

UNIVERSIDADE FEDERAL DE GOIÁS  
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE  
COMPUTAÇÃO

VINICIUS FARIA COSTA MENDANHA

**Análises de Desempenho de Transformadores  
de Potência Imersos em Óleo Mineral Isolante  
com Aplicações de Inteligência Artificial**

Goiânia  
2026



UNIVERSIDADE FEDERAL DE GOIÁS  
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

## TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES

### E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

#### 1. Identificação do material bibliográfico

Dissertação     Tese     Outro\*: \_\_\_\_\_

\*No caso de mestrado/doutorado profissional, indique o formato do Trabalho de Conclusão de Curso, permitido no documento de área, correspondente ao programa de pós-graduação, orientado pela legislação vigente da CAPES.

Exemplos: Estudo de caso ou Revisão sistemática ou outros formatos.

#### 2. Nome completo do autor

VINICIUS FARIA COSTA MENDANHA

#### 3. Título do trabalho

**“Análises de Desempenho de Transformadores de Potência Imersos em Óleo Mineral Isolante com Aplicações de Inteligência Artificial”**

#### 4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento  SIM     NÃO<sup>1</sup>

**[1]** Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

**a)** consulta ao(à) autor(a) e ao(à) orientador(a);

**b)** novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação.

O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

**Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.**



Documento assinado eletronicamente por **Cacilda De Jesus Ribeiro, Professor do Magistério Superior**, em 10/02/2026, às 10:11, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



Documento assinado eletronicamente por **Vinicius Faria Costa Mendanha, Discente**, em 10/02/2026, às 13:09, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



A autenticidade deste documento pode ser conferida no site

[https://sei.ufg.br/sei/controlador\\_externo.php?](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0)

[acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **5951682** e o código CRC **61ED69F8**.

---

VINICIUS FARIA COSTA MENDANHA

# **Análises de Desempenho de Transformadores de Potência Imersos em Óleo Mineral Isolante com Aplicações de Inteligência Artificial**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação, da Escola de Engenharia Elétrica, Mecânica e de Computação (EMC), da Universidade Federal de Goiás (UFG), como requisito para obtenção do título de Mestre em Engenharia Elétrica e de Computação.

**Área de concentração:** Engenharia Elétrica.

**Linha de pesquisa:** Sistemas Eletroeletrônicos.

**Orientadora:** Profa. Cacilda de Jesus Ribeiro, Dra.

**Coorientador:** Prof. André Pereira Marques, Dr.

Goiânia  
2026

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Mendanha, Vinicius Faria Costa  
Análises de Desempenho de Transformadores de Potência Imersos em  
Óleo Mineral Isolante com Aplicações de Inteligência Artificial [manuscrito] /  
Vinicius Faria Costa Mendanha. - 2026.  
132 f.: 2026

Orientadora: Prof(a). Dra. Cacilda de Jesus Ribeiro; co-orientador: Dr. André  
Pereira Marques

Dissertação (Mestrado) - Universidade Federal de Goiás, Escola de  
Engenharia Elétrica, Mecânica e de Computação (EMC), Programa de Pós-  
Graduação em Engenharia Elétrica e de Computação, Goiânia, 2026.

Apêndice.

Bibliografia.

Inclui: lista de figuras, lista de tabelas.

1. Inteligência Artificial. 2. Classificação. 3. Transformadores de  
Potência. 4. Filtros de Partículas. 5. Índice de Desempenho.

I. Ribeiro, Cacilda de Jesus, orient. II. Marques, André Pereira, co-orient. III.  
Título.

CDU 621.3



UNIVERSIDADE FEDERAL DE GOIÁS

ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

### ATA DE DEFESA DE DISSERTAÇÃO

Ata nº 04 da sessão de Defesa de Dissertação de **VINICIUS FARIA COSTA MENDANHA**, que confere o título de Mestre em **Engenharia Elétrica e de Computação**, na área de concentração em **Engenharia Elétrica**.

Aos **trinta dias do mês de janeiro de dois mil e vinte e seis**, a partir das **09:00h**, na sala *Caryocar brasiliensis*, 3o piso do Bloco A da EMC/UFG, realizou-se a sessão pública de Defesa de Dissertação intitulada “**Análises de Desempenho de Transformadores de Potência Imersos em Óleo Mineral Isolante com Aplicações de Inteligência Artificial**”. Os trabalhos foram instalados pela Orientadora, Professora Doutora **Cacilda de Jesus Ribeiro - (EMC/UFG)** e pelo Professor Doutor **André Pereira Marques - (IFG)** Coorientador, com a participação dos demais membros da Banca Examinadora: Professora Doutora **Alana da Silva Magalhães - (IFG)** - Membro Titular Externo, Professora Doutora **Amanda Buosi Gazon Milani - (IME/UFG)** - Membro Titular Externo; Professor Doutor **Álisson Assis Cardoso (EMC/UFG)** - Membro Titular Interno, e Doutor **Yuri Andrade Dias** - Membro Titular Externo, **cuja participação ocorreram presencialmente**. Durante a arguição os membros da banca **não fizeram** sugestão de alteração do título do trabalho. A Banca Examinadora reuniu-se em sessão secreta a fim de concluir o julgamento da Dissertação, tendo sido o candidato **aprovado** pelos seus membros. Proclamados os resultados pela Professora Doutora Cacilda de Jesus Ribeiro, Presidente da Banca Examinadora, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, aos trinta dias do mês de janeiro de dois mil e vinte e seis.

TÍTULO SUGERIDO PELA BANCA



Documento assinado eletronicamente por **Cacilda De Jesus Ribeiro, Professor do Magistério Superior**, em 30/01/2026, às 10:58, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Alisson Assis Cardoso, Professor do Magistério Superior**, em 30/01/2026, às 10:59, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **ANDRE PEREIRA MARQUES, Usuário Externo**, em 30/01/2026, às 11:06, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Alana Da Silva Magalhaes, Usuário Externo**, em 30/01/2026, às 19:28, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Yuri Andrade Dias, Usuário Externo**, em 30/01/2026, às 23:04, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



Documento assinado eletronicamente por **Amanda Buosi Gazon Milani, Professor do Magistério Superior**, em 03/02/2026, às 11:18, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



A autenticidade deste documento pode ser conferida no site [https://sei.ufg.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **5935916** e o código CRC **FOC3DF13**.

---

Referência: Processo nº 23070.049952/2025-60

SEI nº 5935916

À minha mãe, Carla; ao meu pai, Lázaro;  
à minha irmã, Natália; aos meus amigos e professores;  
e a Deus, minha luz-guia.

---

## Agradecimentos

---

À professora titular Dra. Cacilda de Jesus Ribeiro, da Escola de Engenharia Elétrica e de Computação da Universidade Federal de Goiás, pela orientação e amizade durante o desenvolvimento deste trabalho.

Ao professor Dr. André Pereira Marques, do Instituto Federal de Goiás, pela coorientação desta dissertação de mestrado, com ensinamentos valiosos e vivências práticas.

Aos professores do Programa de Pós-Graduação em Engenharia Elétrica e de Computação da Universidade Federal de Goiás (PPGEEC-UFG), em especial, Dr. Álisson Assis Cardoso, Dr. Flávio Henrique Teles Vieira e Dra. Lina Paola Garcés Negrete, pelas colaborações.

Às equipes do Laboratório de Pesquisa em Engenharia de Alta Tensão (LAPEAT-UFG) e do Centro de Excelência em Redes Inteligentes sem fio e Serviços Avançados (CERISE-UFG) pelos apoios.

À Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG) pelo financiamento que viabilizou o desenvolvimento deste trabalho.

Finalmente, a todos que, direta ou indiretamente, tenham contribuído ao desenvolvimento deste trabalho.

Eis o melhor e o pior de mim  
O meu termômetro, o meu quilate  
Vem, cara, me retrate  
Não é impossível  
Eu não sou difícil de ler

**Marisa Monte,**  
*Infinito Particular.*

---

## Resumo

---

O acompanhamento do índice de desempenho de equipamentos elétricos de sistemas de energia, como transformadores de potência, é importante para garantir que eles operem com a confiabilidade esperada, assegurando o suprimento contínuo e adequado de energia elétrica aos consumidores finais. Todavia, esse monitoramento apresenta desafios consideráveis, como a escassez de dados confiáveis, a alta variabilidade das condições operacionais e a complexidade dos fenômenos físicos de degradação associados à ocorrência de falhas. Nesse contexto, tem-se como objetivo, neste trabalho, desenvolver e avaliar ferramentas baseadas em Inteligência Artificial (IA) para prever falhas incipientes nesses ativos, possibilitando o planejamento otimizado de intervenções de manutenção. Na metodologia, foram desenvolvidos: implementação do algoritmo *Local Outlier Factor* (LOF) para detecção de *outliers* em diferentes conjuntos de desempenho de técnicas preditivas; filtros de partículas para predição do índice de desempenho e classificação do estado operacional de transformadores de potência; e ferramenta com classificadores binários do desempenho de transformadores com base em parâmetros de análise de gases dissolvidos (AGD) e ensaios físico-químicos. Os resultados demonstram que esses modelos apresentam desempenhos satisfatórios na classificação do estado de operação dos equipamentos, sob diversos cenários de avaliados. Portanto, as abordagens realizadas representam alternativas viáveis e eficazes para o monitoramento do índice de desempenho de equipamentos de alta tensão, contribuindo para a identificação antecipada de falhas e para otimização das intervenções de manutenção.

### Palavras-chave

Aprendizado de Máquinas, Classificação, Equipamentos de Alta Tensão, Filtros de Partículas, Índice de Desempenho, Inteligência Artificial, Transformadores de Potência.

---

## **Abstract**

---

The monitoring of the performance index of power system electrical equipment, such as power transformers, is essential to ensure that these assets operate with the expected reliability, thereby guaranteeing the continuous and adequate supply of electric energy to end-users. However, this monitoring process presents considerable challenges, including the scarcity of reliable data, the high variability of operational conditions, and the complexity of the physical degradation phenomena associated with failure occurrence. In this context, the objective, in this work, is to develop and evaluate Artificial Intelligence (AI)-based tools for predicting incipient faults in these assets, enabling optimized maintenance planning. In the methodology, the following developments were carried out: implementation of the Local Outlier Factor (LOF) algorithm for outlier detection across different performance datasets from predictive techniques; particle filters for forecasting the performance index and classifying the operational state of power transformers; and a tool composed of binary classifiers for transformer performance based on dissolved gas analysis (DGA) parameters and physicochemical tests. The results show that these models achieve satisfactory performance in classifying the operational state of the equipment under several evaluated scenarios. Therefore, the proposed approaches represent viable and effective alternatives for monitoring the performance index of high-voltage equipment, contributing to the early identification of faults and to the optimization of maintenance interventions.

### **Keywords**

Artificial Intelligence, Classification, High-Voltage Equipment, Machine Learning, Particle Filters, Performance Index, Power Transformers.

---

## Sumário

---

Lista de Figuras	14
Lista de Tabelas	17
1 Introdução	19
1.1 Introdução	19
1.2 Objetivos	20
1.3 Estrutura da dissertação	20
1.4 Trabalhos resultantes	21
2 Revisão da Literatura sobre IA aplicada à Manutenção Preventiva de Transformadores de Potência Imersos em Óleo Mineral Isolante	23
2.1 Introdução	23
2.2 Transformador de potência	24
2.3 Inteligência Artificial aplicada à manutenção de transformadores de potência imersos em óleo mineral isolante	25
2.4 Conclusões	35
3 Predição Otimizada do Índice de Desempenho de Transformadores de Potência Imersos em Óleo Mineral Isolante com Aplicação de Inteligência Artificial	38
3.1 Resumo	38
3.2 Introdução	39
3.3 Metodologia	39
3.4 Resultados	42
3.5 Conclusões	46
4 Hybrid Artificial Intelligence Model for Reliable Decision-Making in the Maintenance of Mineral-Oil-Immersed Power Transformers Through Performance Index Monitoring	48
4.1 Abstract	48
4.2 Introduction	49
4.3 Methodology	52
4.3.1 Artificial Intelligence Algorithms for Identifying Outliers	52
4.3.2 New Method Developed for Identifying Outliers	54
4.3.3 Statistical Validation of Maintenance Interventions	55
4.3.4 Particle Filters for Predicting the Performance Index	56
4.3.5 Filter Performance Metrics	58
4.3.6 Workflow of the Developed Method	59
4.4 Results and Discussion	60

4.4.1	Operating Conditions, Weather Events and Maintenance Interventions	60
4.4.2	Performance Comparison Between Artificial Intelligence Algorithms Tested and the One Developed	61
4.4.3	Hyperparameters of the Particle Filters	64
4.4.4	Execution Time Analysis and Memory Usage	66
4.4.5	Future Behavior Simulation and Technical Assessment of Equipment Operational Patterns	68
4.4.6	Statistical Validation of Maintenance Interventions	74
4.4.7	Time Series Cross-Validation with One-Step-Ahead Forecasting	75
4.4.8	Comparison with State-of-the-Art Methods	76
4.4.9	Limitations and Future Works	77
4.5	Conclusions	78
5	Classificação Binária do Estado Operacional de Transformadores de Potência Imersos em Óleo Mineral Isolante Utilizando Índice de Desempenho e Modelos de Aprendizado de Máquina	85
5.1	Resumo	85
5.2	Introdução	86
5.3	Metodologia	87
5.4	Resultados e Discussões	92
5.5	Conclusões	100
6	Conclusões	106
	Referências	108
A	Estudo comparativo sobre predição do estado de transformadores de potência imersos em óleo mineral isolante por modelos matemáticos de ajuste aplicados	113
A.1	Resumo	113
A.2	Introdução	114
A.3	Metodologia	117
A.4	Resultados	119
A.4.1	Análise de gases dissolvidos (AGD)	119
A.4.2	Ensaio físico-químico	122
A.4.3	Grau de Polimerização/2FAL-Furfuraldeídos	124
A.4.4	Índice de desempenho geral do transformador	124
A.4.5	Validação da ferramenta	128
A.5	Considerações finais	129

---

## Lista de Figuras

---

2.1	Características construtivas de um transformador de potência imerso em óleo mineral isolante	24
2.2	Imagens de microscopia do papel <i>kraft</i> de isolamento dos enrolamentos deteriorado por 0 horas (à esquerda) e 400 horas (à direita) a 140 °C; com valores correspondentes de grau de polimerização (GP) de 717 e 115, nessa ordem	29
2.3	Variações da tensão do ensaio de rigidez dielétrica $U_C$ em função do teor de água $W_C$ para os três óleos A, B e C	32
3.1	Fluxograma com etapas do método desenvolvido neste trabalho	41
3.2	Análise de Gases Dissolvidos, com representação dos subconjuntos de análise, pontos desconsiderados, reta de ajuste e coeficientes de determinação $R^2$	43
3.3	Técnica preditiva de ensaios físico-químicos, com representação dos subconjuntos de análise, pontos desconsiderados, reta de ajuste e coeficiente de determinação $R^2$	44
3.4	Técnica preditiva de ensaios físico-químicos, com representação dos subconjuntos de análise, pontos desconsiderados, retas de ajuste e coeficientes de determinação $R^2$	45
4.1	Workflow of the methodology developed in this study	59
4.2	Example of Silhouette curve for a cluster of the predictive technique ET_PF, which is used to determine the optimal $k$ of the LOF for TR4	63
4.3	Example of Silhouette curve for a cluster of the predictive technique ET_TTR, which is used to determine the optimal contamination of the IF for TR4	63
4.4	Composite score heatmap for TR1 test set, AD-Bootstrap, uniform transition, and exponential observation	65
4.5	Composite score heatmap for TR1 test set, AD-SIS, uniform transition, and exponential observation	66
4.6	Runtime as a function of the number of particles ( $N$ ) for different noise levels ( $\sigma$ ) in TR1, averaged across transition and observation models, including both training and test phases for the AD-Bootstrap filter	67
4.7	Runtime as a function of the number of particles ( $N$ ) for different noise levels ( $\sigma$ ) in TR1, averaged across transition and observation models, including both training and test phases for the AD-SIS filter	67
4.8	Predictive modeling of performance index dynamics for TR1 via AD-Bootstrap and AD-SIS filters	69

4.9	Predictive modeling of performance index dynamics for TR2 via AD-Bootstrap and AD-SIS filters	70
4.10	Predictive modeling of performance index dynamics for TR3 via AD-Bootstrap and AD-SIS filters	71
4.11	Predictive modeling of performance index dynamics for TR4 via AD-Bootstrap and AD-SIS filters	72
4.12	Predictive modeling of performance index dynamics for TR5 via AD-Bootstrap and AD-SIS filters	73
4.13	Accuracy comparison between AD-Bootstrap and AD-SIS across power transformers	76
5.1	Matriz de correção entre variáveis preditoras normalizadas	93
5.2	<i>Boxplots</i> da variável acetileno normalizada por classificação (A até E)	94
5.3	<i>Boxplots</i> da variável DBDS normalizada por classificação (A até E)	94
5.4	<i>Boxplots</i> da variável dióxido de carbono normalizada por classificação (A até E)	95
5.5	<i>Boxplots</i> da variável etileno normalizada por classificação (A até E)	95
5.6	<i>Boxplots</i> da variável etano normalizada por classificação (A até E)	96
5.7	<i>Boxplots</i> da variável metano normalizada por classificação (A até E)	96
5.8	Mapa de calor da frequência relativa de <i>outliers</i> identificados por <i>IQR</i> por variável preditora e classificação de desempenho dos transformadores de potência	98
5.9	Matriz de confusão do algoritmo de classificação binária XGBoost para cada classificação utilizando validação por <i>Leave-One-Out Cross-Validation</i> (LOOCV)	100
A.1	Fluxograma das principais etapas de execução da ferramenta de melhor ajuste proposta	118
A.2	Ajuste linear ao conjunto da AGD utilizando bandas de predição de: (a) 90%, (b) 95% e (c) 99%, com pontos excluídos, pelo método de quadrados mínimos linear	119
A.3	Ajuste quadrático ao conjunto da AGD utilizando bandas de predição de 99%, com pontos excluídos, pelo método de quadrados mínimos linear	120
A.4	Ajuste ao conjunto da AGD utilizando bandas de predição de 99%, com pontos excluídos, pelo método de quadrados mínimos não linear: (a) exponencial e (b) gaussiano	121
A.5	Ajuste por soma de senos ao conjunto da AGD utilizando bandas de predição de 99%, com pontos excluídos, pelo método de quadrados mínimos não linear	122
A.6	Ajustes ao conjunto de ensaios físico-químicos utilizando bandas de predição de 99%, com pontos excluídos, pelo método de quadrados mínimos linear e não linear: (a) linear, (b) quadrático, (c) exponencial, (d) gaussiano e (e) soma de senos	123
A.7	Ajustes ao conjunto de grau de polimerização/2FAL-Furfuraldeídos utilizando bandas de predição de 99%, com pontos excluídos, pelo método de quadrados mínimos linear e não linear: (a) linear, (b) quadrático, (c) exponencial, (d) gaussiano e (e) soma de senos	125

A.8 Ajustes ao conjunto do índice de desempenho geral utilizando bandas de predição de 99%, com pontos excluídos, pelo método de quadrados mínimos linear e não linear: (a) linear, (b) quadrático, (c) exponencial, (d) gaussiano e (e) soma de senos

---

## Lista de Tabelas

---

2.1	Comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base na técnica preditiva AGD	26
2.2	Comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base no grau de polimerização do papel inferido a partir dos compostos furânicos do óleo isolante	29
2.3	Comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base na técnica preditiva ensaios físico-químicos	33
2.4	Comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base na técnica preditiva análise de descargas parciais por emissão acústica	34
3.1	Critério de classificação do estado de operação como uma função do índice de desempenho	42
4.1	Recommended actions based on the predicted performance index classification of the power transformer [20]	52
4.2	Power transformers: simulated operating conditions, weather events, maintenance interventions, and observed effects	60
4.3	Success rates of the applied tools for TR1 to TR3	62
4.4	Success rates of the applied tools for TR4 and TR5	62
4.5	Best hyperparameter configuration based on training performance for each power transformer (AD-SIS)	64
4.6	Best hyperparameter configuration based on training performance for each power transformer (AD-Bootstrap)	64
4.7	Runtime and peak memory from TR1 to TR5: AD-Bootstrap versus AD-SIS across $N$ and $\sigma$	68
4.8	Results of one-sided predictive $t$ -tests for maintenance interventions using $\alpha = 0.1$	74
5.2	Resultados de desempenho dos classificadores binários	97
5.1	Valores de hiperparâmetros em cada modelo de classificador binário utilizado.	99
5.3	Métricas de desempenho do algoritmo de classificação binária <i>XGBoost</i> para cada classificação utilizando validação por <i>Leave-One-Out Cross-Validation</i> (LOOCV)	99
A.1	Ações recomendadas em função da classificação do índice de desempenho predito	116

A.2	Intervalo de tempo, em anos, para cada ação recomendada em função da classificação do índice de desempenho predito pelas curvas de melhor ajuste para cada técnica preditiva: análise de gases dissolvidos, ensaios físico-químicos e grau de polimerização/2FAL-Furfuraldeídos	127
A.3	Raiz do Erro Quadrático Médio (RMSE) considerando o ajuste quadrático para cada técnica preditiva estudada (treino/teste)	128

---

# CAPÍTULO 1

## Introdução

---

### 1.1 Introdução

O acompanhamento do desempenho de equipamentos elétricos de potência é essencial para estabelecer rotinas de manutenção preventiva e, eventualmente, corretiva coerentes, personalizadas e eficientes, configurando um dos grandes desafios do setor elétrico. Além de representarem custos significativos para as empresas do setor elétrico, esses equipamentos são fundamentais para a continuidade do fornecimento de energia elétrica aos consumidores, o que justifica o desenvolvimento deste trabalho com o uso de ferramentas otimizadas aplicadas à manutenção preventiva, com foco no acompanhamento e na avaliação dos índices de desempenho desses ativos. Dessa forma, técnicas envolvendo Inteligência Artificial (IA) têm se mostrado promissoras para o diagnóstico e à predição de falhas incipientes, complementando métodos tradicionais, baseados em inspeções periódicas e análises históricas por especialistas.

Nesse sentido, esta dissertação apresenta um conjunto de soluções baseado em IA, a partir da análise e predição do índice de desempenho de transformadores de potência, utilizando dados factíveis de técnicas preditivas, ou seja, não reais, mas plausíveis e representativos do comportamento operacional dos equipamentos, e exemplos reais, com variáveis relacionadas à análise de gases dissolvidos (AGD) e aos ensaios físico-químicos. O estudo combina diferentes abordagens, incluindo algoritmos de detecção de anomalias, modelos probabilísticos de predição, filtros de partículas e classificadores binários supervisionados, para compreender padrões complexos de degradação desses equipamentos e fornecer subsídios técnicos à tomada de decisões mais assertivas em manutenção. Para tanto, os métodos foram testados em variados cenários, simulados e reais, incluindo séries temporais do índice de desempenho e parâmetros derivados de ensaios reais.

Dentre as contribuições originais desta pesquisa, destacam-se o uso de filtros baseados em *Bootstrap* e *Sequential Importance Sampling* (SIS), com adaptação dinâmica

de partículas, a identificação e exclusão de *outliers* das séries históricas das técnicas preditivas por algoritmos não supervisionados e por uma rotina inédita projetada, e aplicação de modelos de IA para classificação binária. Os resultados demonstram que as ferramentas desenvolvidas apresentam altas acurácias, sendo efetivas e adaptáveis às condições operacionais de alta variabilidade dos equipamentos elétricos de potência. Assim, tais soluções podem ser integradas às práticas de manutenção das empresas mantenedoras do Sistema Elétrico de Potência (SEP).

## 1.2 Objetivos

O objetivo geral deste trabalho é desenvolver e avaliar ferramentas baseadas em Inteligência Artificial (IA) para prever falhas incipientes em equipamentos de alta tensão, possibilitando o planejamento otimizado de intervenções de manutenção.

Os objetivos específicos são:

- apresentar revisão da literatura sobre ferramentas de Inteligência Artificial (IA) aplicadas à manutenção preventiva e corretiva de transformadores de potência imersos em óleo mineral isolante.
- desenvolver ferramentas baseadas em Inteligência Artificial (IA) para prever falhas incipientes em transformadores de potência imersos em óleo mineral isolante, possibilitando o planejamento computacionalmente otimizado de intervenções de manutenção, com base no índice de desempenho, por meio do uso de técnicas preditivas e dos algoritmos de IA: a) *Elbow Method* e *Local Outlier Factor* (LOF); b) LOF, *Isolation Forest* e filtros baseados em *Bootstrap* e *Sequential Importance Sampling* (SIS), além de um algoritmo inédito para identificação e remoção de *outliers* nas séries históricas de cada técnica preditiva avaliada; e c) Classificadores binários, envolvendo *Random Forest*, *HistGradientBoosting*, Regressão Logística Balanceada e XGBoost, com validação cruzada.

## 1.3 Estrutura da dissertação

Esta dissertação está estruturada em seis capítulos. No Capítulo 2, nessa ordem, é apresentada revisão da literatura sobre IA aplicada à manutenção preventiva de transformadores de potência. Em seguida, no Capítulo 3, mostra-se o desenvolvimento de uma ferramenta de aprendizado não supervisionado, denominada *Local Outlier Factor* (LOF), para detecção de *outliers* em conjuntos relacionados às técnicas preditivas de transformadores de potência, a fim de prever o estado operacional desses equipamentos, a partir de seus índices de desempenho.

No Capítulo 4, tem-se o desenvolvimento de uma ferramenta de acompanhamento do histórico do índice de desempenho dos transformadores de potência, considerando um conjunto de nove técnicas preditivas, a partir da combinação de um algoritmo inédito de *clusterização* temporal com filtros de partículas *Bootstrap* e *Sequential Importance Sampling* (SIS).

Em seguida, no Capítulo 5, apresenta-se o desenvolvimento de uma ferramenta de classificação binária do estado operacional de transformadores de potência usando o índice de desempenho e modelos de aprendizado de máquina.

Por fim, no Capítulo 6, tratam-se das principais conclusões desta pesquisa.

## 1.4 Trabalhos resultantes

Como produtos desta dissertação, tem-se os seguintes trabalhos:

1. Capítulo 3: MENDANHA, Vinicius Faria Costa; MARQUES, André Pereira; DIAS, Yuri Andrade; RIBEIRO, Cacilda de Jesus. Predição Otimizada do Índice de Desempenho de Transformadores de Potência com aplicação de Inteligência Artificial. *SODEBRAS*, v. 19, n. 222, p. 1-9, 30 dez. 2024. [1]
2. Capítulo 4: MENDANHA, Vinicius Faria Costa; MARQUES, André Pereira; AGUIAR, Lucas Santos de; SANTOS, Juliermy Junio Pacheco dos; CARDOSO, Álisson Assis; RIBEIRO, Cacilda de Jesus. Hybrid Artificial Intelligence Model for Reliable Decision Making in Power Transformer Maintenance Through Performance Index. *Energies*, v. 18, n. 18, p. 4924, 16 set. 2025. MDPI AG. <http://dx.doi.org/10.3390/en18184924>. [2]
3. Capítulo 5 (submetido): MENDANHA, Vinicius Faria Costa; MARQUES, André Pereira; RIBEIRO, Cacilda de Jesus. Classificação binária do estado operacional de transformadores de potência utilizando índice de desempenho e modelos de aprendizado de máquina. *Brazilian Journal of Production Engineering*. 2025.
4. Apêndice A: MENDANHA, Vinicius Faria Costa; MARQUES, André Pereira; DIAS, Yuri Andrade; RIBEIRO, Cacilda de Jesus. Estudos sobre predição do estado de transformadores de potência imersos em óleo mineral isolante por modelos matemáticos de ajuste aplicados. *Brazilian Journal of Production Engineering*, v. 10, n. 4, p. 226-240, 10 dez. 2024. Universidade Federal do Espírito Santo.
5. Apresentação no Conpeex 2024 (Congresso de Ensino, Pesquisa e Extensão): MENDANHA, Vinicius Faria Costa; MARQUES, André Pereira; CARDOSO, Álisson Assis; RIBEIRO, Cacilda de Jesus. Aplicação de Redes Neurais Recorrentes em predição de série temporal gerada por modelo dinâmico não linear. In: CONGRESSO DE PESQUISA, ENSINO E EXTENSÃO (CONPEEX), 21., 2024, Goiânia. *Anais [...]*. Goiânia: UFG, 2024.

6. Apresentação no Conpeex 2024 (Congresso de Ensino, Pesquisa e Extensão): MENDANHA, Vinicius Faria Costa; MARQUES, André Pereira; RIBEIRO, Ca-cilda de Jesus. Estudos sobre Inteligência Artificial aplicada à detecção de falhas incipientes de disjuntores de média e alta tensão. *In: CONGRESSO DE PESQUISA, ENSINO E EXTENSÃO (CONPEEX), 21., 2024, Goiânia. Anais [...].* Goiânia: UFG, 2024. [3]
7. Apresentação no Seminário de Pós-Graduação em Engenharia Elétrica e de Computação da Universidade Federal de Goiás 2024: MENDANHA, Vinicius Faria Costa. Estudos sobre aplicação de inteligência artificial em equipamentos de média e alta tensão. *In: SEMINÁRIO DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO DA UNIVERSIDADE FEDERAL DE GOIÁS, 2024, Goiânia. Goiânia: UFG, 2024.*
8. Apresentação no Conpeex 2025 (Congresso de Ensino, Pesquisa e Extensão): MENDANHA, Vinicius Faria Costa; MARQUES, André Pereira; RIBEIRO, Ca-cilda de Jesus. Classificação do desempenho de transformadores de potência por rede neural profunda em relação à análise do óleo mineral isolante. *In: CONGRESSO DE PESQUISA, ENSINO E EXTENSÃO (CONPEEX), 22., 2025, Goiânia. Anais [...].* Goiânia: UFG, 2025. [4]
9. Apresentação no Seminário de Pós-Graduação em Engenharia Elétrica e de Computação da Universidade Federal de Goiás 2025: MENDANHA, Vinicius Faria Costa. Classificação do desempenho de transformadores de potência em relação à análise do óleo mineral isolante. *In: SEMINÁRIO DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO DA UNIVERSIDADE FEDERAL DE GOIÁS, 2025, Goiânia. Goiânia: UFG, 2025.*

# Revisão da Literatura sobre IA aplicada à Manutenção Preventiva de Transformadores de Potência Imersos em Óleo Mineral Isolante

---

## 2.1 Introdução

Transformadores de potência são equipamentos indispensáveis à operação de sistemas elétricos de potência. Nesse sentido, suas falhas podem causar interrupções no fornecimento de energia elétrica aos consumidores e prejuízos operacionais e financeiros às empresas do setor elétrico. Diante disso, técnicas preditivas são amplamente empregadas para estimar o índice de desempenho desses equipamentos, sendo a análise de gases dissolvidos (AGD) em óleo e o grau de polimerização (GP) do papel alguns dos principais indicadores utilizados em campo<sup>1</sup>. Assim, o objetivo deste capítulo é apresentar uma revisão da literatura sobre essas técnicas com aplicações de Inteligência Artificial (IA). Como resultados, os trabalhos analisados evidenciam potenciais melhoras à detecção de falhas incipientes em transformadores de potência. A manutenção preventiva baseada em IA pode contribuir para a redução do tempo de inatividade dos transformadores de potência, minimizando custos de manutenção e melhorando a confiabilidade dos sistemas de energia elétrica.


