperparâmetros	Configurações	Selecionados
Função de ativação*	<i>identity, logistic, tanh e relu</i>	<i>logistic</i>
Algoritmo de otimização**	<i>lbfgs; sgd; adam</i>	<i>lbfgs</i>
α	$5 \times 10^{-5}; 5 \times 10^{-4}; 5 \times 10^{-3}$	5×10^{-5}
Número de camadas ocultas	1; 2; 3	1
Número de iterações	100; 500; 1000; 1500	100
Número de neurônios por camada oculta	3; 4; 5; 6	4

Fonte: autor (2025).

4.6.4 MODELO D

O modelo D foi desenvolvido com base no algoritmo SVR, a fim de estimar valores futuros dos índices DDSE e DDNS, utilizando os dados obtidos dos experimentos com poluição artificial com névoa. As entradas para treinamento do modelo também foram dados históricos referentes aos parâmetros da corrente de fuga com correlação forte e muito forte com os índices de poluição DDSE e DDNS, além dos índices DDSE e DDNS. Os dados também foram padronizados com base na média aritmética e desvio padrão das informações históricas selecionadas para desenvolvimento do modelo, para que o modelo fosse treinado de modo adequado. Na fase de treinamento, os hiperparâmetros foram selecionados e a estrutura da definição do modelo foi realizada.

O treinamento do modelo D foi realizado considerando a seleção dos hiperparâmetros utilizando o método *grid search* em conjunto com o método de validação cruzada, a fim de desenvolver um modelo com as melhores configurações possíveis, para alcançar o melhor desempenho para o conjunto de dados utilizado. Os hiperparâmetros utilizados no *grid search* e selecionados para desenvolvimento do modelo D são apresentados na Tabela 4.7. Assim como foi realizado para o modelo B, os índices DDSE e DDNS também foram modelados de forma independente.

Tabela 4.7 – Configurações dos hiperparâmetros testados e selecionados para o modelo D.

Hiperparâmetros	Configurações	Selecionados
<i>Kernel</i>	<i>linear; poly; sigmoid; rbf</i>	<i>sigmoid</i>
<i>C</i>	0,1; 1; 10; 100; 1000	10
<i>Gamma</i> (γ)	<i>scale; auto; 0,001; 0,01; 0,1; 1</i>	0,001
<i>Epsilon</i> (ϵ)	0,01; 0,1; 1; 10	0,1
<i>Shrinking</i>	<i>True; False</i>	<i>True</i>

Fonte: autor (2025).

4.7 AVALIAÇÃO DE DESEMPENHO DOS MODELOS DE PREVISÃO

Para avaliar o desempenho dos modelos de previsão (A, B, C e D), foram utilizados diferentes métricas e estratégias nas etapas de treinamento e teste/validação. Durante as fases de treinamento e teste, o coeficiente de determinação, R^2 , e o MAPE foram utilizados para mensurar a qualidade do ajuste dos modelos aos dados e avaliar a acurácia das previsões, respectivamente. Como os modelos apresentam duas saídas (DDSE e DDNS), além da obtenção dessas métricas para as previsões de cada um dos índices DDSE e DDNS, determinou-se a média dos valores referentes aos dois índices para cada uma das métricas: coeficiente de determinação e MAPE, com o intuito de sumarizar os resultados para auxiliar na tomada de decisão quanto ao modelo com melhor desempenho, para as situações sem névoa e com névoa. As definições utilizadas para determinação da média de cada um dos índices são apresentadas em (4.2) e (4.3).

$$MAPE_{DDSE_DDNS} = \frac{MAPE_{DDSE} + MAPE_{DDNS}}{2}, \quad (4.2)$$

$$R^2_{DDSE_DDNS} = \frac{R^2_{DDSE} + R^2_{DDNS}}{2}, \quad (4.3)$$

4.8 ESTRATÉGIA PARA ESTIMATIVA DO MOMENTO ÓTIMO PARA REALIZAÇÃO DE LIMPEZA EM ISOLADORES

A estratégia para estimar o momento ótimo para a realização de limpeza em isoladores foi baseada nas previsões de poluição (valores dos índices DDSE e DDNS) geradas por modelos de previsão de séries temporais desenvolvidos com algoritmos de *machine learning*. Para compor a estratégia desenvolvida, realizou-se uma análise do desempenho dos modelos desenvolvidos, selecionando-se os que apresentaram melhor desempenho para as situações sem névoa e com névoa. Assim, os modelos selecionados foram utilizados para prever o acúmulo de poluentes nos isoladores, com base nos índices DDSE e DDNS. A partir das previsões realizadas, fez-se a contagem do intervalo de tempo necessário para que os níveis de poluição atingissem um limiar crítico, definido previamente com base nos experimentos em laboratório.

A contagem do horizonte temporal teve início no ponto imediatamente subsequente ao último conjunto de dados utilizado para o treinamento dos modelos, correspondente à quarta semana de setembro de 2023, considerando a base com os dados povoados. Assim, as previsões geradas pelos modelos começaram a partir desse ponto temporal, e a estimativa do momento até a necessidade de limpeza foi obtida ao observar o período previsto até que os valores de DDSE e DDNS atingissem os níveis críticos estabelecidos. Essa estratégia possibilitou uma estimativa do momento mais propício para manutenção, permitindo a programação de intervenções de acordo com as previsões realizadas pelos modelos, prevenindo tanto a antecipação desnecessária quanto o risco de atrasos que possam comprometer a funcionalidade dos isoladores e, conseqüentemente, a operação do sistema elétrico. O fluxograma da estratégia para estimar o momento ótimo para realizar manutenção de limpeza em isoladores é apresentada na Figura 4.24.

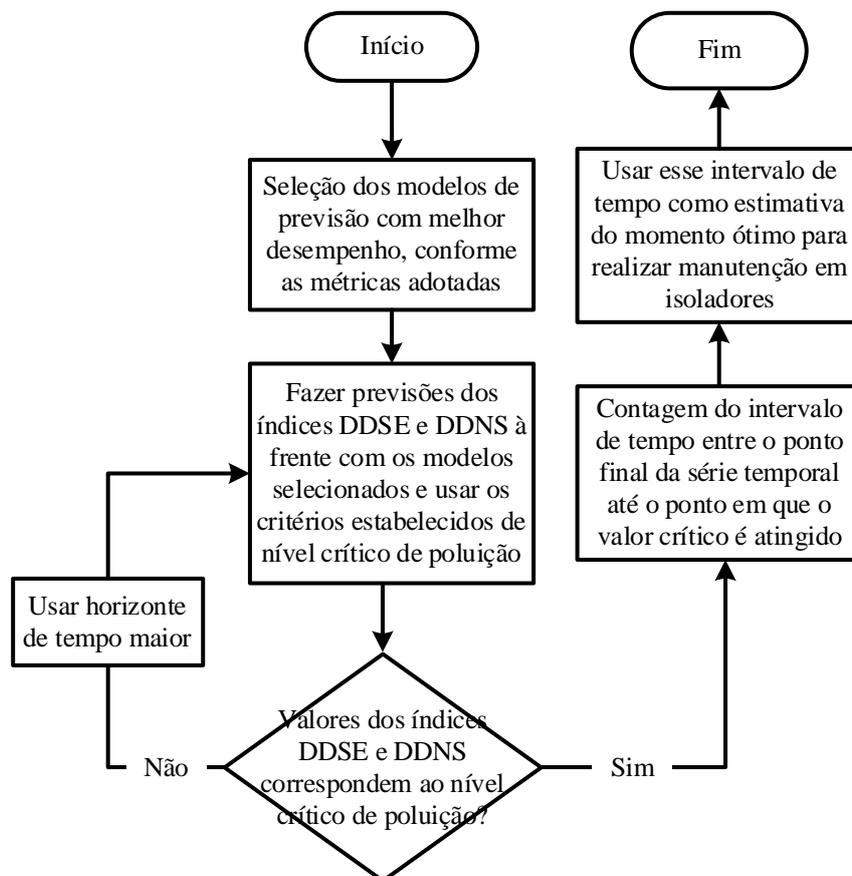
4.9 RESUMO DO CAPÍTULO

Este capítulo apresentou os procedimentos práticos e simulações computacionais que foram realizados para o desenvolvimento da tese. Para alcançar os objetivos específicos e geral, os procedimentos práticos e computacionais foram detalhadamente descritos, contemplando os experimentos de poluição superficial em ambiente externo; a

construção das séries temporais da DDSE e DDNS dos níveis de poluição superficial; os ensaios de poluição superficial em laboratório; o povoamento da base de dados; a investigação de critérios para o nível crítico de poluição superficial; os modelos de previsão baseados em inteligência artificial; e estratégia para estimativa do momento ótimo para realização de limpeza em isoladores.

No capítulo seguinte, os principais resultados obtidos da pesquisa serão apresentados e discutidos.

Figura 4.24 – Fluxograma da metodologia proposta para estimar o momento ótimo para realizar manutenção de limpeza em isoladores.



Fonte: autor (2025).

CAPÍTULO 5

RESULTADOS E DISCUSSÕES

O propósito principal desta tese é estimar o momento ótimo para realização de limpeza em isoladores de vidro por meio de modelagens computacionais baseadas em inteligência artificial, utilizando informações temporais da corrente de fuga, além dos índices DDSE e DDNS. Para tanto, neste capítulo serão apresentados os resultados obtidos por meio dos experimentos em ambiente externo, dos ensaios de poluição artificial realizados nos isoladores de vidro e das modelagens computacionais das séries temporais dos índices DDSE e DDNS utilizando os algoritmos MLP e SVR.

Os resultados obtidos a partir dos modelos desenvolvidos serão avaliados de forma quantitativa, com base nos valores do coeficiente de determinação e do MAPE; e qualitativa, por meio de inspeção gráfica das previsões realizadas nas fases de treinamento e teste. Nessa avaliação, o coeficiente de determinação será usado para verificar se os modelos se ajustaram aos dados medidos na fase de treinamento (70% da base de dados); enquanto o MAPE será empregado na fase de teste, com 15% e 30% da base de dados. Os resultados fornecidos pelos quatro modelos computacionais desenvolvidos serão discutidos, para verificar os mais adequados para estimar os valores da DDSE e DDNS, sem névoa e com névoa.

Os valores futuros da DDSE e DDNS que indicam nível crítico de poluição serão apresentados, para as situações de ensaio sem névoa e com névoa. Esses valores serão utilizados em conjunto com os modelos computacionais que forem os mais adequados para representar o processo de poluição, a fim de que os valores da DDSE e DDNS estimados pelos modelos possam ser utilizados e comparados com os valores que indicam nível crítico de poluição (presença de descargas superficiais). Dessa forma, manutenções poderão ser realizadas, a fim de evitar eventos mais críticos, como uma descarga disruptiva, devido ao acúmulo de poluição superficial.

Os modelos que forem selecionados para realizar previsão dos valores dos índices DDSE e DDNS, para as situações sem névoa e com névoa, serão submetidos às análises de sensibilidade, a fim de avaliar o quanto as saídas dos modelos podem ser influenciadas

por variações nos parâmetros da corrente de fuga, por causas que não estejam associadas com elevação do nível de poluição, além de investigar o quanto essas variações podem influenciar na acurácia dos modelos.

5.1 AVALIAÇÃO DOS MODELOS COMPUTACIONAIS

Os valores de R^2 e MAPE obtidos durante a fase de treinamento dos modelos A, B, C e D são apresentadas na Tabela 5.1 e Figura 5.1, respectivamente. Os erros obtidos pelos modelos desenvolvidos são apresentados nas Figuras 5.2 e 5.3, que são referentes, respectivamente, aos valores previstos dos índices DDSE e DDNS, na fase de teste. Esses erros foram calculados individualmente e também pela média dos valores de MAPE obtidos separadamente para cada índice. Os valores do MAPE referentes aos modelos A e B foram obtidos para os ensaios de poluição sem névoa, já os resultados dos modelos C e D foram obtidos para os ensaios com névoa. Os resultados gráficos das previsões nas fases de treinamento e teste dos modelos A, B, C e D são apresentados nas Figuras 5.4 a 5.11.

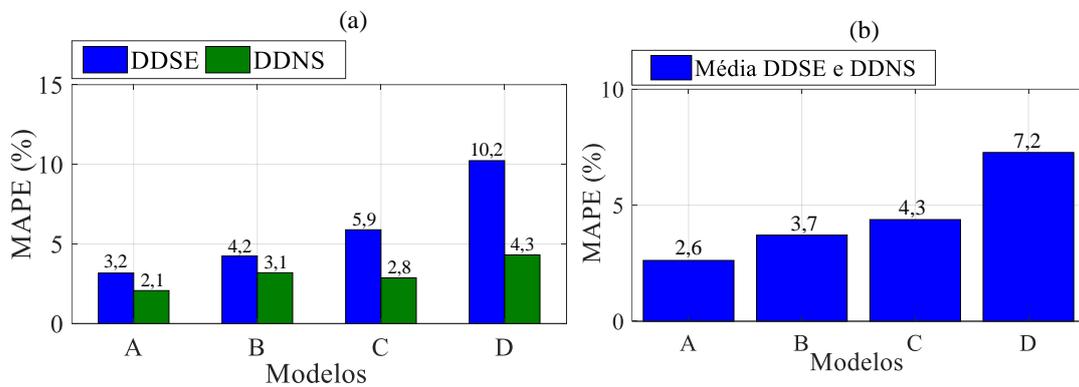
Com base na Tabela 5.1 e Figura 5.1, considerando os resultados de treinamento dos modelos A e B, o melhor ajuste dos dados para DDSE e DDNS estimados em relação aos medidos ocorre com o modelo A, pois os valores do coeficiente de determinação são maiores e se aproximam mais do valor unitário que os valores associados ao modelo B, além dos valores do MAPE associados ao modelo A serem menores que os valores do modelo B. Ao analisar os valores dos coeficientes obtidos para os modelos C e D, considerando os ensaios com névoa, é possível afirmar que o modelo C apresentou melhor desempenho na fase de treinamento, pois o modelo se ajustou bem à dinâmica dos valores dos índices DDSE e DDNS, como foi verificado para o modelo A, além dos valores do MAPE também serem menores em relação ao modelo D. Dessa forma, os modelos que foram desenvolvidos baseados no algoritmo MLP apresentaram desempenho superior em relação aos modelos baseados no algoritmo SVR, na fase de treinamento.