---

<sup>1</sup>No caso do GP, o monitoramento realizado em campo se restringe à sua inferência matemática a partir da análise do teor de compostos furânicos no óleo isolante, não se tratando de um ensaio analítico direto sobre amostras de papel isolante.

## 2.2 Transformador de potência

Os transformadores de potência são equipamentos fundamentais e de alto custo no sistema elétrico de potência [5]. Eles<sup>2</sup> são responsáveis por adequar os níveis de tensão e corrente, a fim de viabilizar a geração, a transmissão a longas distâncias e a distribuição de energia elétrica, com elevado rendimento e reduzidas perdas de potência [6, 7], podendo ser trifásicos ou monofásicos, a depender das necessidades específicas de cada aplicação. A Figura 2.1 [8] exibe os diversos componentes desses equipamentos, que podem ser descritas da seguinte forma: 1. Núcleo, 2. Enrolamentos, 3. Tanque principal, 4. Tanque de Expansão de Óleo, 5. Buchas, 6. Comutador sob carga, 7. Acionamento do comutador sob carga, 8. Radiadores/trocadores de calor, 9. Painel de controle, 10. Secador de ar e 11. Termômetros.

Figura 2.1: Características construtivas de um transformador de potência imerso em óleo mineral isolante



Fonte: extraído de BECHARA, R. (2010) [8]

Em face da importância desses equipamentos, é necessário acompanhar seus desempenhos, para realizar o monitoramento do impacto de suas condições operativas, do sistema isolante e das condições de funcionamento de seus acessórios [5–7]. Nesse sentido, são desenvolvidas e empregadas as chamadas técnicas preditivas, as quais visam incrementar a eficiência de processos de manutenção preventiva para preservar a vida útil

<sup>2</sup>Conforme adotado em [5–7], aqui não se distinguem entre os termos transformadores imersos em óleo mineral isolante e autotransformadores, sendo ambos referidos como os primeiros.

dos equipamentos, garantindo confiabilidades satisfatórias. Para tanto, existem conjuntos diversificados de métodos de avaliação do índice de desempenho de transformadores [9].

Assim, neste trabalho, destacam-se os métodos de análise de gases dissolvidos (AGD) no óleo mineral isolante, grau de polimerização (GP) do papel, inferido por meio da concentração de compostos furânicos no óleo isolante, os ensaios físico-químicos (FQ) e o método de detecção de descargas parciais (DPs) por emissão acústica (EA). Além dessas técnicas, há os ensaios elétricos em geral, entre eles, resistência de isolamento (EE\_RI), fator de potência do isolamento (EE\_FP), relação de transformação de espiras (EE\_RT), resistência elétrica dos enrolamentos (EE\_RE), corrente de excitação com tensão reduzida (EE\_CE) e capacitância e tangente delta de buchas condensivas (EE\_BU).

Nesse sentido, o objetivo deste capítulo é apresentar a caracterização das principais técnicas preditivas usadas e as ferramentas de Inteligência Artificial (IA) aplicadas à sua análise. Para tanto, tal procedimento é precedido por uma revisão da literatura a fim de contextualizar os métodos empregados e fundamentar a aplicação das abordagens baseadas em IA.

## **2.3 Inteligência Artificial aplicada à manutenção de transformadores de potência imersos em óleo mineral isolante**

Em função dos esforços elétricos e térmicos, o óleo isolante do transformador de potência sofre processos de decomposição molecular, nos quais seus hidrocarbonetos constituintes se quebram e dão origem aos gases dissolvidos presentes no óleo. Os principais gases formados durante a operação do transformador são: hidrogênio ( $H_2$ ), metano ( $CH_4$ ), etano ( $C_2H_6$ ), etileno ( $C_2H_4$ ), acetileno ( $C_2H_2$ ), monóxido de carbono (CO) e dióxido de carbono ( $CO_2$ ) [5, 8, 10–12]. Além disso, o conteúdo total de gases combustíveis é considerado um dos indicadores de avaliação.

Algumas abordagens foram desenvolvidas para avaliar as condições de desempenho de transformadores com base nos dados provenientes da AGD, tendo sido amplamente utilizadas metodologias baseadas em conhecimento especializado, com destaque para a Técnica das Razões entre Gases [13–15] e para o Método do Gás-Chave [16]. No cenário brasileiro, por sua vez, destacam-se os critérios normativos estabelecidos pela ABNT NBR 7274:2012 [17], a qual define as relações básicas entre gases ( $CH_4/H_2$ ,  $C_2H_2/C_2H_4$  e  $C_2H_4/C_2H_6$ ), os limites característicos dessas relações para cada tipo de falha, bem como as condições de confiabilidade para valores típicos, taxas de evolução e níveis de alarme do conjunto de gases combustíveis.

Contudo, observa-se que, em alguns cenários, determinados conjuntos de razões entre as concentrações de gases dissolvidos em óleo mineral isolante não se enquadram simultaneamente nas faixas de diagnóstico previstas pela norma ABNT NBR 7274:2012 [17]. Por exemplo, valores de  $C_2H_2/H_2$  fora do intervalo de 0 até 2,5, de  $CH_4/H_2$  inferiores a 0,1 ou superiores a 4, ou, ainda, de  $C_2H_4/C_2H_6$  situados entre 0,2 e 1 não conduzem, isoladamente, a um diagnóstico automático. Ainda assim, a norma considera a evolução temporal e os níveis absolutos dos gases, de modo que a dificuldade não decorre de uma limitação normativa, mas da complexidade de integrar simultaneamente esses critérios, o que pode dificultar a automatização baseada apenas em regras fixas.

Em contraponto, para a realização de diagnósticos sistemáticos e abrangentes, a IA é empregada na interpretação da AGD. Para tanto, diversas abordagens, como redes neurais artificiais, máquinas de vetor de suporte (SVM), redes bayesianas, redes profunda de crenças (DBN) e *autoencoder* de dupla camada empilhada têm promovido avanços significativos no estado da arte de manutenção preventiva de transformadores de potência. A Tabela 2.1 apresenta uma síntese das principais contribuições científicas envolvendo a aplicação de ferramentas de IA à interpretação da análise de gases dissolvidos (AGD) em transformadores de potência, com vista à inclusão de trabalhos relevantes, os quais utilizam desde arquiteturas clássicas, como redes neurais do tipo MLP (*Multilayer Perceptron*), até modelos híbridos e técnicas avançadas como Autoencoders Empilhados e redes CNN-LSTM (Redes Neurais Convolucionais com *Long Short-Term Memory*).

Tabela 2.1: Comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base na técnica preditiva AGD

Estudo	Ferramentas de IA	Vantagens	Desvantagens
Trabalho [18]	MLP com treinamento Levenberg–Marquardt e com <i>Backpropagation</i> Adaptativo (MLP-LM e MLP-ABP).	Acurácia média para $C_2H_2$ : 96,48%; e para $H_2$ , 87,65%. Supera os métodos IEEE/IEC (Gás chave: 45,19% e Rogers: 40,00%). Diagnóstico direto de falhas com média de 72,24%.	Baixa acurácia para CO (67,34%). Sensível a erros laboratoriais e requer normalização dos dados e validação em campo.

Tabela 2.1 (continuação): Comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base na técnica preditiva AGD

<b>Estudo</b>	<b>Ferramentas de IA</b>	<b>Vantagens</b>	<b>Desvantagens</b>
Trabalho [19]	<i>Autoassociative Neural Network (AANN)</i> com agrupamento <i>Mean Shift</i> .	Diagnóstico não supervisionado. Detecta anomalias por reconstrução do vetor de entrada e acurácia de 84,38% em falhas conhecidas (64 casos reais).	Sensível a ruídos e dados limítrofes. Exige pré-processamento criterioso e ajuste delicado de parâmetros do <i>Mean Shift</i> .
Trabalho [20]	Rede Neural Artificial (ANN) com lógica baseada em regras.	Diagnóstico com classificação por níveis de severidade. Precisão de até 97,5% e média superior a 95% nas falhas críticas.	Desempenho reduzido em classificações pouco representadas (até 88,3%). Exige dados rotulados e balanceados, e é sensível à arquitetura e à inicialização da ANN.
Trabalho [21]	<i>Autoencoder</i> Duplamente Empilhado (do inglês, <i>Double-Stacked Autoencoder</i> ).	Acurácia de 96,83%, superando ANN convencional (87,06%). Redução de 50% no erro de reconstrução. Ideal para dados desbalanceados.	Requer ajuste fino de hiperparâmetros. Necessita arquitetura personalizada e poder computacional elevado.
Trabalho [22]	ANFIS (do inglês, <i>Adaptive Neuro-Fuzzy Inference System</i> ) + <i>K-means</i> .	Capacidade interpretativa das regras <i>fuzzy</i> . Acurácia de 94,25%. Combina classificação com agrupamento.	Sensível à inicialização dos <i>clusters</i> . Pode sofrer <i>overfitting</i> em bases de dados pequenas.

Tabela 2.1 (continuação): Comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base na técnica preditiva AGD

<b>Estudo</b>	<b>Ferramentas de IA</b>	<b>Vantagens</b>	<b>Desvantagens</b>
Trabalho [23]	Modelo híbrido CNN + LSTM.	Acurácia superior a 98%. Explora dependência espacial e temporal entre as variáveis. Alta robustez ao ruído.	Alta complexidade computacional. Requer grandes volumes de dados rotulados.

Fonte: próprio autor (2025)

Os resultados na Tabela 2.1 destacam aumentos expressivos de acurácia das ferramentas de IA em comparação aos métodos tradicionais, como os propostos pelas normas IEEE/IEC [18]. Além disso, há inserção de métodos resistentes ao ruído, capacidade de lidar com bases de dados desbalanceados, isto é, conjuntos em que a quantidade de registros de falha é muito menor que a quantidade de registros de operação normal, o que prejudica o aprendizado dos modelos, e potencial de aplicação em diagnósticos não supervisionados, a fim de diminuir a necessidade de rotulação de dados por especialistas.


Todavia, algumas limitações persistem, como a necessidade de ajustes complexos de hiperparâmetros, como o número de vizinhos mais próximos, a quantidade de camadas ocultas, o número de neurônios em cada camada e o volume representativo de amostras imputadas. Isso pode impactar a generalização do modelo, exigindo estratégias adicionais de validação e seleção automatizada de parâmetros. Em relação às abordagens mais recentes, destaca-se o uso de *Autoencoders* Empilhados, projetados para tratar bases de dados desbalanceados. Esse cenário é bastante comum em situações de campo, em que registros de falhas reais em transformadores podem sofrer com a escassez de amostras representativas para determinadas classificações de operação. Nessa lógica, os modelos baseados em *Autoencoders* Duplamente Empilhados se mostraram eficazes ao realizar, concomitantemente, a reconstrução do vetor de entrada e a predição supervisionada de classificações [21].

Outrossim, a vida útil do transformador de potência está diretamente relacionada à integridade de sua isolação celulósica, isto é, do papel isolante que envolve os condutores dos enrolamentos [5]. Nesse contexto, o grau de polimerização da celulose (GP) é um indicador importante do estado dessa isolação e, portanto, da perda de vida útil.

Para tanto, a medição do grau de polimerização (número médio de monômeros de  $\beta$ -glicose anidra,  $C_6H_{10}O_5$ , na molécula da celulose), de materiais celulósicos novos e envelhecidos, utilizados na isolação elétrica de transformadores de potência, é realizada

de acordo com [5, 24]. O ensaio é realizado por meio de amostras de papel tipo *kraft* ou *kraft* termoestabilizado, que devem ser coletadas em pontos do enrolamento que tenham sido submetidos às maiores temperaturas. A Figura 2.2 [25] ilustra as alterações na morfologia da superfície do papel *kraft*, em consequência ao envelhecimento térmico.

Figura 2.2: Imagens de microscopia do papel *kraft* de isolamento dos enrolamentos deteriorado por 0 horas (à esquerda) e 400 horas (à direita) a 140 °C; com valores correspondentes de grau de polimerização (GP) de 717 e 115, nessa ordem



Fonte: JACOB, N. D.; KORZI, B; SHERIF, S. S. (2020) [25]

Desse modo, na Figura 2.2, mostra-se que, em um papel em condição nova (GP = 717), é possível observar fibras individuais intactas em uma rede entrelaçada, enquanto que, em um envelhecido (GP = 115), nota-se o afinamento das fibras, além de uma maior densidade de rachaduras e fissuras nas paredes [25]. Em seguida, a Tabela 2.2 aborda a comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base em GP.

Tabela 2.2: Comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base no grau de polimerização do papel inferido a partir dos compostos furânicos do óleo isolante

<b>Estudo</b>	<b>Ferramentas de IA</b>	<b>Vantagens</b>	<b>Desvantagens</b>
Trabalho [26]	Regressão Vetorial de Suporte (SVR) e otimização por Enxame de Partículas (PSO).	Alta acurácia na predição do grau de polimerização e uso eficaz de dados não invasivos.	Dependência de hiperparâmetros e dados de laboratório. Sem cenários reais de envelhecimento.

Tabela 2.2 (continuação): Comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base no grau de polimerização do papel inferido a partir dos compostos furânicos do óleo isolante

<b>Estudo</b>	<b>Ferramentas de IA</b>	<b>Vantagens</b>	<b>Desvantagens</b>
Trabalho [25]	SVM (do inglês, <i>Support Vector Machine</i> ) (com PSO), KNN (do inglês, <i>K-Nearest Neighbors</i> ) e BPNN (do inglês, <i>Backpropagation Neural Network</i> ).	Alta precisão na predição da Vida Útil Remanescente do Transformador (RUL), PSO otimiza os parâmetros do SVM e comparação entre métodos realizada de forma sistemática.	Conjunto de dados limitado (110 amostras), ausência de códigos ou detalhes reprodutíveis e resultados limitados ao Grau de Polimerização como alvo direto.
Trabalho [27]	CNN (do inglês, <i>Convolutional Neural Network</i> ), LSTM (do inglês, <i>Long Short-Term Memory</i> ) e GRU (do inglês, <i>Gated Recurrent Unit</i> ).	Previsão da RUL com base em dados temporais, sendo que a LSTM alcançou 92,3% de acurácia, superando CNN (89,6%) e GRU (91,5%).	Dependência de séries temporais bem rotuladas e alto custo computacional para treinamento de redes profundas.
Trabalho [28]	LSTM, Bi-LSTM e CNN.	Acurácia de 95,6%, precisão de 92,5%, <i>recall</i> de 93,1% e <i>f1-score</i> de 92,8%. Robusto a ruídos nos dados de sensores.	Necessidade de grande volume de dados rotulados e sensível à escolha dos hiperparâmetros e arquitetura.

Tabela 2.2 (continuação): Comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base no grau de polimerização do papel inferido a partir dos compostos furânicos do óleo isolante

<b>Estudo</b>	<b>Ferramentas de IA</b>	<b>Vantagens</b>	<b>Desvantagens</b>
Trabalho [29]	<i>Stacked Autoencoder</i> (do Inglês, SAE), <i>Random Forest</i> (do Inglês, RF), SVM, MLP e CNN.	Fornece aprendizado de características profundas e redução de dimensionalidade. CNN otimiza desempenho com imagens térmicas. Acurácia máxima de 94,4% com CNN.	Abordagem baseada em imagens depende fortemente de qualidade da câmera infravermelha e a aplicação pode ser limitada em ambientes reais com ruído térmico elevado.

Fonte: próprio autor (2025)

A Tabela 2.2 explicita a aplicação de ferramentas de Inteligência Artificial (IA) ao diagnóstico baseado no Grau de Polimerização (GP) da isolamento celulósica de transformadores de potência, destacando algoritmos como SVR (do inglês, *Support Vector Regression*), SVM (do inglês, *Support Vector Machine*), LSTM (do inglês, *Long Short-Term Memory*), CNN (do inglês, *Convolutional Neural Network*) e *Autoencoders*. Para tanto, observa-se que abordagens híbridas e baseadas em aprendizado profundo, como LSTM–CNN e SAE–CNN (do inglês, *Stacked Autoencoder – Convolutional Neural Network*), foram as mais eficientes na previsão da Vida Útil Remanescente (do inglês, *Remaining Useful Life*) e na classificação do estado de envelhecimento do isolamento, alcançando acurácias superiores a 90%.

Todavia, tais metodologias apresentam, como desvantagens, a necessidade de grandes volumes de dados rotulados, alta demanda computacional e limitação de reprodutibilidade em ambientes operacionais reais. Nesse sentido, há perspectiva para pesquisas que integrem dados reais de operação e explicabilidade dos modelos, para integrar os desafios práticos da engenharia de manutenção ao diagnóstico por IA.

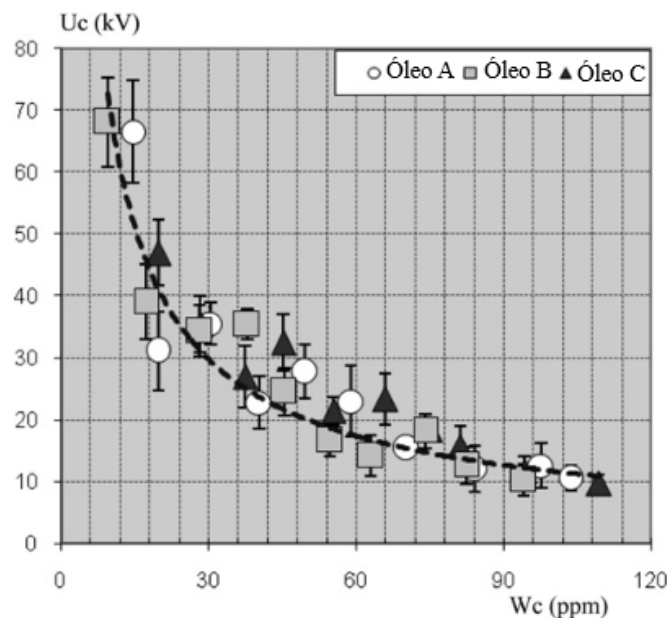
Em seguida, consideram-se os ensaios físico-químicos, por meio dos quais se obtêm os valores das grandezas tensão interfacial, índice de neutralização, índice de cor, fator de potência, rigidez dielétrica, teor de água e densidade [5, 30–33]. É possível obter dois grupos principais, sendo eles [5, 7, 30]:

- Grupo I: composto pelas grandezas tensão interfacial, índice de neutralização e índice de cor, relacionadas à degradação do óleo, à oxidação do fluido e à formação de borra; e

- Grupo II: formado por fator de potência, rigidez dielétrica e teor de umidade, com suas respectivas classificações, sendo elas mais relacionadas à detecção de contaminantes, umidade e compostos polares no óleo.

Salienta-se que a rigidez dielétrica ( $U_C$ ) é o elemento fundamental na avaliação da condição do óleo mineral [33]. A Figura 2.3 [33] representa a variação da rigidez dielétrica em função do teor de água ( $W_C$ ). Para cada valor medido de teor de água em ppm, há um valor médio correspondente de rigidez dielétrica, obtido após seis descargas sucessivas, conforme as recomendações da norma IEC 60156 [34].

Figura 2.3: Variações da tensão do ensaio de rigidez dielétrica  $U_C$  em função do teor de água  $W_C$  para os três óleos A, B e C



Fonte: TOUDJA, T. et al (2014) [33]

Para os três óleos da Figura 2.3 [33], a rigidez dielétrica representa a característica mais evidente quanto à influência do teor de água na qualidade dielétrica do óleo, qualquer que seja sua origem: novo, não tratado ou usado, sendo que ela diminui de forma acentuada, tornando o óleo cada vez mais degradado para uso após ultrapassar cerca de 10 ppm de água [32]. Assim, o efeito qualitativo da umidade no óleo está diretamente correlacionado à diminuição da rigidez dielétrica independentemente da idade do óleo, conforme (2.1) [32], sendo  $\alpha$  e  $\beta$  constantes dependentes do tipo de óleo.

$$U_C = \alpha W_C^{-\beta} \quad (2.1)$$

A Tabela 2.3 apresenta a aplicação de ferramentas de Inteligência Artificial (IA) ao diagnóstico baseado em ensaios físico-químicos.

Tabela 2.3: Comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base na técnica preditiva ensaios físico-químicos

<b>Estudo</b>	<b>Ferramentas de IA</b>	<b>Vantagens</b>	<b>Desvantagens</b>
Trabalho [35]	Sistema híbrido com Redes Neurais Artificiais (RNA).	Dados reais. Adota uma abordagem multiclassificação (acurácia de máxima de 89%).	Exige base histórica bem estruturada. Apresenta baixa interpretabilidade e é sensível à normalização das entradas.
Trabalho [36]	Regressão baseada em modelos múltiplos: <i>Random Forest</i> (RF), <i>Categorical Boosting</i> (CatBoost) e <i>Light Gradient Boosted Machine</i> (LightGBM).	Mostrou os transformadores a serem priorizados em intervenções de manutenção e os fatores ligados à degradação dos equipamentos.	Conjunto de dados limitado, com transformadores de uma mesma classificação de tensão. Índice de saúde indicando degradação severa não foi utilizado.

Fonte: próprio autor (2025)

Assim, destacam-se algoritmos como *Random Forest*, *CatBoost*, *LightGBM* e Redes Neurais Artificiais, com foco na classificação de desempenho de transformadores de potência (Tabela 2.3). Outra técnica preditiva bastante importante é o método de detecção de descargas parciais (DP) por emissão acústica (EA). Trata-se de um indicador crítico da degradação da isolação em transformadores de potência, sendo sua detecção oportuna essencial para prevenir falhas catastróficas. Ela consiste na medição de ondas de pressão produzidas por descargas elétricas incompletas ou parciais no meio isolante do transformador de potência [5, 37–39]. Como vantagens, esse método possui alta sensibilidade e capacidade de detectar descargas parciais em estruturas fechadas de transformadores [37, 40], embora os sensores de EA sejam dependentes da posição de instalação e exijam interpretação complexa dos sinais, tornando-os suscetíveis a eventos de DP não detectados ou mal classificados [41]. Os principais desafios relacionados a essa técnica são [5, 37–41]:

- eficácia das técnicas de EA é, muitas vezes, limitada pela dificuldade em diferenciar sinais efetivamente associados a descargas parciais daqueles resultantes de fontes

de ruído mecânico, elétrico ou ambiental. Isso demanda a adoção de métodos adicionais de processamento de sinais para aumentar a taxa de sucesso à identificação das ocorrências de DP;

- interferência de ruído, que dificulta a classificação de falhas e reduz a precisão do diagnóstico;
- sinais de DP, geralmente, embutidos em um fundo ruidoso, causado por perturbações ambientais, harmônicos do sistema de potência e interferência eletromagnética;
- presença de vibrações mecânicas e fontes acústicas externas, interferindo em sinais fracos de DP, resultando em falsos positivos ou detecções de falhas não realizadas;
- ruídos dinâmicos, que tornam as técnicas convencionais de processamento de sinais, como transformada de Fourier e análise *wavelet*, ineficazes na filtragem do ruído e extração de características de DP; e
- os métodos tradicionais de análise de DP requerem avaliação humana e ajuste manual de parâmetros, o que pode introduzir inconsistências na detecção de falhas.

As técnicas de processamento de sinais com base em IA melhoraram, significativamente, a detecção de DP por meio da automação da extração de características, melhoria da filtragem de ruído e otimização da classificação de falhas [37, 42]. Desse modo, a Tabela 2.4 apresenta os principais trabalhos que aplicaram técnicas de IA à análise de descargas parciais em transformadores de potência, com base em emissão acústica.

Tabela 2.4: Comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base na técnica preditiva análise de descargas parciais por emissão acústica

<b>Estudo</b>	<b>Ferramentas de IA</b>	<b>Vantagens</b>	<b>Desvantagens</b>
Trabalho [38]	Transformada Discreta de Fourier, Decomposição <i>wavelet</i> , Análise de Componentes Principais (PCA), KNN e Máquina de Suporte de Vetores (SVM).	Alta acurácia (até 94% em condições controladas), extração robusta de características e sensores de baixo custo.	Necessidade de reamostragem variada, dependência de sensores e ausência de validação em condições de campo.

Tabela 2.4 (continuação): Comparação entre ferramentas de IA aplicadas ao diagnóstico de transformadores de potência com base na técnica preditiva descargas parciais por emissão acústica

<b>Estudo</b>	<b>Ferramentas de IA</b>	<b>Vantagens</b>	<b>Desvantagens</b>
Trabalho [40]	ANFIS Aprimorado (do inglês, <i>Improved Adaptive Neuro-Fuzzy Inference System</i> ).	Alta sensibilidade para detecção do pulso ultravioleta, alta correlação com intensidade de descarga real e robustez a ruído.	Necessidade de sensores específicos, dependência de calibração precisa e pouca validação para generalização.
Trabalho [41]	MobileNets CNN aprimoradas, com blocos <i>Squeeze-and-Excitation</i> (SE) e função de ativação <i>h-swish</i> , para reconhecimento de padrões de DP.	Alta acurácia, processamento direto de dados, boa generalização entre diferentes tipos de DP e melhora da capacidade de atenção.	Necessidade de imagens bem rotuladas, requer GPU para treinamento e validação apenas em laboratório.
Trabalho [42]	Árvore de decisão binária, Máquina de Suporte Cúbico de Vetores (do inglês, <i>Cubic-SVM</i> ), KNN e <i>Ensemble</i> de árvores com <i>bagging</i> (EBT).	Alta acurácia global (superior a 98%) na identificação de PD e estratégia de classificação em duas etapas.	Desbalanceamento das classificações e dependência de sinal AE de qualidade.

Fonte: próprio autor (2025)

Logo, as aplicações de IA em transformadores de potência representam inovações na área de engenharia elétrica, pois são incorporados métodos avançados de análise de dados, relacionados ao aprendizado de máquina e à análise preditiva de falhas incipientes. Dessa maneira, a integração da IA a esses equipamentos possui potencial de melhorar a confiabilidade e as práticas de manutenção preventiva nesses equipamentos.

## 2.4 Conclusões

Neste capítulo, foi apresentada uma revisão da literatura das principais técnicas preditivas aplicadas ao diagnóstico e à manutenção de transformadores de potência,

com ênfase na aplicação de ferramentas de Inteligência Artificial (IA). As metodologias baseadas na Análise de Gases Dissolvidos (AGD), no grau de polimerização (GP), nos ensaios físico-químicos (FQ) e na detecção de descargas parciais (DP) foram abordadas, de forma sistemática, ressaltando-se as vantagens e limitações de cada uma.

Primeiramente, observou-se que a AGD é amplamente adotada devido à sua natureza não invasiva e à capacidade de fornecer diagnósticos rápidos e eficientes. No entanto, métodos tradicionais, baseados em Razões entre Gases ou no Gás-Chave, apresentam limitações frente à complexidade dos dados reais, uma vez que nem todas as combinações observadas de concentrações e razões entre as variáveis conduzem a um diagnóstico conclusivo. Assim, em situações práticas, determinados padrões medidos não se enquadram nos critérios predefinidos por essas metodologias, o que pode resultar em casos não classificáveis ou em diagnósticos inconclusivos quando tais métodos são aplicados de forma isolada. Nesse cenário, técnicas de IA, baseadas em redes neurais profundas, *autoencoders* empilhados e modelos híbridos, têm apresentado resultados promissores em acurácia e robustez, especialmente, em contextos com dados desbalanceados ou ruidosos. Isso é essencial para fundamentar decisões de especialistas em manutenção, evitando gastos desnecessários com intervenções.

Em seguida, em relação ao Grau de Polimerização, as abordagens baseadas em IA mostraram-se eficazes na previsão da vida útil remanescente do transformador, sobretudo, quando integradas a dados temporais e modelos como LSTM e CNN. Ainda assim, a exigência de dados rotulados e o alto custo computacional permanecem como desafios na área. Ademais, os ensaios físico-químicos, por sua vez, ofereceram uma alternativa acessível e com grande disponibilidade histórica de dados. Nesse domínio, técnicas de aprendizado supervisionado, como *Random Forest*, *CatBoost* e redes neurais, vêm sendo utilizadas com sucesso para a classificação do estado do equipamento, embora enfrentem, frequentemente, obstáculos, tais como a baixa interpretabilidade dos modelos e a heterogeneidade dos conjuntos de dados.

Além disso, a detecção de descargas parciais por emissão acústica representa uma ferramenta promissora, cuja eficácia pode ser substancialmente ampliada por algoritmos de IA capazes de realizar a filtragem de ruídos e a classificação automática dos eventos detectados. Ainda assim, há dependência de sinais de alta qualidade e possibilidade de detecções equivocadas. Isso exige cautela na implantação prática e ampla validação em campo.