Tabela 5.1 – Valores do coeficiente de determinação dos modelos computacionais A, B, C e D.

Modelos	A	B	C	D
R_{DDSE}^2	0,9719	0,9498	0,9471	0,8801
R_{DDNS}^2	0,9529	0,9388	0,9243	0,8962

Fonte: autor (2025).

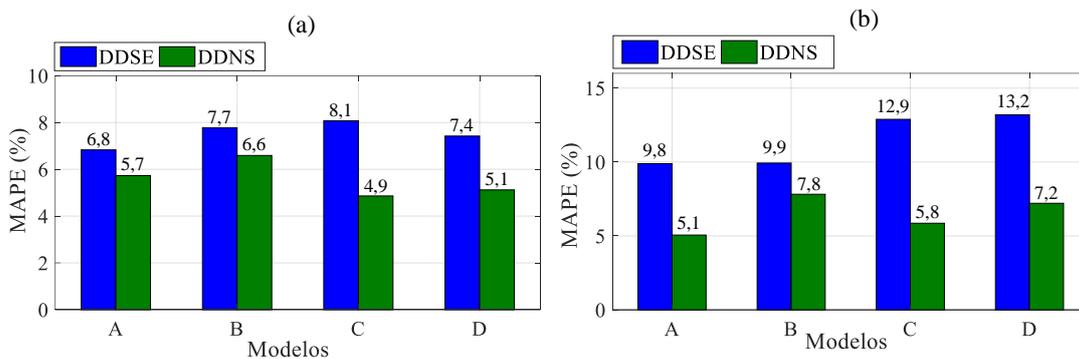
Figura 5.1 – Valores das métricas obtidos na fase de treinamento dos modelos A, B, C e D:
(a) métricas individuais dos índices DDSE e DDNS e (b) média das métricas dos índices DDSE e DDNS.



Fonte: autor (2025).

Figura 5.2 – Valores das métricas obtidas na fase de teste dos modelos A, B, C e D:

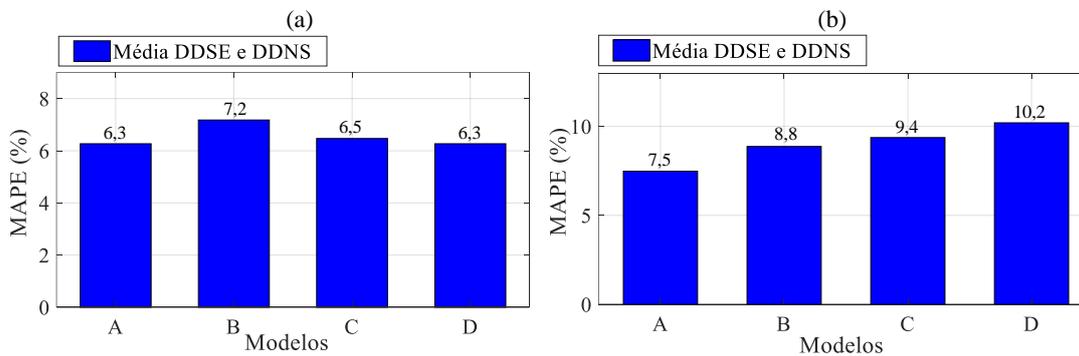
(a) 15% e (b) 30% da base de dados.



Fonte: autor (2025).

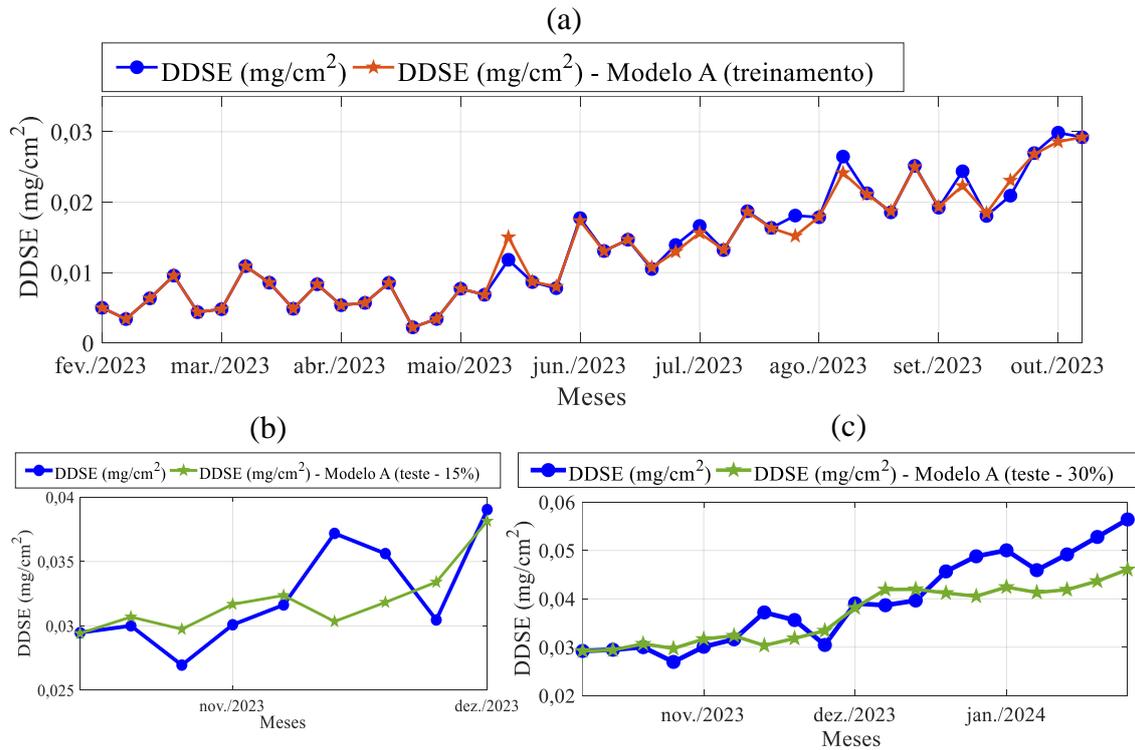
Figura 5.3 – Valores médios das métricas obtidas na fase de teste dos modelos A, B, C e D:

(a) 15% e (b) 30% da base de dados.



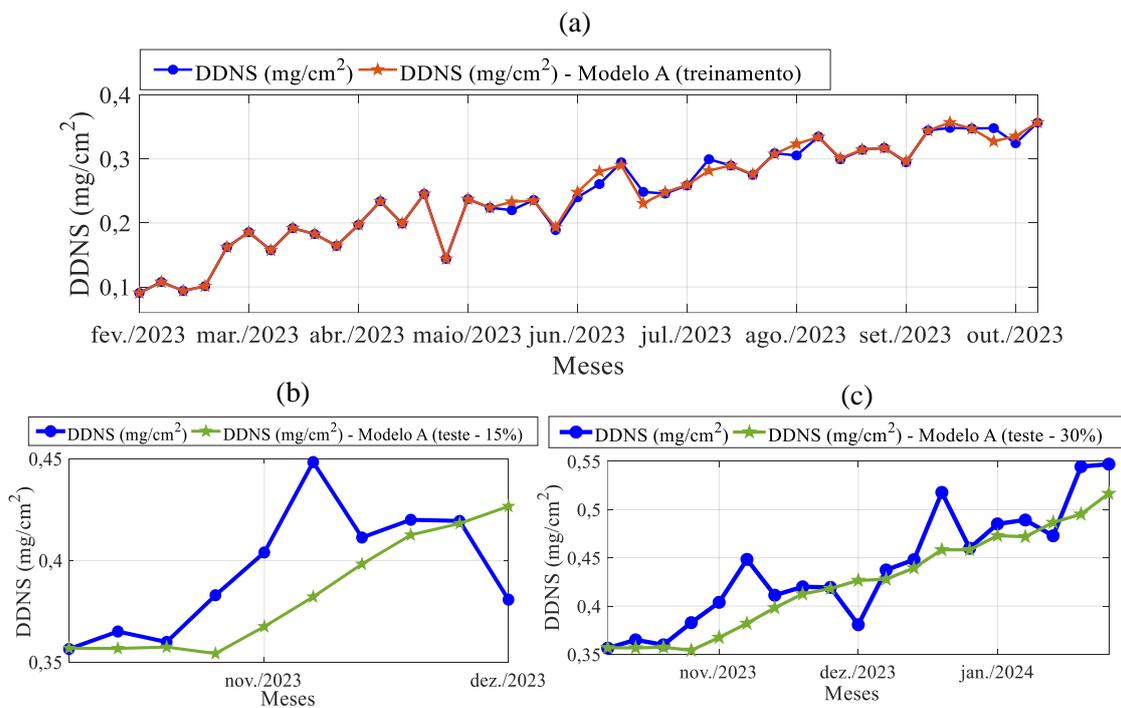
Fonte: autor (2025).

Figura 5.4 – Previsões realizadas com o modelo A, considerando o DDSE, para (a) treinamento e teste com (b) 15% e (c) 30%.



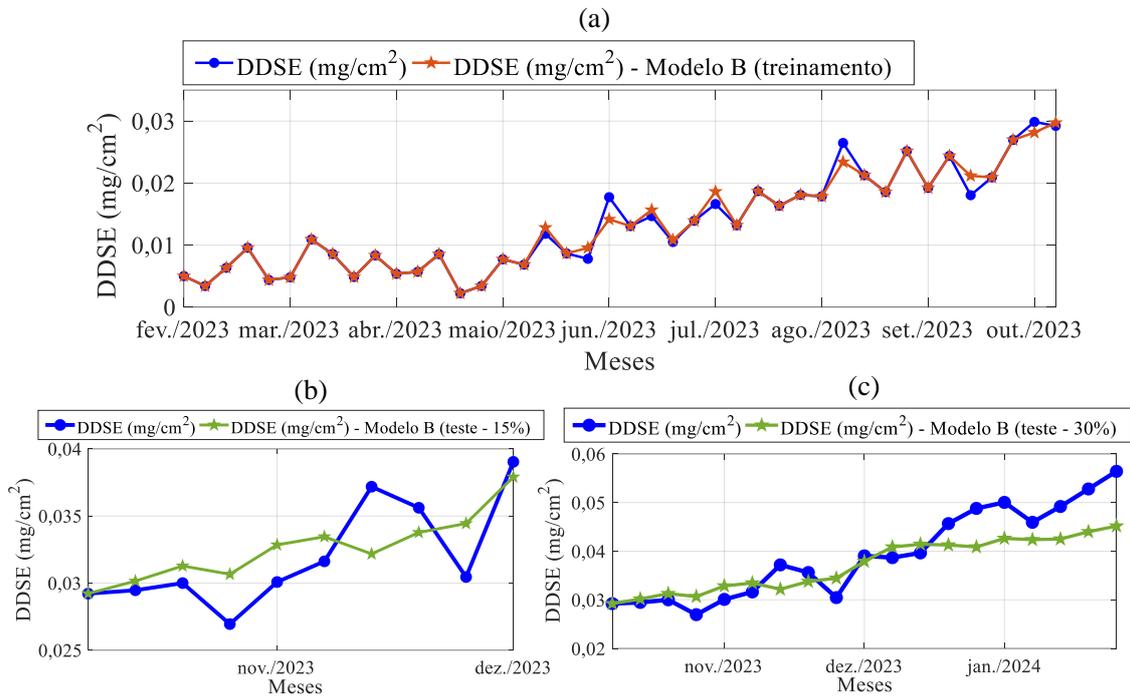
Fonte: autor (2025).

Figura 5.5 – Previsões realizadas com o modelo A, considerando o DDNS, para (a) treinamento e teste com (b) 15% e (c) 30%.



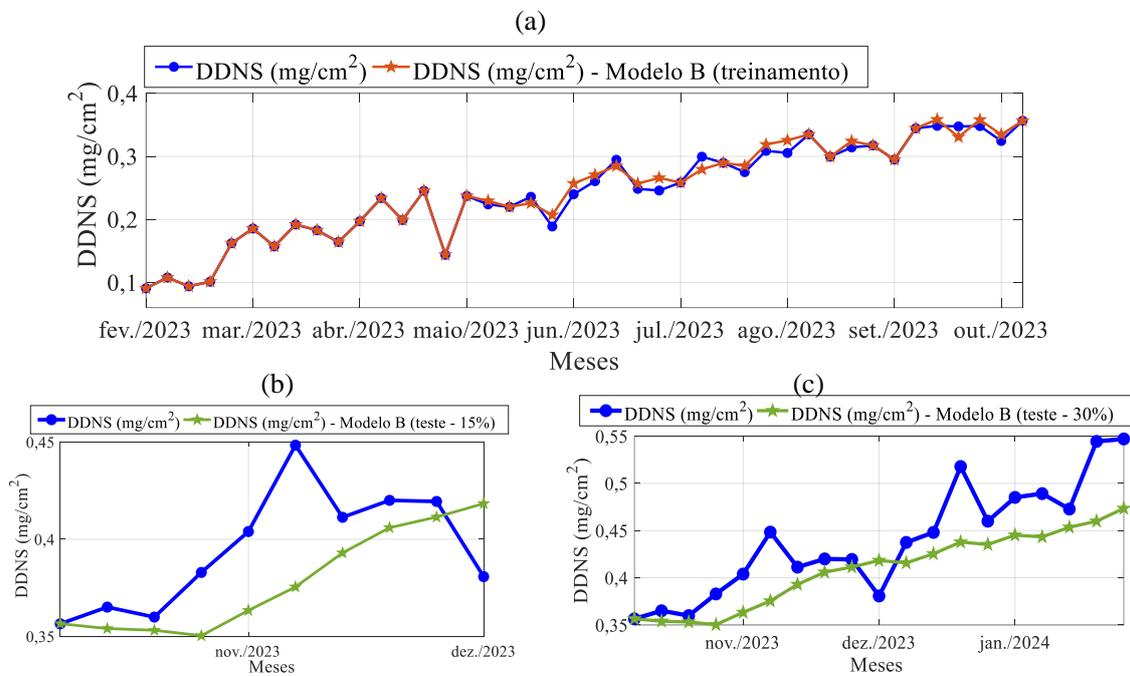
Fonte: autor (2025).

Figura 5.6 – Previsões realizadas com o modelo B, considerando o DDSE, para (a) treinamento e teste com (b) 15% e (c) 30%.