Portanto, o uso de Inteligência Artificial no diagnóstico de transformadores de potência tem promovido avanços no campo da manutenção preventiva. Contudo, para que esses modelos sejam integrados às rotinas de monitoramento de transformadores de potência, é necessário considerar metodologias frente a dados incompletos, explicabilidade dos modelos de decisão e a compatibilidade com os sistemas já adotados pelas empresas

---

do setor elétrico. Além disso, o desenvolvimento de sistemas híbridos e completos, que combinem desempenho técnico com transparência e aplicabilidade prática, pode contribuir com os trabalhos por meio de aplicações de novas tecnologias nesta área.

# Predição Otimizada do Índice de Desempenho de Transformadores de Potência Imersos em Óleo Mineral Isolante com Aplicação de Inteligência Artificial

---

## 3.1 Resumo

Transformadores de potência são equipamentos essenciais para a operação do sistema elétrico, exigindo manutenções com diagnósticos precisos e eficientes. Dessa forma, tem-se como objetivo, neste trabalho, apresentar o desenvolvimento de uma ferramenta com aplicação de inteligência artificial para a predição do estado operacional baseada no Índice de Desempenho, por meio do uso de técnicas preditivas. A combinação dessas técnicas aos algoritmos de Inteligência Artificial possibilita uma análise adequada e individualizada, otimizando os recursos de manutenção. Na metodologia empregada tem-se o cálculo desse índice de desempenho e as correspondentes ações recomendadas, que variam desde o monitoramento até a retirada imediata de operação do equipamento, em conjunto com os algoritmos Curva de Cotovelo (*Elbow Method*) e Fator de *Outlier* Local (*Local Outlier Factor*), que são usados para identificar e excluir amostras discrepantes, garantindo a consistência dos dados. A validação foi realizada por meio de estudos de casos e os resultados foram satisfatórios, concluindo-se que esta ferramenta proporciona a prevenção de falhas, contribuindo com uma gestão assertiva destes equipamentos e auxiliando as equipes de manutenção na tomada de decisão em relação ao momento adequado de intervenção<sup>3</sup>.

**Palavras-chave:** índice de desempenho, predição, transformador de potência.

---

<sup>3</sup>Este capítulo contém os resultados publicados no trabalho [1].

## 3.2 Introdução

A manutenção preventiva de transformadores de potência é essencial para garantir a confiabilidade desses equipamentos, sendo também realizada por meio das técnicas preditivas que são aplicadas para avaliar seus correlatos índices de desempenho, proporcionando um diagnóstico correspondente acurado, para apoio às tomadas de decisão.

As avaliações do índice de desempenho baseiam-se, em geral, na condição momentânea/atual do ativo [2]. Por sua vez, em diferentes trabalhos da literatura [3–5], apresentam-se abordagens que fazem avaliações de condições dos equipamentos baseando-se em modelos de confiabilidade e probabilidade de falha, a partir do uso de estatísticas de falha de um certo espaço amostral de um determinado universo de equipamentos. Esses trabalhos apresentam também previsões baseadas em conjuntos de amostras, que em condições operativas distintas, poderão incorrer em grande perda de sensibilidade analítica. Isso proporciona uma limitação para equipamentos com características construtivas muito distintas e quando se possuem poucos dados históricos de manutenções preventivas disponíveis, como é a realidade dos transformadores de potência de subestações de energia elétrica em muitas empresas.

Assim, este artigo tem como originalidade o desenvolvimento de uma ferramenta com aplicação de inteligência artificial para excluir resultados discrepantes dos resultados das técnicas preditivas obtidas em campo, predizendo, de forma otimizada, a condição momentânea do equipamento (individualmente), por meio do índice de desempenho e do histórico destes equipamentos, observando-se que, em algumas situações, podem ocorrer equívocos nas obtenções dos resultados destas técnicas, resultantes das condições ambientais, das condições preparatórias dos executores ou do próprio equipamento de medição, dificultando a observação de tendências. Dessa forma, este trabalho se justifica por apresentar uma ferramenta que auxilia na identificação de falhas, eliminando pontos discrepantes (*outliers*) por meio de recursos de inteligência artificial, evitando intervenções desnecessárias e tendo como objetivo principal prever o índice de desempenho durante a vida útil destes equipamentos importantes para o sistema elétrico de potência.

## 3.3 Metodologia

A metodologia desenvolvida é um modelo híbrido de inteligência artificial, voltado para a predição do estado de transformadores de potência, utilizando o índice de desempenho. Esse modelo combina dois algoritmos principais com estruturas condicionais para uma análise aprofundada dos dados, a saber:

- **Curva de Cotovelo (*Elbow Method*)**: utilizada para determinar o número ideal de vizinhos mais próximos em subconjuntos de dados. De forma geral, ela descreve a

distorção medida pela soma do erro quadrático,  $\varepsilon_q$ , a cada valor  $k$  testado, referente ao melhor número de vizinhos, conforme (3.1), sendo  $d_{i,j}$  a distância de cada amostra  $n$  ao seu respectivo centroide  $k$  [6].

$$\varepsilon_q = \sum_{i=1}^k \sum_{j=1}^n d_{i,j}^2 \quad (3.1)$$

De (3.1), quanto menor for o valor de  $\varepsilon_q$ , as amostras estão mais próximas de seus respectivos centroides [6]. Assim, é possível obter um gráfico para análise, em que o eixo das abcissas corresponde ao melhor número de vizinhos testado  $k$ , enquanto o das ordenadas representa a soma do erro quadrático. Desse modo, o algoritmo da curva de cotovelo seleciona o valor ótimo de  $k$ , evitando o fenômeno de *overfitting*. Essa maneira de determinar  $k$  é utilizada com o algoritmo de Fator de *Outlier Local*, neste trabalho.

- **Fator de *Outlier Local* (*Local Outlier Factor* ou **LOF**):** trata-se do algoritmo de Inteligência Artificial para identificação e eliminação de amostras da análise, por estarem contaminadas por ruídos excessivos. É uma técnica não supervisionada de aprendizado de máquinas, que localiza os pontos a serem excluídos de determinado conjunto de dados sem a suposição prévia de uma distribuição de dados específica [7, 8]. A partir de conjunto de dados  $\mathbf{X} \in \mathbb{R}^{m \times n}$  e de um conjunto de teste  $\mathbf{x} \in \mathbb{R}^m$ , o LOF procede da seguinte forma:

1. Considera-se a amostra  $x$  e os  $k$  vizinhos mais próximos, denotando-se a distância euclidiana por  $N(\mathbf{x}) = [x^1, x^2, \dots, x^K]$ , sendo que o parâmetro  $K$  representa a dimensão do conjunto avaliado.
2. Para cada amostra vizinha,  $\mathbf{x}^f$ , com  $1 \leq f \leq K$ , a distância  $K$  de  $\mathbf{x}^f$ ,  $k_{distance}(\mathbf{x}^f)$ , é calculada, sendo a distância euclidiana entre  $\mathbf{x}^f$  e seus  $K$ -ésimos vizinhos mais próximos.
3. Obtém-se a distância de alcance,  $reach_d$ , da amostra  $\mathbf{x}$ , conforme (3.2), sendo  $d(\mathbf{x}, \mathbf{x}^f)$  a distância euclidiana entre  $\mathbf{x}$  e seu  $f$ -ésimo vizinho.

$$reach_d(\mathbf{x}, \mathbf{x}^f) = \max \{ k_{distance}(\mathbf{x}^f), d(\mathbf{x}, \mathbf{x}^f) \} \quad (3.2)$$

4. Calculam-se a densidade local de alcance para a amostra  $\mathbf{x}$ ,  $lrd(\mathbf{x})$ , como em (3.3), e o LOF da amostra  $\mathbf{x}$ ,  $LOF(\mathbf{x})$ , dado em (3.4).

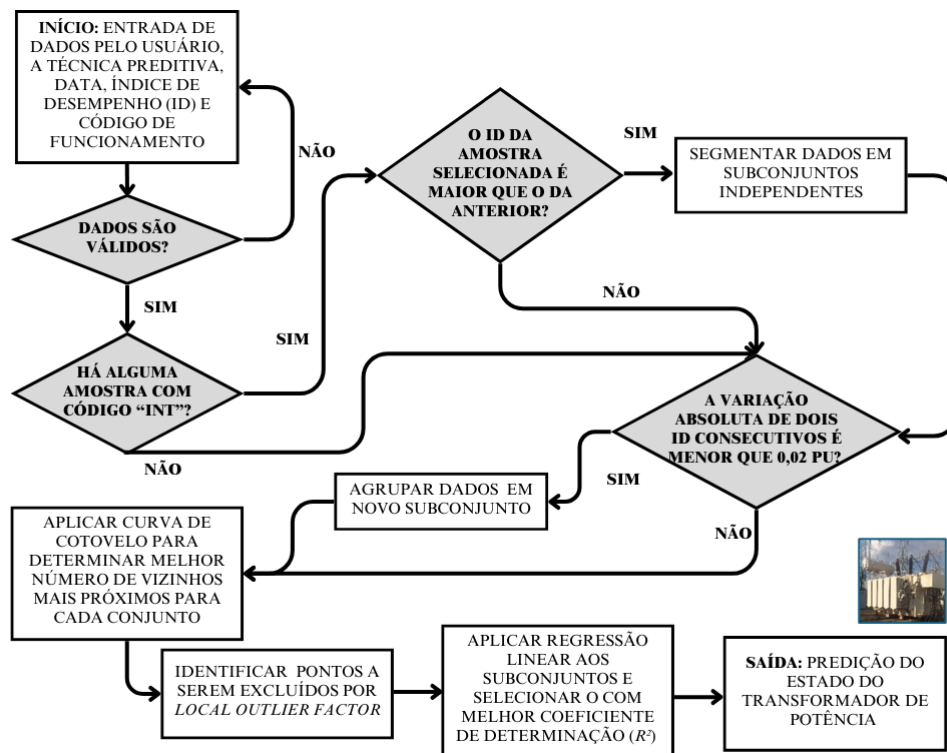
$$lrd(\mathbf{x}) = \frac{K}{\sum_{f=1}^K reach_d(\mathbf{x}, \mathbf{x}^f)} \quad (3.3)$$

$$LOF(\mathbf{x}) = \frac{1}{K} \sum_{f=1}^K \frac{lrd(\mathbf{x}^f)}{lrd(\mathbf{x})} \quad (3.4)$$

5. A partir do procedimento de cálculo do LOF, indica-se o grau de isolamento de uma amostra em relação aos seus vizinhos. Se a amostra  $x$  não for um ponto a ser excluído, o valor LOF será, aproximadamente, unitário.

Além desses algoritmos, a ferramenta incorpora estruturas condicionais para avaliar a variação absoluta entre duas amostras de datas consecutivas, aprimorando a análise dos dados, como se houve intervenção (INT). O modelo é aplicado a nove técnicas preditivas do equipamento, que são: Corrente de Excitação (EE\_CE), Fator de Potência (EE\_FP), Relação de Transformação (EE\_RT), Resistência de Isolamento (EE\_RI), Resistência Elétrica (EE\_RE), Ensaio em Buchas (EE\_BU), Análise de Gases Dissolvidos (AGD), Ensaio Físico-Químicos (FQ) e Grau de Polimerização/2FAL-Furfuraldeídos (GP\_2FAL). O fluxograma das etapas do método desenvolvido está representado na Figura 3.1.

Figura 3.1: Fluxograma com etapas do método desenvolvido neste trabalho



Fonte: próprios autores (2024)

Com os modelos de regressão e de identificação dos pontos excluídos da análise, realiza-se a predição do estado do transformador de potência com base nos subconjuntos processados. O final do processo inclui duas principais informações: a predição do estado do transformador de potência, conforme Tabela 3.1, e as ações recomendadas ao usuário, como sugestões sobre intervir ou não no equipamento.

Tabela 3.1: Critério de classificação do estado de operação como uma função do índice de desempenho

Estado de operação	Faixa de ID	Ação recomendada
A (Excelente)	$0,80 \leq ID \leq 1,00$	Continuar a operar o equipamento normalmente
B (Bom)	$0,65 \leq ID < 0,80$	Continuar a operar o equipamento atento à evolução dos resultados nos próximos registros
C (Marginal)	$0,50 \leq ID < 0,65$	Investigar e realizar outros testes a curto prazo para confirmar resultados e tendências
D (Ruim)	$0,35 \leq ID < 0,50$	Planejar a retirada de operação do equipamento para inspeção interna, localização e correção de defeitos
E (Muito ruim)	$0,00 \leq ID < 0,35$	Remover o equipamento de operação imediatamente para inspeção interna, localização e correção de defeitos

Fonte: adaptado de DIAS, Y. A. (2023) [2]

A classificação utilizada na Tabela 3.1 é baseada nos resultados da análise e tem como objetivo assegurar que o transformador de potência opere dentro de faixas desejadas, identificando e abordando potenciais problemas de forma técnica. O estado final do equipamento é, portanto, o pior estado predito, considerando a totalidade das técnicas preditivas utilizadas.


### 3.4 Resultados

A ferramenta desenvolvida foi validada com dados factíveis de transformadores de potência considerando as nove técnicas preditivas disponíveis e citadas anteriormente. Desta forma, na Figura 3.2, ilustra-se um dos estudos de caso com dados históricos concernentes à técnica preditiva de Análise de Gases Dissolvidos (AGD), em que são observados quatro subconjuntos resultantes do processo de segmentação proposta, considerando a efetividade das intervenções executadas no equipamento.

De forma eficiente, os dados são segmentados em quatro subconjuntos independentes, conforme ilustra a Figura 3.2. Esse processo produz *clusters* coerentes ao observado pelo especialista em campo. Nesse sentido, são utilizados mais dois tipos de ajuste para os outros subconjuntos, obtidos por regressão, além do linear: os polinomiais de segunda e terceira ordens. Assim, com base nos resultados apresentados, o especialista poderia agendar intervenções seguindo as recomendações fornecidas pela ferramenta. Considerando que o histórico do equipamento é até o mês 792 (equivalente a 66 anos),

estima-se quando o transformador atingirá um estado de operação ruim, definido quando o ID for igual ou inferior a 0,35, conforme Tabela 3.1.

Figura 3.2: Análise de Gases Dissolvidos, com representação dos subconjuntos de análise, pontos desconsiderados, reta de ajuste e coeficientes de determinação  $R^2$



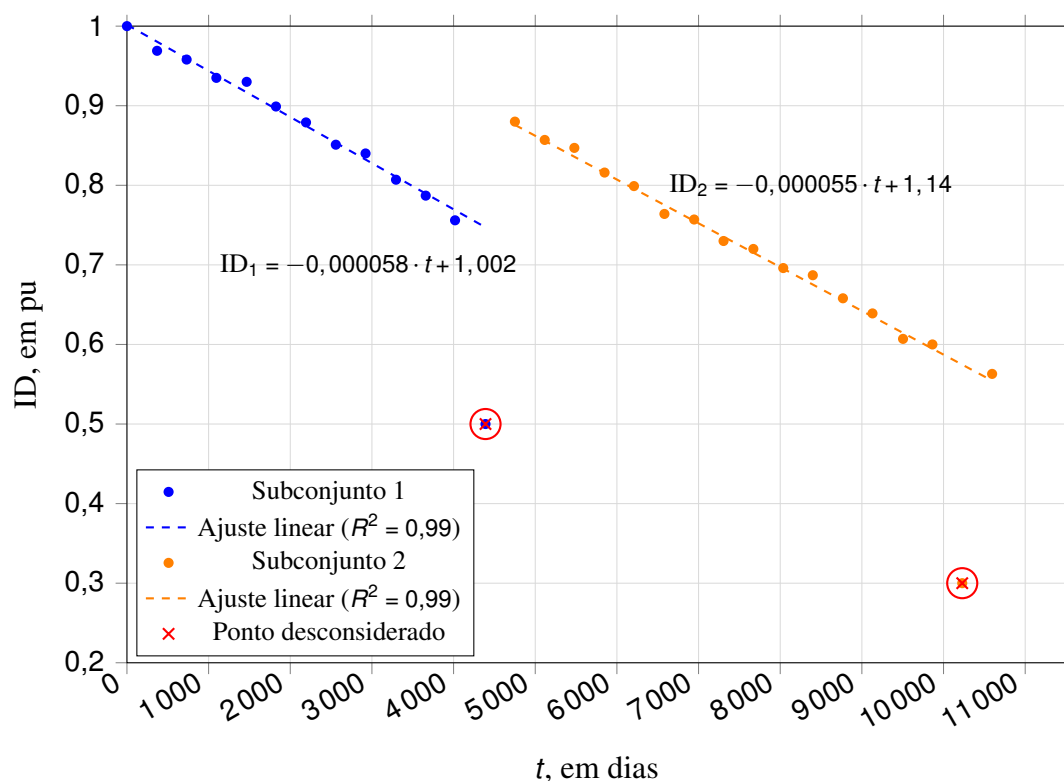
Fonte: próprios autores (2024)

De acordo com a equação do subconjunto  $ID_3$ , esse valor seria alcançado após 516,8 meses de operação, ou seja, quando transcorridos 43,1 anos de funcionamento do transformador. No entanto, devido à intervenção realizada após o último ponto de  $ID_3$ , por volta dos 500 meses, o índice crítico foi atingido somente após 724,8 meses, conforme  $ID_4$ , o que resultou em um prolongamento de 17 anos no período de operação do equipamento. Além disso, ao se analisar, em uma visão holística, o comportamento dos 4 subconjuntos da Figura 1, observa-se que, para os subconjuntos  $ID_1$  e  $ID_2$ , os valores são estáveis e elevados, indicando um excelente estado do equipamento. Entretanto, para

o subconjunto  $ID_3$ , tem-se um decaimento bastante acentuado dos índices, o que levou a se realizar a intervenção no equipamento por volta dos 500 meses de operação. No subconjunto  $ID_4$ , ocorre a elevação abrupta do índice de desempenho devido a uma intervenção nele realizada. Entretanto, os valores voltam a decair de forma ainda mais acelerada do que em  $ID_3$ . Uma análise mais acurada poderia levar a se inferir uma falha iminente e/ou o final de vida útil do equipamento na região à direita de  $ID_4$ .

A fim de avaliar a capacidade do algoritmo desenvolvido para detectar amostras extremamente afetadas por dados espúrios, são inseridos, propositalmente, dois valores a serem desconsiderados pela ferramenta, os quais estão circulos na Figura 3.3. Constatase desta forma, que a ferramenta aplicada foi capaz de identificar corretamente todas as amostras inadequadas, sem gerar falsos positivos ou falsos negativos. Além disso, verifica-se que o decaimento de valores dos dois subconjuntos apresenta comportamento semelhante.

Figura 3.3: Técnica preditiva de ensaios físico-químicos, com representação dos subconjuntos de análise, pontos desconsiderados, reta de ajuste e coeficiente de determinação  $R^2$

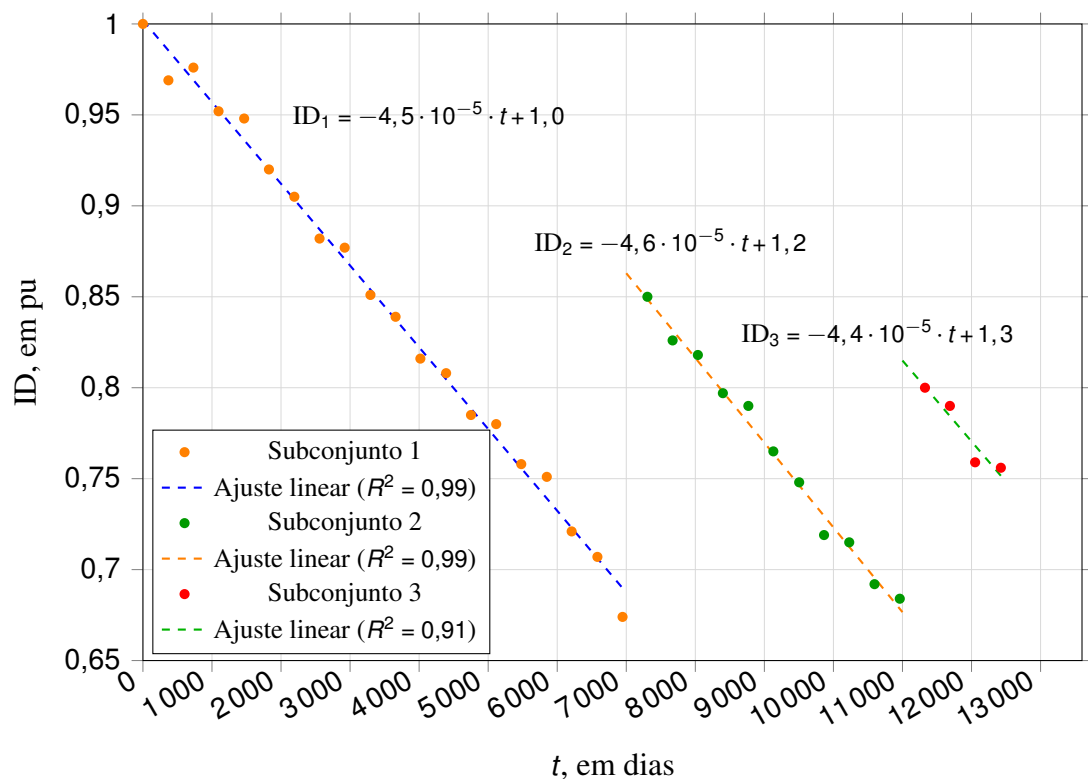


Fonte: próprios autores (2024)

Complementando a análise, na Figura 3.4, tem-se o resultado de um dos estudos de caso com dados históricos relativos aos ensaios físico-químicos (EE\_FQ), em que não há pontos a serem excluídos, e a ferramenta, de forma correta, considera todas as

amostras de entrada. Neste caso, observa-se que houve uma intervenção no equipamento após o último dado de  $ID_1$ , o que elevou o índice de desempenho de 0,65 para 0,85 (primeiro dado de  $ID_2$ ), e que, sucessivamente, quando o subconjunto  $ID_2$  atingiu valor de 0,65, houve outra intervenção, a qual elevou o índice para 0,8 (primeiro dado de  $ID_3$ ). Além disso, constata-se que os três subconjuntos apresentam decaimentos semelhantes de valores de índices de desempenho.

Figura 3.4: Técnica preditiva de ensaios físico-químicos, com representação dos subconjuntos de análise, pontos desconsiderados, retas de ajuste e coeficientes de determinação  $R^2$



Fonte: próprios autores (2024)

As métricas de precisão e *recall* (sensibilidade) foram calculadas de acordo com (3.5) e (3.6), respectivamente. Os resultados da precisão e do *recall* foram de 100%, constando que a ferramenta é eficiente na identificação de amostras a serem excluídas dos conjuntos analisados.

$$\text{Precisão} = \frac{\text{Verdadeiros positivos}}{\text{Verdadeiros positivos} + \text{Falsos positivos}} \quad (3.5)$$

$$\text{Recall} = \frac{\text{Verdadeiros positivos}}{\text{Verdadeiros positivos} + \text{Falsos negativos}} \quad (3.6)$$

## 3.5 Conclusões

A ferramenta desenvolvida neste trabalho apresenta a predição do índice de desempenho auxiliando a equipe de manutenção de transformadores de potência a intervir no momento adequado. A integração do uso de inteligência artificial, do Fator de *Outlier* Local (Local *Outlier* Factor ou LOF) e a Curva de Cotovelo, para determinar o número ideal de vizinhos mais próximos e segmentar os dados em subconjuntos significativos, demonstrou uma precisão e *recall* de 100% nas técnicas preditivas avaliadas, evidenciando sua eficácia na identificação correta das amostras a serem excluídas. Esses resultados destacam a alta acurácia da ferramenta na predição do estado dos transformadores e na análise da extensão da vida útil do equipamento, refletindo a efetividade das intervenções realizadas, favorecendo a aplicação de recursos financeiros de manutenção também eficientes.

Este artigo apresenta estudos de casos de transformadores de potência. Porém, esta ferramenta possui abrangência ampla com aplicações possíveis em outros equipamentos de média e alta tensão e em condições operacionais diversas. Portanto, conclui-se que a abordagem deste trabalho possibilita uma programação acertada da manutenção preventiva, com intuito de otimizar o desempenho dos transformadores de potência de forma individualizada de acordo com o seu histórico. A combinação de modelos de regressão precisos de inteligência artificial proporcionou uma análise detalhada e segmentada dos dados, fornecendo aos especialistas, informações para o planejamento e implementação de ações corretivas e preventivas nestes equipamentos importantes para o sistema elétrico de potência.

## Referências

- [1] MENDANHA, Vinícius Faria Costa; MARQUES, André Pereira; DIAS, Yuri Andrade; RIBEIRO, Cacilda de Jesus. Predição Otimizada do Índice de Desempenho de Transformadores de Potência com aplicação de Inteligência Artificial. **Sodebras**, v. 19, n. 222, 2024.
- [2] DIAS, Yuri Andrade. **Method for Predicting the Performance Indices of Power Transformers Immersed in Mineral Insulating Oil and Medium and High-Voltage Circuit Breakers**. 2023. PhD Thesis – Federal University of Goiás.
- [3] IDREES, M. *et al.* Fuzzy Logic Based Calculation and Analysis of Health Index for Power Transformer Installed in Grid Stations. *In: 2019 INTERNATIONAL SYMPOSIUM ON RECENT ADVANCES IN ELECTRICAL ENGINEERING (RAEE)*, 2019. **Anais [...]**. Islamabad, Pakistan: IEEE, 2019.

- [4] FREITAG, Suelen Cristiane; SPERANDIO, Mauricio. Determining the Reliability of Power Transformers Considering a Five States Markov Model. **IEEE Latin America Transactions**, Institute of Electrical e Electronics Engineers (IEEE), v. 19, n. 02, p. 335–341, fev. 2021. Dataset. Disponível em: <http://dx.doi.org/10.1109/TLA.2021.9443076>. Acesso em: 13 jun. 2025. DOI: 10.1109/TLA.2021.9443076.
- [5] GÓES, Helano Oliveira *et al.* Falhas em transformadores de potência: estudo de caso do sutf6-03 na uhe samuel. **Research, Society and Development**, v. 10, n. 6, p. 1–10, 2021.
- [6] PEREIRA, L. D. N. **Avaliação da degradação de disjuntores de alta tensão por meio de técnicas de machine learning**. 2023. Diss. (Mestrado) – Universidade de São Paulo, São Paulo.
- [7] QIN, J. F. *et al.* Outlier detection for on-line monitoring data of transformer based on wavelet transform and weighted LOF. *In: IOP CONFERENCE SERIES: EARTH AND ENVIRONMENTAL SCIENCE*, 1., 2019. **Anais [...]**.
- [8] ALGHUSHAIRY, Omar; ALSINI, Raed; SOULE, Terence; MA, Xiaogang. A Review of Local Outlier Factor Algorithms for Outlier Detection in Big Data Streams. **Big Data and Cognitive Computing**, MDPI AG, v. 5, n. 1, p. 1–24, dez. 2020. ISSN 2504-2289. DOI: 10.3390/bdcc5010001.

# Hybrid Artificial Intelligence Model for Reliable Decision-Making in the Maintenance of Mineral-Oil-Immersed Power Transformers Through Performance Index Monitoring

---

## 4.1 Abstract

The preventive maintenance of power transformers is essential to ensure their reliability and is supported by efficient predictive techniques and accurate diagnostics. In this context, the objective of this work is to present a hybrid Artificial Intelligence (AI) model for reliable decision making in transformer maintenance based on performance index monitoring. The innovation lies in the application of Monte Carlo filters to monitor the operational state of transformers combined with a novel clustering strategy. The used methodology includes the development of an algorithm for outlier removal in the historical series of each predictive technique as well as the implementation of stochastic filters to forecast the overall operational condition. The results demonstrate the robustness and effectiveness of the developed model. This work contributes a new AI-based strategy for supporting preventive maintenance decisions, enabling precise and individualized actions for each piece of equipment, with broad applicability to companies in the electrical power sector<sup>4</sup>.

**Keywords:** artificial intelligence, performance index, power transformers, preventive maintenance, reliability.

---

<sup>4</sup>Este capítulo é baseado no artigo submetido a um periódico internacional [1].

## 4.2 Introduction

Power transformers are frequently subjected to diagnostic tests aimed at predicting the operational condition of their components [2]. These procedures produce datasets for each predictive technique, typically composed of the normalized performance index (ranging from 0 to 1 pu), measured at specific time intervals (in days, months, or years), along with the operational status classified as either operation or intervention. However, effective analytical strategies are needed to process these datasets in a way that allows maintenance specialists to objectively and comprehensively assess the overall equipment performance by integrating the outputs of all techniques. This integrated analysis supports improved decision making and enhances the reliability of the power system. Although the AI model developed in this work is general and applicable to any power transformer, this paper focuses on case studies involving high-voltage power transformers immersed in mineral-insulating oil.

Among the most used predictive techniques for evaluating the paper–oil system are Dissolved Gas Analysis (DGA), Degree of Polymerization (DP), and Physicochemical Tests (PC), all of which are widely employed in the power sector to detect incipient faults in transformers [3, 4]. In addition, electrical tests are performed to assess the integrity of the transformer and its components, including Insulation Resistance (ET\_IR), Insulation Power Factor (ET\_PF), Turns Transformation Ratio (ET\_TTR), Winding Resistance (ET\_WR), Low Voltage Excitation Current (ET\_LVEC), and Capacitance and Tangent Delta of Condenser Bushings (ET\_CB).

However, potential outliers in the sample data, arising from electromagnetic interference, environmental fluctuations, sampling inconsistencies, or calibration errors in data acquisition equipment, can hinder the consistent interpretation of predictive technique results. Such discrepancies introduce bias into the analysis, complicating the identification of actual operational patterns. As a result, diagnostic quality may be compromised, directly impacting maintenance decisions, especially regarding the optimal timing of interventions to prevent catastrophic failures and unplanned service interruptions in utility operations.

Thus, it is essential to employ tools capable of detecting outliers in these datasets. To this end, several solutions based on machine learning algorithms have been proposed for analyzing predictive technique data, including the Local Outlier Factor (LOF), K-Nearest Neighbors (KNN), Isolation Forest (IF), Gaussian Mixtures, and Density-Based Spatial Clustering of Applications with Noise (DBSCAN) [5–7]. However, these algorithms exhibit some limitations: their accuracy is highly sensitive to the volume of data and the number of neighbors selected. Moreover, for large datasets, they tend to impose a high computational cost.