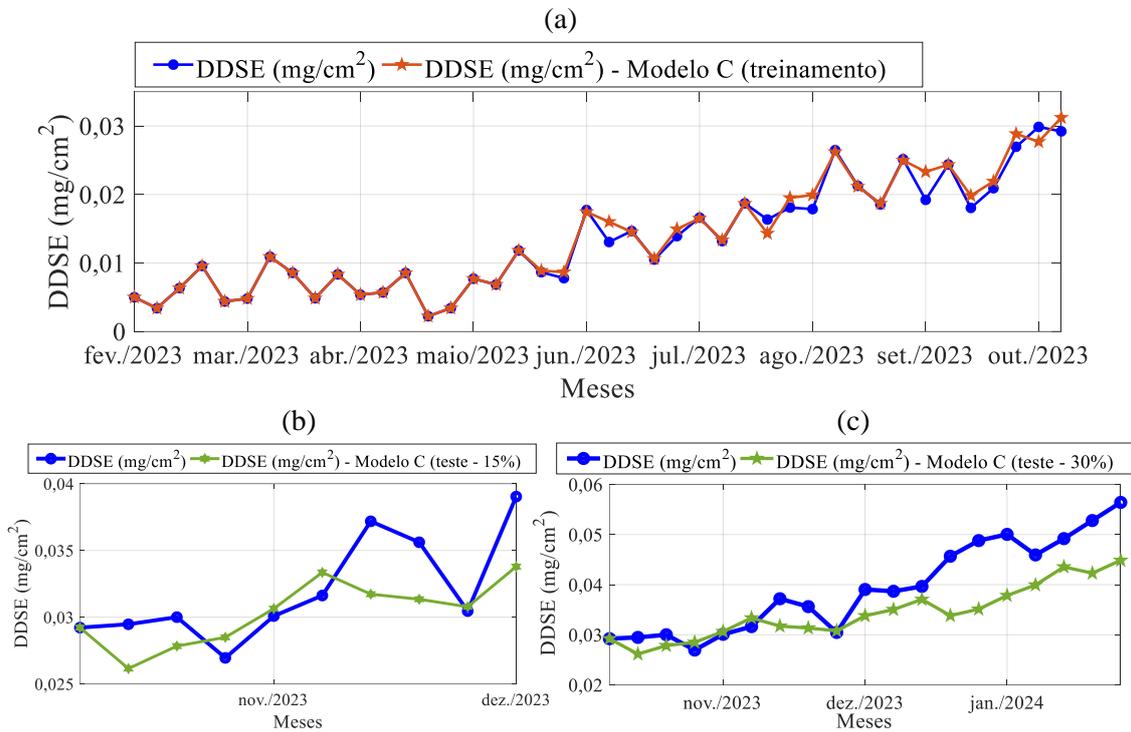
Fonte: autor (2025).

Figura 5.7 – Previsões realizadas com o modelo B, considerando o DDNS, para (a) treinamento e teste com (b) 15% e (c) 30%.



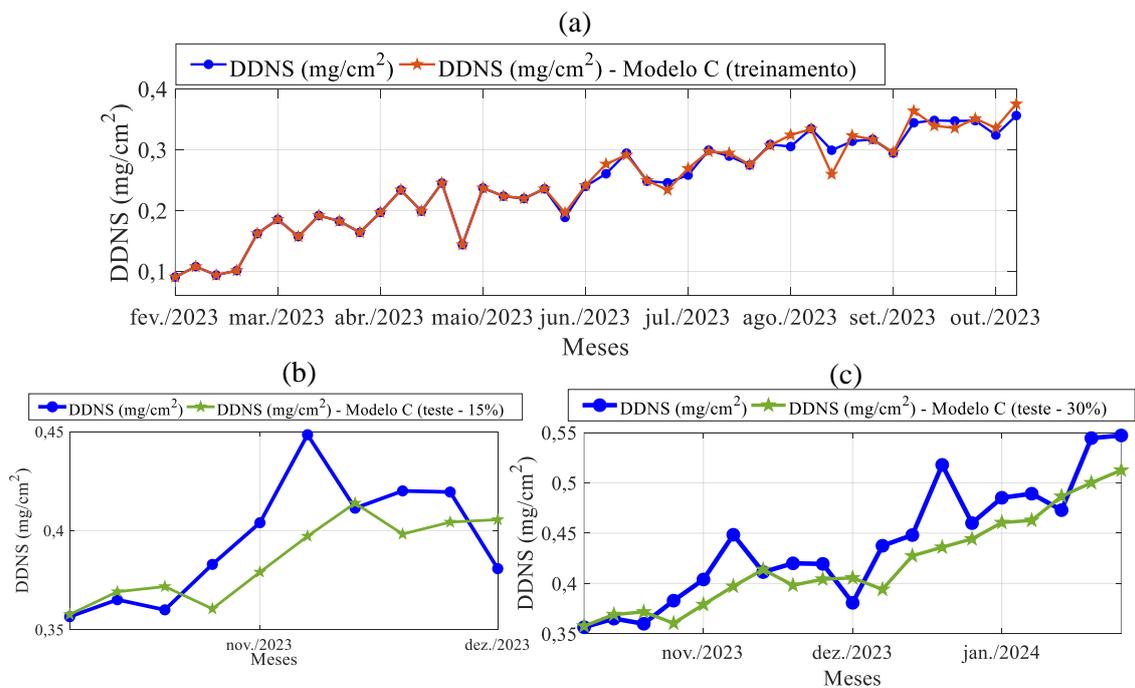
Fonte: autor (2025).

Figura 5.8 – Previsões realizadas com o modelo C, considerando o DDSE, para (a) treinamento e teste com (b) 15% e (c) 30%.



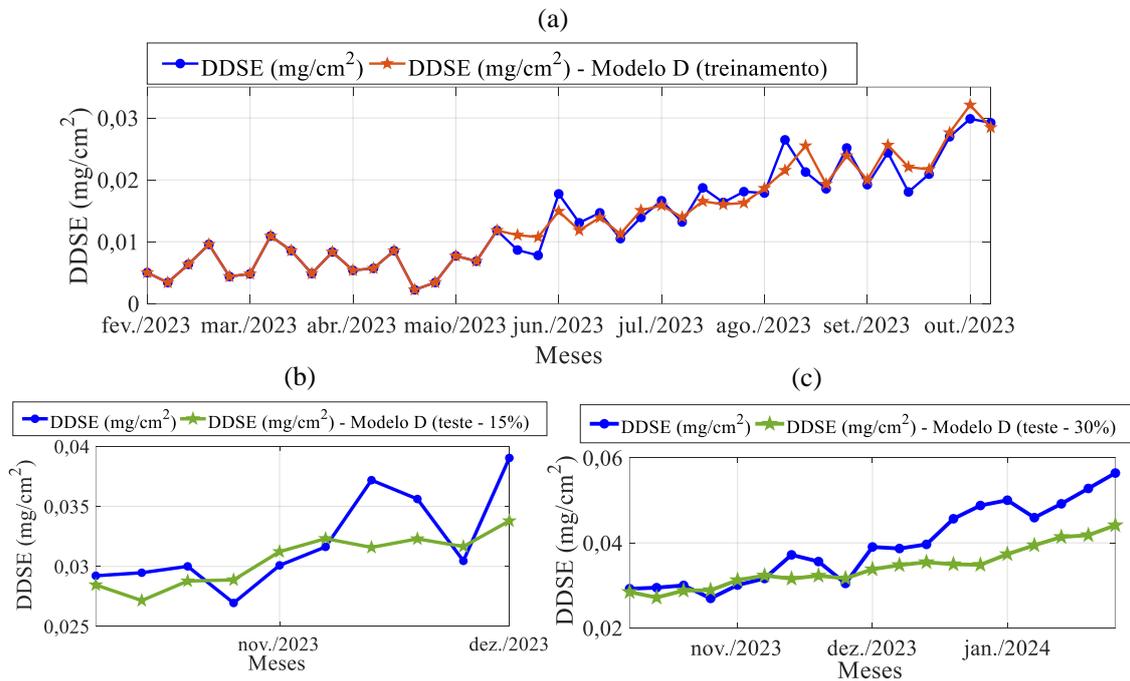
Fonte: autor (2025).

Figura 5.9 – Previsões realizadas com o modelo C, considerando o DDNS, para (a) treinamento e teste com (b) 15% e (c) 30%.



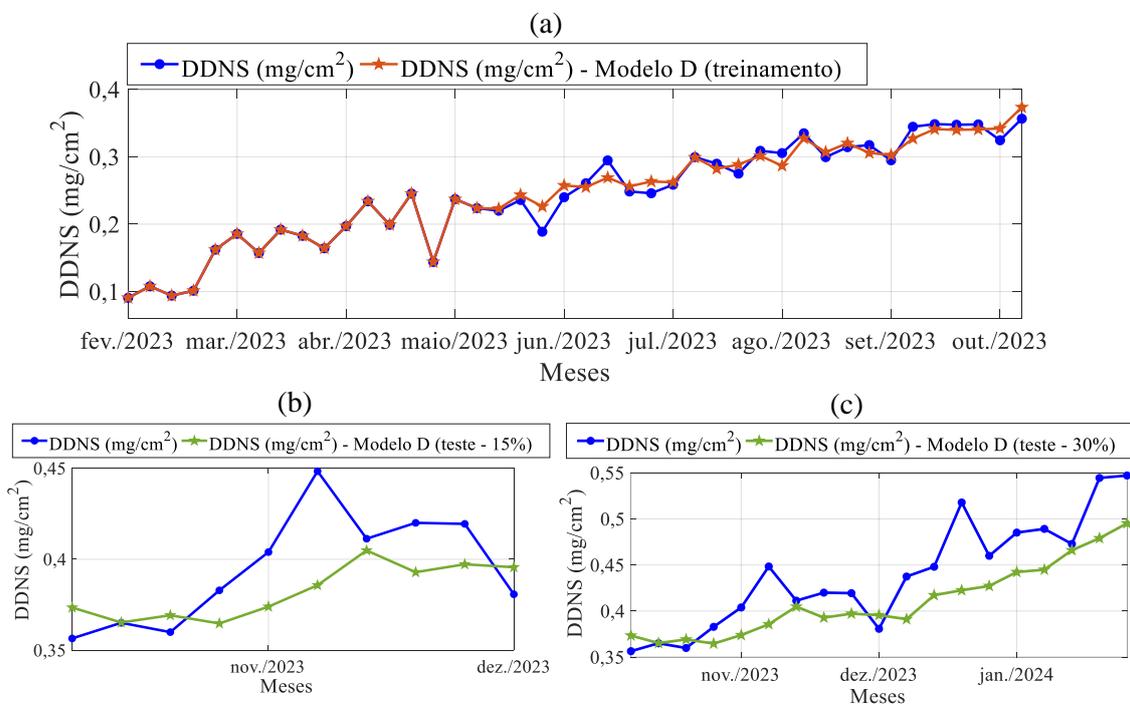
Fonte: autor (2025).

Figura 5.10 – Previsões realizadas com o modelo D, considerando o DDSE, para (a) treinamento e teste com (b) 15% e (c) 30%.



Fonte: autor (2025).

Figura 5.11 – Previsões realizadas com o modelo D, considerando o DDNS, para (a) treinamento e teste com (b) 15% e (c) 30%.



Fonte: autor (2025).

Na fase de teste dos modelos A e B (cenário sem névoa e considerando o horizonte de previsão com 15% dos dados, de novembro a dezembro de 2023), com base nos valores do MAPE, o modelo A apresentou melhor desempenho para as previsões dos índices DDSE e DDNS que o modelo B, conforme pode ser verificado no gráfico da Figura 5.2-(a). Ainda considerando o horizonte de previsão com 15% dos dados, com névoa, o modelo D apresentou melhor desempenho em relação ao modelo C para as previsões da DDSE, porém o desempenho do modelo C foi melhor para as previsões da DDNS. Considerando as previsões com horizonte de tempo mais longo (30% da base de dados, de novembro a janeiro de 2024), o modelo A apresentou melhor desempenho para as previsões dos índices DDSE e DDNS que o modelo B, para o cenário sem névoa, conforme pode ser verificado no gráfico da Figura 5.2-(b). Ainda com base no mesmo gráfico, o modelo C apresentou melhor desempenho que o modelo D para as previsões da DDSE e DDNS, para o cenário com névoa.

Com o intuito de sumarizar os valores da métrica de desempenho (MAPE), os valores médios do MAPE foram obtidos, com base nos valores individuais do MAPE calculados para a DDSE e DDNS, para os horizontes de previsão com 15% e 30% da base de dados, como pode ser verificado na Figura 5.3. Para o horizonte de previsão mais crítico (com 30%), o qual é apresentado na Figura 5.3-(b), os modelos A e C apresentam o melhor desempenho para os cenários sem névoa e com névoa, respectivamente. Dessa forma, para o cenário mais crítico de previsão (horizonte de previsão mais longo), os modelos A e C (baseados no algoritmo MLP) apresentaram melhor desempenho que os demais modelos (baseados no algoritmo SVR), tendo valores do MAPE abaixo de 10%, isto é, com exatidão muito alta das estimativas realizadas, considerando a classificação apresentada na Tabela 2.3.

Para avaliação qualitativa dos modelos A, B, C e D, os resultados gráficos obtidos nas fases de treinamento e teste são utilizados. Nesse sentido, os resultados gráficos dos modelos A, B, C e D são apresentados nas Figuras 5.4 a 5.11, contemplando as fases de treinamento e teste (15% e 30% da base de dados). Por inspeção, constata-se que os modelos A e C, que se baseiam no algoritmo MLP, se ajustaram melhor às séries temporais da DDSE e DDNS que os demais modelos, considerando a fase de treinamento (de fevereiro de 2023 até outubro de 2023). Com base ainda nos resultados gráficos, para a fase de teste (15% e 30%), constata-se que os modelos A e C foram capazes de acompanhar a parcela das séries temporais destinadas para teste, para ambos os horizontes de tempo, além de apresentar desempenho superior em relação aos demais modelos. Os

resultados gráficos estão coerentes com as métricas de desempenho obtidas. Essas análises qualitativas são complementares às análises baseadas nas métricas de desempenho, pois é possível analisar a tendência futura dos valores previstos dos índices DDSE e DDNS.

O desempenho do modelo de previsão na fase de treinamento está relacionado com o seu desempenho na etapa de teste, na maioria dos casos (GÉRON, 2019; BARBOSA *et al.*, 2021; BARBOSA *et al.*, 2024). Os resultados apresentados nas Tabela 5.1 e Figuras 5.2 e 5.3. corroboram com isso, tendo em vista que os modelos A e C apresentaram os maiores valores do coeficiente de determinação (próximo do valor unitário), na fase de treinamento, e os menores valores para o MAPE, na fase de teste, principalmente para o horizonte de tempo mais crítico (30%).

O modelo possuir exatidão muito alta, como foi verificado para os modelos A e C na fase de teste, sobretudo para o horizonte de tempo mais crítico (30%), é importante para que as estimativas realizadas pelos modelos sejam confiáveis e os *insights* obtidos a partir das previsões sejam utilizados com segurança. Assim, o nível de poluição superficial dos isoladores pode ser previsto e ações para manutenção preditiva podem ser adotadas com base nas estimações realizadas.

De maneira semelhante às constatações apresentados nesta pesquisa, diversos outros trabalhos também demonstraram o desempenho superior do algoritmo MLP em comparação ao SVR (HAYKIN, 2008; GÉRON, 2019; NIELSEN, 2019). O algoritmo SVR requer o armazenamento de vetores de suporte, que são pontos de dados cruciais para a construção do hiperplano de regressão. Quando o número de vetores de suporte é substancial, pode haver uma demanda significativa por memória para armazenamento. Por outro lado, o algoritmo MLP não possui essa exigência adicional de armazenamento. Além disso, o algoritmo SVR pode ser sensível a *outliers* e ruídos nos dados de treinamento, o que pode impactar a localização e a forma do hiperplano de regressão, afetando os resultados do modelo. O algoritmo MLP é menos suscetível a esses problemas e consegue lidar melhor com mudanças abruptas nos dados. Ademais, o algoritmo MLP pode aproveitar o processamento paralelo para melhorar o desempenho computacional e acelerar o processamento de grandes volumes de dados, reduzindo o tempo de execução. Diante dos resultados obtidos e das limitações do algoritmo SVR, os modelos baseados em MLP deve ser escolhido para integrar a metodologia proposta.

5.2 CRITÉRIOS PARA PREVISÃO DO NÍVEL CRÍTICO DE POLUIÇÃO

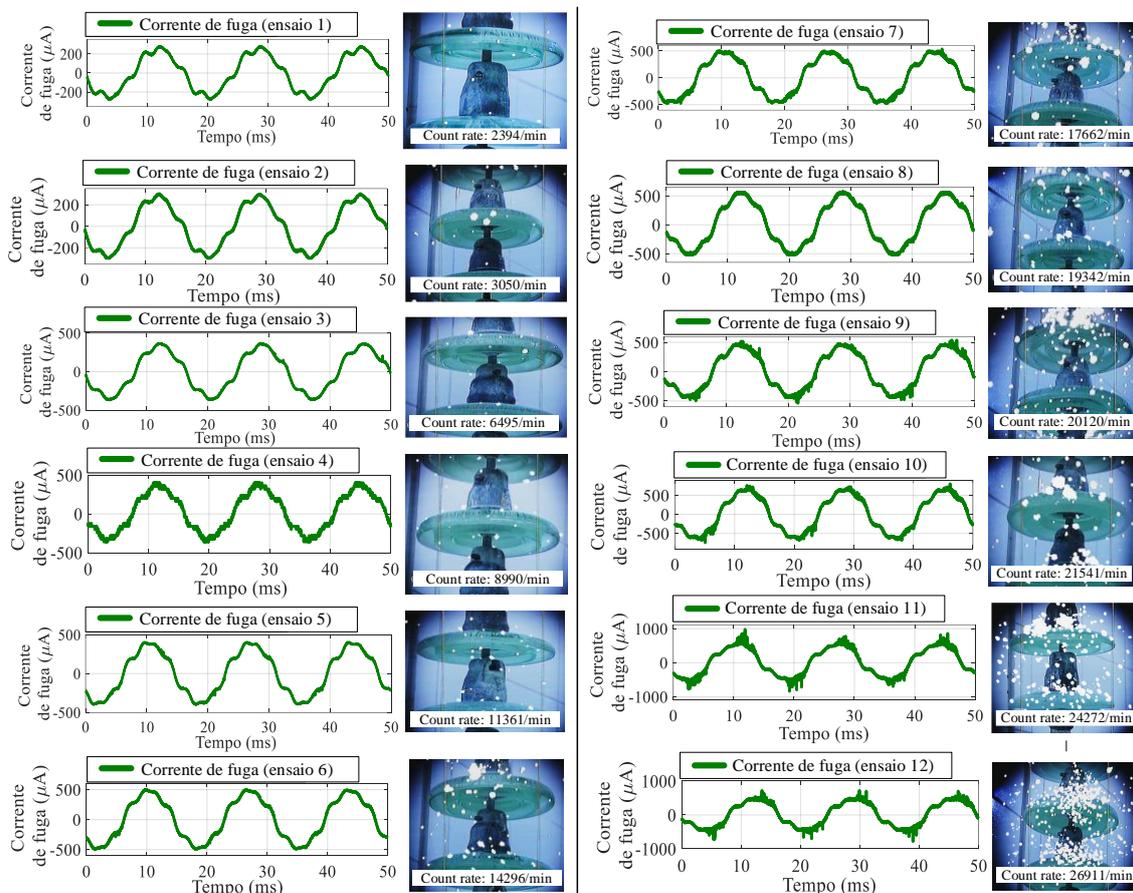
A determinação de um critério para indicar o nível crítico de poluição em isoladores de vidro foi realizada neste trabalho, por meio de investigações baseadas nos ensaios de poluição artificial. Para isso, ao longo dos ensaios de poluição artificial foram registrados os sinais da corrente de fuga, imagens capturadas pela câmera UV e os valores da DDSE e DDNS. O nível crítico de poluição foi associado à presença de descargas superficiais. A ocorrência dessas descargas pode provocar *spikes* nos locais de vale e crista do sinal da corrente de fuga, como também altos níveis de emissões de radiação UV (BARROS, 2011). Considerando isso, investigações em laboratório foram realizadas por meio de ensaios de poluição artificial, com o intuito de identificar os níveis de poluição (DDSE e DDNS) responsáveis por causar descargas superficiais na cadeia de isoladores de vidro utilizada como objeto de teste.

Nas Figuras 5.12 e 5.13 são apresentados sinais da corrente de fuga e registros realizados com a câmera UV para os doze níveis de poluição artificial simulados em laboratório, sem névoa e com névoa, respectivamente. Ao longo dos registros dos sinais de corrente e imagens da câmera UV, a tensão manteve-se praticamente constante, com valores médios de 41,8 kV e 41,5 kV para os ensaios sem névoa e com névoa, nessa ordem, conforme apresentado nas Tabelas 4.2 e 4.3. Nos gráficos apresentados dos sinais da corrente de fuga, as legendas indicam o ensaio correspondente e a numeração possui o mesmo sentido do nível de poluição, de modo que o ensaio 1 corresponde ao menor nível de poluição (nível de poluição leve) e o ensaio 12 refere-se ao maior nível de poluição (nível de poluição pesada), dentre os níveis simulados. Nesse sentido, considerando a combinação dos índices DDSE e DDNS, os ensaios 1, 2, 3 e 4 correspondem ao nível de poluição leve; os ensaios 5, 6, 7, 8, 9 e 10 referem-se ao nível de poluição médio; e os ensaios 11 e 12 correspondem ao nível de poluição pesada.

Nos sinais de corrente de fuga e imagens da câmera UV apresentados na Figura 5.12, sem presença de névoa, verifica-se a elevação da amplitude da corrente à medida que o nível de poluição cresce, com variação de 280 μA no ensaio 1 para 1080 μA no ensaio 12; além do aumento de emissões UV por minuto, com 2394 fótons/min. para o ensaio 1 e 26911 fótons/min. para o ensaio 12. Para o nível de poluição referente ao ensaio 10 (DDSE = 0,0347 mg/cm^2 e DDNS = 0,4152 mg/cm^2),

ainda nível de poluição moderada e já no limítrofe da poluição pesada, constata-se a presença de *spikes* nos locais de crista do sinal de corrente, principalmente; e a intensidade de radiações UV cresce conforme o aumento da presença de *spikes* (valor de 20120 fótons/minutos); caracterizando, assim, a ocorrência de descargas superficiais. No ensaio de poluição 1, correspondente ao nível de poluição leve, não são observados *spikes*, indicando que não há descargas superficiais nos isoladores; além disso, o contador de radiações UV está ligeiramente baixo, com valor de 2394 fótons/min.

Figura 5.12 – Registros dos sinais da corrente de fuga e das imagens dos isoladores oriundas da câmera UV, contemplando os doze ensaios de poluição artificial, sem aplicação de névoa.

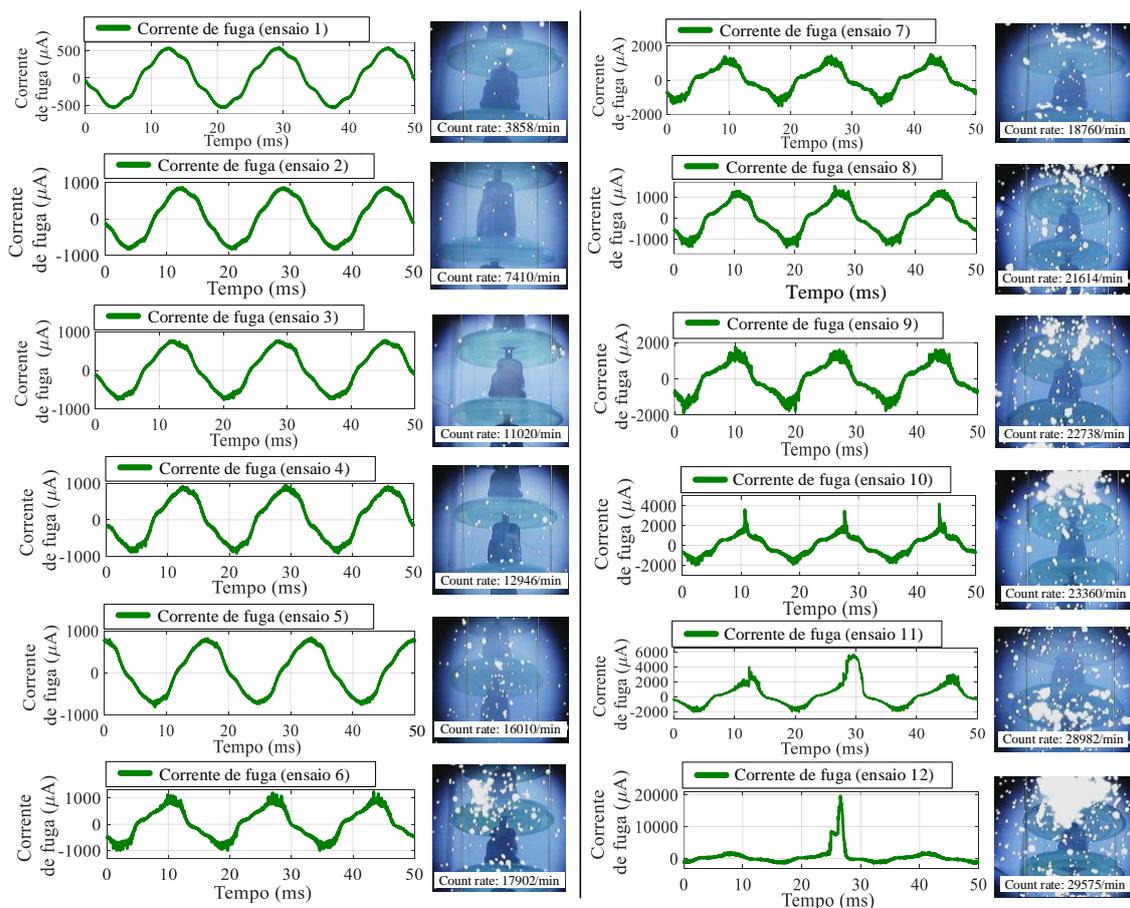


Fonte: autor (2025).

Em relação aos ensaios de poluição com aplicação de névoa, considerando a Figura 5.13, constata-se também a elevação da amplitude da corrente à medida que o nível de poluição cresce, com variação de 552 µA no ensaio 1 para 19600 µA no ensaio 12; além do aumento de emissões UV por minuto, com 3858 fótons/min. para o ensaio 1 e 29575 fótons/min. para o ensaio 12. Para o nível de poluição referente ao ensaio 9 (DDSE = 0,0320 mg/cm² e DDNS = 0,3798 mg/cm²), ainda nível de poluição moderada, constata-se a presença de *spikes* persistentes nos locais de crista do sinal de corrente,

principalmente; e a intensidade de radiações UV cresce conforme o aumento da presença de *spikes* (valor de 18760 fótons/min.); caracterizando, assim, a ocorrência de descargas superficiais. No ensaio de poluição 1, referente ao nível de poluição leve, não são observados *spikes*, indicando que não há descargas superficiais nos isoladores; além disso, o contador de radiações UV está consideravelmente baixo, com valor de 3858 fótons/min.

Figura 5.13 – Registros dos sinais da corrente de fuga e das imagens dos isoladores oriundas da câmera UV, contemplando os doze ensaios de poluição artificial, com aplicação de névoa.



Fonte: autor (2025).

Com base nos resultados experimentais obtidos neste trabalho, valores da DDSE e DDNS que indicam nível crítico de poluição (ocorrência de descargas superficiais) foram definidos, para situações sem névoa e com névoa. Para os ensaios sem névoa, foram constatadas descargas superficiais nos níveis de poluição para $DDSE \geq 0,0347 \text{ mg/cm}^2$ e $DDNS \geq 0,4152 \text{ mg/cm}^2$ (limítrofe superior do nível de poluição moderado); e para os ensaios com névoa, surgiram descargas superficiais nos níveis de poluição para $DDSE \geq 0,0320 \text{ mg/cm}^2$ e $DDNS \geq 0,3798 \text{ mg/cm}^2$ (ainda dentro do nível de poluição moderado).