With regard to the prediction of power transformer performance during operation, several tools have been proposed for continuous monitoring. One such approach involves a methodology based on Analytic Hierarchy Process (AHP) multicriteria analysis, which was developed to assess the operating conditions of power transformers by considering both their lifespan characteristics (failure risk factor) and their systemic importance (impact factor) within the electrical network [8]. Similarly, another diagnostic methodology was proposed to estimate the operational state of transformers by incorporating the influence of harmonic distortions into the calculation of the health index [9].

Moreover, a finite-state machine-based diagnostic model for power transformers in substations was proposed by [10], in which chromatographic, physicochemical, and electrical analyses are used to determine operational states and to recommend preventive maintenance actions. In the context of applying artificial intelligence to preventive maintenance processes, several studies have been conducted. For instance, machine learning has been employed to estimate the Degree of Polymerization (DP), which is a key indicator of transformer aging [11]. In addition, prognostics and the health management of power transformers have been explored using a whale-inspired hybrid optimization algorithm [12]. In the domain of dissolved gas analysis (DGA), gas forecasting has been investigated through mixed-kernel support vector regression (SVR) combined with genetic algorithms [13]. Furthermore, expertise-guided machine learning (EGML) has been applied to diagnose internal faults in power transformers, using backpropagation neural networks (BPNNs) enhanced by genetic algorithms (GAs) and Memetic Evolutionary Algorithms (MEAs) [14].

Advances in artificial intelligence research have also made significant contributions to the modeling of predictive processes in dynamic systems. For example, an extensive empirical comparison of time series anomaly detection algorithms was conducted, many of which rely on forecasting mechanisms to model expected behavior and detect deviations [15]. The study highlights how prediction-based techniques, including deep learning architectures such as Long Short-Term Memory (LSTM) networks and autoencoders, can effectively support maintenance strategies by anticipating performance degradation. Additionally, causal discovery methods tailored for time series data are designed, offering new perspectives on identifying structural dependencies in dynamic environments, presenting a comprehensive survey and an evaluation of algorithms designed to uncover causal relationships across time, including constraint-based, score-based, and functional-model-based approaches [16]. These methods can be instrumental in preventive maintenance scenarios by enabling systems not only to forecast future behavior but also to infer underlying causal mechanisms responsible for degradation. This causal observation can augment traditional prediction strategies, such as those based on recurrent neural networks or forecasting filters, like Kalman filters and particle filters, by provi-

ding more robust explanations and improving interpretability in model-based maintenance planning.

Furthermore, stochastic modeling approaches based on D-spectrum theory and failure counting processes provide a probabilistic foundation for reliability assessment in complex systems [17]. Performance improvements from time series data augmentation have also been observed in small-sample signal recognition scenarios, highlighting the benefits of enhanced data under constraints typical of industrial monitoring datasets [18]. This scenario is particularly common in maintenance environments, as utilities often have limited historical data for certain types of equipment due to infrequent failures, incomplete records, or newly deployed assets. A hierarchical deep learning strategy combining syntactic and semantic graph representations has also been proposed for defect prediction in source code, offering transferable insights for degradation modeling through enriched feature learning [19]. These studies reinforce the relevance of AI-based methods in reliability engineering and point to the continued demand for interpretable and data-efficient models under uncertainty.

In that way, the objective of this study is to present a hybrid artificial intelligence model aimed at supporting assertive decision making in power transformer maintenance that is grounded in performance monitoring data. The model is structured in the following stages:

- Preprocessing stage: the accuracy of two unsupervised AI algorithms, the Local Outlier Factor (LOF) and Isolation Forest (IF), is assessed using expert-labeled data. Their outputs are compared to a novel outlier detection method developed in this work, which removes inconsistencies based on historical neighborhood consistency while preserving critical anomalies relevant to maintenance decisions.
- Output stage: maintenance recommendations are generated based on the classification of the performance index into five categories (A to E), reflecting the equipment's condition. Forecasting is then conducted using the AD-SIS and AD-Bootstrap frameworks, which estimate the future evolution of the performance index by modeling dynamic systems under uncertainty.

The main contribution of this study lies in the development of two custom Monte Carlo-based filtering frameworks (AD-Bootstrap and AD-SIS) specifically designed to handle noisy, incomplete, and irregularly sampled conditions, enabling reliability-centered probabilistic forecasting of equipment behavior. The proposed approach integrates unsupervised learning for outlier detection, temporal clustering based on intervention effectiveness, and Monte Carlo filtering, applied to real operational datasets. In contrast to previous models that analyze predictive techniques in isolation, this methodology seeks to consolidate nine predictive techniques into a unified and interpretable decision-making framework. By structuring these elements within a single model, the framework

is expected to support a more informed analysis of degradation trends and assist utility professionals in planning maintenance actions with greater confidence.

## 4.3 Methodology

In the methodology adopted in this study, a computational tool was developed to apply the classification criteria for the power transformer performance index, as defined in Table 4.1 [20], based on the worst predicted value at each time instant.

Table 4.1: Recommended actions based on the predicted performance index classification of the power transformer [20]

Performance Index ( $y$ )	Classification	Recommended Actions
$0.80 \leq y \leq 1.00$	A (Excellent)	The equipment should continue operating normally.
$0.65 \leq y < 0.80$	B (Good)	The equipment should continue operating, monitoring the evolution of results in upcoming records.
$0.50 \leq y < 0.65$	C (Marginal)	The equipment should be investigated, and additional tests should be conducted in the short term to confirm results and trends.
$0.35 \leq y < 0.50$	D (Poor)	Planning for the equipment's removal from operation for internal inspection, fault localization, and correction.
$0.00 \leq y < 0.35$	E (Very Poor)	The equipment must be immediately removed from operation for internal inspection, fault identification, and correction.

The classification from Table 4.1 [20] considers a total of nine tests, namely Dissolved Gas Analysis (DGA), Physicochemical Tests (PC), Degree of Polymerization (DP), Electrical Tests of Low Voltage Excitation Current (ET\_LVEC), Insulation Power Factor (ET\_PF), Turns Transformation Ratio (ET\_TTR), Insulation Resistance (ET\_IR), Winding Resistance (ET\_WR), and Capacitance and Tangent Delta of Condenser Bushings (ET\_CB). These tests represent the main predictive techniques used in transformer diagnostics, covering chemical, electrical, and physical indicators of degradation, and thus ensure a comprehensive assessment of equipment condition [2, 20, 21].

### 4.3.1 Artificial Intelligence Algorithms for Identifying Outliers

Initially, during the data preprocessing stage, two Artificial Intelligence algorithms, the Local Outlier Factor (LOF) and Isolation Forest (IF), assess the performance history of the power transformer throughout its operation, considering each set of the nine

predictive techniques. Individually, the tool performs a clustering based on the effectiveness of the intervention. To this end, at each observed time instant,  $t_i$ , with  $i \in [1, n]$  and  $n$  being the number of samples for each technique, the status is monitored. If an intervention is recorded at time  $t_i$ , the algorithm analyzes the performance index of the transformer  $y(t_i)$ . If it shows improvement compared to the previous sample,  $y(t_{i-1})$ , a new cluster  $\mathcal{C}$  is initiated. Otherwise, it is understood that the maintenance was not effective for the evaluated predictive technique, i.e., it did not result in performance improvement for that set, and the subsequent data remain within the previous cluster, according to the decision rule defined in (4.1).

$$\mathcal{C}(y(t_i)) = \begin{cases} \mathcal{C}_{\text{new}}, & \text{if } y(t_i) > y(t_{i-1}) \\ \mathcal{C}_{\text{previous}}, & \text{otherwise} \end{cases} \quad (4.1)$$

At the end of this stage, the sets of each predictive technique may be divided into subsets, in which the data exhibit well-defined temporal coherence, as the operational status is taken into account in the assessment of power transformer performance. Then, Artificial Intelligence algorithms are executed for the clusters. The first algorithm is the Local Outlier Factor (LOF), which is an unsupervised tool for outlier detection based on density and neighborhood. For each instance  $x = (y_j, t_j)$ , with  $j \in [1; n']$  and  $n'$  being the total number of elements in the cluster, the Euclidean distance  $d_k(x)$  between  $x$  and its  $k$ -nearest neighbors is computed [22, 23]. Additionally,  $\mathcal{M}(x)$  represents the set of training instances in the neighborhood of  $x$ , and for each  $s \in \mathcal{M}(x)$ , the distance  $d_k(s)$  is determined. By comparing  $d_k(x)$  with the mean value of  $d_k(s)$  for each  $s$ , the Local Outlier Factor (LOF( $x$ )) is calculated according to (4.2), where  $|\mathcal{M}(x)| = k$ . If the resulting value is close to 1, the instance  $x$  is not considered an outlier; otherwise, it is likely to be an outlier.

$$\text{LOF}(x) = \frac{d_k(x) \cdot |\mathcal{M}(x)|}{\sum_{s \in \mathcal{M}(x)} d_k(s)} \quad (4.2)$$

The second algorithm used for outlier detection is Isolation Forest (IF). It generates random trees to partition the data within each cluster and computes the number of nodes required to isolate each training vector [24]. Thus, outliers are identified as the vectors with the shortest average path lengths for isolation, based on the principle that anomalies are easier to isolate than normal points, thus requiring fewer splits and yielding shorter average path lengths. The anomaly score, denoted by  $\text{score}(x)$ , for each instance is computed in (4.3), where  $E[h(x)]$  represents the expected average path length to isolate point  $x$  in the forest, and  $c(\psi)$  is the average path length value for a dataset of size  $\psi$ , which is used as a normalizing factor [24].

$$\text{score}(x) = 2^{-\frac{E[h(x)]}{c(n)}} \quad (4.3)$$

Finally, the expected average path length  $h(x)$  required to isolate a point in a dataset with  $n$  elements, denoted as  $c(n)$ , is computed for  $n$  samples in (4.4), where  $H(n)$  represents the harmonic number of the  $n$ -th term. For large values,  $H(n) = \ln(n) + 0.577$  [24].

$$c(n) = 2H(n-1) - \frac{2(n-1)}{n} \quad (4.4)$$

Based on the values obtained in (4.3) and (4.4), the following conclusions are drawn:

- If  $E[h(x)] = c(n)$ , then  $\text{score}(x) = 0.5$ , indicating nominal behavior for  $x$ .
- If  $E[h(x)] \rightarrow \infty$ , then  $x$  is not isolated, meaning it exhibits nominal behavior.
- If  $E[h(x)]$  is small compared to  $c(n)$ , then  $\text{score}(x)$  tends to one, indicating that  $x$  is an outlier.

After the outlier detection and removal stage, the data from each predictive technique are compared at each time instant, and the overall performance index  $y(t)$  is obtained as the minimum value among all individual indices at that time. This conservative criterion prioritizes the worst-performing predictive component at each instant, aligning with preventive maintenance strategies by emphasizing early intervention based on the most critical signal.

### 4.3.2 New Method Developed for Identifying Outliers

The algorithm developed (AD) in this work for detecting and eliminating outliers is based on two main assumptions:

1. The performance index of power transformers does not increase in the absence of maintenance or intervention. Thus, any spontaneous increment is interpreted as an undue improvement, i.e., for a given sample  $i$ , where  $y(t_i)$  and  $y(t_{i-1})$  denote the performance index at times  $t_i$  and  $t_{i-1}$ , respectively, as expressed in (4.5).

$$\Delta y(t_i) = y(t_i) - y(t_{i-1}) > 0 \quad (4.5)$$

2. Abrupt drops in  $y(t)$ , when compared to the local degradation pattern of neighboring points, are considered outliers unless they are immediately followed by a consistent degradation trend. In this case, the drop is interpreted as a natural event of accelerated aging rather than an inconsistency. The detection rule is expressed in

(4.6), where  $\mu_{\Delta y}$  and  $\sigma_{\Delta y}$  are, respectively, the mean and standard deviation of the negative variations in cluster  $\mathcal{C}$ .

$$\begin{cases} \Delta y(t_i) = y(t_i) - y(t_{i-1}) < \mu_{\Delta y} - 2\sigma_{\Delta y} \\ \Delta y(t_{i+1}) = y(t_{i+1}) - y(t_i) \geq \mu_{\Delta y} - 2\sigma_{\Delta y} \end{cases} \quad (4.6)$$

This criterion detects outliers as abrupt drops in  $y_t$  that significantly deviate from the expected local variation. The  $2\sigma$  threshold assumes that the distribution of negative variations within each cluster  $\mathcal{C}$  is approximately normal. Importantly, the analysis is carried out within clusters so that variability is assessed locally rather than globally.

Furthermore, the second condition in (4.6) ensures that an abrupt drop is only considered an outlier if it is not immediately followed by a consistent degradation trend. This distinction is crucial to avoid false positives, for example, in cases where the natural degradation of components such as bushings produces sudden but legitimate declines. The values flagged as outliers are replaced by empty cells, preventing them from influencing subsequent analyses. The proposed AD algorithm combines domain-specific assumptions with local statistical criteria, improving the reliability of outlier detection in power transformer performance index data.

At the end, it is important to emphasize that power transformers do not exhibit self-recovery of performance. The cellulosic insulation ages irreversibly through hydrolysis and oxidation, leading to kraft paper depolymerization and a permanent loss of mechanical strength [25, 26]. Although interventions like oil drying and acid removal can slow degradation, they cannot reverse the chemical damage that has already occurred. The aging process is autocatalytic, accelerated by moisture and acidic by-products, ensuring that performance improvement stems only from corrective maintenance [27]. The degree of polymerization (DP) monotonically declines over service life and can only be restored by replacing the insulating material [28]. The transformer lifetime is consumed cumulatively, and it is particularly influenced by hot-spot temperatures as prescribed in IEC/IEEE loading guides [29]. High hot-spot temperatures degrade the insulation irreversibly and increase brittleness [30, 31]. This foundational understanding justifies the developed algorithm's assumption of degrading performance.

### 4.3.3 Statistical Validation of Maintenance Interventions

To assess whether a recorded intervention produced a statistically significant improvement in the performance index  $y(t)$ , a local comparison strategy is applied, which is based on the last observation immediately before the intervention and the first two observations available after it. Let  $t_0$  denote the intervention instant. The last pre-intervention observation is denoted by  $y_{\text{pre}}$ , while the two post-intervention values are

denoted by  $y(t_0)$  (if available at the same time as the intervention) and  $y(t_{0+})$  (the first non-intervention observation with  $t > t_0$ ). If no measurement exists exactly at  $t_0$ , the first two non-intervention points with  $t > t_0$  are used instead.

The differences relative to the baseline are defined in (4.7). The sample mean  $\bar{d}$  and variability  $s_d$  of these differences are computed as in (4.8). The test statistic in (4.9) follows Student's  $t$  distribution under the null hypothesis with  $df = 1$  degree of freedom.

$$d_1 = y(t_0) - y_{\text{pre}} \quad \text{and} \quad d_2 = y(t_{0+}) - y_{\text{pre}} \quad (4.7)$$

$$\bar{d} = \frac{d_1 + d_2}{2} \quad \text{and} \quad s_d = \sqrt{(d_1 - \bar{d})^2 + (d_2 - \bar{d})^2} \quad (4.8)$$

$$t = \frac{\bar{d}}{s_d/\sqrt{2}}, \quad df = 1 \quad (4.9)$$

The hypotheses are formally written as  $H_0 : \bar{d} \leq 0$  versus  $H_1 : \bar{d} > 0$ . The one-sided  $p$ -value is defined as  $p = \Pr\{T_1 \geq t\} = \text{sf}(t; 1)$  where  $T_1$  is a  $t$  random variable with one degree of freedom. Here,  $\Pr\{\cdot\}$  denotes probability: that is,  $\Pr\{A\}$  is the probability that event  $A$  occurs. In addition, the notation  $\text{sf}(t; 1)$  refers to the survival function of the  $t$  distribution with one degree of freedom, defined as  $\text{sf}(x) = 1 - F(x) = \Pr(X \geq x)$ , where  $F(x)$  is the cumulative distribution function (CDF). At the end, the decision rule relies exclusively on the  $p$ -value.

- If  $p < \alpha$ , the intervention is classified as Effective;
- If  $p \geq \alpha$ , the intervention is classified as Not Statistically Effective (NSE).

#### 4.3.4 Particle Filters for Predicting the Performance Index

Subsequently, two custom Monte Carlo-based filters developed in this study and referred to as AD-SIS and AD-Bootstrap are applied. Unlike standard Sequential Importance Sampling (SIS) and Bootstrap filters, these frameworks incorporate specific mechanisms to address irregular sampling, autoregressive forecasting, and condition-based classification. Monte Carlo techniques are widely used for probabilistic inference in nonlinear dynamic systems [9, 32, 33] and constitute an important branch of Artificial Intelligence (AI) for modeling uncertainty.

Initially, the unobserved signal (hidden states)  $\mathbf{x}_t$  with  $t \in \mathbb{N}$  is considered to be modeled as a Markov process with an initial distribution  $p(\mathbf{x}_0)$  and transition probability  $p(\mathbf{x}_t | \mathbf{x}_{t-1})$ . The observations  $\mathbf{y}_t$  with  $t \in \mathbb{N}^*$  are assumed to be conditionally independent given the stochastic process and the marginal distribution  $p(\mathbf{y}_t | \mathbf{x}_t)$ . Additionally, let  $\mathbf{x}_{0:t} \triangleq \{x_0, \dots, x_t\}$  and  $\mathbf{y}_{1:t} \triangleq \{y_1, \dots, y_t\}$  represent, respectively, the signal and the observations at time  $t$ . First, Bayes' theorem is applied to compute  $p(\mathbf{x}_t | \mathbf{y}_{1:t-1})$  in (4.10).

$$\rho(\mathbf{x}_{0:t} | \mathbf{y}_{1:t}) = \frac{\rho(\mathbf{y}_{1:t} | \mathbf{x}_{0:t}) \rho(\mathbf{x}_{0:t})}{\int \rho(\mathbf{y}_{1:t} | \mathbf{x}_{0:t}) \rho(\mathbf{x}_{0:t}) d\mathbf{x}_{0:t}} \quad (4.10)$$

In the Sequential Importance Sampling (AD-SIS) filter, the importance sampling method produces an estimate of  $\rho(\mathbf{x}_{0:t} | \mathbf{y}_{1:t})$ , defined as  $\hat{P}_N(d\mathbf{x}_{0:t} | \mathbf{y}_{1:t})$ , without altering the past simulated trajectories, given by  $\mathbf{x}_{0:t-1}^{(i)}$ , with  $i = 1, \dots, N$ , where  $N$  is the number of independent and identically distributed (i.i.d.) random samples, which are referred to as particles [33]. Thus, the importance function  $\pi(\mathbf{x}_{0:t} | \mathbf{x}_{1:t})$  at time  $t$ , understood as a marginal distribution at  $t - 1$ , satisfies the relationship in (4.11), which is obtained by a recursive structure of the posterior distribution based on the Markov assumption, serving as the foundation for Sequential Importance Sampling. Furthermore, the importance weights  $\tilde{w}_t^{(i)}$  are computed recursively, as shown in (4.12).

$$\pi(\mathbf{x}_{0:t} | \mathbf{y}_{1:t}) = \rho(\mathbf{x}_0) \prod_{k=1}^t \rho(\mathbf{x}_k | \mathbf{x}_{k-1}) \quad (4.11)$$

$$\tilde{w}_t^{(i)} \propto \tilde{w}_{t-1}^{(i)} \frac{\rho(\mathbf{y}_t | \mathbf{x}_t^{(i)}) \rho(\mathbf{x}_t^{(i)} | \mathbf{x}_{t-1}^{(i)})}{\pi(\mathbf{x}_t^{(i)} | \mathbf{x}_{0:t}, \mathbf{y}_{1:t})} \quad (4.12)$$

In the AD-Bootstrap filter, the importance weights are considered as  $\rho(\mathbf{y}_t | \tilde{\mathbf{x}}_t^{(i)})$ , where  $\tilde{\mathbf{x}}_t^{(i)} \sim \rho(\mathbf{x}_t | \mathbf{x}_{t-1}^{(i)})$ . This modification, compared to the AD-SIS filter, enhances the adjustment of particles to observations by eliminating additional importance functions present in the latter. As a result, the AD-Bootstrap filter discards low-relevance particles and focuses computations on the most representative ones.

The observation  $\mathbf{y}_t$  is assumed to be conditionally dependent on the latent state through an observation function  $\mathbf{h}_t(\cdot)$ , which is also subject to measurement noise. In this study, two forms of observation models were considered:

1. Direct observation with additive Gaussian noise, modeled as  $\mathbf{h}_t(\mathbf{x}_t) = \mathbf{x}_t + \eta_t$ , with  $\eta_t \sim \mathcal{N}(0, \sigma^2 \mathbf{I})$ ;
2. A likelihood function with exponential form,  $\mathcal{L}(\mathbf{x}_t; \mathbf{y}_t) = \exp\left(-\frac{1}{2} \frac{(\mathbf{x}_t - \mathbf{y}_t)^2}{\sigma^2}\right)$ , which is suitable for simulating asymmetric or peaked behaviors in the observation process.

The transition model at time  $t$  is defined as  $\mathbf{x}_t = \text{clip}(f_t(\mathbf{x}_{t-1}) + \varepsilon_t, 0, 1)$ ,  $\varepsilon_t \sim \mathcal{N}(0, \sigma^2 \mathbf{I})$ , where  $f_t(\cdot)$  is a scalar-valued function applied component-wise to each particle in  $\mathbf{x}_{t-1}$ , and  $\text{clip}(\cdot)$  limits each resulting element to the interval  $[0, 1]$ , ensuring consistency with the normalized domain of the performance index. The following forms were considered for  $f_t(x)$ , where  $x$  denotes a generic particle in the vector  $\mathbf{x}_{t-1}$ : sine-based,  $f_t(x) = 0.5(1 + \sin(x))$ ; linear decay,  $f_t(x) = 0.8x$ ; quadratic with sine,  $f_t(x) = 0.5(1 + \sin(x)) + 0.1x^2$ ; and uniform noise,  $x_t \sim \mathcal{U}(0, 1)$ , independently drawn.

### 4.3.5 Filter Performance Metrics

Additionally, to evaluate the performance of the filters, the following metrics are used: MAE (Mean Absolute Error) and  $R^2$  (coefficient of determination), as defined in Equations (4.13) and (4.14), respectively. In this context,  $\hat{y}_l$  and  $y_l$  denote, in that order, the predicted and observed values of the performance index at instance  $l$ , while  $\bar{y}$  represents the mean of the observed values. High-performance models are expected to exhibit low MAE values, indicating minimal prediction errors, and  $R^2$  values close to one, reflecting the high explanatory power of the model.

$$\text{MAE} = \frac{1}{n} \sum_{l=1}^n |\hat{y}_l - y_l| \quad (4.13)$$

$$R^2 = 1 - \frac{\sum_{l=1}^n (y_l - \hat{y}_l)^2}{\sum_{l=1}^n (y_l - \bar{y})^2} \quad (4.14)$$

The best hyperparameter configurations for each model are determined using a composite score, as defined in (4.15), which combines both prediction accuracy and explanatory power. Lower values of the composite score indicate better overall performance, as they reflect a combination of reduced prediction error (via MAE) and improved goodness of fit (via  $R^2$ ).

$$\text{Composite score} = \text{MAE} + (1 - R^2) \quad (4.15)$$

Each particle was initialized by sampling from a uniform prior distribution over the interval  $[0, 1]$ , which corresponds to the normalized domain of the performance index. The state transition model incorporated Gaussian noise added to each particle with the standard deviation  $\sigma$ . In Monte Carlo methods, the typical estimation error decreases on the order of  $\mathcal{O}(1/\sqrt{N})$  as the number of samples  $N$  increases [34, 35] yet with diminishing returns beyond a certain threshold. The set  $N \in \{400; 800; 1000; 1600; 4000; 10,000\}$  was selected to span a wide computational range that enables an evaluation of the error curve as a function of  $N$ , where precision gains stabilize, typically between approximately  $10^3$  and a few thousand particles [36]. It is also useful to observe convergence behavior and compare outcomes to a high asymptotic reference point,  $N = 10,000$ .

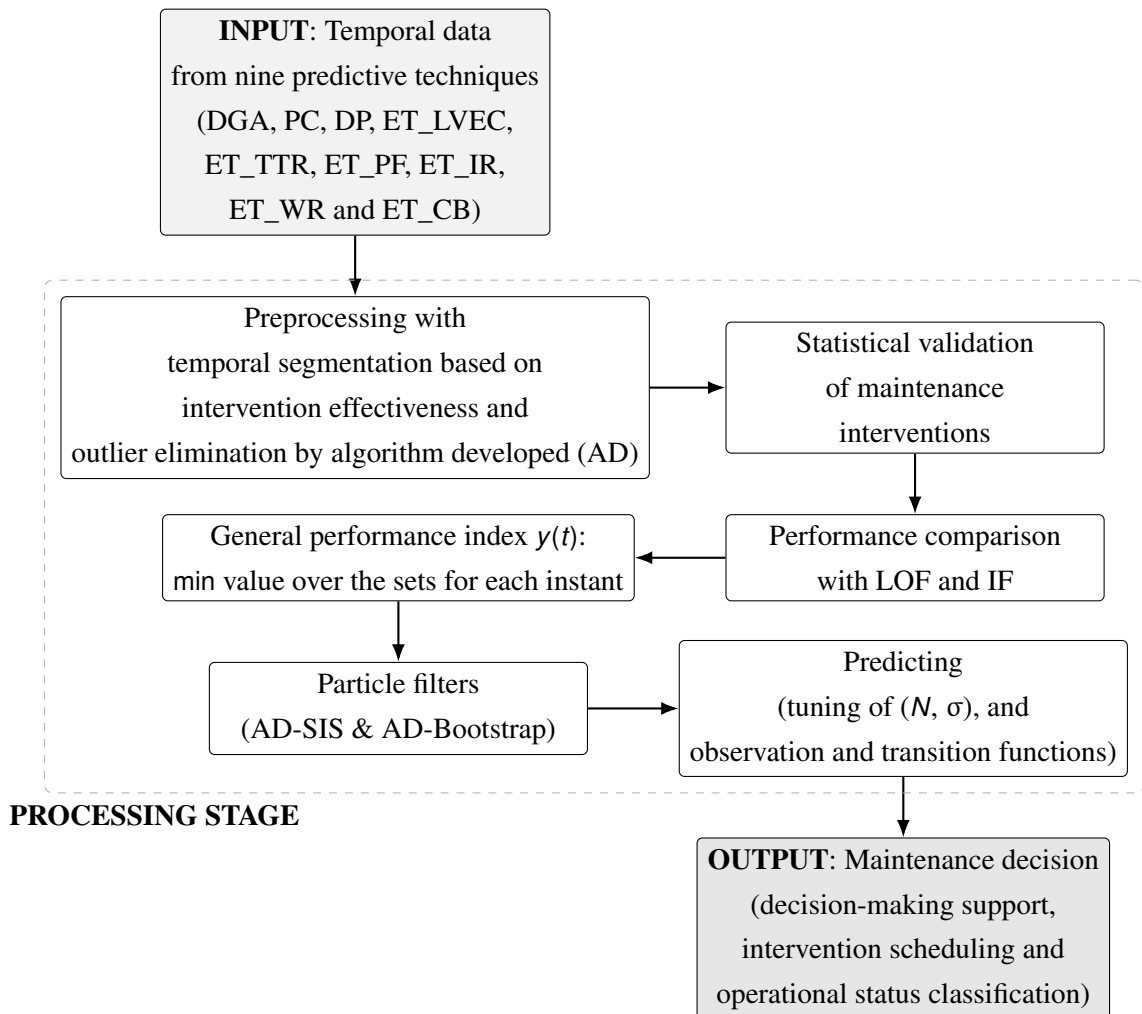
Adaptive resampling via the Bootstrap approach is triggered when the Effective Sample Size (ESS) falls below  $N/2$ . This is a well-established heuristic widely reported in the literature [37, 38], which helps prevent weight degeneracy while preserving particle diversity. For the process and observation noise, the levels were set to  $\sigma \in \{0.005, 0.01, 0.05, 1.5, 2.0\}$ , with all values defined over the normalized domain  $[0, 1]$ , as follows [39]:

- Low values of  $\sigma$  (0.005 to 0.01): represent near-deterministic dynamics where weight collapse is likely if the likelihood function is sharp.
- Intermediate value (around 0.05): corresponds to typical post-normalization variability, offering a balance between tracking flexibility and smoothing.
- High values (1.5 to 2.0): serve as stress tests (negative controls), inducing excess diffusion that challenges the filter's robustness under over-smoothed or poorly identifiable regimes.

### 4.3.6 Workflow of the Developed Method

For better visualization, the developed method is outlined in the flowchart of Figure 4.1. It depicts the main sequence of steps described in Section 4.3, which comprise the designed approach, from data input to output.

Figure 4.1: Workflow of the methodology developed in this study



Source: the authors (2025)

As illustrated, the workflow in Figure 4.1 presents the sequential logic of the method, from data preprocessing to decision-making support, and provides a basis for the reader to follow the subsequent results.

## 4.4 Results and Discussion

### 4.4.1 Operating Conditions, Weather Events and Maintenance Interventions

In this study, the simulated faults, defined according to the operating conditions of each unit, and their respective implications for the predictive techniques are presented in Table 4.2. To enhance comparability and emphasize the observed effects, five power transformers (TR1 to TR5) immersed in insulating mineral oil with broadly similar characteristics were selected.

Table 4.2: Power transformers: simulated operating conditions, weather events, maintenance interventions, and observed effects

Equipment	Operating Conditions, Weather Events and Maintenance Interventions	Observed Effects
TR1	Natural aging; no electrical overloads; no severe atmospheric events or adverse weather; no damaging systemic transients; no maintenance intervention.	Slight and general decay in performance indices across various techniques.
TR2	Natural aging; no electrical overloads; no severe atmospheric events or adverse weather; no damaging systemic transients; maintenance interventions performed.	Slight and general decay in performance indices across various techniques.
TR3	Electrical overloads present; no severe atmospheric events or bad weather; no damaging systemic transients; maintenance interventions performed.	Accelerated decay in DGA and DP; slightly lower decay in ET_IR, ET_PF, and PC.
TR4	Normal loading; severe atmospheric events; harsh weather with water ingress through active-part seals; systemic transients stressing insulation; maintenance interventions with bushing replacement.	Accelerated decay in PC, ET_IR, ET_PF, and ET_CB; slightly lower decay in DGA and DP.