5.3 PREVISÃO DO NÍVEL CRÍTICO DE POLUIÇÃO

Como os modelos A e C apresentaram desempenho superior aos demais modelos nas fases de treinamento (maior coeficiente de determinação) e teste (menores valores do MAPE), eles devem ser utilizados para prever as séries temporais referentes aos índices DDSE e DDNS, conforme definido na estratégia proposta. E utilizando os critérios baseados na DDSE e DDNS, que indicam o surgimento de descargas superficiais (nível crítico de poluição superficial), torna-se possível realizar estimativa do momento ótimo para manutenção de limpeza em isoladores de vidro.

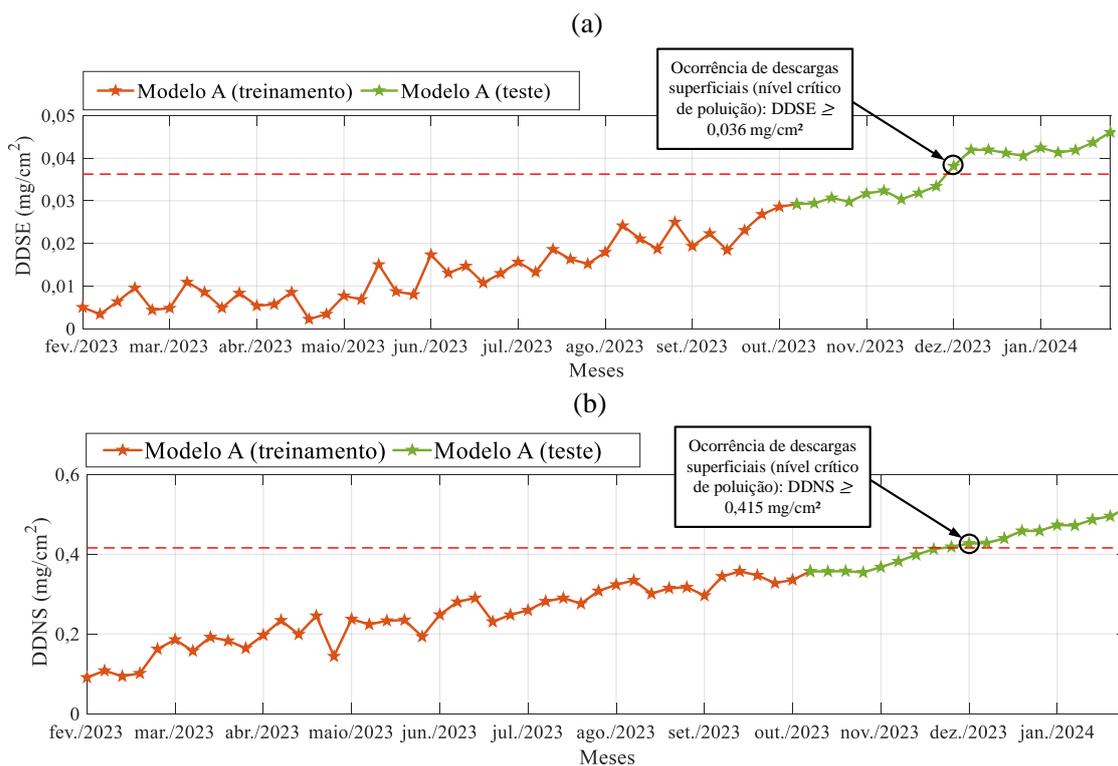
A previsão do momento ótimo para manutenção de limpeza em isoladores de vidro empregados neste trabalho inicia com o desenvolvimento dos modelos A e C, ambos baseados em MLP e com os hiperparâmetros que proporcionam os melhores resultados (sem acarretar em *overfitting*), para as situações sem névoa e com névoa, respectivamente. Como esses modelos foram treinados e testados, eles podem ser utilizados para fazer previsões das séries temporais dos índices DDSE e DDNS, sem névoa e com névoa, até que o nível de poluição crítica seja alcançado. Dessa forma, o momento ótimo para realização de limpeza em isoladores é estimado a partir das previsões de séries temporais da DDSE e DDNS realizadas pelos modelos computacionais desenvolvidos, que utilizam como entradas os dados históricos referentes aos parâmetros da corrente de fuga e valores dos índices DDSE e DDNS, aplicando como critérios os valores limiares da DDSE e DDNS (indicadores da ocorrência de descargas superficiais) definidos empiricamente. Para estimativa do momento ótimo, realiza-se a contagem do intervalo de tempo iniciando imediatamente após o último valor de cada uma das séries temporais (a partir de outubro de 2023) até a data em que o nível crítico de poluição (com base na DDSE e DDNS) é alcançado, que vai depender dos cenários sem névoa e com névoa.

Com base nos modelos A e C, os valores das séries temporais da DDSE e DDNS foram previstos, abrangendo todos os níveis de poluição considerados neste trabalho (leve, moderado e pesado), para os ensaios sem névoa e com névoa, nessa ordem. Realizou-se previsão de teste de 4 meses (cerca de 20 semanas) à frente, conforme indicado nas Figuras 5.14 e 5.15, pois esse horizonte de previsão foi o suficiente para alcançar os níveis de DDSE e DDNS referentes ao nível crítico de poluição, viabilizando o estudo de caso para determinar o momento ótimo para manutenção de limpeza em isoladores. Os valores destacados nessas figuras indicam os valores da DDSE e DDNS

associados aos níveis críticos de poluição (quando há ocorrência de descargas superficiais), para as situações sem névoa e com névoa.

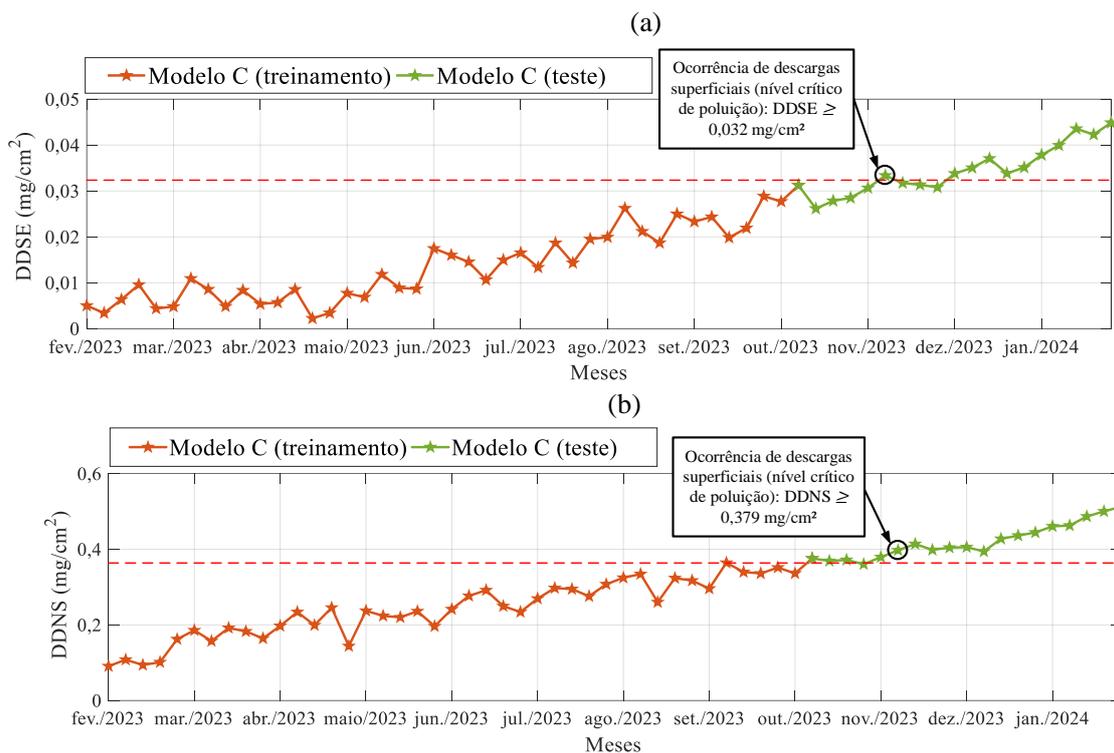
Com base nas previsões realizadas pelo modelo A, que é apresentada na Figura 5.14 e referente ao contexto sem névoa, para as séries temporais da DDSE e DDNS, estima-se que o momento ótimo para realizar manutenção de limpeza nos isoladores considerados neste trabalho seria aproximadamente 2 meses à frente da data de previsão, isto é, no término de novembro de 2023, considerando que a data de previsão ocorreu no início de outubro do mesmo ano. De forma similar, para o contexto com névoa, analisando as previsões realizadas pelo modelo C e apresentadas na Figura 5.14, estima-se que o momento ótimo para realizar manutenção de limpeza nos isoladores seria aproximadamente 1 mês à frente da data de previsão, ou seja, no início de novembro de 2023, considerando que a data de previsão ocorreu no início de outubro do mesmo ano.

Figura 5.14 – Previsões das séries temporais da (a) DDSE e (b) DDNS realizadas pelo modelo A, para a situação sem névoa.



Fonte: autor (2025).

Figura 5.15 – Previsões das séries temporais da (a) DDSE e (b) DDNS realizadas pelo modelo C, para a situação com névoa.



Fonte: autor (2025).

A realização de previsões dos níveis de poluição (DDSE e DDNS) é uma atividade dinâmica, de modo que a previsão do nível crítico de poluição (ocorrência de descargas superficiais) não deve ser adotada como absoluta, pois fatores ambientais e adversos (por exemplo, danos físicos, condições climáticas desfavoráveis, projeto inadequado) podem favorecer o aparecimento desse tipo de descarga. Conseqüentemente, o momento ótimo para realização de manutenção de limpeza nos isoladores depende de vários fatores ambientais, de modo que o momento estimado que foi apresentado é válido para a cadeia de isoladores de vidro adotada como objeto de teste nesta pesquisa e nas condições em que os isoladores foram submetidos. Ao adicionar novas medições de dados históricos (parâmetros da corrente de fuga e valores dos índices DDSE e DDNS) à base de dados, a estimativa do momento ótimo de limpeza pode ser diferente em virtude de ser necessário realizar uma nova modelagem e novas previsões das séries temporais da DDSE e DDNS.

Os critérios $DDSE \geq 0,0347$ mg/cm² e $DDNS \geq 0,4152$ mg/cm² para poluição sem névoa e $DDSE \geq 0,0320$ mg/cm² e $DDNS \geq 0,3798$ mg/cm² para poluição com névoa foram adequados para os isoladores de vidro com as especificações utilizadas neste trabalho. Para isoladores com especificações diferentes, os critérios definidos não devem

ser adotados de forma absoluta/universal, de modo que maiores investigações devem ser realizadas, visto que o nível de poluição depende de diferentes combinações dos índices de DDSE e DDNS. Por consequência disso, os critérios propostos para auxiliar a estimar o momento ótimo para manutenção de limpeza em isoladores de vidro podem variar também em virtude dos diferentes níveis de poluição derivados das diferentes combinações da DDSE e DDNS.

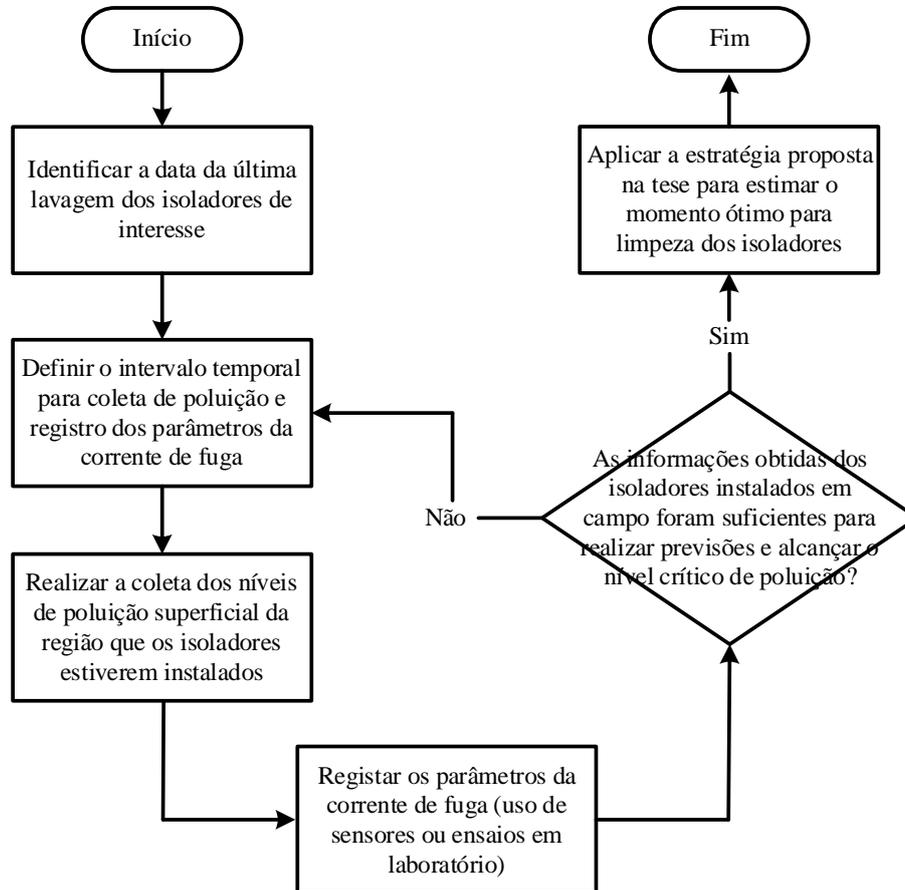
5.4 PROPOSIÇÃO DE APLICAÇÃO EM CAMPO

A estratégia proposta para estimar o momento ótimo de limpeza nos isoladores de vidro pode ser empregada em campo, conforme as etapas apresentadas no fluxograma da Figura 5.16. Uma vez que os modelos tenham sido treinados e testados com informações após a última lavagem dos isoladores, eles poderiam ser alimentados com novos dados históricos, respeitando a quantidade de amostras históricas definida para fazer previsões futuras dos índices DDSE e DDNS. Como os modelos utilizam informações históricas de parâmetros da corrente de fuga, DDSE e DDNS como entradas, a realização de coletas seria necessária para que os modelos pudessem ser alimentados e novas previsões fossem feitas. Para obter as entradas para alimentação dos modelos é preciso fazer registros ao longo do tempo dos sinais da corrente de fuga (ou apenas os parâmetros selecionados para modelagem) do sistema elétrico no qual os isoladores estão instalados, por meio de sensores de baixo custo, e fazer coletas dos níveis de DDSE e DDNS, a fim de que as previsões da DDSE e DDNS possam ser realizadas e o momento ótimo para limpeza dos isoladores possa ser estimado. Para coleta dos níveis de poluição, uma cadeia com isoladores similares aos aplicados na região de interesse poderia ser usada para o depósito da poluição superficial ao longo do tempo.

Ainda no sentido de aplicar a metodologia em campo, uma alternativa do registro dos sinais de corrente de fuga por meio de sensores seriam a simulação em laboratório, para simular as condições semelhantes ao ambiente de manutenção e obter todos os dados em ambiente controlado (em relação ao nível de tensão aplicada). Entretanto, esse tipo de alternativa poderia ter ônus, por ser necessário o deslocamento dos isoladores com os níveis de poluição para serem ensaiados em laboratório. Com isso, seria possível inferir as informações dos sinais da corrente de fuga das outras cadeias de isoladores instaladas

ao longo da linha de transmissão, considerando que os isoladores adotados para coleta de poluição estivessem com níveis de poluição correspondentes ao ambiente em que a metodologia fosse aplicada.

Figura 5.16 – Fluxograma das etapas para aplicação em campo da metodologia apresentada na tese.



Fonte: autor (2025).

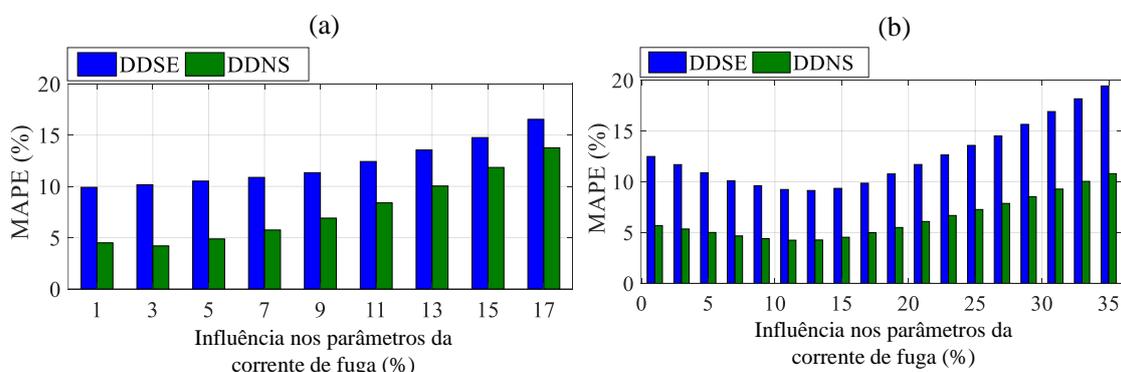
5.5 INFLUÊNCIA DA VARIAÇÃO DA CORRENTE DE FUGA NAS SAÍDAS DOS MODELOS

Uma vez que os modelos foram avaliados e selecionados para compor a estratégia para estimativa do momento ótimo para manutenção de limpeza nos isoladores, a análise da influência da variação da corrente de fuga nas saídas (DDSE e DDNS) dos modelos A e C é necessária, tendo em vista que a saída de cada modelo pode ser sensível a elevações de tensão presentes no sistema elétrico, pois parâmetros da corrente de fuga também foram utilizados como atributos de entrada. Considerando isso, o intuito é mensurar o

quanto as saídas de cada modelo são influenciadas por variações nos parâmetros da corrente de fuga, por motivos que não estejam relacionados com elevação do nível de poluição. E também analisar o quanto essas variações podem influenciar na acurácia dos modelos.

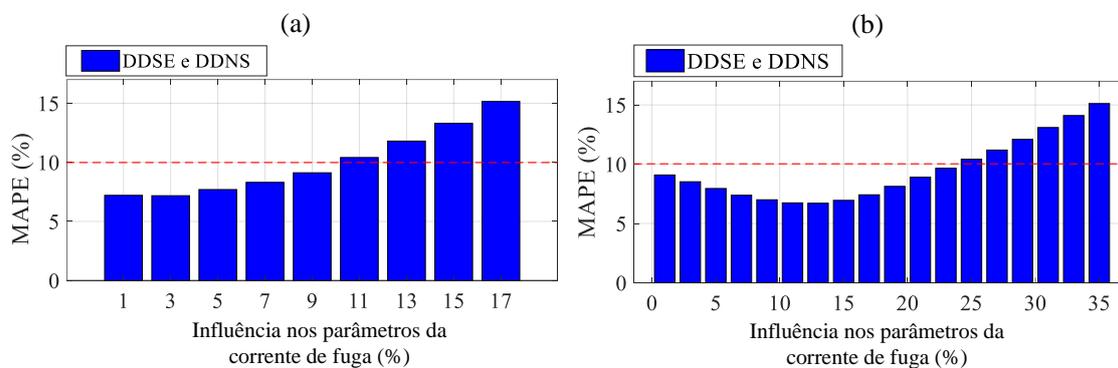
A análise da influência da variação dos parâmetros da corrente de fuga nas saídas dos modelos é realizada com base no MAPE, para avaliar o quanto a acurácia de cada modelo é afetada, considerando que as variações não sejam provocadas por oscilações no nível de poluição. Para essa análise, apenas os parâmetros da corrente de fuga foram alterados, multiplicando-os por fatores, de modo a provocar elevação da corrente de fuga de modo gradual. A elevação foi realizada até que fosse verificado o valor do MAPE acima de 10%, considerando o valor médio para as saídas referentes aos índices DDSE e DDNS. Nas Figuras 5.17 e 5.18 são apresentados gráficos ilustrando os valores do MAPE obtidos para cada um dos fatores aplicados nos parâmetros da corrente de fuga, sabendo que foram aplicados os fatores com este formato: 1,01; 1,03; 1,05; 1,07; 1,09; 1,11; 1,13; 1,15; 1,17; para os resultados obtidos com ensaios sem névoa. E para os resultados obtidos em ensaios com névoa, os seguintes fatores foram empregados: 1,01; 1,03; 1,05; 1,07; 1,11; 1,13; 1,15; 1,17; 1,19; 1,21; 1,23; 1,25; 1,27; 1,29; 1,31; 1,33; 1,35. Com base nos valores do MAPE obtidos para cada um dos fatores, considerando os valores médios apresentados na Figura 5.18-(a), para a situação sem névoa, é possível um aumento de 9% nos parâmetros da corrente de fuga sem ultrapassar o valor de 10% do MAPE; e a situação com névoa, referente aos valores apresentados na Figura 5.18-(b), é possível um aumento de 23% nos parâmetros da corrente de fuga sem ultrapassar o valor de 10% do MAPE.

Figura 5.17 – Valores do MAPE obtidos para análise da variação das saídas dos modelos (para cada índice DDSE e DDNS), para as situações (a) sem névoa (modelo A) e (b) com névoa (modelo B).



Fonte: autor (2025).

Figura 5.18 – Valores do MAPE obtidos para análise da variação das saídas do modelo A (considerando o valor médio dos desvios dos índices DDSE e DDNS), para as situações (a) sem névoa (modelo A) e (b) com névoa (modelo B).



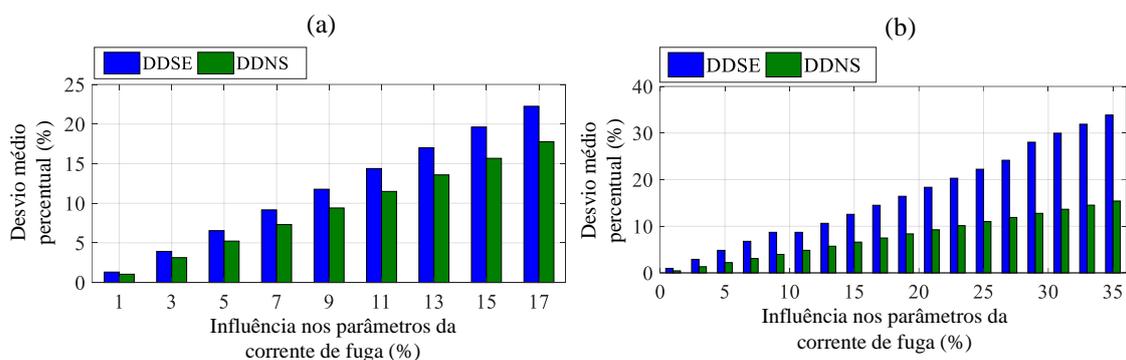
Fonte: autor (2025).

De forma complementar, a análise da influência da variação dos parâmetros da corrente de fuga nas saídas dos modelos também é realizada por meio do desvio médio percentual (com forma de cálculo semelhante ao MAPE), comparando os valores previstos sem alteração dos parâmetros da corrente de fuga com as previsões realizadas com alteração apenas da corrente de fuga, a fim de analisar o quanto as saídas são sensíveis às alterações realizadas nos parâmetros da corrente. De modo semelhante à análise realizada anteriormente e usando os mesmos fatores, apenas os parâmetros da corrente de fuga foram alterados, multiplicando-os por fatores, de modo a provocar elevação da corrente de fuga de modo gradual. Nas Figuras 5.19 e 5.20, são apresentados gráficos ilustrando os valores obtidos do desvio médio percentual. Com base sobretudo na Figura 5.20-(a), verifica-se que a realização de alteração nos parâmetros da corrente de fuga em até 9% provoca um desvio médio percentual de aproximadamente 10% nas previsões dos índices da DDSE e DDNS, para a situação sem névoa (modelo A); e para as previsões dos índices da DDSE e DDNS, para a situação com névoa (modelo C), com base na Figura 5.20-(b), a realização de elevação apenas dos parâmetros da corrente de fuga de 23% provoca um desvio médio percentual de aproximadamente 16% em relação aos valores previstos sem alteração nos parâmetros da corrente.

As oscilações de tensão no SEP podem ocorrer por diversas razões, sendo as mais comuns: variações na demanda de carga, condições meteorológicas adversas, falta de reativos adequados, faltas nos sistemas elétricos e comutação de bancos de capacitores ou reatores. Independente da causa, existindo oscilação da tensão, espera-se que não ultrapasse a margem recomendada pela ANEEL, que está entre 0,95 p.u. e 1,05 p.u., em

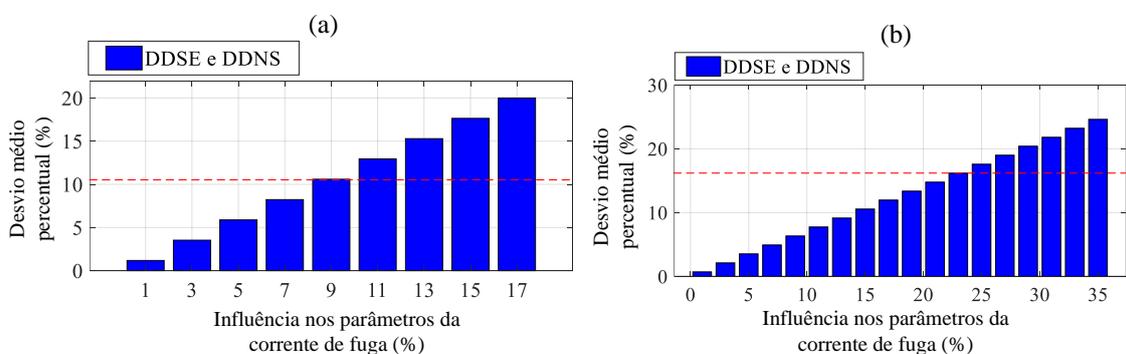
relação à tensão nominal (ANEEL, 2020). Existindo a regulação da tensão dentro dessa faixa permitida pela ANEEL, não ocorrerá mudanças significativas nas previsões realizadas pelos modelos A e C, em relação ao desempenho (acurácia baseada no MAPE) e desvio médio percentual (quando comparado com a situação em que a regulação de tensão não existisse). Considerando as constatações obtidas por meio das análises da influência da variação dos parâmetros da corrente de fuga nas saídas dos modelos e se a tensão oscilar dentro da faixa recomendada pela ANEEL (0,95 p.u. a 1,05 p.u.), não haverá impacto significativo na acurácia (MAPE) ou no desvio médio percentual das previsões dos modelos A e C, conforme evidenciado.

Figura 5.19 – Valores do desvio médio percentual obtidos da comparação das saídas sem alteração e com alteração dos parâmetros da corrente de fuga para análise da variação das saídas dos modelos (para cada índice DDSE e DDNS), para as situações (a) sem névoa (modelo A) e (b) com névoa (modelo B).



Fonte: autor (2025).

Figura 5.20 – Valores do desvio médio percentual obtidos da comparação das saídas sem alteração e com alteração dos parâmetros da corrente de fuga para análise da variação das saídas dos modelos (considerando o valor médio dos desvios dos índices DDSE e DDNS), para as situações (a) sem névoa (modelo A) e (b) com névoa (modelo B).



Fonte: autor (2025).

5.6 RESUMO DO CAPÍTULO

Este capítulo apresentou os resultados obtidos por meio dos ensaios de poluição ambiente, que foram utilizados para nortear os ensaios de poluição artificial, e modelagens computacionais utilizando os algoritmos MLP e SVR, como também uma estrutura de dados adequada para realização de previsão de séries temporais. Nesse sentido, os resultados obtidos a partir dos modelos desenvolvidos foram avaliados de forma quantitativa e qualitativa, a fim de selecionar os melhores modelos para serem usados na previsão de valores futuros dos indicadores DDSE e DDNS (para determinação do nível crítico de poluição) usando dados históricos de parâmetros da corrente de fuga, DDSE e DDNS, permitindo estimar o momento ótimo para manutenção de limpeza em isoladores de vidro. Os modelos selecionados para representar a poluição superficial da cadeia de isoladores de vidro foram baseados no algoritmo MLP. Os valores da DDSE e DDNS associados ao nível crítico de poluição foram definidos a partir de ensaios realizados em laboratório, para as situações de ensaio sem névoa e com névoa. A partir dos modelos computacionais desenvolvidos e dos critérios propostos para identificar a ocorrência de descargas superficiais nos isoladores de vidro utilizados neste estudo, foi implementada a estratégia definida para estimar o momento ótimo de manutenção de limpeza dos isoladores. E, ainda, realizou-se a análise da influência da variação dos parâmetros da corrente de fuga nas saídas dos modelos A e C diante de elevações dos parâmetros da corrente de fuga, por motivos que não estejam relacionados com elevação do nível de poluição.