Table 4.2 (continued): Power transformers: simulated operating conditions, weather events, maintenance interventions, and observed effects

<b>Equipment</b>	<b>Operating Conditions, Weather Events and Maintenance Interventions</b>	<b>Observed Effects</b>
TR5	Electrical overloads in some years (not all); no severe atmospheric events or bad weather; no stressful systemic transients; maintenance interventions performed.	Accelerated decay in DGA and DP; slightly faster decay in ET_IR and PC.

Source: the authors (2025)

Table 4.2 includes the adoption of a common set of predictive techniques and uniform data-sampling procedures, which collectively provide a standardized framework for performance assessment. While the equipment shares these structural and methodological attributes, it differs in specific operational aspects, such as the occurrence of electrical overloading, exposure to extreme weather events, and the execution of maintenance interventions. These controlled variations allow for a comparative analysis of how distinct fault scenarios influence the outcomes of the predictive techniques.

Although the operating conditions and fault scenarios presented in Table 4.2 are simulated, they were designed to reproduce patterns actually found in practice. Each case mirrors plausible degradation processes and intervention outcomes, showing how stress factors such as overloading, weather events, and maintenance actions interact with the deterioration of insulating materials and structural components. By integrating a broad range of predictive techniques, the dataset preserves completeness and represents consistent behaviors across different scenarios. Hence, this synthetic yet realistic construction ensures methodological control while still reflecting field-relevant dynamics, thus strengthening the connection between simulated analysis and operational evidence.

#### **4.4.2 Performance Comparison Between Artificial Intelligence Algorithms Tested and the One Developed**

Tables 4.3 and 4.4 present the comparison of the success rates of the outlier classification, based on the labeling provided by experts in power transformer maintenance, considering the three algorithms evaluated: the Local Outlier Factor (LOF), Isolation Forest (IF) and the algorithm designed (AD) in this work.

Table 4.3: Success rates of the applied tools for TR1 to TR3

Predictive Technique	TR1			TR2			TR3		
	LOF	IF	AD	LOF	IF	AD	LOF	IF	AD
DGA	100%	80.0%	100%	100%	80.0%	100%	100%	84.1%	100%
PC	100%	85.7%	100%	98.3%	82.0%	97.1%	98.3%	84.1%	100%
DP	100%	80.0%	100%	100%	80.0%	100%	100%	87.4%	100%
ET_LVEC	94.3%	91.4%	100%	94.3%	91.4%	100%	94.3%	91.4%	100%
ET_PF	100%	82.9%	97.1%	98.3%	85.3%	100%	98.3%	87.4%	91.4%
ET_TTR	97.1%	94.3%	94.3%	97.1%	94.3%	94.3%	97.1%	94.3%	94.3%
ET_IR	100%	85.7%	97.1%	98.3%	85.3%	91.4%	98.3%	87.4%	97.1%
ET_WR	94.3%	88.6%	91.4%	94.3%	88.6%	100%	94.3%	88.6%	91.4%
ET_CB	100%	82.9%	94.3%	100%	88.5%	100%	100%	88.5%	100%
Result	98.4%	85.7%	97.1%	97.8%	86.2%	98.1%	97.8%	88.1%	97.1%

Source: the authors (2025)

Table 4.4: Success rates of the applied tools for TR4 and TR5


Predictive Technique	TR4			TR5		
	LOF	IF	AD	LOF	IF	AD
DGA	94.3%	94.3%	97.1%	91.7%	81.7%	91.4%
PC	94.3%	94.3%	100%	93.8%	89.2%	91.4%
DP	97.1%	91.4%	97.1%	100%	91.4%	97.1%
ET_LVEC	94.3%	91.4%	91.4%	94.3%	91.4%	100%
ET_PF	88.6%	85.7%	100%	100%	84.5%	97.1%
ET_TTR	97.1%	94.3%	94.3%	97.1%	94.3%	94.3%
ET_IR	82.9%	85.7%	100%	100%	87.5%	82.9%
ET_WR	94.3%	88.6%	91.4%	94.3%	88.5%	97.1%
ET_CB	95.6%	83.1%	100%	100%	82.9%	100%
Result	93.2%	89.9%	96.8%	96.8%	87.9%	94.6%

Source: the authors (2025)

For the LOF, the main hyperparameter is the number of nearest neighbors  $k$ , which controls the local density estimation. To determine the optimal value of  $k$  for each temporal cluster in the LOF, the Silhouette score ( $S$ ) was employed, defined in (4.16) [22, 40, 41], where  $a_i$  denotes the mean intra-cluster distance,  $b_i$  represents the mean nearest-cluster distance, and  $n$  is the number of samples in the cluster, as illustrated in Figure 4.2.

$$S = \frac{1}{n} \sum_{i=1}^n \frac{b_i - a_i}{\max(a_i, b_i)} \quad (4.16)$$

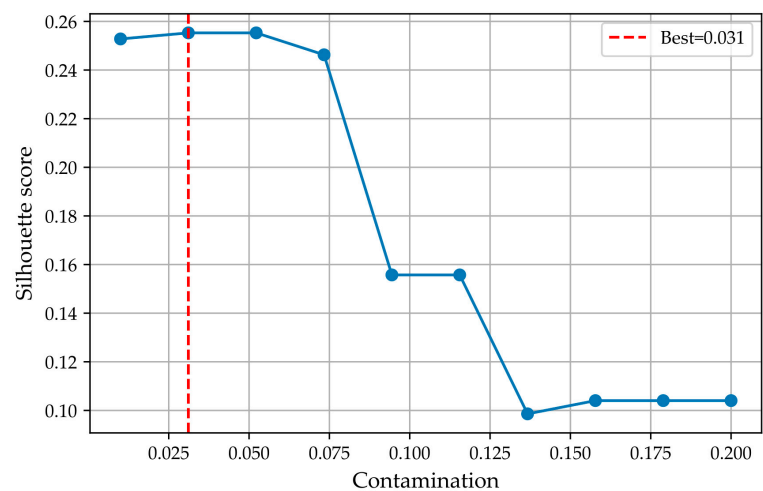
Figure 4.2: Example of Silhouette curve for a cluster of the predictive technique ET\_PF, which is used to determine the optimal  $k$  of the LOF for TR4



Source: the authors (2025)

Similarly, for the IF, the contamination parameter, which represents the expected proportion of outliers in Scikit-learn library [42–44], was optimized using a grid:  $\text{contamination} \in \{0.01, 0.03, 0.05, \dots, 0.20\}$ , because the lower bound reflects the realistic assumption that anomalies in equipment time series are rare, while the upper bound accounts for clusters with higher proportions of abnormal behavior due to concentrated interventions. Figure 4.3 exemplifies that optimization process.

Figure 4.3: Example of Silhouette curve for a cluster of the predictive technique ET\_TTR, which is used to determine the optimal contamination of the IF for TR4



Source: the authors (2025)

The results presented in Tables 4.3 and 4.4 highlight the high success rate of the

proposed algorithm (AD). For instance, in the DGA, PC, and DP techniques, AD achieved a success rate of 100% for TR1 and TR3, whereas the LOF and IF almost always exhibited lower performances. On average, considering the five evaluated transformers, AD reached a success rate of 96.7%, which is superior to IF (87.6%) and comparable to the LOF (96.8%). It is worth noting that IF consistently yielded lower accuracies among the tested methods, although still maintaining values above 80%. These findings demonstrate that the proposed strategy is consistent across different techniques and power transformers, confirming its robustness and broad applicability.

### 4.4.3 Hyperparameters of the Particle Filters

Tables 4.5 and 4.6 summarize the optimal hyperparameter configurations identified for each particle filter and power transformer based on training performance, corresponding to AD-SIS and AD-Bootstrap, respectively. A time-aware split was adopted, where the first 70% of the temporal data was allocated to the training set and the subsequent 30% to the testing set, in order to avoid data leakage and maintain the natural sequence of events.

Table 4.5: Best hyperparameter configuration based on training performance for each power transformer (AD-SIS)

Equipment	Transition	Observation	$N$	$\sigma$
TR1	Uniform	Exponential	1000	0.01
TR2	Uniform	Gaussian	800	0.01
TR3	Uniform	Exponential	4000	0.005
TR4	Uniform	Exponential	4000	0.005
TR5	Uniform	Exponential	400	0.005

Source: the authors (2025)

Table 4.6: Best hyperparameter configuration based on training performance for each power transformer (AD-Bootstrap)


Equipment	Transition	Observation	$N$	$\sigma$
TR1	Uniform	Exponential	10,000	0.005
TR2	Uniform	Exponential	10,000	0.01
TR3	Uniform	Exponential	10,000	0.005
TR4	Uniform	Exponential	10,000	0.005
TR5	Uniform	Exponential	10,000	0.005

Source: the authors (2025)

All reported results were obtained using the best-ranked combinations of transition and observation functions, as determined by the consolidated analysis. For the AD-Bootstrap filter, increasing the number of particles to  $N = 10,000$  consistently resulted in outstanding predictive performance. The test set  $R^2$  values approached unity, reaching 0.99998, 0.99988, 0.99999, 0.99998, and 0.99999 for TR1 through TR5, respectively. Furthermore, the training metrics exhibited extremely low error levels with MAE values ranging from 0.00033 to 0.00037. These findings demonstrate the model's strong ability to fit the training data while maintaining excellent generalization when a sufficiently high number of particles is used.

These results provide an intuitive understanding of how the number of particles ( $N$ ) and the noise level ( $\sigma$ ) jointly influence filter performance. For instance, for transformer TR1, the best configuration for the AD-Bootstrap filter was  $N = 10,000$  and  $\sigma = 0.005$ , using a uniform transition function and an exponential observation function. This same combination yielded the best result on the test set. In the case of the AD-SIS filter, the optimal configuration on both the training and test sets was  $N = 1000$  and  $\sigma = 0.01$ , under the same transition and observation functions as AD-Bootstrap. Figures 4.4 and 4.5 present the composite score heatmaps for the test set of TR1 under the evaluated configurations of AD-Bootstrap and AD-SIS filters with the best-performing combination of transition and observation functions.


Figure 4.4: Composite score heatmap for TR1 test set, AD-Bootstrap, uniform transition, and exponential observation



Source: the authors (2025)

Conversely, the Sequential Importance Sampling (AD-SIS) filter exhibited substantially lower predictive accuracy even when using its best configuration of transition and observation functions. The best  $R^2$  values on the test set were significantly lower,

Figure 4.5: Composite score heatmap for TR1 test set, AD-SIS, uniform transition, and exponential observation



Source: the authors (2025)


with some even negative (e.g., 0.4430 for TR1,  $-0.3060$  for TR2, and  $-1.6606$  for TR4), and only moderate or acceptable results for TR3 (0.5678) and TR5 (0.2601). Although a few configurations achieved decent training performance (with MAE ranging from 0.0618 to 0.0816), the large gap between training and testing metrics indicates overfitting and limited generalization capacity. These outcomes suggest that AD-SIS is more sensitive to noise and less robust than AD-Bootstrap, especially when using fewer particles or under conditions of higher model variance.

#### 4.4.4 Execution Time Analysis and Memory Usage

The computational time required by each configuration was evaluated as a function of the number of particles  $N$ . All simulations were executed on a laptop equipped with an Intel(R) Core(TM) i5-1035G1 CPU @ 1.0–1.2 GHz (8 logical cores) and 12 GB of RAM, running Windows 11 Home 64-bit. The implementation was developed in Python 3.12 using the Spyder IDE. Figures 4.6 and 4.7 illustrate, for TR1, the computational runtime (in seconds) of the particle filters as a function of the number of particles ( $N$ ) for different noise levels ( $\sigma$ ). Each curve represents the mean runtime across transition and observation models, including both training and test phases.


The runtime in Figures 4.6 and 4.7 increases approximately linearly with  $N$  for all levels of  $\sigma$ , reflecting the additional sampling and weight update operations required by particle filters. This analysis is essential to assess the practical feasibility of the proposed models, since although larger  $N$  values generally improve accuracy, as

Figure 4.6: Runtime as a function of the number of particles ( $N$ ) for different noise levels ( $\sigma$ ) in TR1, averaged across transition and observation models, including both training and test phases for the AD-Bootstrap filter



Source: the authors (2025)

Figure 4.7: Runtime as a function of the number of particles ( $N$ ) for different noise levels ( $\sigma$ ) in TR1, averaged across transition and observation models, including both training and test phases for the AD-SIS filter



Source: the authors (2025)

illustrated in Figures 4.4 and 4.5, the execution cost must remain acceptable for real-world applications. Moreover, it is necessary to seek a balance between computational cost and the improvement in the composite score given in (4.15), as beyond a certain point the accuracy gains become marginal relative to the additional runtime.

In addition, the computational assessment considered both runtime and memory usage, since these aspects are decisive for the feasibility of particle filter implementations. In that way, peak memory was measured with *tracemalloc* to capture Python-level allocations. Although native buffers (such as those handled by NumPy) may not be fully accounted for, the observed memory footprints remained well below the RAM capacity of a standard laptop. While the full set of results was obtained across all  $(N, \sigma)$  configurations, Table 4.7 highlights both the maximum and minimum runtime and memory usage observed per transformer and filter. This representation not only indicates the upper bound of execution time but also makes explicit the associated peak memory usage. It is interesting to note that since the series lengths across TR1 to TR5 are similar, the most critical runtime and memory usage values are essentially the same for all transformers, being driven primarily by the  $(N, \sigma)$  configuration rather than by equipment-specific characteristics.

Table 4.7: Runtime and peak memory from TR1 to TR5: AD-Bootstrap versus AD-SIS across  $N$  and  $\sigma$

Configuration	Average Runtime (s)	Peak Memory (MB)	Filter
$N = 400, \sigma = 0.005$	0.01	0.02	AD-Bootstrap
$N = 10,000, \sigma = 2.000$	0.04	0.51	AD-Bootstrap
$N = 400, \sigma = 0.005$	0.01	0.02	AD-SIS
$N = 400, \sigma = 0.005$	0.01	0.02	AD-SIS
$N = 10,000, \sigma = 2.000$	0.02	0.46	AD-SIS

Source: the authors (2025)

The results in Table 4.7 show that memory usage remained very modest across all settings, even for  $N = 10,000$  particles. Thus, runtime is the dominant limiting factor in practice, whereas memory requirements are not expected to restrict real-world applications on standard hardware. The relative difference between AD-Bootstrap and AD-SIS mainly reflects the resampling overhead of the former, confirming that the performance gain of AD-Bootstrap comes at the cost of longer execution times but without substantial memory impact.

#### 4.4.5 Future Behavior Simulation and Technical Assessment of Equipment Operational Patterns

To simulate the future behavior of the equipment performance index, a forecasting strategy based on the AD-Bootstrap particle filter was employed, using the best configuration identified during the training phase for each transformer. This configuration includes the best combination of transition and observation models, particle count  $N$ , and


noise level  $\sigma$ . In the absence of actual future observations, the forecast was conducted under a conservative hypothesis: no new maintenance actions are performed, and the system undergoes continuous natural degradation. This assumption reflects a worst-case scenario, which is relevant to planning and risk analysis in asset management.

At each forecasting step, the most recent estimated value is reused as a proxy observation to feed the filter, forming an autoregressive process. This iterative procedure allows the uncertainty to propagate throughout the horizon, generating a sequence of performance index estimates. To ensure that the resulting trajectory remains physically consistent, i.e., exhibits progressive degradation, a controlled correction mechanism is applied. The procedure includes the following:

1. Trend correction: At each step, the local trend is estimated by fitting a linear model to the last  $k$  predicted values. If the trend is positive (indicating improvement), it is replaced by a fixed negative slope to ensure a conservative decay pattern.
2. Noise injection: A small Gaussian perturbation is added at every iteration to simulate the intrinsic variability of equipment behavior, accounting for minor fluctuations that may arise even in the absence of external events.
3. Value clipping: All predicted values are constrained to the interval  $[0, 1]$  to maintain consistency with the normalized domain of the performance index.

This approach avoids unrealistic increases in the performance index when no maintenance is performed and results in a smooth downward curve that represents the system's natural aging. The forecasted values offer a practical basis for estimating degradation timelines and scheduling preventive interventions. Figure 4.8 illustrates the predicted decline in the performance index of transformer TR1 under ideal operating conditions with no electrical overloads, nor severe weather events, nor harmful transients, nor maintenance actions.

Figure 4.8: Predictive modeling of performance index dynamics for TR1 via AD-Bootstrap and AD-SIS filters




Source: the authors (2025)

According to the simulation, TR1 is expected to reach a performance index of 0.65 pu (Classification C—Marginal) in approximately 6,946 days (around 19 years), and 0.5 pu (Classification D—Poor) in around 9,864 days (around 27 years), which significantly increases the probability of failure. These results suggest that timely preventive maintenance could considerably extend the useful life of the equipment.

In the forecast for TR2, this observation is imposed, as depicted in Figure 4.9, which illustrates the natural degradation trajectory of the performance index  $y$  under favorable operating conditions with no electrical overloads, nor atmospheric discharges, nor severe weather events, nor damaging transients in the power system.

Figure 4.9: Predictive modeling of performance index dynamics for TR2 via AD-Bootstrap and AD-SIS filters



Source: the authors (2025)


Differently from TR1, however, TR2 underwent three maintenance interventions. The first was performed at 3,295 days of operation (approximately 9 years), but it proved ineffective, resulting in virtually no change in the performance index. The second intervention, conducted at 7,306 days (around 20 years), led to a more substantial improvement, increasing the index from 0.638 pu (Classification C—Marginal) to 0.796 pu (Classification B—Good). Finally, the third intervention, carried out at 11,326 days of operation (approximately 31 years), raised the performance index from 0.611 pu (Classification C—Marginal) to 0.676 pu (Classification B—Good). This contrast underscores the importance of technically sound maintenance actions in achieving measurable improvements in transformer performance.

Nevertheless, it is important to highlight that as a result of the three maintenance interventions, the forecasting framework developed in this study, when applied via the AD-Bootstrap particle filter, projects that the overall performance index for TR2 will remain above 0.6 pu (Classification C—Marginal) until approximately 16,000 days of

operation (around 44 years), which is the upper bound of the forecasting window. This projected trajectory reflects a considerably more favorable degradation profile when compared to TR1. Therefore, the findings strongly support the conclusion that timely and technically appropriate maintenance actions have a substantial positive impact on extending the service life of power transformers, as quantitatively captured by the developed methodology.

In that way, Figure 4.10 presents the degradation trajectory of the overall performance index for TR3 under adverse operating conditions. The equipment was subjected to electrical overloads, but neither atmospheric events nor severe weather nor harmful system transients occurred. Maintenance interventions were performed. The first intervention occurred at 3,295 days of operation (approximately 9 years), and the second occurred at 7,306 days (approximately 20 years), during which the overall index showed only a slight improvement from 0.629 pu (Classification C—Marginal) to 0.693 pu (Classification B—Good).

Figure 4.10: Predictive modeling of performance index dynamics for TR3 via AD-Bootstrap and AD-SIS filters




Source: the authors (2025)

This limited recovery is explained by the fact that although the oil treatment improved the performance indices of the Physicochemical Tests (PC), Insulation Resistance (ET\_IR), and Power Factor (ET\_PF), the Degree of Polymerization (DP) was significantly impacted by the electrical overloads. These overloads accelerated the degradation of the cellulose insulation in the windings, which was a component directly associated with DP measurements. When comparing Figure 4.10 (TR3) with Figure 4.9 (TR2), it becomes evident that TR3 undergoes faster degradation due to the effects of overload. Notably, the third intervention carried out on TR3 at 10,595 days (around 29 years) proved ineffective, as no significant improvement in the overall performance index was observed following

its execution. In such scenarios, the tool developed in this study proves valuable for predicting the equipment's degradation trend, enabling preventive maintenance actions or even its removal from operation at a more favorable time.

The evolution of the performance index  $y$  for TR4 reveals the impact of various stressors encountered throughout its operational life, as illustrated in Figure 4.11.

Figure 4.11: Predictive modeling of performance index dynamics for TR4 via AD-Bootstrap and AD-SIS filters



Source: the authors (2025)

Although the transformer operated under nominal loading conditions, it was exposed to a combination of external aggressions, including atmospheric discharges, severe weather events, water ingress through sealing points, and harmful transients in the electrical network. These adverse conditions triggered two maintenance interventions; the second involved the replacement of bushings.


The first intervention, performed at 5,116 days of operation (approximately 14 years), resulted in a notable performance improvement, increasing  $y$  from 0.67 pu (Classification B—Good) to 0.85 pu (Classification A—Excellent). The second occurred at 8,399 days (approximately 23 years), following an abrupt decline in the bushing performance index to 0.22 (Classification E—Very Poor), which was caused by damage attributed to systemic transients. In response, the bushings were replaced preventively prior to catastrophic failure, and additional preventive maintenance actions were carried out on the transformer. As a result, the global performance index recovered to 0.67 (Classification B—Good).

In light of these interventions, the forecasting tool developed in this study, using the AD-Bootstrap particle filter, estimates that the overall performance index will remain close to 0.6 pu (Classification C—Marginal) until approximately 16,000 days of operation (around 44 years), which is the upper limit of the forecasting window. This outcome

reinforces the model's ability to capture long-term trends and highlights the effectiveness of condition-based maintenance strategies in preserving asset performance and extending its operational lifespan.

A similar analysis applies to TR5, whose performance trajectory is depicted in Figure 4.12. Throughout its operational life, the transformer experienced alternating periods with and without electrical overloads but remained unaffected by atmospheric discharges, severe weather events, and systemic transients, which are factors that typically impose additional stress on insulation systems.

Figure 4.12: Predictive modeling of performance index dynamics for TR5 via AD-Bootstrap and AD-SIS filters



Source: the authors (2025)

Nonetheless, the persistent exposure to overload conditions led to a progressive decline in the overall performance index. In response, four maintenance interventions were executed at 2,922 days (approximately 8 years), 5,116 days (around 14 years), 8,768 days (around 24 years), and 10,961 days (around 30 years). Despite improvements in oil quality parameters following these interventions, their impact on the overall condition of the transformer was limited. The primary reason lies in the accelerated degradation of the cellulose insulation, which was particularly evidenced by the persistent deterioration in the Degree of Polymerization (DP) index. Given that such degradation is irreversible without complete factory-level reconditioning of the windings, the interventions failed to produce sustained improvements in the equipment's health.

This case underscores the value of the predictive framework developed in this study. By revealing consistent long-term downward trends in the general performance index, the tool enables the early identification of irreversible degradation processes and offers quantitative support for asset retirement decisions, thereby contributing to more reliable and cost-effective fleet management strategies.

#### 4.4.6 Statistical Validation of Maintenance Interventions

Table 4.8 presents the results of the statistical validation procedure of maintenance interventions for each equipment unit (from TR1 to TR5), considering a significance level of  $\alpha = 0.10$ . It details, step by step, each parameter employed, as well as the results of Student's  $t$ -test and the corresponding  $p$ -value. Based on the formulated hypothesis test, the applied maintenance intervention is classified as Effective or Not Statistically Effective (NSE).

The formulation shown in Table 4.8 formalizes the graphical interpretation of the intervention effectiveness analysis. Thus, what could previously only be visually inferred from the behavior of the performance index after the intervention is now supported by a parametric hypothesis test. Therefore, it was possible to demonstrate, in a mathematical and reproducible manner, whether the variation observed in the performance index after each intervention can be attributed to a real maintenance effect or merely to chance. It is important to highlight, in this sense, that the graphical interpretations are consistent with the statistical results obtained, reinforcing the validity and reliability of the proposed procedure.

Table 4.8: Results of one-sided predictive  $t$ -tests for maintenance interventions using  $\alpha = 0.1$

Equipment	$t_0$ (Days)	$y(t_0)$	$y_{pre}$	$y(t_0^+)$	$t$ -Student	$p$ -Value	Decision
TR1	—	—	—	—	—	—	No intervention
TR2	3,295	0.791	0.830	0.768	-4.391	0.929	NSE *
	7,306	0.775	0.638	0.766	29.444	0.011	Effective
	11,326	0.676	0.611	0.660	7.125	0.044	Effective
TR3	3,295	0.787	0.826	0.763	-4.250	0.926	NSE *
	7,306	0.672	0.629	0.655	4.059	0.077	Effective
	10,595	0.467	0.520	0.439	-4.786	0.934	NSE *
TR4	5,116	0.824	0.668	0.825	277.133	0.001	Effective
	8,399	0.663	0.222	0.627	23.066	0.014	Effective
	11,326	0.676	0.535	0.660	16.595	0.019	Effective
TR5	2,922	0.826	0.790	0.813	4.538	0.069	Effective
	5,116	0.723	0.690	0.717	10.000	0.032	Effective
	8,768	0.564	0.602	0.551	-6.846	0.954	NSE *
	10,961	0.446	0.400	0.435	7.364	0.043	Effective

Source: the authors (2025)

### 4.4.7 Time Series Cross-Validation with One-Step-Ahead Forecasting

The evaluation of the predictive performance of particle filters was conducted to avoid bias from a single train–test split. To this end, a nested temporal cross-validation procedure with one-step-ahead prediction was adopted. In the outer loop, each series was divided into  $k = 5$  progressive folds. Moreover, within each training segment, an inner loop ( $k = 3$  folds) was applied to select the best hyperparameter configuration (number of particles  $N$ , noise level  $\sigma$ , and transition and observation models). This design ensured that model selection was carried out solely on the training data, while the external test fold remained completely unseen until the final evaluation.

The metric used for hyperparameter selection is defined in (4.15), where lower values indicate a better trade-off between accuracy and explanatory power. Once the best configuration was identified in the inner loop, it was fixed and evaluated on the corresponding test fold. In addition to regression-based indicators, categorical performance was assessed by discretizing the performance index into classes A to E, according to Table 4.1. The following classification metrics were considered:

1. Strict accuracy ( $A_{cc}$ ), corresponding to exact matches between predicted and observed classes;
2. Accuracy  $\pm 1$  ( $A_{cc\pm 1}$ ), which allows deviations of at most one adjacent class.


Figure 4.13 summarizes the one-step-ahead nested CV results. Random seeds were deterministically varied across outer/inner folds and candidate configurations (offsets of a base seed) to reduce sensitivity to stochastic sampling and resampling.

The average performance of the AD-Bootstrap and AD-SIS filters, shown in Figure 4.13, considers all time series evaluated under the nested time-series cross-validation scheme. The AD-Bootstrap filter achieved globally superior results compared to AD-SIS with a strict accuracy of 85.33% and perfect accuracy  $\pm 1$  ( $A_{cc\pm 1} = 100\%$ ). This indicates that even when AD-Bootstrap misclassifies, it tends to remain within the neighborhood of the correct class.

In contrast, AD-SIS exhibited lower values across all metrics with strict accuracy of 79.67% and tolerant accuracy of 97.00%. These findings highlight the superior predictive performance of AD-Bootstrap over AD-SIS in one-step-ahead forecasting scenarios, although the latter still demonstrates reasonable generalization, making it a viable option in contexts where lower computational cost or model simplicity are decisive factors.

Overall, these results demonstrate that particle filters are effective in preserving the ordinal structure of transformer performance classes even under different operating conditions. In particular, the robustness of AD-Bootstrap makes it the most promising candidate for practical deployment.

Figure 4.13: Accuracy comparison between AD-Bootstrap and AD-SIS across power transformers



Source: the authors (2025)

#### 4.4.8 Comparison with State-of-the-Art Methods

To perform systematic and comprehensive diagnostics, AI has been employed in the interpretation of DGA. Applications of Multilayer Perceptron networks trained with Levenberg–Marquardt and adaptive backpropagation achieved accuracies above 96% for  $C_2H_2$  and 87% for  $H_2$ , significantly outperforming conventional IEEE/IEC methods (key gas and Rogers) [45]. There are also models of autoassociative neural networks combined with Mean Shift, enabling unsupervised diagnostics with accuracies close to 84% [46]. Other AI approaches combine artificial neural networks with rule-based logic, reaching more than 95% accuracy in critical faults [47]. Advances include Double-Stacked Autoencoders, which achieved 96.83% accuracy [48]. Also, a mathematical approach and Support Vector Machines (SVMs) were employed as decision-making methods in hybrid fault diagnosis systems. Tests conducted with 317 real fault datasets from power transformers demonstrated an accuracy of 95.58% for the mathematical approach and 96.23% for the SVM-based model [49]. These contributions highlight that modern AI techniques can outperform traditional diagnostic methods but still present high computational complexity and sensitivity to hyperparameters.

Regarding the aging of cellulosic insulation, AI-based approaches have been applied to diagnostics using the degree of polymerization (DP). For example, temporal networks are explored, where LSTM achieved 92.3% accuracy, outperforming convulo-

tional networks (89.6%) [50]. Despite promising results, these techniques require large volumes of labeled data and high computational costs. Physicochemical tests have also been interpreted with AI. Hybrid artificial neural networks have been applied, reaching a maximum accuracy of 89% in multiclass classification, although with low interpretability and dependence on input normalization [51]. However, these approaches still depend on limited datasets restricted to specific voltage classes.

Partial discharge (PD) detection by acoustic emission has also benefited from AI. Fourier and wavelet transforms integrated with classification models achieved up to 94% accuracy in controlled conditions [52]. Methods such as Cubic-Support Vector Machine and tree ensembles with bagging surpassed 98% accuracy [53]. Nevertheless, challenges remain, including class imbalance and dependency on the quality of acoustic signals. In addition, the recent production has explored the use of systems analysis and virtual modeling to support predictive maintenance in complex energy infrastructures [54].