No próximo capítulo, as conclusões e a proposição de pesquisas futuras serão apresentadas.

CAPÍTULO 6

CONCLUSÕES

Nesta tese, a estimativa do momento ótimo para manutenção de limpeza em isoladores de vidro foi proposta e realizada, considerando as situações sem névoa e com névoa, utilizando dados históricos (parâmetros de corrente de fuga e valores dos índices DDSE e DDNS), modelos otimizados baseados no algoritmo MLP e critérios que indicam a ocorrência de descargas superficiais.

A construção de um banco de dados com informações históricas dos parâmetros da corrente de fuga, níveis de poluição (DDSE e DDNS) e variáveis ambientais foi realizada. Para construção desse banco de dados, experimentos em ambiente externo foram realizados a fim de registrar as evoluções dos níveis de poluição ao longo de 12 meses. A partir dos níveis de poluição registrados (DDSE e DDNS), ensaios em laboratório foram realizados para simular esses níveis de poluição e obter os sinais da corrente de fuga correspondentes, bem como as correspondentes condições ambientais. A base de dados resultante dos ensaios em laboratório foi utilizada para o desenvolvimento dos modelos A, B, C e D, os quais foram estudados, avaliados e comparados utilizando métricas estatísticas.

Os modelos computacionais foram baseados nos algoritmos MLP e SVR, para realizar previsão de séries temporais da DDSE e DDNS utilizando dados históricos de parâmetros da corrente de fuga que apresentaram correlação forte e muito forte com a poluição superficial de isoladores. A utilização dos algoritmos MLP e SVR possibilitou a construção de modelos dependentes de parâmetros da corrente de fuga (I_{Pico} , I_{RMS} , I_{1Harm} , I_{3Harm} , I_{5Harm} e I_{DHT}) e valores da DDSE e DDNS, tornando a estimativa mais robusta e com maior capacidade de incorporar informações associadas ao nível de poluição na cadeia de isoladores de vidro.

Os modelos A, B, C e D desenvolvidos foram avaliados considerando métricas estatísticas, nas fases de treinamento e teste, a fim de avaliar o desempenho de cada um deles e selecionar os modelos que apresentassem o melhor desempenho para representar o processo de poluição artificial depositado na superfície de isoladores de vidro, para as

situações sem névoa e com névoa. Como os valores do R^2 obtidos para os modelos baseado no algoritmo MLP (A e C) foram maiores que os obtidos para os modelos baseados no algoritmo SVR (B e D) e, para a fase de teste, os erros associados aos modelos A e C foram os menores, considerando os valores médios do MAPE, então os modelos com os menores valores desse tipo de erro foram utilizados para prever o momento que o nível crítico de poluição iria ser alcançado, possibilitando estimar o momento ótimo para realização de manutenção de limpeza nos isoladores.

Os critérios para determinar o nível crítico de poluição na superfície dos isoladores utilizados neste trabalho foram baseados nos valores de DDSE e DDNS e determinados experimentalmente, para as situações sem névoa e com névoa. Assim, verificou-se a presença de descargas superficiais nos isoladores para $DDSE \geq 0,0347 \text{ mg/cm}^2$ e $DDNS \geq 0,4152 \text{ mg/cm}^2$, considerando o ambiente sem névoa; e para o ambiente com névoa, determinou-se $DDSE \geq 0,0320 \text{ mg/cm}^2$ e $DDNS \geq 0,3798 \text{ mg/cm}^2$ como indicadores de presença de descargas superficiais. Esses critérios foram utilizados para estimar o momento ótimo para realizar manutenção de limpeza nos isoladores considerados neste trabalho, com a utilização dos modelos computacionais A e C.

Por meio da estratégia proposta foi possível estimar o momento ótimo para manutenção de limpeza dos isoladores de vidro utilizados como objeto de teste, para as situações com névoa e sem névoa. Verificou-se que o momento ótimo para manutenção de limpeza nos isoladores seria de 2 meses à frente da data de previsão (início de outubro de 2023), para a situação sem névoa; e para a situação com névoa, o momento ótimo para realizar limpeza nos isoladores seria de 1 mês à frente do tempo de previsão (também início de outubro de 2023).

A análise da influência da variação dos parâmetros da corrente de fuga nas saídas dos modelos A e C foi realizada, a fim de mensurar o quanto as saídas de cada modelo são influenciadas por variações nos parâmetros da corrente de fuga, por motivos que não estejam relacionados com elevação do nível de poluição. Para a análise com base no MAPE, com o intuito de avaliar o quanto a acurácia do modelo é afetada, para a situação sem névoa (modelo A), constatou-se um aumento de 9% nos parâmetros da corrente de fuga sem ultrapassar o valor de 10% do MAPE; e para a situação com névoa (modelo C), é possível um aumento de 23% nos parâmetros da corrente de fuga sem ultrapassar o valor de 10% do MAPE. Com relação à análise baseada no desvio médio percentual, para o modelo A, verifica-se que a realização de alteração nos parâmetros da corrente de fuga em até 9% provoca um desvio médio percentual de aproximadamente 10% nas previsões

dos índices da DDSE e DDNS; e para o modelo C, a realização de elevação apenas dos parâmetros da corrente de fuga de 23% provoca um desvio médio percentual de aproximadamente 16% em relação aos valores previstos sem alteração nos parâmetros da corrente.

Embora a estratégia para estimativa do momento ótimo tenha sido realizada com base nos dados obtidos por meio dos ensaios de laboratório e experimentos feitos em ambiente externo, a estratégia também pode ser aplicada em situações práticas, desde que sejam coletados dados de corrente de fuga e níveis de poluição (DDSE e DDNS) históricos, de forma que o modelo possa ser ajustado para o novo conjunto de dados.

Com a estratégia proposta para estimativa do momento ótimo para realização de limpeza em isoladores de vidro, a tomada de decisão com relação ao tempo de limpeza pode ser otimizada por meio da previsão de séries temporais do nível de poluição (DDSE e DDNS) baseado nos modelos propostos neste trabalho. Desse modo, por meio do conhecimento do momento ótimo, manutenções preditivas, tal como a limpeza da cadeia de isoladores anterior ao acúmulo de poluição suficiente para gerar descargas superficiais persistentes, podem ser realizadas para evitar a ocorrência de descargas disruptivas.

6.1 PESQUISAS FUTURAS

Apesar do trabalho proposto já tenha apresentado resultados relevantes, pesquisas futuras correlatas podem ser realizadas, as quais são apresentadas a seguir.

- Realizar experimentos de poluição ambiente nos isoladores em diferentes regiões geográficas, para abranger áreas litorâneas (com presença de maresia) e regiões de alta atividade industrial, com períodos mais prolongados (de pelo menos dois anos), dado que o tipo de poluição superficial é diretamente influenciado pela localização e dois anos é o suficiente para analisar a sazonalidade. Esses experimentos permitirão identificar padrões distintos de poluição e variações sazonais, contribuindo para a construção de uma base de dados mais robusta e modelos de previsão com maior capacidade de adaptação a diferentes condições ambientais.

- Ajustar a metodologia proposta para isoladores com materiais dielétricos distintos, como os isoladores de material polimérico e porcelana, pois esses materiais possuem propriedades distintas, como comportamento em relação a descargas superficiais e resistência a agentes poluentes.
- Realizar maiores investigações acerca dos critérios que indicam a ocorrência de descargas superficiais, com monitoramento da corrente de fuga e radiações ultravioletas usando a câmera UV, buscando combinar outros valores dos índices DDSE e DDNS, para abranger uma região mais ampla no gráfico de poluição.
- Analisar a viabilidade da construção de um modelo de previsão genérico, que contemple as situações com névoa e sem névoa, a fim de evitar que o modelo dependa de outras variáveis além dos atributos utilizados na construção dos modelos.
- Integrar à metodologia proposta a realização de processamento de imagem usando os registros feitos pela câmera UV, para quantificar de forma mais exata o nível de corona presente na superfície dos isoladores a serem usados como objetos de teste, possibilitando a determinação de critérios que indiquem ocorrência de descargas superficiais de modo ainda mais confiável.
- Realizar ensaios elétricos de poluição artificial com níveis diferentes de tensão do qual foi definido para esta tese (69 kV), com cadeias de isoladores de vidro dimensionadas para sistemas de 230 kV, por exemplo, a fim de contemplar outros níveis presentes no SEP. Concomitante a isso, a realização de experimentos em ambiente externo com a cadeia energizada também seria uma sugestão, para adicionar mais um estudo de caso à pesquisa a ser desenvolvida, pois os níveis de poluição identificados para uma cadeia de isoladores desenergizada podem ser diferentes de uma cadeia energizada.

6.2 PUBLICAÇÕES

Publicações foram realizadas em eventos e periódicos, durante o desenvolvimento das atividades relacionadas ao Doutorado, conforme apresentado na Tabela 6.1.

Tabela 6.1 – Trabalhos publicados ou em processo de publicação em eventos e/ou periódicos.

Autores	Título	Evento/periódico	Ano	Situação
V. R. N. Barbosa ; G. R. S. Lira; E. G. Costa; G. M. B. Galdino; A. H. P. Oliveira; A. C. Santos Júnior	Estimation of the Pollution Critical Level on the Surface of Glass Insulators Based on Leakage Current	IEEE Transactions on Power Delivery	2024	Publicado
Giovanny M. B. Galdino, Marianna B. B. Dias, Samuel C. Nóbrega, Arthur S. Souza, Edson G. da Costa, Vandilson R. N. Barbosa , George R. S. Lira, João V. J. de Melo	Useful Life Estimation of Insulated Cables Based on Loss Tangent Measurement and SVR	International Symposium on High Voltage Engineering	2023	Publicado
V. R. N. Barbosa ; E. G. Costa; G. R. S. Lira; M. B. B. Dias; I. B. Oliveira; A. H. P. Oliveira; G. M. B. Galdino; M. V. A. Nascimento	Metodologia para Estimar a Vida Útil de Para-raios de Óxido de Zinco Baseada na Aplicação do Sistema Neuro-Fuzzy Adaptativo	Simpósio Brasileiro de Sistemas Elétricos	2022	Publicado
V. R. N. Barbosa ; E. G. Costa; G. R. S. Lira; M. B. B. Dias	Estimação da Vida Útil de Para-raios de Óxido de Zinco Baseado em Sistema de Inferência Neuro-Fuzzy Adaptativo e Corrente de Fuga	X Workspot	2022	Publicado

Fonte: autor (2025).

Referências

- ABNT NBR 10621: 2005. **Isoladores utilizados em sistemas de alta tensão em corrente alternada — Ensaio de poluição artificial**. NBR 2ª ed., 2005.
- ANEEL. **PRODIST – Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – Módulo 8: Qualidade da Energia Elétrica**. Versão 11. Brasília, 2020. Disponível em: <https://www2.aneel.gov.br/cedoc/aren2020888_prodist_modulo_8_v11.pdf>. Acesso em: 15 de abril de 2025.
- BARBOSA, V. R. N. *et al.* **Estimation of metal oxide surge arresters' useful life based on time series forecasts**. IEEE Transactions on Power Delivery, v. 37, n. 2, p. 842-850, 2021.
- BARBOSA, V. R. N. *et al.* **Estimation of the Pollution Critical Level on the Surface of Glass Insulators Based on Leakage Current**. IEEE Transactions on Power Delivery, vol. 39, no. 2, pp. 1222-1232, 2024.
- BARROS, W. P. P. **Análise do efeito corona para diagnóstico de isoladores poliméricos**. Dissertação de Mestrado, Departamento de Engenharia Elétrica, Universidade Federal de Campina Grande, 2011.
- BERRY, R. **A Brief History of Porcelain Insulators**. Insulators: Glass and Porcelain, 2008.
- BHATTARAI, B. P. *et al.* **Big data analytics in smart grids: state-of-the-art, challenges, opportunities, and future directions**. IET Smart Grid, v. 2, n. 2, p. 141-154, 2019.
- BISHOP, C. M.; NASRABADI, N. M. **Pattern recognition and machine learning**. New York: Springer, 2006.
- BOX, G. E. *et al.* **Time series analysis: forecasting and control**. John Wiley & Sons, 2015.
- BROCKWELL, P. J.; DAVIS, R. A. **Introduction to Time Series and Forecasting**. 2ª Ed. Springer, 2002.
- BUENO-BARRACHINA, J. M. *et al.* **Novel technique for estimating pollution-associated leakage current in high-voltage insulators based on adaptive filtering in long-term recording**. IEEE Transactions on Power Delivery, v. 32, n. 5, p. 055105-055112, 2021.
- CASTILLO-SIERRA, R. *et al.* **A novel method for prediction of washing cycles of electrical insulators in high pollution environments**. International Journal of Electrical Power & Energy Systems, v. 130, p. 107026, 2021.
- CAUVET, L. A. **Threads formed internally for screw pin. 1865**. Disponível em: <<https://patents.google.com/patent/US48906A/en>>. Acesso em: 13 abril 2025.
- CHAKRABORTY, R. **Studies on Silicone Rubber Insulators used for High Voltage Transmission**. Thesis of Master of Science (Engineering), Department of Electrical Engineering, Indian Institute of Science, Indian Institute of Science, 2011.

- CHEN, Y. *et al.* **Short-term electrical load forecasting using the support vector regression (SVR) model to calculate the demand response baseline for office buildings.** *Applied Energy*, v. 195, p. 659-670, 2017.
- CHERNEY, E. A. *et al.* **Evaluation of and replacement strategies for aged high-voltage toughened glass-suspension insulators.** *IEEE Transactions on Power Delivery*, v. 30, n. 3, p. 1145-1152, 2015.
- CIGRÉ. **Polluted insulators: A review of current knowledge.** CIGRE brochure N° 158, 2000. Disponível em: <<https://www.e-cigre.org/publications/detail/158-polluted-insulators-a-review-of-current-knowledge.html>> Acesso em: 13 de abril de 2025.
- CUENCA, W. H. **Caracterização dos sinais de Descargas Parciais em Equipamentos de Alta Tensão a partir de Modelos Experimentais.** Engineering Department (COPPE). Universidade Federal do Rio de Janeiro, Rio de Janeiro, p. 2064-2065, 2005.
- DHIMAN, H. S. *et al.* **Hybrid machine intelligent SVR variants for wind forecasting and ramp events.** *Renewable and Sustainable Energy Reviews*, v. 108, p. 369-379, 2019.
- DIAS, B. A. **Simulação computacional da poluição biológica em isoladores de vidro.** Dissertação de Mestrado, Departamento de Engenharia Elétrica, Universidade Federal de Campina Grande, 2017.
- DUGAN, R. C.; MCGRANAGHAN, M. F.; SANTOSO, S.; BEATY, H. W. **Electrical Power Systems Quality.** 2ª ed., Ed. McGraw-Hill, 2004.
- ESMAIELI, M. *et al.* **Condition assessment criteria evaluation of asymmetric aged and fully aged silicone rubber insulators based on leakage current harmonics.** *IET Science, Measurement & Technology*, 2024.
- FASSBINDER, G. **A new ceramic body concept for high strength HV insulators.** In: *Int. Symp. on High Voltage Engineering (ISH)*, v. 13, p. 214-220, 2003.
- FEITOSA NETO, S. A. *et al.* **Relatório de Análise: Desligamentos Forçados do Sistema de Transmissão.** Agência Nacional de Energia Elétrica – Brasília, 2017.
- FERNANDO, M. A. R. M.; GUBANSKI, S. M. **Leakage current patterns on contaminated polymeric surfaces.** *IEEE Transactions on Dielectrics and Electrical Insulation*, v. 6, n. 5, p. 688-694, 1999.
- FERREIRA, T. V. **Estudo do trilhamento de núcleo em isoladores poliméricos.** Dissertação de Mestrado, Departamento de Engenharia Elétrica, Universidade Federal de Campina Grande, 2007.
- FERREIRA, T. V. **Estimação Inteligente da Poluição de Isolamentos Elétricos Baseada nos VECSE do Ruído Ultrassônico.** Tese de Doutorado, Departamento de Engenharia Elétrica, Universidade Federal de Campina Grande, 2011.
- GAO, S. *et al.* **Prediction method of leakage current of insulators on the transmission line based on BP neural network.** In: *2018 IEEE 2nd International Electrical and Energy Conference (CIEEC)*, p. 569-572, 2018.
- GÉRON, A. **Hands-On machine learning with scikit-learn, keras and tensorflow.** [S.l.]: O'Reilly Media, v. 2, 2019.

- GILAT, A.; SUBRAMANIAM, V. **Numerical methods for engineers and scientists: an introduction with applications using MATLAB**. 3^a ed., Columbus, O., USA: Wiley Global Education, 2013, p. 251-298.
- GISH, E. **Fred M. Locke: A Biography**. Lumberton: Infinity Press, 1994.
- GORUR, R. S.; CHERNEY, E. A.; BURNHAM, J. T. **Outdoor insulators**. Phoenix, Arizona: Ravi S. Gorur, Inc, 1999.
- GORUR, R. S. *et al.* **Evaluation of and replacement strategies for aged high-voltage toughened glass-suspension insulators**. IEEE Transactions on Power Delivery, v. 30, n. 3, p. 1145-1152, 2015.
- HAN, J.; PEI, J.; KAMBER, M. **Data mining: concepts and techniques**. Elsevier, 2011.
- HAYKIN, S. O. **Neural networks and learning machines**. Plastics, 3rd ed., Upper Saddle River, NJ, USA: Prentice Hall, p. 268-303, 2008.
- HINRICHSEN, V. **Metal-Oxide Surge Arresters in High-Voltage Power Systems**. Erlangen, Germany: Siemens AG, p. 3-58, 2012.
- HONG, W. C. **Hybrid advanced techniques for forecasting in energy sector**. Printed Edition of the Special Issue Published in Energies, 2018.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. OTexts, 2018.
- IEC Publication 60507: 2013. **Artificial pollution tests on high-voltage ceramic and glass insulators to be used on a.c. systems**. IEC 3rd ed., 2013.
- IEC Publication 60815-1: 2008. **Selection and dimensioning of high-voltage insulators intended for use in polluted conditions - Part 1: Definitions, information and general principles**. IEC 1st ed., 2008.
- INMR. **Expanded test criteria to ensure quality of glass insulators**. INMR. Disponível em: <<https://www.inmr.com/expanded-test-criteria-to-ensure-quality-of-glass-insulators/>>. Acessado em: 13 de abril de 2025.
- JIANYUAN, X.; YUN, T.; XIN, L. **Study of polluted insulator flashover forecasting based on nonlinear time series analysis**. In: 2008 International Conference on High Voltage Engineering and Application. IEEE, p. 148-151, 2008.
- KARADY, G. G.; AMARH, F. **Signature analysis for leakage current waveforms of polluted insulators**. In: 1999 IEEE Transmission and Distribution Conference, v. 2, p. 806-811, 1999.
- KAKIHATA, E. M. *et al.* **Intrusion detection system based on flows using machine learning algorithms**. IEEE Latin America Transactions, v. 15, n. 10, p. 1988-1993, 2017.
- KHAFAF, N. A. L. *et al.* **Bayesian regularization of neural network to predict leakage current in a salt fog environment**. IEEE Transactions on Dielectrics and Electrical Insulation, v. 25, n. 2, p. 686-693, 2018.

- KHAN, A. N. *et al.* **A forecasting model approach of sustainable electricity management by developing adaptive neuro-fuzzy inference system.** Environmental Science and Pollution Research, p. 1-12, 2019.
- KIM, Y. S. **Failure prediction of metal oxide varistor using nonlinear surge look-up table based on experimental data.** Trans. Elect. Electron. Mater., v. 16, n. 6, p. 317–322, 2015.
- KIM, S. H.; CHERNEY, E. A.; HACKAM, R. **Effects of filler level in RTV silicone rubber coatings used in HV insulators.** IEEE Transactions on Electrical Insulation, v. 27, n. 6, p. 1065-1072, 1992.
- KO, C. N.; LEE, C. M. **Short-term load forecasting using SVR (support vector regression)-based radial basis function neural network with dual extended kalman filter.** Energy, v. 49, p. 413-422, 2013.
- KRIESEL, D. **A brief introduction to neural networks.** 2007. Disponível em: <<http://www.dkriesel.com>>. Acessado em: 13 de abril de 2025.
- KUFFEL, E.; ZAENGL, W.; KUFFEL, J. **High voltage engineering: fundamentals.** 2ª ed. Butterworth-Heinemann, 2000.
- KUMAGAI, S.; YOSHIMURA, N. **Leakage current characterization for estimating the conditions of ceramic and polymeric insulating surfaces.** IEEE Transactions on Dielectrics and Electrical Insulation, v. 11, n. 4, p. 681-690, 2004.
- LI, J. *et al.* **Contamination level prediction of insulators based on the characteristics of leakage current.** IEEE Transactions on Power Delivery, v. 25, n. 1, p. 417–424, 2010.
- LIN, Y. T.; & KUO, C. C. **Real-Time Salt Contamination Monitoring System and Method for Transmission Line Insulator Based on Artificial Intelligence.** Applied Sciences, v. 14, n. 4, p. 1506, 2024.
- LIEBERMANN, J. **Reliability of materials for high-voltage insulators.** American Ceramic Society Bulletin, v.79, p. 55-58, 2000.
- LIU, Y. *et al.* **Statistical analysis on the DC discharge path of ice-covered insulators under natural conditions.** International Journal of Electrical Power & Energy Systems, v. 130, p. 106961, 2021.
- LINS, Ricardo Leite. **Relatório de índice de falhas em isoladores Chesf.** [S.I.], 2018.
- LIRA, G. R. S.; COSTA, E. G. **MOSA monitoring technique based on analysis of total leakage current.** IEEE Transactions on Power Delivery, v. 28, n. 2, p. 1057–1062, 2013.
- LOPES, L. F. D. **Métodos Quantitativos.** 1ª edição. Santa Maria: Universidade Federal de Santa Maria, 2016.
- LURGIO, S. A. **Forecasting principles and applications.** Singapore: McGraw-Hill, 1998.
- MARAABA, L. *et al.* **Estimation of high voltage insulator contamination using a combined image processing and artificial neural networks.** In: 2014 IEEE 8th International Power Engineering and Optimization Conference, pp. 214-219, 2014.

- MARTINS, D. W. P. **Inteligência artificial aplicada em séries temporais**. Dissertação (Mestrado em Estatística), Universidade de São Paulo, 2024.
- MATSUOKA, R. *et al.* **Influence of nonsoluble contaminants on the flashover voltages of artificially contaminated insulators**. IEEE Transactions on Power Delivery, v. 11, n. 1, p. 420-430, 1996.
- MAVRIKAKIS, N. C. *et al.* **Evaluation of field-ageing effects on insulating materials of composite suspension insulators**. IEEE Transactions on Dielectrics and Electrical Insulation, v. 24, n. 1, p. 490-498, 2017.
- METWALLY, I. A. *et al.* **Performance improvement of 33 kV line-post insulators in harsh environment**. Electric Power Systems Research, Volume 76, p. 778-785, 2006.
- MERRY, R. J. E. **Wavelet Theory and Applications: A literature study**. Eindhoven University of Technology, 2005.
- METCALFE, A. V. & COWPERTWAIT, P. S. P. **Introductory Time Series with R**. Springer-Verlag New York, 2009.
- MILLS, T. C. **Applied Time Series Analysis: A Practical Guide to Modeling and Forecasting**. Editora: Academic Press, 2019.
- MONTGOMERY, D. C.; JENNINGS, C. L; KULAHCI, M. **Introduction to time series analysis and forecasting**. John Wiley & Sons, 2008.
- MORETTIN, P. A.; TOLOI, C. **Análise de Séries Temporais**. Editora Blucher, 2006.
- MUNIRAJ, C.; CHANDRASEKAR, S. **Adaptive neurofuzzy inference system-based pollution severity prediction of polymeric insulators in power transmission lines**. Adv. in Art. Neural Systems, vol. 2011, p. 1-9, 2011.
- NAITO, K. *et al.* **Investigation results of silicone rubber insulators under wet and contaminated conditions**. In: Proceedings of 1994 4th International Conference on Properties and Applications of Dielectric Materials (ICPADM). v. 2, p. 519-522. IEEE, 1994.
- NIELSEN, A. **Practical Time Series Analysis: Prediction with Statistics and Machine Learning**. Editora O'Reilly Media, Inc., 2019.
- NOBREGA, R. B. **Influência da cera de carnaúba do desempenho de revestimento de silicone aplicados no isolamento externo**. Tese (Doutorado em Engenharia Elétrica), Programa de Pós-Graduação em Engenharia Elétrica, Centro de Engenharia Elétrica e Informática, Universidade Federal de Campina Grande - Paraíba - Brasil, 2019.
- NOCEDAL, J.; WRIGHT, S. J. **Numerical Optimization**. 2ª ed. Springer, 2006.
- OAKMAN, S. **Double petticoat design for style similar to CD 162. An annual recess to receive paraffin to form a broad band of surface protected from moisture**. 288360. 30 de jul. de 1883. [S.l.], p. 1 Disponível em: <<https://reference.insulators.info/patents/detail/?patent=U288360>>. Acesso em: 13 abril 2025.
- OAKMAN, S. **Dove-tail ears on crown-helmet**. 430296. 01 de nov. de 1890. [S.l.], p. 1. Disponível em: <<https://reference.insulators.info/patents/detail/?patent=U430296>>. Acesso em: 13 abril 2025.

- ONS. **Relatório Anual do ONS 2009**. Brasília, 2009. Disponível em: <<https://www.ons.org.br/sites/multimedia/Documentos%20Compartilhados/relatorios%20anuais/2009/arquivos/ONS-Relatorio-Anual-2009.pdf>>. Acesso em: 13 abril 2025.
- OLIVEIRA, S. C. **Sistema de detecção óptica de descargas parciais em cadeias de isoladores de linhas de transmissão de alta tensão**. Tese de Doutorado, Departamento de Engenharia Elétrica, Universidade Federal de Pernambuco, Recife, 2008.
- PALANGAR, M. F.; MIRZAIIE, M. **Predicting critical conditions in polluted insulators using phase angle index of leakage current**. In: 2020 IEEE International Conference on High Voltage Engineering and Application (ICHVE), p. 1-4, 2020.
- PASCANU, R.; MIKOLOV, T.; BENGIO, Y. **On the difficulty of training recurrent neural networks**. In International conference on machine learning, p. 1310-1318, 2013.
- POURDARYAEI, A. *et al.* **Hybrid ANN and artificial cooperative search algorithm to forecast short-term electricity price in de-regulated electricity market**. IEEE Access, v. 7, p. 125369-125386, 2019.
- PYLARINOS, D. *et al.* **Investigation and classification of field leakage current waveforms**. IEEE Transactions on Dielectrics and Electrical Insulation, v. 19, n. 6, p. 2111-2118, 2012.
- ROCHA, P. H. V. **Estimação da Poluição de Isoladores em Linhas de Transmissão a partir da Irradiação de RF**. Tese de Doutorado, Departamento de Engenharia Elétrica, Universidade Federal de Campina Grande, 2019.
- SOPELSA NETO, N. F. *et al.* **Fault prediction based on leakage current in contaminated insulators using enhanced time series forecasting models**. Sensors, v. 22, n. 16, p. 6121, 2022.
- TANG, K. T. **Mathematical Methods for Engineers and Scientists 3**. New York: Springer, 2007. 438 p. ISBN: 103-540-44695-8.
- WIRTH, R.; HIPPEL, J. **CRISP-DM: Towards a Standard Process Model for Data Mining**. In: Proceedings of the 4th International Conference on the Practical Applications of Knowledge Discovery and Data Mining (PAKDD 2000), p. 29-39, 2000.
- ZELLER, H. R. **Breakdown and prebreakdown phenomena in solid dielectrics**. IEEE Transactions on Electrical insulation, v. 2, p. 115-122, 1987.
- ZHAO, S. *et al.* **Flashover voltage prediction of composite insulators based on the characteristics of leakage current**. IEEE Transactions on Power Delivery, v. 28, n. 3, p. 1699-1708, 2013.