In the specific problem addressed in this study (one-step-ahead forecasting of a continuous index mapped into ordinal classes A to E), the AD-Bootstrap filter achieved 85.33% strict accuracy and 100%  $\pm 1$ -class accuracy, while AD-SIS achieved 79.67% and 97.00%, respectively. Although this is not a direct comparison with other studies, given the differences in datasets, diagnostic and prognostic objectives, and performance metrics, the results obtained here indicate that AD-Bootstrap, in particular, is competitive with state-of-the-art AI algorithms and especially stable under the  $\pm 1$ -class metric (more appropriate for ordinal classifications).

Moreover, in this study, performance is evaluated with respect to the temporal forecasting of an ordinal index, unlike most approaches that focus on fault classification in static scenarios without incorporating the temporal dimension. Therefore, the developed methodology provides a balanced trade-off between accuracy, computational efficiency, and interpretability, directly addressing limitations reported in previous works, and making it suitable for practical deployment in utility maintenance planning.

#### 4.4.9 Limitations and Future Works

As a limitation of this study, it is noted that the transition and observation models employed represent abstractions of the real behavior of power transformers; however, this does not necessarily constitute a drawback, as it allowed for a more tractable analysis. In addition, the performance of particle filters is strongly influenced by the number of particles  $N$ , which creates a balance between accuracy and computational cost. Recursive forecasting, in turn, propagates uncertainties over time. From a computational perspective, runtime grows with  $N$ , which reinforces the need to reconcile accuracy with practicality.

As suggestions for future research, it is considered that integrating advanced

resampling schemes and adaptive noise strategies could further mitigate particle degeneration in particle filters while preserving computational efficiency.

## 4.5 Conclusions

This study presented a hybrid Artificial Intelligence (AI) model incorporating two novel Monte Carlo-based filtering frameworks: AD-Sequential Importance Sampling (AD-SIS) and AD-Bootstrap, which were both developed to enhance probabilistic forecasting and classification in power transformer monitoring systems. The methodology integrated an innovative outlier removal algorithm, based on neighborhood consistency and temporal clustering derived from intervention effectiveness, with probabilistic inference mechanisms tailored to handle noisy and incomplete time-series data.

The experimental results highlighted the superior performance of the AD Bootstrap filter, which achieved 85.45% accuracy across all simulated scenarios. Its effectiveness is attributed to the adaptive resampling mechanism, which mitigates particle degeneracy and enables dynamic response to abrupt changes in system behavior, such as maintenance interventions.

In contrast, the AD-SIS filter demonstrated reduced generalization capacity under conditions of high variability. This limitation is primarily due to its reliance on fixed importance sampling without resampling, which often results in particle impoverishment and a loss of diversity in the particle set over time. Furthermore, the outlier detection strategy developed in this work outperformed standard approaches such as the Local Outlier Factor (LOF) and Isolation Forest (IF), efficiently filtering inconsistent measurements while preserving critical behavioral patterns and rare anomalies essential for assertive decision making.

The main contributions of this research include the consolidation of heterogeneous diagnostic techniques into a unified and interpretable decision-support framework; the robust identification and treatment of inconsistencies in operational time-series data from the performance index; and the capability to simulate realistic degradation trajectories for preventive maintenance. The developed strategy strengthens both the interpretability and reliability of performance index monitoring, supporting more assertive and individualized maintenance decisions. As a result, the approach offers valuable support to utility companies by enhancing asset management and facilitating intelligent, data-driven decision making with the explicit objective of reducing failure rates and ensuring the continuity of energy supply.

## Referências

- [1] MENDANHA, Vinícius Faria Costa; MARQUES, André Pereira; AGUIAR, Lucas Santos de; SANTOS, Juliermy Junio Pacheco dos; CARDOSO, Álisson Assis; RIBEIRO, Cacilda de Jesus. Hybrid Artificial Intelligence Model for Reliable Decision Making in Power Transformer Maintenance Through Performance Index. **Energies**, MDPI AG, v. 18, n. 18, p. 4924, set. 2025. ISSN 1996-1073. DOI: 10.3390/en18184924.
- [2] MARQUES, André Pereira. **Optimized diagnosis of power transformers through the integration of predictive techniques**. 2018. PhD Thesis – Federal University of Goiás.
- [3] DUTTA, Saurabh; DEY, Jagriti; MISHRA, Deepak; BARAL, Arijit; CHAKRAVORTI, Sivaji. Prediction of Insulation Sensitive Parameters of Power Transformer Using Detrended Fluctuation Analysis Based Method. **IEEE Transactions on Power Delivery**, v. 37, n. 3, p. 1963–1973, 2022. DOI: 10.1109/TPWRD.2021.3102075.
- [4] NANFAK, Arnaud; EKE, Samuel; MEGHNEFI, Fethi; FOFANA, Issouf; NGALEU, Gildas Martial; KOM, Charles Hubert. Hybrid DGA Method for Power Transformer Faults Diagnosis Based on Evolutionary k-Means Clustering and Dissolved Gas Subsets Analysis. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 30, n. 5, p. 2421–2428, 2023. DOI: 10.1109/TDEI.2023.3275119.
- [5] LIU, Hang; WANG, Youyuan; CHEN, Weigen. Anomaly detection for condition monitoring data using auxiliary feature vector and density-based clustering. en. **IET Gener. Transm. Distrib.**, Institution of Engineering e Technology (IET), v. 14, n. 1, p. 108–118, jan. 2020.
- [6] SHEN, Li; DU, Hongjun; LIU, Shuji; CHEN, Shuo; QIAO, Lin; LIU, Sai; LIU, Jiahua; LI, Kexin; LI, Jing. Real time outlier monitoring for power transformer fault diagnosis based on isolated forest. **IOP Conf. Ser. Mater. Sci. Eng.**, IOP Publishing, v. 715, n. 1, p. 12–33, jan. 2020.
- [7] ZOU, Dexu; XIANG, Yongjian; ZHOU, Tao; PENG, Qingjun; DAI, Weiju; HONG, Zhihu; SHI, Yong; WANG, Shan; YIN, Jianhua; QUAN, Hao. Outlier detection and data filling based on KNN and LOF for power transformer operation data classification. en. **Energy Rep.**, Elsevier BV, v. 9, p. 698–711, set. 2023.
- [8] FEIL, Dion Lenon Prediger. **Replacement of power transformers in power substations: A global strategy**. 2019. PhD Thesis – Federal University of Santa Maria.
- [9] SILVA, Daniella Gonzalez Tinois da. **Enhanced health index for power transformer diagnosis**. 2020. PhD Thesis – São Paulo State University.

- [10] JUNIOR, Aarão Pedro Pires de Medeiros. **Prediction of power transformer failures in substations using finite-state machines**. 2011. Master's Thesis – Federal University of Mato Grosso do Sul, Campo Grande, MS, Brazil.
- [11] FEHLBERG, Rafael; CARRIJO, Daniel; GOMES, Gabriel; LOPES, Sofia; FLAUZINO, Rogério; SANTA ROSA, Renan; PATRIOTA, Iony. Prediction of the Degree of Polymerization Using Machine Learning: A New Methodology for Assessing the Lifespan of Power Transformers. *In: PROCEEDINGS OF THE XVI BRAZILIAN SYMPOSIUM ON INTELLIGENT AUTOMATION AND X BRAZILIAN SYMPOSIUM ON ELECTRICAL SYSTEMS, 2023. Anais [...]*.
- [12] ZHANG, Wei; YANG, Xiaohui; DENG, Yeheng; LI, Anyi. An inspired machine-learning algorithm with a hybrid whale optimization for power transformer PHM. *en. Energies*, MDPI AG, v. 13, n. 12, p. 31–43, jun. 2020.
- [13] KARI, Tusongjiang; GAO, Wensheng; TULUHONG, Ayiguzhali; YAERMAI-MAITI, Yilihamu; ZHANG, Ziwei. Mixed kernel function support vector regression with genetic algorithm for forecasting dissolved gas content in power transformers. *en. Energies*, MDPI AG, v. 11, n. 9, p. 24–37, set. 2018.
- [14] WU, Qunli; ZHANG, Hongjie. A novel expertise-guided machine learning model for internal fault state diagnosis of power transformers. *en. Sustainability*, MDPI AG, v. 11, n. 6, p. 15–62, mar. 2019.
- [15] FREEMAN, Cynthia; MERRIMAN, Jonathan; BEAVER, Ian; MUEEN, Abdullah. Experimental comparison and survey of twelve time series anomaly detection algorithms. *J. Artif. Intell. Res.*, AI Access Foundation, v. 72, p. 849–899, nov. 2021.
- [16] ASSAAD, Charles K; DEVIJVER, Emilie; GAUSSIÉ, Eric. Survey and evaluation of causal discovery methods for time series. *J. Artif. Intell. Res.*, AI Access Foundation, v. 73, p. 767–819, fev. 2022.
- [17] ZAREZADEH, Somayeh; ASADI, Majid. Network Reliability Modeling Under Stochastic Process of Component Failures. *IEEE Transactions on Reliability*, v. 62, n. 4, p. 917–929, 2013. DOI: 10.1109/TR.2013.2285054.
- [18] CAI, Zhuoran; MA, Wenxuan; WANG, Xinrui; WANG, Hanhong; FENG, Zhongming. The Performance Analysis of Time Series Data Augmentation Technology for Small Sample Communication Device Recognition. *IEEE Transactions on Reliability*, v. 72, n. 2, p. 574–585, 2023. DOI: 10.1109/TR.2022.3178707.
- [19] ABDU, Ahmed; ZHAI, Zhengjun; ABDO, Hakim A.; ALGABRI, Redhwan. Software Defect Prediction Based on Deep Representation Learning of Source Code From Contextual Syntax and Semantic Graph. *IEEE Transactions on Reliability*, v. 73, n. 2, p. 820–833, 2024. DOI: 10.1109/TR.2024.3354965.

- [20] DIAS, Yuri Andrade. **Method for Predicting the Performance Indices of Power Transformers Immersed in Mineral Insulating Oil and Medium and High-Voltage Circuit Breakers**. 2023. PhD Thesis – Federal University of Goiás.
- [21] CUNHA BRITO, Leonardo da; MARQUES, André Pereira; JESUS RIBEIRO, Cacilda de; MOURA, Nicolas Kemerich de; DIAS, Yuri Andrade; AZEVEDO, Cláudio Henrique Bezerra; SANTOS, José Augusto Lopes dos; SILVA PALHARES, Pedro Henrique da. A general methodology for evaluation and classification of oil-immersed power transformers: Application to electrical and physicochemical parameters. en. **J. Control Autom. Electr. Syst.**, Springer Science e Business Media LLC, v. 30, n. 5, p. 832–839, out. 2019.
- [22] ALPAYDIN, Ethem. **Introduction to Machine Learning**. 3rd. Cambridge, MA, USA: MIT Press, 2014.
- [23] ALGHUSHAIRY, Omar; ALSINI, Raed; SOULE, Terence; MA, Xiaogang. A Review of Local Outlier Factor Algorithms for Outlier Detection in Big Data Streams. **Big Data and Cognitive Computing**, MDPI AG, v. 5, n. 1, p. 1–24, dez. 2020. ISSN 2504-2289. DOI: 10.3390/bdcc5010001.
- [24] LESOUPLE, Julien; BAUDOIN, Cédric; SPIGAI, Marc; TOURNERET, Jean-Yves. Generalized isolation forest for anomaly detection. en. **Pattern Recognit. Lett.**, Elsevier BV, v. 149, p. 109–119, set. 2021.
- [25] ADEKUNLE, Andrew Adewunmi; OPARANTI, Samson Okikiola; FOFANA, Issouf; PICHER, Patrick; RODRIGUEZ-CELIS, Esperanza Mariela; ARROYO-FERNANDEZ, Oscar Henry; MEGHNEFI, Fethi. Degradation Mechanisms of Cellulose-Based Transformer Insulation: The Role of Dissolved Gases and Macromolecular Characterisation. **Macromol**, MDPI AG, v. 5, n. 2, p. 20, 2025. ISSN 2673-6209. DOI: 10.3390/macromol5020020.
- [26] LUNDGAARD, L.E.; HANSEN, W.; LINHJELL, D.; PAINTER, T.J. Aging of oil-impregnated paper in power transformers. **IEEE Transactions on Power Delivery**, v. 19, n. 1, p. 230–239, 2004. DOI: 10.1109/TPWRD.2003.820175.
- [27] ZHANG, Enze; LIU, Jiang; ZHANG, Chaohai; ZHENG, Peijun; NAKANISHI, Yosuke; WU, Thomas. State-of-Art Review on Chemical Indicators for Monitoring the Aging Status of Oil-Immersed Transformer Paper Insulation. **Energies**, MDPI AG, v. 16, n. 3, p. 1396, 2023. ISSN 1996-1073. DOI: 10.3390/en16031396.
- [28] MONTERO, Andrés; GARCÍA, Belén; LÓPEZ, Carlos. Life Expectancy of Transformer Paper Insulation Retrofilled with Natural Ester in the Laboratory. **Polymers**, MDPI AG, v. 15, n. 22, p. 4345, 2023. ISSN 2073-4360. DOI: 10.3390/polym15224345.

- [29] FENG, D.Y.; WANG, Z.D.; JARMAN, P. Modeling thermal life expectancy of the UK transmission power transformers. *In: 2012 INTERNATIONAL CONFERENCE ON HIGH VOLTAGE ENGINEERING AND APPLICATION, 2012. Anais [...]*.
- [30] FENG, Dawei; HAO, Jian; LIAO, Ruijin; CHEN, Xin; CHENG, Lin; LIU, Mengna. Comparative Study on the Thermal-Aging Characteristics of Cellulose Insulation Polymer Immersed in New Three-Element Mixed Oil and Mineral Oil. **Polymers**, MDPI AG, v. 11, n. 8, p. 1292, 2019. ISSN 2073-4360. DOI: 10.3390/polym11081292.
- [31] SEIFADDINI, Najmeh; FOFANA, Issouf; RAJESH KANDALA, N.V.P.S.; LIM, Kok-Sing; OOI, Cheong-Weng; UDOS, Waldo; SEKONGO, Bekibenan; CHEHRI, Abdellah; OUHROUCHE, Mohand; LEENA, Gautam. Aging characterization of thermally aged transformer paper based on its reflectance. **Results in Optics**, Elsevier BV, v. 16, p. 100716, 2024. ISSN 2666-9501. DOI: 10.1016/j.rio.2024.100716.
- [32] SILVA, Felipe Carvalho Álvares da. **Bayesian Sequential Monte Carlo Methods: Computational, Inferential, and Applied Aspects**. 2016. PhD Thesis – Federal University of Minas Gerais, Belo Horizonte, MG, Brazil.
- [33] DOUCET, Arnaud; FREITAS, Nando de; GORDON, Neil (ed.). **Sequential Monte Carlo Methods in Practice**. New York, USA: Springer, 2001.
- [34] ELVIRA, Víctor; MIGUEZ, Joaquín; DJURIĆ, Petar M. On the performance of particle filters with adaptive number of particles. *en. Stat. Comput.*, Springer Science e Business Media LLC, v. 31, n. 6, 2021. DOI: 10.1007/s11222-021-10056-0.
- [35] AKYILDIZ, Ömer Deniz; MÍGUEZ, Joaquín. Nudging the particle filter. *en. Stat. Comput.*, Springer Science e Business Media LLC, v. 30, n. 2, p. 305–330, 2020. DOI: 10.1007/s11222-019-09884-y.
- [36] CHEN, Xiongjie; LI, Yunpeng. An overview of differentiable particle filters for data-adaptive sequential Bayesian inference. **Foundations of Data Science**, American Institute of Mathematical Sciences (AIMS), v. 0, n. 0, p. 1–29, 2023. ISSN 2639-8001. DOI: 10.3934/fods.2023014.
- [37] ZHAO, Fangfang; CAI, Ruijie. Adaptive particle filter for state estimation with application to non-linear system. **IET Signal Processing**, Institution of Engineering e Technology (IET), v. 16, n. 9, p. 1023–1033, 2022. ISSN 1751-9683. DOI: 10.1049/sil2.12147.
- [38] ASPEEL, Antoine; GOUVERNEUR, Amaury; JUNGERS, Raphael M.; MACQ, Benoit. Optimal Intermittent Particle Filter. **IEEE Transactions on Signal Processing**, Institute of Electrical e Electronics Engineers (IEEE), v. 70, p. 2814–2825, 2022. ISSN 1941-0476. DOI: 10.1109/TSP.2022.3179877.

- [39] ELFRING, Jos; TORTA, Elena; MOLENGRAFT, René van de. Particle Filters: A Hands-On Tutorial. **Sensors**, MDPI AG, v. 21, n. 2, p. 438, 2021. ISSN 1424-8220. DOI: 10.3390/s21020438.
- [40] SHAHAPURE, Ketan Rajshekhar; NICHOLAS, Charles. Cluster Quality Analysis Using Silhouette Score. *In: 2020 IEEE 7TH INTERNATIONAL CONFERENCE ON DATA SCIENCE AND ADVANCED ANALYTICS (DSAA), 2020. Anais [...]*.
- [41] MULYANI, Heti; SETIAWAN, Ricak Agus; FATHI, Halimil. Optimization of K Value in Clustering Using Silhouette Score (Case Study: Mall Customers Data). **Journal of Information Technology and Its Utilization**, Sekolah Tinggi Multi Media Yogyakarta, v. 6, n. 2, p. 45–50, dez. 2023. ISSN 2654-802X. DOI: 10.56873/jitu.6.2.5243.
- [42] PEDREGOSA, Fabian; VAROQUAUX, Gaël; GRAMFORT, Alexandre; MICHEL, Vincent; THIRION, Bertrand; GRISEL, Olivier; BLONDEL, Mathieu; PRETTENHOFER, Peter; WEISS, Ron; DUBOURG, Vincent; VANDERPLAS, Jake; PASSOS, Alexandre; COURNAPEAU, David; BRUCHER, Matthieu; PERROT, Matthieu; DUCHESNAY, Édouard. Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, v. 12, n. 85, p. 2825–2830, 2011.
- [43] BUITINCK, Lars; LOUPPE, Gilles; BLONDEL, Mathieu; PEDREGOSA, Fabian; MUELLER, Andreas C.; GRISEL, Olivier; NICULAE, Vlad; PRETTENHOFER, Peter; GRAMFORT, Alexandre; GROBLER, Jaques; LAYTON, Robert; VANDERPLAS, Jake; JOLY, Arnaud; HOLT, Brian; VAROQUAUX, Gael. API design for machine learning software: experiences from the scikit-learn project. *In: ECML PKDD WORKSHOP: LANGUAGES FOR DATA MINING AND MACHINE LEARNING, 2013. Anais [...]*.
- [44] VAROQUAUX, Gaël; BUITINCK, Lars; LOUPPE, Gilles; GRISEL, Olivier; PEDREGOSA, Fabian; MUELLER, Andreas. Scikit-learn. **GetMobile: Mobile Computing and Communications**, ACM, v. 19, n. 1, p. 29–33, 2015.
- [45] BARBOSA, F. R.; ALMEIDA, O. M.; BRAGA, A. P. S.; AMORA, M. A. B.; CARTAXO, S. J. M. Application of an artificial neural network in the use of physicochemical properties as a low cost proxy of power transformers DGA data. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 19, n. 1, p. 239–246, fev. 2012.
- [46] MIRANDA, V.; CASTRO, A. R. G.; LIMA, S. Diagnosing faults in power transformers with autoassociative neural networks and mean shift. **IEEE Transactions on Power Delivery**, v. 27, n. 3, p. 1350–1357, jul. 2012.
- [47] GHONEIM, S. S. M.; TAHA, I. B. M.; ELKALASHY, N. I. Integrated ANN-based proactive fault diagnostic scheme for power transformers using dissolved gas analysis.

- IEEE Transactions on Dielectrics and Electrical Insulation**, v. 23, n. 3, p. 1838–1845, jun. 2016.
- [48] YANG, Dongsheng; QIN, Jia; PANG, Yongheng; HUANG, Tingwen. A Novel Double-Stacked Autoencoder for Power Transformers DGA Signals With an Imbalanced Data Structure. **IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS**, v. 69, n. 2, p. 1977–1987, fev. 2022.
- [49] BAKER, Engin; NESE, Secil Varbak; DURSUN, Erkan. Hybrid Condition Monitoring System for Power Transformer Fault Diagnosis. **Energies**, MDPI AG, v. 16, n. 3, p. 1151, 2023. ISSN 1996-1073. DOI: 10.3390/en16031151.
- [50] GORGINPOUR, Hamed; GHIMATGAR, Hojat; TOULABI, Mohammad Sedigh. Lifetime Estimation and Optimal Maintenance Scheduling of Urban Oil-Immersed Distribution-Transformers Considering Weather-Dependent Intelligent Load Model and Unbalanced Loading. **IEEE Transactions on Power Delivery**, v. 37, n. 5, p. 4154–4165, 2022. DOI: 10.1109/TPWRD.2022.3146154.
- [51] SENOUSSAOUI, Mohammed El Amine; BRAHAMI, Mostefa; FOFANA, Issouf. Transformer Oil Quality Assessment Using Random Forest with Feature Engineering. **Energies**, MDPI AG, v. 14, n. 7, p. 1809, mar. 2021. ISSN 1996-1073. DOI: 10.3390/en14071809.
- [52] HARBAJI, Mustafa; SHABAN, Khaled; EL-HAG, Ayman. Classification of common partial discharge types in oil-paper insulation system using acoustic signals. **IEEE Transactions on Dielectrics and Electrical Insulation**, Institute of Electrical and Electronics Engineers (IEEE), v. 22, n. 3, p. 1674–1683, jun. 2015. ISSN 1070-9878. DOI: 10.1109/tdei.2015.7116364.
- [53] KUNICKI, Michał; WOTZKA, Daria. A Classification Method for Select Defects in Power Transformers Based on the Acoustic Signals. **Sensors**, MDPI AG, v. 19, n. 23, p. 5212, nov. 2019. ISSN 1424-8220. DOI: 10.3390/s19235212.
- [54] ILYUSHIN, Yury; NOSOVA, Victoria; KRAUZE, Andrei. Application of Systems Analysis Methods to Construct a Virtual Model of the Field. **Energies**, MDPI AG, v. 18, n. 4, p. 1–34, 2025. ISSN 1996-1073. DOI: 10.3390/en18041012.

# **Classificação Binária do Estado Operacional de Transformadores de Potência Imersos em Óleo Mineral Isolante Utilizando Índice de Desempenho e Modelos de Aprendizado de Máquina**

---

## **5.1 Resumo**

Transformadores de potência são ativos valiosos e estratégicos em sistemas elétricos, uma vez que falhas inesperadas deles podem resultar em prejuízos operacionais e financeiros expressivos às empresas do setor elétrico e aos consumidores. Embora haja avanços no monitoramento de suas condições operativas, algumas metodologias ainda requerem interpretação especializada, além de serem pouco padronizadas ou adotarem modelos cuja complexidade pode dificultar a integração com práticas operacionais usuais dos profissionais de manutenção. Nesse sentido, o objetivo deste trabalho é desenvolver classificadores binários relacionados a algoritmos de aprendizado de máquina para predição rápida e eficiente do estado operacional de transformadores de potência, rotuladas como Satisfatório ou Insatisfatório, com base em dados oriundos de ensaios físico-químicos, análise de gases dissolvidos (AGD), e índices de desempenho, a partir de exemplos reais de equipamentos. Na metodologia, desenvolvem-se modelos supervisionados de aprendizado de máquinas, como *Random Forest*, *HistGradientBoosting*, Regressão Logística Balanceada e *XGBoost*, implementados com validação cruzada estratificada. Os resultados indicam que os classificadores são capazes de identificar satisfatoriamente os transformadores em condição crítica, mesmo em um cenário com relevante dispersão nos dados. Portanto, a abordagem desenvolvida representa uma ferramenta promissora à decisão téc-

nica em estratégias de manutenção preventiva, aliando confiabilidade, escalabilidade e facilidade de aplicação em ambientes de campo.

**Palavras-chave:** aprendizado de máquinas, classificador, índice de desempenho, técnicas preditivas, transformador de potência.

## 5.2 Introdução

Os ensaios físico-químico e a análise de gases dissolvidos (AGD) são técnicas preditivas utilizadas em transformadores de potência para auxiliar na determinação do índice de desempenho deles [1–5]. Embora algumas metodologias tradicionais desenvolvam expressões analíticas e ponderadas para relacionar os parâmetros que compõem cada uma dessas técnicas [1–5], a diversidade de variáveis envolvidas e a necessidade de etapas adicionais para a verificação de discrepâncias nos valores amostrados podem tornar oneroso o processo de classificação da condição operativa dos equipamentos. Além disso, por consequência de uma insatisfatória etapa anterior, a indicação das ações corretivas a serem tomadas podem ser prejudicadas, levando o equipamento a, em casos extremos, falhas catastróficas, com danos direto ao patrimônio das empresas do setor elétrico e aos consumidores de energia elétrica.

Primeiramente, quando se analisa o óleo mineral isolante de transformadores de potência, são determinadas suas propriedades físico-químicas com o intuito de verificar se ainda preservam as características necessárias à função primordial de isolamento. Entre os principais parâmetros avaliados, destacam-se: fator de potência, tensão interfacial, teor de água, rigidez dielétrica, índice de neutralização e índice de cor [1–4]. A deterioração progressiva desses parâmetros indica processos de envelhecimento do óleo, contaminação por agentes externos ou degradação térmica, sendo, portanto, fundamentais para a tomada de decisões relativas à manutenção corretiva, preventiva, envolvendo a filtragem, a substituição do fluido isolante e/ou do papel celulósico (em última instância).

Outrossim, em decorrência de fenômenos elétricos e térmicos, por exemplo, o óleo mineral isolante produz quantidades de gases [3, 6, 7]. Assim, uma das formas de diagnosticar anormalidade na operação dos transformadores de potência, de forma não intrusiva e sem desligamentos, é por meio da técnica preditiva de análises de gases dissolvidos (AGD), cujo diagnóstico por ser feito, dentre outros, pelo método de gás chave [8–10], além da interpretação da correlação entre gases e sua evolução na série histórica (relação temporal). A análise de gases dissolvidos (AGD) contempla os seguintes compostos: hidrogênio ( $H_2$ ), metano ( $CH_4$ ), etano ( $C_2H_6$ ), etileno ( $C_2H_4$ ), monóxido de carbono (CO) e dióxido de carbono ( $CO_2$ ), além do nitrogênio ( $N_2$ ) e oxigênio ( $O_2$ ). A partir deles, é possível identificar eventos distintos em transformadores [6, 11], como: maus contatos, superaquecimento do óleo, superaquecimento do papel isolante, descargas

parciais e arco elétrico. Todavia, não deve ser feita análise de AGD de maneira isolada [6] mas sim correlacionando os resultados desta com outros ensaios, inclusive os elétricos, de forma a ser obter uma visão integrativa do que ocorre.

Embora os métodos tradicionais utilizados em AGD, como o de gás chave e o de Rogers, dentre outros, desempenhem papel fundamental na interpretação diagnóstica e possuam boa aceitação na prática técnica, os avanços proporcionados por técnicas de Inteligência Artificial (IA), como as redes neurais, têm se mostrado promissores no aprimoramento da acurácia e na melhoria do processo decisório. Por exemplo, foram obtidos resultados mais acurados na classificação de equipamentos em relação à aplicação da metodologia de gás chave e Rogers, respectivamente, com acurácias de 45,19% e 40,00%, em relação à 72,24% obtidos de uma rede Multilayer Perceptron (MLP) [12]. Assim, a aplicação de Inteligência Artificial (IA) pode funcionar como ferramenta complementar ao suporte decisório em práticas de manutenção preventiva de transformadores.

Nesse sentido, o objetivo deste capítulo é desenvolver classificadores binários relacionados a algoritmos de aprendizado de máquina para predição rápida e eficiente do estado operacional de transformadores de potência, rotuladas como Satisfatório ou Insatisfatório, com base em dados, oriundos de ensaios físico-químicos e AGD, e índices de desempenho, a partir de exemplares reais de equipamentos de vários países e em condições operacionais diversas. Embora nenhuma técnica preditiva deva ser utilizada isoladamente para o diagnóstico do equipamento, pretende-se estudar se a quantidade de parâmetros usada descreve, com satisfatória abrangência, o desempenho geral do transformador de potência.

Para tanto, são desenvolvidas estratégias específicas para lidar com o desbalançamento de dados entre classificações e para validar, de maneira rigorosa, o desempenho dos modelos por meio de técnicas de validação cruzada. Como principal contribuição, este estudo resulta no desenvolvimento de uma ferramenta inédita, capaz de auxiliar profissionais de engenharia de manutenção à tomada de decisão quanto ao estado operacional de transformadores de potência, promovendo agilidade e confiabilidade no diagnóstico com base em dados acessíveis de rotina.

## 5.3 Metodologia

Os dados dos parâmetros preditivos do óleo mineral isolante utilizados neste trabalho, formados por resultados das técnicas preditivas de ensaios físico-químico (FQ) e análise de gases dissolvidos (AGD), estão disponíveis em [13]. Eles foram, originalmente, publicados e complementados por amostras de óleo coletadas de transformadores de potência, totalizando 470 registros [14, 15]. Especificamente, foram extraídos pontos de [8, 14–20]. Ao todo, 360 amostras de óleo foram obtidas a partir de transformadores

localizados em diferentes regiões do Peru, Colômbia e Chile, abrangendo equipamentos com distintas idades, especificações técnicas e condições operacionais [14].

Inicialmente, o arquivo de entrada é carregado e a variável-alvo *Health index* ( $HI$ ) é lida. Cada exemplo é classificado em A (Excelente), B (Bom), C (Marginal), D (Ruim) ou E (Muito Ruim), conforme (5.1), com base no valor calculado do  $HI$  [2, 3, 21–24]. Para cada classificação, há ações recomendadas correspondentes, sendo [2, 4]: A (continuar a operar o equipamento normalmente), B (continuar a operar o equipamento atento à evolução dos resultados nos próximos registros), C (investigar e realizar outros testes a curto prazo para confirmar resultados e tendências), D (planejar a retirada de operação do equipamento para inspeção interna, localização e correção de defeitos) e E (remover o equipamento de operação imediatamente para inspeção interna, localização e correção de defeitos).

$$\text{Classificação} = \begin{cases} A & \text{se } HI \geq 80 \\ B & \text{se } 65 \leq HI < 80 \\ C & \text{se } 50 \leq HI < 65 \\ D & \text{se } 35 \leq HI < 50 \\ E & \text{se } HI < 35 \end{cases} \quad (5.1)$$

Após esta etapa, cada atributo  $x$  passa por um processo de normalização *z-score*, conforme (5.2) [25, 26], em que  $x'_i$  é o valor normalizado, e  $\bar{x}$  e  $\sigma_x$  são, nessa ordem, a média e o desvio padrão de  $x$ . Assim, todas as variáveis preditoras têm média zero e variância unitária, evitando que atributos com magnitudes maiores dominem o processo de aprendizado dos algoritmos de classificação. Em seguida, a partir do coeficiente de Pearson para os dados normalizados,  $r_{xy}$ , conforme (5.3) [25, 26], sendo  $n$  o número de tuplas,  $x_i$  e  $y_i$  os respectivos valores de  $x$  e  $y$  na  $i$ -ésima tupla,  $\bar{x}$  e  $\bar{y}$  os respectivos valores médios de  $x$  e  $y$ , e  $\sigma_x$  e  $\sigma_y$  os respectivos desvios-padrão de  $x$  e  $y$ , é possível construir a matriz de correlação entre as variáveis preditoras. Além disso, o coeficiente  $r_{xy} \in [-1, 1]$ . Se  $r_{xy}$  for maior que 0, então as variáveis são positivamente correlacionadas, isto é, os valores de uma aumentam à medida que os valores de outra também. Quanto maior o valor, mais forte é a correlação (ou seja, mais cada atributo implica no outro) [25, 26].

$$x'_i = \frac{x_i - \bar{x}}{\sigma_x} \quad (5.2)$$

$$r_{xy} = \frac{\sum_{i=1}^n (x_i y_i) - n \bar{x} \bar{y}}{n \sigma_x \sigma_y} \quad (5.3)$$

Neste trabalho, os algoritmos classificadores são treinados e testados para reconhecer duas classificações distintas de transformadores, sendo elas: a Satisfatória, composta por exemplares oriundos das classificações A, B e C; e a Insatisfatória, formada por

exemplos das classificações D e E. O agrupamento adotado fundamenta-se na interpretação técnica dos níveis de desempenho dos transformadores, conforme preconizado [2, 3, 21–24]. Desse modo, as classificações A, B e C correspondem a equipamentos com condição operacional satisfatória, variando entre Excelente e Marginal. Assim, a atuação corretiva indicada pode ser postergada ou, várias vezes, avaliada com cautela em um curto espaço de tempo. Todavia, as classificações D e E são compostas por equipamentos com severa degradação e que exigem atuação de intervenção em curto prazo ou até imediata e priorização em rotinas de manutenção corretiva, bem como substituição para inspeção interna, localização e correção de defeitos.

Além disso, a estratégia discutida visa facilitar a aplicação dos modelos preditivos no contexto real de gestão de ativos, permitindo a identificação binária (Satisfatório ou Insatisfatório) de transformadores de potência que necessitam de intervenção imediata e os que podem seguir operando com boas confiabilidades, atentando-se à evolução histórica dos parâmetros avaliados. Outrossim, esse procedimento reduz a complexidade da tarefa de classificação, ao mesmo tempo que que preserva sua utilidade prática para a tomada de decisão por equipes de manutenção nas empresas do setor elétrico. Para tanto, aplicam-se quatro algoritmos de aprendizado supervisionado, a saber:

- *Random Forest* (RF): algoritmo baseado em conjuntos (ensemble). Ele constrói múltiplas árvores de decisão e árvores de classificação e regressão (CART) utilizando subconjuntos aleatórios dos dados e das variáveis preditoras, sendo que a decisão final é obtida por meio da votação majoritária entre as árvores, dada em (5.4) [27, 28], sendo  $h_t(x)$  a predição da  $t$ -ésima árvore para a instância  $x$  e  $\text{mode}(\cdot)$  a classificação mais votada entre as árvores. Essa abordagem reduz o risco de sobreajuste *overfitting* e melhora a generalização do modelo [27, 28]. Na estrutura, as regras de divisão são representadas por nós, as decisões por ramos e as previsões finais por folhas e cada árvore construída maximizando o ganho de impureza, dado pelo índice de Gini, em (5.5) [27, 28], em que  $S$  é o conjunto de amostras em um nó da árvore de decisão,  $K$  é o número total de classificações possíveis e  $p_k$  é a proporção de amostras da classificação  $k$  no conjunto  $S$ , com  $p_k = n_k/n$ , sendo:  $n_k$  o número de amostras da classificação  $k$  no nó e  $n$  o número total de amostras no nó.

$$\hat{y} = \text{mode}(h_t(\mathbf{x})_{t=1}^T) \quad (5.4)$$

$$\text{Gini}(S) = 1 - \sum_{k=1}^K p_k^2 \quad (5.5)$$

- *Regressão Logística Balanceada* (LogReg): estima a probabilidade de uma instância pertencer à classificação positiva usando a função logística, em (5.6) [29–31], sendo

$x \in \mathbb{R}^n$  o vetor de atributos,  $\mathbf{w} \in \mathbb{R}^n$  o vetor de pesos,  $b$  o viés e  $\sigma(\cdot)$  a função sigmoide.

$$P(y = 1 | \mathbf{x}) = \sigma(\mathbf{w}^\top \mathbf{x} + b) = \frac{1}{1 + e^{-(\mathbf{w}^\top \mathbf{x} + b)}} \quad (5.6)$$

A otimização é feita minimizando a função de perda logística regularizada,  $\mathcal{L}(\mathbf{w}, b)$ , dada em (5.7) [29–31], em que  $N$  representa o número total de amostras no conjunto de dados,  $y_i \in \{0, 1\}$  é o rótulo verdadeiro da  $i$ -ésima amostra,  $p_i = \sigma(\mathbf{w}^\top \mathbf{x}_i + b)$  corresponde à probabilidade prevista pelo modelo para a classificação e  $\lambda$  é o hiperparâmetro de regularização. O primeiro termo da equação corresponde à entropia cruzada, usada para medir a discrepância entre os rótulos verdadeiros e as previsões do modelo, enquanto o segundo,  $\lambda \|\mathbf{w}\|^2$ , corresponde à regularização do tipo  $L_2$ , penalizando coeficientes elevados de  $\mathbf{w}$  com o objetivo de evitar *overfitting*.

$$\mathcal{L}(\mathbf{w}, b) = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] + \lambda \|\mathbf{w}\|^2 \quad (5.7)$$

- *HistGradientBoosting* (HistGB): algoritmo otimizado de *Gradient Boosting* [32]. A predição é uma soma de modelos fracos (árvores), dado em (5.8) [33, 34], sendo  $f_t$  a árvore adicionada na iteração  $t$ ,  $\eta$  a taxa de aprendizado e  $\hat{y}_i^{(t)}$  a predição acumulada após  $t$  iterações. Ademais, o modelo  $f_t$  é treinado para minimizar o gradiente da função de perda  $L$  com relação às previsões anteriores, conforme (5.9) [34, 35], em que  $\hat{y}_i^{(t)}$  é a predição do modelo para a  $i$ -ésima amostra após  $t$  iterações,  $\hat{y}_i^{(t-1)}$  é a predição acumulada até a iteração anterior,  $\eta$  é a taxa de aprendizado,  $f_t(x_i)$  é a predição fornecida pela árvore  $f_t$  para a entrada  $x_i$ ,  $L(y_i, \hat{y}_i^{(t-1)})$  é a função de perda entre o valor real  $y_i$  e a predição anterior e  $g_i^{(t)}$  é o gradiente da função de perda em relação à predição anterior para a  $i$ -ésima amostra.

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + \eta \cdot f_t(x_i) \quad (5.8)$$

$$g_i^{(t)} = \frac{\partial L(y_i, \hat{y}_i^{(t-1)})}{\partial \hat{y}_i^{(t-1)}} \quad (5.9)$$

- *Extreme Gradient Boosting* (XGBoost): baseia-se no algoritmo de *Gradient Boosting*, com regularização explícita [36]. A predição é modelada como uma soma de funções pertencentes ao espaço das árvores de decisão  $F$ , conforme (5.10) [37, 38], em que  $f_k$  representa a  $k$ -ésima árvore de decisão e  $K$  é o total de árvores. Além disso, a função objetivo a ser minimizada, dada em (5.11) [37, 38], combina a perda associada à predição com um termo de regularização, sendo  $l(y_i, \hat{y}_i)$  a função de perda para classificação binária,  $\Omega(f_k)$  a complexidade da árvore  $f_k$ , com

$T_k$  número de folhas,  $\omega_j$  a predição na  $j$ -ésima folha, e  $\gamma$  e  $\lambda$  hiperparâmetros de regularização.

$$\hat{y}_i = \Phi(x_i) = \sum_{k=1}^K f_k(x_i), \quad f_k \in F \quad (5.10)$$

$$L(\Phi) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k), \quad \Omega(f_k) = \gamma T_k + \frac{1}{2} \lambda \sum_{j=1}^{T_k} \omega_j^2 \quad (5.11)$$

Na classificação binária, a função de perda adotada é  $l$ , dada em (5.12), com  $\sigma(\hat{y}_i) = \frac{1}{1+e^{-\hat{y}_i}}$  sendo a função sigmoide que transforma a predição em probabilidade.

$$l(y_i, \hat{y}_i) = -[y_i \log(\sigma(\hat{y}_i)) + (1 - y_i) \log(1 - \sigma(\hat{y}_i))] \quad (5.12)$$

Para diminuir o desbalanceamento entre as classificações originais A, B, C, D e E, aplica-se o algoritmo SMOTE (*Synthetic Minority Over-sampling Technique*) com a estratégia `sampling_strategy = 'not majority'`. Essa abordagem preserva a quantidade de amostras da classificação majoritária e gera instâncias sintéticas apenas para as demais classificações, por meio da interpolação entre uma amostra da classificação minoritária e um de seus  $k$  vizinhos mais próximos. O processo é definido em (5.13) [39], em que  $x_i$  representa uma instância da classificação minoritária,  $x_{nn}$  é um dos seus vizinhos mais próximos e  $\delta \sim U(0, 1)$  é uma variável aleatória com distribuição uniforme.

$$x_{\text{novo}} = x_i + \delta \cdot (x_{nn} - x_i) \quad (5.13)$$

Assim, as amostras sintéticas são utilizadas, apenas, no conjunto de treinamento, enquanto o conjunto de teste permanece composto apenas pelas originais. Essa estratégia evita o sobreajuste associado à replicação simples de instâncias e deve contribuir para um aprendizado mais robusto dos classificadores. Também, para todos os modelos desenvolvidos, aplica-se validação cruzada estratificada (*Stratified K-Fold*). Ela consiste em dividir o conjunto de dados em  $k_f = 5$  subconjuntos (*folds*) de forma que cada um mantenha, aproximadamente, a proporção original das classificações. O treinamento é realizado  $k_f$  vezes, sendo que, em cada uma, utilizam-se  $k_f - 1$  subconjuntos para treinar o modelo e o subconjunto restante para teste. As métricas de desempenho são calculadas, então, como os valores médios a cada iteração.

Posteriormente, para o modelo com melhor desempenho, utiliza-se a validação cruzada *Leave-One-Out* (LOOCV), a qual representa um caso limite da validação cruzada com  $k_f = n$ , sendo  $n$  o número total de observações. Nesse caso, cada amostra é usada uma única vez como conjunto de teste, enquanto as demais compõem o conjunto de treino. Essa estratégia é adotada, pois permite uma avaliação menos enviesada do modelo final, o que é essencial no conjunto de dados avaliado, que possui grande desbalanceamento e nú-

mero de amostras limitado para a classificação Satisfatório. As métricas de desempenho avaliadas neste trabalho são: Acurácia, dada em (5.14), Precisão, dada em (5.15), *Recall*, dada em (5.16), *F1-score*, dada em (5.17), e *F1-score weighted*, dada em (5.18), sendo  $TP_k$  o número de verdadeiros positivos da classificação  $k$ ,  $FP_k$  o número de falsos positivos,  $FN_k$  o número de falsos negativos,  $n_k$  o número de amostras reais da classificação  $k$ ,  $n$  o número total de amostras e  $K$  é o número total de classificações.

$$\text{Acurácia} = \frac{TP_k + TN_k}{TP_k + TN_k + FP_k + FN_k} \quad (5.14)$$

$$\text{Precisão} = \frac{TP_k}{TP_k + FP_k} \quad (5.15)$$

$$\text{Recall} = \frac{TP_k}{TP_k + FN_k} \quad (5.16)$$

$$\text{F1-score} = 2 \cdot \frac{\text{Precisão} \cdot \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (5.17)$$


$$\text{F1-score}_{\text{weighted}} = \sum_{k=1}^K \frac{n_k}{n} \cdot \text{F1}_k \quad (5.18)$$

## 5.4 Resultados e Discussões

Utiliza-se o *StandardScaler* do *sklearn*, em Python, para normalizar as variáveis preditoras numéricas de interesse, sendo elas: hidrogênio, em ppm; metano, em ppm; etileno, em ppm; acetileno, em ppm; fator de potência, adimensional; tensão interfacial, em mN/m; monóxido de carbono, em ppm; dióxido de carbono, em ppm; oxigênio, em ppm; nitrogênio, em ppm; teor de água, em mg/kg; rigidez dielétrica, em kV; e DBDS (Dibenzil Dissulfeto), em mg/kg. A Figura 5.1 exibe a correlação entre as variáveis preditoras normalizadas.

Inicialmente, a distribuição por classificações é a seguinte: A (5 equipamentos), B (5 equipamentos), C (41 equipamentos), D (132 equipamentos) e E (287 equipamentos), totalizando 470 exemplares. Na Figura 5.1, evidencia-se que o par de gases metano e etileno apresenta correlação igual a 0,91, indicando que são gerados ou evoluem concomitantemente, fenômeno característico do processo de pirólise do óleo mineral isolante. Além disso, há alta correlação entre etileno e etano de 0,76, reforçando a hipótese de que tais compostos derivam de mecanismos análogos de degradação térmica. Já os gases monóxido de carbono e dióxido de carbono exibem correlação moderada de 0,56, coerente com a origem comum na decomposição da celulose presente no papel isolante. Por outro lado, o composto DBDS não apresenta correlação significativa com os

Figura 5.1: Matriz de correção entre variáveis predictoras normalizadas



Fonte: próprios autores (2025)


gases dissolvidos. Por fim, o teor de água apresentou correlação negativa com a tensão interfacial, igual a  $-0,46$ , e com o fator de potência, a  $0,08$ , indicando que a presença de umidade contribui para a degradação da qualidade dielétrica do óleo, o que pode comprometer a eficiência e a confiabilidade do sistema de isolamento.

Posteriormente, plotam-se os *boxplots* referentes a cada variável por classificação, por exemplo, dados na Figuras 5.2 e 5.3. Neles, é possível observar o comportamento estatístico das variáveis ao longo das diferentes categorias de desempenho, por meio do destaque à mediana, aos quartis e à presença de possíveis valores discrepantes (*outliers*). Neste trabalho, os dados discrepantes não serão removidos. Entende-se que eles compõem o conjunto de observações, podendo representar comportamentos atípicos da operação dos transformadores de potência, todavia, verdadeiros.

O acetileno (Figura 5.2), um dos gases associados a falhas elétricas por arco elétrico, é encontrado em concentração elevada, principalmente, na classificação C, com valores residuais ou nulos nas demais. Isso indica que esse tipo de falha é pontual e menos comum nos extremos do espectro de desempenho (A, B, D e E). Por sua


vez, o composto DBDS (Figura 5.3) apresenta maior concentração na classificação B, seguida pela D, sugerindo que a presença de enxofre corrosivo está associada a estágios iniciais de degradação. No dióxido de carbono, subproduto da degradação térmica da celulose, evidencia-se distribuição mais homogênea ao longo das classificações, porém, com aumento progressivo da dispersão nas classificações C, D e E, reforçando sua relação com o envelhecimento da isolação sólida, conforme Figura 5.4.

Figura 5.2: *Boxplots* da variável acetileno normalizada por classificação (A até E)



Fonte: próprios autores (2025)


Figura 5.3: *Boxplots* da variável DBDS normalizada por classificação (A até E)



Fonte: próprios autores (2025)

Já as variáveis etileno (Figura 5.5), etano (Figura 5.6) e metano (Figura 5.7), relacionadas, principalmente, à pirólise do óleo mineral isolante, apresentam máximos na

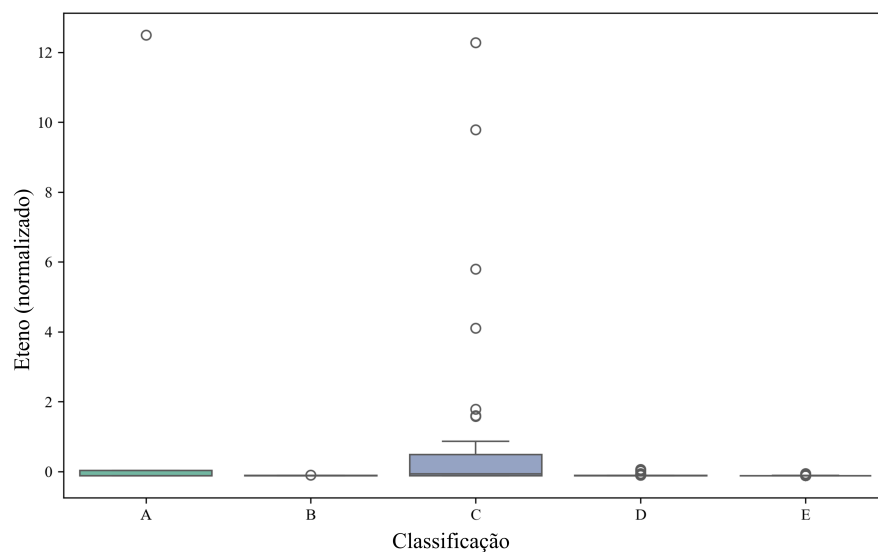
Figura 5.4: *Boxplots* da variável dióxido de carbono normalizada por classificação (A até E)




Fonte: próprios autores (2025)

classificação C, indicando que, ainda em transformadores classificados com satisfatório desempenho, podem ocorrer eventos térmicos localizados. Esse comportamento ressalta a hipótese de que a presença desses gases não é restrita a casos de desempenhos classificados como ruins ou muito ruins, podendo ocorrer, inclusive, em equipamentos com índices de desempenho altos e desejáveis. Assim, exige-se uma abordagem cuidadosa na interpretação dos resultados.


Figura 5.5: *Boxplots* da variável etileno normalizada por classificação (A até E)



Fonte: próprios autores (2025)

Figura 5.6: *Boxplots* da variável etano normalizada por classificação (A até E)

Fonte: próprios autores (2025)

Figura 5.7: *Boxplots* da variável metano normalizada por classificação (A até E)

Fonte: próprios autores (2025)

É válido ressaltar a presença de outliers pronunciados em diversas variáveis, como etileno (Figura 5.5), etano (Figura 5.6) e metano (Figura 5.7), sobretudo, nas classificações C, D e E. Isso sugere que há casos isolados com comportamento atípico ou intensificação repentina de processos de falha, os quais podem dificultar a generalização de modelos classificadores baseados em Inteligência Artificial.

A presença de registros discrepantes foi detectada na própria visualização dos boxplots, utilizando o intervalo interquartil (IQR). A partir dessa abordagem, consideram-se como valores extremos aqueles que satisfazem (19), em que  $Q_1$  e  $Q_3$  são, nessa ordem,

o primeiro e o terceiro quartis da distribuição da variável analisada, sendo o intervalo interquartil definido como  $IQR = Q_3 - Q_1$ . Assim, valores abaixo de  $Q_1 - 1,5 \times IQR$  ou acima de  $Q_3 + 1,5 \times IQR$  são considerados *outliers*.

$$x_{\text{outlier}} \in (-\infty, Q_1 - 1,5 \times IQR] \cup [Q_3 + 1,5 \times IQR, +\infty) \quad (5.19)$$

A variável fator de potência, na Figura 5.8, por exemplo, destaca-se com elevado número de *outliers* nas classificações A e E, o que pode estar associado tanto à variabilidade do processo de medição quanto à natureza não normal da distribuição. Desse modo, a análise de valores atípicos constitui uma etapa fundamental no diagnóstico da qualidade dos dados, permitindo a identificação de amostras que destoam do comportamento geral da população. É importante destacar, todavia, que esses dados não foram descartados na análise. A decisão de mantê-los fundamenta-se no entendimento de que, em muitos casos, os valores atípicos não correspondem a erros de medição ou registros incorretos, mas podem refletir condições extremas de operação, como altos carregamentos ou situações de estresse no sistema. Tais ocorrências carregam informações relevantes sobre o fenômeno estudado e, portanto, merecem ser preservadas. Além disso, a exclusão desses pontos poderia introduzir vieses, comprometendo a representatividade da amostra e reduzindo a capacidade do modelo de capturar toda a variabilidade do sistema. Dessa forma, optou-se por considerar esses dados nas análises subsequentes, assegurando uma interpretação mais fidedigna e abrangente dos resultados.

A Tabela 5.1 explicita os hiperparâmetros usados em cada classificador binário. Em seguida, para avaliar o desempenho dos algoritmos de aprendizado de máquina na atividade de classificação dos transformadores entre Satisfatório e Insatisfatório, foram consideradas três métricas: acurácia, *F1-score* e *F1-score weighted*. A Tabela 5.2, por sua vez, apresenta os resultados obtidos para cada um dos modelos, permitindo uma análise comparativa quanto à capacidade de generalização e ao equilíbrio na classificação entre as classificações.


Tabela 5.2: Resultados de desempenho dos classificadores binários

<b>Algoritmo</b>	<b>Acurácia</b>	<b>F1-score</b>	<b>F1-score weighted</b>
<i>Random Forest</i>	96,38%	90,73%	96,40%
<i>LogReg</i>	92,98%	83,14%	93,23%
<i>HistGB</i>	96,60%	91,20%	96,60%
<i>XGBoost</i>	96,60%	91,63%	96,98%

Fonte: próprios autores (2025)

Os modelos baseados em *ensemble*, que são o *Random Forest*, o *HistGB* e o *XGBoost*, apresentaram desempenhos bastante similares, com acurácias superiores a

Figura 5.8: Mapa de calor da frequência relativa de *outliers* identificados por *IQR* por variável preditora e classificação de desempenho dos transformadores de potência



Fonte: próprios autores (2025)

96% e F1-scores acima de 90%. O *XGBoost* se destacou levemente nas três métricas, consolidando-se como a melhor técnica com desempenho global no conjunto de dados avaliado. A regressão logística, embora tenha apresentado resultados promissores, com métricas acima de 83%, é superada pelas demais abordagens, especialmente no que se

Tabela 5.1: Valores de hiperparâmetros em cada modelo de classificador binário utilizado.

<b>Modelo</b>	<b>Hiperparâmetros</b>	<b>Valores</b>
<i>Random Forest</i>	<i>random_state</i>	42
	Demais parâmetros	Padrão ( <i>n_estimators</i> =100, <i>max_depth</i> =None)
<i>LogReg</i>	<i>class_weight</i>	Balanced
	<i>max_iter</i>	1000
	Demais parâmetros	Padrão ( <i>penalty</i> ='l2', <i>solver</i> ='lbfgs')
<i>HistGB</i>	<i>random_state</i>	42
	Demais parâmetros	Padrão ( <i>learning_rate</i> =0.1, <i>max_iter</i> =100)
<i>XGBoost (K-Fold)</i>	<i>use_label_encoder</i>	False
	<i>eval_metric</i>	logloss
	<i>random_state</i>	42
	Demais parâmetros	Padrão ( <i>n_estimators</i> =100, <i>learning_rate</i> =0.3)
<i>XGBoost (LOOCV)</i>	<i>use_label_encoder</i>	False
	<i>eval_metric</i>	logloss
	<i>random_state</i>	42
	<i>scale_pos_weight</i>	10
	Demais parâmetros	Padrão

Fonte: próprios autores (2025)

refere ao *F1-score*, indicando menor equilíbrio na classificação entre as classificações.

A Tabela 5.3 exibe as métricas de desempenho de precisão, *recall* e *F1-score* para o *XGBoost*, algoritmo com o melhor desempenho, utilizando a validação por *Leave-One-Out Cross-Validation* (LOOCV). Esses resultados podem ser visualizados, também, na matriz de confusão, Figura 5.9, em que são exibidas as classificações feitas pelo *XGBoost* e o estado real do transformador de potência.

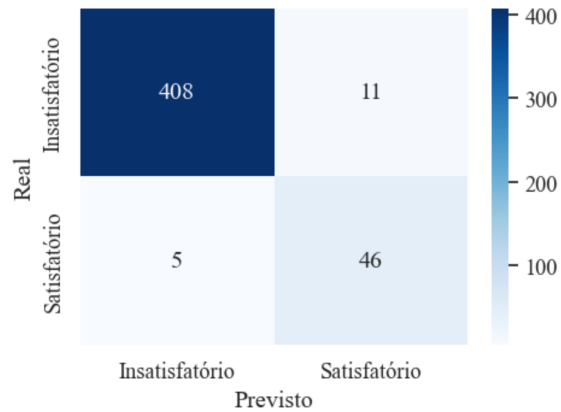
Tabela 5.3: Métricas de desempenho do algoritmo de classificação binária *XGBoost* para cada classificação utilizando validação por *Leave-One-Out Cross-Validation* (LOOCV)

<b>Classificação</b>	<b>Precisão</b>	<b>Recall</b>	<b>F1-score</b>
<i>Satisfatório</i>	75,41%	90,20%	82,14%
<i>Insatisfatório</i>	98,78%	96,42%	97,58%

Fonte: próprios autores (2025).

Considerando a aplicação da validação *Leave-One-Out Cross-Validation* (LO-

Figura 5.9: Matriz de confusão do algoritmo de classificação binária XGBoost para cada classificação utilizando validação por *Leave-One-Out Cross-Validation* (LOOCV)



Fonte: próprios autores (2025)

OCV), na Tabela 5.3 e na Figura 5.9, consta-se que o *XGBoost* obteve desempenho excelente, com acurácia final de 96% e destaque para a classificação Insatisfatório, com precisão de 98,78%. Ainda que a classificação Satisfatório tenha apresentado F1-score inferior à outra, observa-se uma taxa de *recall* de 90,20%, indicando que poucas amostras dessa classificação foram erroneamente classificadas. A acurácia final foi de cerca de 96%.

## 5.5 Conclusões

Este estudo demonstra que dados de ensaios físico-químicos e de AGD, quando tratados estatisticamente e processados por algoritmos de aprendizado supervisionado, podem ser utilizados de forma eficaz para classificação binária do estado operacional de transformadores de potência por meio do índice de desempenho. Ademais, a adoção da estratégia para tornar menos significante o desbalanceamento original de exemplares entre classificações, a partir do algoritmo SMOTE e da aplicação rigorosa de validação cruzada, permitiu avaliar com o desempenho dos modelos preditivos em cenários realistas.

Os resultados obtidos indicam que XGBoost e HistGradientBoosting são capazes de alcançar altos índices de F1-score, respectivamente, 91,63% e 91,20%, ainda que em conjuntos de dados heterogêneos e com alta variabilidade. Isso atesta a aplicabilidade da metodologia desenvolvida em ambientes de campo. Além disso, como principal contribuição, há a construção de uma ferramenta de classificação que, embora baseada em dados de rotina, fornece subsídios técnicos confiáveis para a priorização de ações de manutenção, reduzindo, por consequência, o risco de falhas incipientes e catastróficas e

os custos operacionais associados, com acurácia máxima de 96,60%.

Como limitações, tem-se a dependência de bases históricas consistentes, bem como a ausência de séries temporais que possibilitem análises preditivas mais refinadas do desempenho ao longo do tempo para cada equipamento. Nesse sentido, pesquisas futuras podem integrar dados adicionais, tais como medições on-line e variáveis ambientais (quando disponíveis).

Logo, a ferramenta projetada possui amplas possibilidades de uso prático. Além de robusta e de fácil replicação nos ambientes das empresas do setor elétrico, pode ser incorporada a sistemas de apoio à decisão rápida nas empresas, sem a necessidade de aquisição de equipamentos adicionais, como sensores, ou de técnicas invasivas de diagnóstico, uma vez que os ensaios físico-químicos e da AGD não exigem o desligamento dos equipamentos analisados.

## Referências

- [1] CAMPI, Rodrigo Luz. **Modelagem fuzzy da concentração dos gases dissolvidos em óleo mineral isolante de transformadores baseada em resultados de ensaios físico-químicos**. 2014. Diss. (Mestrado) – Universidade de São Paulo.
- [2] DIAS, Yuri Andrade. **Method for Predicting the Performance Indices of Power Transformers Immersed in Mineral Insulating Oil and Medium and High-Voltage Circuit Breakers**. 2023. PhD Thesis – Federal University of Goiás.
- [3] MARQUES, A. P.; AZEVEDO, C. H. B.; SANTOS, J. A. L.; MACHADO, S. G.; RIBEIRO, C. J. R.; MOURA, N. K.; DIAS, Y. A.; BRITO, L. C. Metodologia para Reenergização de Transformadores de Potência após Interrupções não Programadas no Sistema Elétrico. *In: XXIV SEMINÁRIO NACIONAL DE PRODUÇÃO E TRANSMISSÃO DE ENERGIA ELÉTRICA (SNPTEE 2017)*, 2017. **Anais [...]**. Curitiba, PR, Brasil, 2017.
- [4] MARQUES, André Pereira. **Optimized diagnosis of power transformers through the integration of predictive techniques**. 2018. PhD Thesis – Federal University of Goiás.
- [5] MOURA, Nicolas Kemerich de. **Otimização Computacional da Avaliação de Resultados de Ensaios Físico-químicos em Transformadores de Potência**. 2018. Diss. (Mestrado) – Universidade Federal de Goiás.
- [6] BECHARA, Ricardo. **Análise de falhas de transformadores de potência**. 2010. Diss. (Mestrado) – Universidade de São Paulo.

- [7] MARQUES, André; MOURA, Nicolas Kemerich de; DIAS, Yuri Andrade; JESUS RIBEIRO, Cacilda de; ROCHA, Adson Silva; CUNHA BRITO, Leonardo da; BEZERRA AZEVEDO, Claudio Henrique; LOPES DOS SANTOS, Jose Augusto. Method for the evaluation and classification of power transformer insulating oil based on physicochemical analyses. **IEEE Electrical Insulation Magazine**, v. 33, n. 1, p. 39–49, 2017. DOI: 10.1109/MEI.2017.7804315.
- [8] DUVAL, Michel; PABLA, A. de. Interpretation of gas-in-oil analysis using new IEC publication 60599 and IEC TC 10 databases. **IEEE Electrical Insulation Magazine**, v. 17, n. 2, p. 31–41, 2001. Disponível em: <https://doi.org/10.1109/57.917529>. Acesso em: 13 jun. 2025. DOI: 10.1109/57.917529.
- [9] ROGERS, R. R. IEEE and IEC codes to interpret incipient faults in transformers using gas in oil analysis. **IEEE Transactions on Electrical Insulation**, EI-13, n. 5, p. 349–354, out. 1978.
- [10] SENOUSSAOUI, Mohammed El Amine; BRAHAMI, Mostefa; FOFANA, Issouf. Transformer Oil Quality Assessment Using Random Forest with Feature Engineering. **Energies**, MDPI AG, v. 14, n. 7, p. 1809, mar. 2021. ISSN 1996-1073. DOI: 10.3390/en14071809.
- [11] IEEE POWER & ENERGY SOCIETY. **C57.104-2019 - IEEE Guide for the Interpretation of Gases Generated in Mineral Oil-Immersed Transformers**. [S. l.], 2019. Disponível em: <https://ieeexplore.ieee.org/document/8890040>. Acesso em: 25 jun. 2025.
- [12] BARBOSA, F. R.; ALMEIDA, O. M.; BRAGA, A. P. S.; AMORA, M. A. B.; CARTAXO, S. J. M. Application of an artificial neural network in the use of physicochemical properties as a low cost proxy of power transformers DGA data. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 19, n. 1, p. 239–246, fev. 2012.
- [13] ARIAS, Ricardo. **Dados para análise de causa raiz aprimorada com aprendizado de máquina para análise de falhas em transformadores de potência**. [S. l.]: Mendeley, 2020.
- [14] VELÁSQUEZ, Ricardo Manuel Arias; MEJÍA, Lara Jennifer Vanessa. Análise de causa raiz aprimorada com aprendizado de máquina para análise de falhas em transformadores de potência. en. **Eng. Fail. Anal.**, Elsevier BV, v. 115, n. 104684, p. 104684, 2020.
- [15] VELÁSQUEZ, Ricardo Manuel Arias; MEJÍA, Lara Jennifer Vanessa. Corrosive Sulphur effect in power and distribution transformers failures and treatments. **Engineering Failure Analysis**, Elsevier BV, v. 92, p. 240–267, out. 2018. ISSN 1350-6307. DOI: 10.1016/j.engfailanal.2018.05.018.

- [16] CASTRO, A. R. G.; MIRANDA, V. Knowledge discovery in neural networks with application to transformer failure diagnosis. **IEEE Transactions on Power Systems**, v. 20, n. 2, p. 717–724, 2005. Disponível em: <https://doi.org/10.1109/TPWRS.2005.846074>. Acesso em: 13 jun. 2025. DOI: 10.1109/TPWRS.2005.846074.
- [17] DURAISAMY, V.; DEVARAJAN, N.; SOMASUNDARESWARI, D.; VASANTH, A. Antony Maria; SIVANANDAM, S. N. Neuro fuzzy schemes for fault detection in power transformer. **Applied Soft Computing**, v. 7, p. 534–539, 2007. Disponível em: <https://doi.org/10.1016/j.asoc.2006.10.001>. Acesso em: 13 jun. 2025. DOI: 10.1016/j.asoc.2006.10.001.
- [18] NARESH, R.; SHARMA, V.; VASHISTH, M. An integrated neural fuzzy approach for fault diagnosis of transformers. **IEEE Transactions on Power Delivery**, v. 23, n. 4, p. 2017–2024, 2008. Disponível em: <https://doi.org/10.1109/TPWRD.2008.2002652>. Acesso em: 13 jun. 2025. DOI: 10.1109/TPWRD.2008.2002652.
- [19] RICHARDSON, Z.J.; FITCH, J.; TANG, W.H.; GOULERMAS, J.Y.; WU, Q.H. A Probabilistic Classifier for Transformer Dissolved Gas Analysis With a Particle Swarm Optimizer. **IEEE Transactions on Power Delivery**, Institute of Electrical and Electronics Engineers (IEEE), v. 23, n. 2, p. 751–759, abr. 2008. ISSN 1937-4208. DOI: 10.1109/tpwrd.2008.915812.
- [20] YADAAIAH, N.; RAVI, N. Internal fault detection techniques for power transformers. **Applied Soft Computing**, v. 11, p. 5259–5269, 2011. DOI: 10.1016/j.asoc.2011.05.034.
- [21] NADERIAN, A.; CRESS, S.; PIERCY, R.; WANG, F.; SERVICE, J. An Approach to Determine the Health Index of Power Transformers. *In*: CONFERENCE RECORD OF THE 2008 IEEE INTERNATIONAL SYMPOSIUM ON ELECTRICAL INSULATION, 2008. **Anais [...]**.
- [22] WANG, J.; WU, Kuihua; ZHU, Wenbing; GU, Chao. Condition Assessment for Power Transformer Using Health Index. *In*: PROCEEDINGS OF THE 2ND ASIA CONFERENCE ON POWER AND ELECTRICAL ENGINEERING (ACPEE), 2017. **Anais [...]**. Shanghai, China: ACPEE, 2017.
- [23] WATTAKAPAIBOON, W.; PATTANADECH, N. The New Developed Health Index for Transformer Condition Assessment. *In*: 2016 INTERNATIONAL CONFERENCE ON CONDITION MONITORING AND DIAGNOSIS (CMD), 2016. **Anais [...]**. Xi'an, China: IEEE, 2016.
- [24] ZEINODDINI-MEYMAND, H.; VAHIDI, B. Health index calculation for power transformers using technical and economical parameters. **IET Science, Measurement**

- & Technology**, v. 10, n. 7, p. 823–830, out. 2016. DOI: 10.1049/iet-smt.2016.0184.
- [25] BISHOP, Christopher M. **Pattern Recognition and Machine Learning**. New York: Springer, 2006.
- [26] HAN, Jiawei; KAMBER, Micheline; PEI, Jian. **Data Mining: Concepts and Techniques**. 3. ed. Amsterdam: Elsevier, 2011.
- [27] LI, Jin; HEAP, Andrew D.; POTTER, Anna; DANIELL, James J. Application of machine learning methods to spatial interpolation of environmental variables. **Environmental Modelling & Software**, Elsevier BV, v. 26, n. 12, p. 1647–1659, dez. 2011. ISSN 1364-8152. DOI: 10.1016/j.envsoft.2011.07.004.
- [28] SEKULIĆ, Aleksandar; KILIBARDA, Milan; HEUVELINK, Gerard B.M.; NIKOLIĆ, Mladen; BAJAT, Branislav. Random Forest Spatial Interpolation. **Remote Sensing**, MDPI AG, v. 12, n. 10, p. 1687, maio 2020. ISSN 2072-4292. DOI: 10.3390/rs12101687.
- [29] DEMPSTER, Angus; WEBB, Geoffrey I.; SCHMIDT, Daniel F. **Prevalidated ridge regression is a highly-efficient drop-in replacement for logistic regression for high-dimensional data**. [S. l.]: arXiv, 2024. DOI: 10.48550/ARXIV.2401.15610.
- [30] WANG, Jing; XIE, Xiao; WANG, Pengwei; SUN, Jian; LIU, Yaochen; ZHANG, Li. Incorporating Symmetric Smooth Regularizations into Sparse Logistic Regression for Classification and Feature Extraction. **Symmetry**, MDPI AG, v. 17, n. 2, p. 151, jan. 2025. ISSN 2073-8994. DOI: 10.3390/sym17020151.
- [31] ZHANG, Yanfang; WEI, Chuanhua; LIU, Xiaolin. Group Logistic Regression Models with  $l_p, q$  Regularization. **Mathematics**, MDPI AG, v. 10, n. 13, p. 2227, jun. 2022. ISSN 2227-7390. DOI: 10.3390/math10132227.
- [32] MILLER, Clayton; HAO, Liu; FU, Chun. Gradient boosting machines and careful pre-processing work best: ASHRAE Great Energy Predictor III lessons learned. arXiv, 2022. DOI: 10.48550/ARXIV.2202.02898.
- [33] KARBASI, Z. S.; HASSANI, Hamed; KALE, Satyen; AMIN, (A.) Federated Functional Gradient Boosting. *In*: PROCEEDINGS OF THE 25TH INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE AND STATISTICS (AISTATS), 2022. **Anais [...]**.
- [34] SHI, Yu; KE, Guolin; CHEN, Zhuoming; ZHENG, Shuxin; LIU, Tie-Yan. **Quantized Training of Gradient Boosting Decision Trees**. [S. l.]: arXiv, 2022. DOI: 10.48550/ARXIV.2207.09682.

- [35] VELARDE, Gissel; WEICHERT, Michael; DESHMUNKH, Anuj; DESHMANE, Sanjay; SUDHIR, Anindya; SHARMA, Khushboo; JOSHI, Vaibhav. Tree boosting methods for balanced and imbalanced classification and their robustness over time in risk assessment. **Intelligent Systems with Applications**, Elsevier BV, v. 22, p. 200354, jun. 2024. ISSN 2667-3053. DOI: 10.1016/j.iswa.2024.200354.
- [36] SHERIDAN, Robert P.; WANG, Wei Min; LIAW, Andy; MA, Junshui; GIFFORD, Eric M. Extreme Gradient Boosting as a Method for Quantitative Structure–Activity Relationships. **Journal of Chemical Information and Modeling**, American Chemical Society (ACS), v. 56, n. 12, p. 2353–2360, dez. 2016. ISSN 1549-960X. DOI: 10.1021/acs.jcim.6b00591.
- [37] CHERIF, Iyad Lahsen; KORTEBI, Abdesselem. On using eXtreme Gradient Boosting (XGBoost) Machine Learning algorithm for Home Network Traffic Classification. *In*: 2019 WIRELESS DAYS (WD), 2019. **Anais [...]**.
- [38] SHI, Haotian; WANG, Haoren; HUANG, Yixiang; ZHAO, Liquan; QIN, Chengjin; LIU, Chengliang. A hierarchical method based on weighted extreme gradient boosting in ECG heartbeat classification. **Computer Methods and Programs in Biomedicine**, Elsevier BV, v. 171, p. 1–10, abr. 2019. ISSN 0169-2607. DOI: 10.1016/j.cmpb.2019.02.005.
- [39] CHAWLA, N. V.; BOWYER, K. W.; HALL, L. O.; KEGELMEYER, W. P. SMOTE: Synthetic Minority Over-sampling Technique. **Journal of Artificial Intelligence Research**, AI Access Foundation, v. 16, p. 321–357, jun. 2002. ISSN 1076-9757. DOI: 10.1613/jair.953.

---

## CAPÍTULO 6

# Conclusões

---

Neste trabalho, foram desenvolvidos e avaliados métodos baseados em IA para o monitoramento e diagnóstico da condição operacional de transformadores de potência, a partir do índice de desempenho, com foco em estratégias de predição de falhas incipientes e detecção de comportamentos atípicos. Assim, esta pesquisa contribui de forma inédita ao desenvolver abordagens orientadas ao histórico dos próprios equipamentos e com base na diversidade de comportamentos observados entre eles.

Inicialmente, foi apresentada, no Capítulo 2, uma revisão da literatura sobre o uso de IA na manutenção de transformadores de potência. Por meio dessa etapa, verificou-se que houve avanços na aplicação de modelos supervisionados e não supervisionados ao diagnóstico desses ativos, incluindo o apontamento de vantagens e limitações, como pouca interpretabilidade de modelos, escassez de dados rotulados e representativos, e necessidade de validação em cenários reais em campo, sendo estes alguns dos desafios que nortearam o desenvolvimento das soluções propostas nesta dissertação.

No Capítulo 3, que se dedica à detecção de *outliers*, foi implementado o algoritmo *Local Outlier Factor* (LOF), com otimização do número de vizinhos pela Curva de Cotovelo, para análise de agrupamentos temporais do índice de desempenho. Isso resultou em métricas de desempenho excelentes para identificação de comportamentos atípicos nos *clusters* avaliados. Essa ferramenta possibilitou associar eventos de degradação a padrões previamente não mapeados, contribuindo para o diagnóstico técnico individualizado por transformador, com base em técnicas preditivas não invasivas e no acompanhamento histórico do índice de desempenho.

Posteriormente, no Capítulo 4, foram desenvolvidos filtros de partículas adaptativos, baseados em *Bootstrap* e *Sequential Importance Sampling* (SIS), integrados ao denominado Algoritmo de Consistência Temporal Baseado na Efetividade da Intervenção (CTBEI), desenvolvido nesta dissertação de mestrado e previamente referido como AD. A partir da simulação de cenários operacionais realistas, contemplando variações

climáticas, intervenções de manutenção e diferentes perfis de degradação, as arquiteturas CTBEI-Bootstrap e CTBEI-SIS mostraram-se capazes de prever o índice de desempenho com elevada taxa de acertos, atingindo 100% em distintos cenários avaliados.

No Capítulo 5, foram construídos classificadores binários utilizando técnicas supervisionadas, a saber: *Random Forest*, *HistGradientBoosting*, Regressão Logística Balanceada e XGBoost, treinados com dados sintéticos balanceados gerados por SMOTE. Eles apresentaram desempenho consistente, com acurácia máxima de 96%, ainda que diante da alta variabilidade das variáveis preditoras, destacando-se pela capacidade de generalização para novos equipamentos com dados limitados em algumas classificações, como A e B.

Como sugestões para trabalhos futuros, tem-se: a extensão da metodologia desenvolvida para transformadores isolados a óleo vegetal, permitindo a análise comparativa de modelos de degradação nas técnicas preditivas respectivas; e a criação de protocolos especialistas para relatórios técnicos automatizados, visando padronizar a comunicação de ações de manutenção recomendadas e os diagnósticos gerados pelos modelos.

Dessa forma, este estudo representa um avanço no uso de IA aplicada à manutenção de equipamentos de alta tensão para a construção de soluções eficazes e adaptáveis à gestão desses importantes ativos, com abrangência e implementação nas empresas em geral, analisando os desempenhos dos transformadores de potência imersos em óleo mineral isolante e possibilitando o planejamento otimizado de intervenções de manutenção. Portanto, conclui-se que as abordagens desenvolvidas auxiliam na tomada de decisão técnica em ambientes operacionais e contribuem com estratégias de inovação voltadas à confiabilidade e inteligência aplicadas à gestão de ativos nas empresas do setor elétrico.

---

## Referências

---

- [1] MENDANHA, Vinícius Faria Costa; MARQUES, André Pereira; DIAS, Yuri Andrade; RIBEIRO, Cacilda de Jesus. Predição Otimizada do Índice de Desempenho de Transformadores de Potência com aplicação de Inteligência Artificial. **Sodebras**, v. 19, n. 222, 2024.
- [2] MENDANHA, Vinícius Faria Costa; MARQUES, André Pereira; AGUIAR, Lucas Santos de; SANTOS, Juliermy Junio Pacheco dos; CARDOSO, Álisson Assis; RIBEIRO, Cacilda de Jesus. Hybrid Artificial Intelligence Model for Reliable Decision Making in Power Transformer Maintenance Through Performance Index. **Energies**, MDPI AG, v. 18, n. 18, p. 4924, set. 2025. ISSN 1996-1073. DOI: 10.3390/en18184924.
- [3] MENDANHA, Vinícius Faria Costa; MARQUES, André Pereira; RIBEIRO, Cacilda de Jesus. Estudos sobre Inteligência Artificial aplicada à detecção de falhas incipientes de disjuntores de média e alta tensão. *In*: CONGRESSO DE PESQUISA, ENSINO E EXTENSÃO (CONPEEX), 2024, Goiânia. **Anais [...]**. Goiânia: UFG, 2024.
- [4] MENDANHA, Vinícius Faria Costa; MARQUES, André Pereira; RIBEIRO, Cacilda de Jesus. Classificação do desempenho de transformadores de potência por rede neural profunda em relação à análise do óleo mineral isolante. *In*: CONGRESSO DE PESQUISA, ENSINO E EXTENSÃO (CONPEEX), 2025, Goiânia. **Anais [...]**. Goiânia: UFG, 2025.
- [5] MARQUES, André Pereira. **Optimized diagnosis of power transformers through the integration of predictive techniques**. 2018. PhD Thesis – Federal University of Goiás.
- [6] DIAS, Yuri Andrade. **Method for Predicting the Performance Indices of Power Transformers Immersed in Mineral Insulating Oil and Medium and High-Voltage Circuit Breakers**. 2023. PhD Thesis – Federal University of Goiás.
- [7] MOURA, Nicolas Kemerich de. **Otimização Computacional da Avaliação de Resultados de Ensaios Físico-químicos em Transformadores de Potência**. 2018. Diss. (Mestrado) – Universidade Federal de Goiás.

- [8] BECHARA, Ricardo. **Análise de falhas de transformadores de potência**. 2010. Diss. (Mestrado) – Universidade de São Paulo.
- [9] SUÑE, Jaime; HEREDIA, Leonardo A.; OUTROS. **Guia de Manutenção para Transformadores de Potência**. Brasil, nov. 2013. Disponível em: <https://cigre.org.br/brochuras/>. Acesso em: 13 set. 2022.
- [10] YANG, Dongsheng; QIN, Jia; PANG, Yongheng; HUANG, Tingwen. A Novel Double-Stacked Autoencoder for Power Transformers DGA Signals With An Imbalanced Data Structure. **IEEE Transactions on Industrial Electronics**, v. 69, n. 2, p. 1977–1987, 2022. DOI: 10.1109/TIE.2021.3059543.
- [11] SAHA, T. K. Review of modern diagnostic techniques for assessing insulation condition in aged transformers. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 10, n. 5, p. 903–917, out. 2003.
- [12] WANG, Y.; MA, G.; ZHENG, D.; LIAO, W.; JIANG, J.; QIN, W. Detection of dissolved acetylene in power transformer oil based on photonic crystal fiber. **IEEE Sensors Journal**, v. 20, n. 18, p. 10981–10988, set. 2020.
- [13] ROGERS, R. R. IEEE and IEC codes to interpret incipient faults in transformers using gas in oil analysis. **IEEE Transactions on Electrical Insulation**, EI-13, n. 5, p. 349–354, out. 1978.
- [14] DUVAL, M. A review of faults detectable by gas-in-oil analysis in transformers. **IEEE Electrical Insulation Magazine**, v. 18, n. 3, p. 8–17, maio 2002.
- [15] WANI, S. A. *et al.* Multiple incipient fault classification approach for enhancing the accuracy of dissolved gas analysis (DGA). **IET Science, Measurement & Technology**, v. 13, n. 7, p. 959–967, 2019.
- [16] SENOUSSAOUI, M. E. A.; BRAHAMI, M.; FOFANA, I. Combining and comparing various machine-learning algorithms to improve dissolved gas analysis interpretation. **IET Generation, Transmission & Distribution**, v. 12, n. 15, p. 3673–3679, 2018.
- [17] ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR 7274:2012 – Interpretação da análise dos gases de transformadores em serviço**. Rio de Janeiro: [s. n.], 2012. Norma Brasileira. ICS 29.040.20.
- [18] BARBOSA, F. R.; ALMEIDA, O. M.; BRAGA, A. P. S.; AMORA, M. A. B.; CARTAXO, S. J. M. Application of an artificial neural network in the use of physicochemical properties as a low cost proxy of power transformers DGA data. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 19, n. 1, p. 239–246, fev. 2012.

- [19] MIRANDA, V.; CASTRO, A. R. G.; LIMA, S. Diagnosing faults in power transformers with autoassociative neural networks and mean shift. **IEEE Transactions on Power Delivery**, v. 27, n. 3, p. 1350–1357, jul. 2012.
- [20] GHONEIM, S. S. M.; TAHA, I. B. M.; ELKALASHY, N. I. Integrated ANN-based proactive fault diagnostic scheme for power transformers using dissolved gas analysis. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 23, n. 3, p. 1838–1845, jun. 2016.
- [21] YANG, Dongsheng; QIN, Jia; PANG, Yongheng; HUANG, Tingwen. A Novel Double-Stacked Autoencoder for Power Transformers DGA Signals With an Imbalanced Data Structure. **IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS**, v. 69, n. 2, p. 1977–1987, fev. 2022.
- [22] YAO, Z.; WANG, Y.; ZHANG, H. Diagnosis of Transformer Faults Based on Adaptive Neuro-Fuzzy Inference System and K-means Clustering. **IEEE Access**, v. 11, p. 12918–12928, 2023.
- [23] ZHANG, X.; LIU, R.; ZHAO, Y. Hybrid Deep Learning Model for Fault Diagnosis of Power Transformers Based on DGA. **IEEE Transactions on Instrumentation and Measurement**, v. 70, p. 1–11, 2021.
- [24] UNITED STATES DEPARTMENT OF THE INTERIOR – BUREAU OF RECLAMATION. **Facilities Instructions, Standards and Techniques (FIST) Manuals. Transformer Diagnostics. Volume 3-31**. [S. l.], 2000.
- [25] JACOB, Nathan D.; KORDI, Behzad; SHERIF, Sherif S. Assessment of Power Transformer Paper Ageing Using Wavelet Texture Analysis of Microscopy Images. **IEEE Transactions on Dielectrics and Electrical Insulation**, Institute of Electrical e Electronics Engineers (IEEE), v. 27, n. 6, p. 1898–1905, dez. 2020. ISSN 1558-4135. DOI: 10.1109/tdei.2020.009086.
- [26] LI, Shijun; GE, Zhao; ABU-SIADA, Ahmed; YANG, Liuqing; LI, Shengtao; WAKIMOTO, Kiyoshi. A New Technique to Estimate the Degree of Polymerization of Insulation Paper Using Multiple Aging Parameters of Transformer Oil. **IEEE Access**, Institute of Electrical e Electronics Engineers (IEEE), v. 7, p. 157471–157479, 2019. ISSN 2169-3536. DOI: 10.1109/access.2019.2949580.
- [27] GORGINPOUR, Hamed; GHIMATGAR, Hojat; TOULABI, Mohammad Sedigh. Lifetime Estimation and Optimal Maintenance Scheduling of Urban Oil-Immersed Distribution-Transformers Considering Weather-Dependent Intelligent Load Model and Unbalanced Loading. **IEEE Transactions on Power Delivery**, v. 37, n. 5, p. 4154–4165, 2022. DOI: 10.1109/TPWRD.2022.3146154.

- [28] ALBALAWI, Fahad. MACHINE LEARNING METHODS FOR TRANSFORMER HEALTH BASED ON THE DEGREE OF POLYMERIZATION OF INSULATING PAPER. **Indian Journal of Computer Science and Engineering**, ENGG Journals Publications, v. 14, n. 6, p. 929–936, dez. 2023. ISSN 0976-5166. DOI: 10.21817/indjcse/2023/v14i6/231406052.
- [29] ADEKUNLE, Andrew Adewunmi; FOFANA, Issouf; PICHER, Patrick; RODRIGUEZ-CELIS, Esperanza Mariela; ARROYO-FERNANDEZ, Oscar Henry. Analyzing Transformer Insulation Paper Prognostics and Health Management: A Modeling Framework Perspective. **IEEE Access**, Institute of Electrical e Electronics Engineers (IEEE), v. 12, p. 58349–58377, 2024. ISSN 2169-3536. DOI: 10.1109/access.2024.3391823.
- [30] MARQUES, André; MOURA, Nicolas Kemerich de; DIAS, Yuri Andrade; JESUS RIBEIRO, Cacilda de; ROCHA, Adson Silva; CUNHA BRITO, Leonardo da; BEZERRA AZEVEDO, Claudio Henrique; LOPES DOS SANTOS, Jose Augusto. Method for the evaluation and classification of power transformer insulating oil based on physicochemical analyses. **IEEE Electrical Insulation Magazine**, v. 33, n. 1, p. 39–49, 2017. DOI: 10.1109/MEI.2017.7804315.
- [31] FALATAH, Ahmed M.; YEHIA EL-NAGGAR, Ashraf. Transformer oil quality in view of its physicochemical, electrical properties and dissolved gas analysis. **Petroleum Science and Technology**, Informa UK Limited, v. 36, n. 19, p. 1552–1558, out. 2018. ISSN 1532-2459. DOI: 10.1080/10916466.2018.1482326.
- [32] KASSI, K. S.; FARINAS2, M. I.; FOFANA, I.; VOLAT, C. Analysis of Aged Oil on the Cooling of Power Transformers from Computational Fluid Dynamics and Experimental Measurements. **Journal of Applied Fluid Mechanics**, Academic World Research, v. 9, SI2, jun. 2016. ISSN 1735-3645. DOI: 10.36884/jafm.9.si2.25830.
- [33] TOUDJA, Tahar; MOULAI, Hocine; NACER, Azzeddine; BELDJILALI, Abdeslem; KHELIFANE, Ilham; DEBCHE, Ahmed. Moisture and electrical discharges effect on naphthenic mineral oil properties. **IET Science, Measurement & Technology**, Institution of Engineering e Technology (IET), v. 8, n. 6, p. 588–594, nov. 2014. ISSN 1751-8830. DOI: 10.1049/iet-smt.2013.0262.
- [34] INTERNATIONAL ELECTROTECHNICAL COMMISSION. **IEC 60156: Insulating liquids - Determination of the breakdown voltage at power frequency - Test method**. [S. l.: s. n.], 2025. Disponível em: <https://webstore.iec.ch/en/publication/66317>. Acesso em: 23 jun. 2025.
- [35] SENOUSSAOUI, Mohammed El Amine; BRAHAMI, Mostefa; FOFANA, Issouf. Transformer Oil Quality Assessment Using Random Forest with Feature Engineering.

- Energies**, MDPI AG, v. 14, n. 7, p. 1809, mar. 2021. ISSN 1996-1073. DOI: 10.3390/en14071809.
- [36] JUNIOR, Valdemir Sales Matias. **METODOLOGIA PARA AVALIAÇÃO DE TRANSFORMADORES DE ATÉ 24,2 kV ATRAVÉS DE TÉCNICAS DE APRENDIZADO DE MÁQUINA PARA DETERMINAÇÃO DO ÍNDICE DE SAÚDE**. 2023. Diss. (Mestrado) – Universidade Estadual Paulista Júlio de Mesquita Filho.
- [37] KHAN, M A Masud. AI AND MACHINE LEARNING IN TRANSFORMER FAULT DIAGNOSIS: A SYSTEMATIC REVIEW. **American Journal of Advanced Technology and Engineering Solutions**, American Scholarly Publishing Group Inc, v. 1, n. 01, p. 290–318, fev. 2025. ISSN 3067-0470. DOI: 10.63125/sxb17553.
- [38] HARBAJI, Mustafa; SHABAN, Khaled; EL-HAG, Ayman. Classification of common partial discharge types in oil-paper insulation system using acoustic signals. **IEEE Transactions on Dielectrics and Electrical Insulation**, Institute of Electrical e Electronics Engineers (IEEE), v. 22, n. 3, p. 1674–1683, jun. 2015. ISSN 1070-9878. DOI: 10.1109/tdei.2015.7116364.
- [39] LU, Shibo; CHAI, Hua; SAHOO, Animesh; PHUNG, B. T. Condition Monitoring Based on Partial Discharge Diagnostics Using Machine Learning Methods: A Comprehensive State-of-the-Art Review. **IEEE Transactions on Dielectrics and Electrical Insulation**, Institute of Electrical e Electronics Engineers (IEEE), v. 27, n. 6, p. 1861–1888, dez. 2020. ISSN 1558-4135. DOI: 10.1109/tdei.2020.009070.
- [40] WANG, Jingang; LI, Peiyuan; DENG, Xudong; LI, Na; XIE, Xi; LIU, Hang; TANG, Juan. Evaluation on Partial Discharge Intensity of Electrical Equipment Based on Improved ANFIS and Ultraviolet Pulse Detection Technology. **IEEE Access**, Institute of Electrical e Electronics Engineers (IEEE), v. 7, p. 126561–126570, 2019. ISSN 2169-3536. DOI: 10.1109/access.2019.2938784.
- [41] SUN, Yuanyuan; MA, Shuo; SUN, Shengya; LIU, Ping; ZHANG, Lina; OUYANG, Jun; NI, Xianfeng. Partial Discharge Pattern Recognition of Transformers Based on MobileNets Convolutional Neural Network. **Applied Sciences**, MDPI AG, v. 11, n. 15, p. 6984, jul. 2021. ISSN 2076-3417. DOI: 10.3390/app11156984.
- [42] KUNICKI, Michał; WOTZKA, Daria. A Classification Method for Select Defects in Power Transformers Based on the Acoustic Signals. **Sensors**, MDPI AG, v. 19, n. 23, p. 5212, nov. 2019. ISSN 1424-8220. DOI: 10.3390/s19235212.

---

## APÊNDICE A

# Estudo comparativo sobre predição do estado de transformadores de potência imersos em óleo mineral isolante por modelos matemáticos de ajuste aplicados

---

### A.1 Resumo

Os transformadores de potência são fundamentais para o sistema elétrico no que concerne ao fornecimento contínuo de energia, exigindo ferramentas eficazes de manutenção preventiva. Assim, o objetivo, neste trabalho, é a previsão acurada dos índices de desempenho de técnicas preditivas não invasivas aplicadas à avaliação de transformadores, oferecendo uma abordagem inovadora aplicável a diferentes cenários. Além disso, o índice de desempenho geral do equipamento é utilizado como referência para apoiar a tomadas de decisões. Nesse sentido, a metodologia adotada inclui o ajuste de curvas para três técnicas preditivas: análise de gases dissolvidos, ensaios físico-químicos e grau de polimerização/2FAL-Furfuraldeídos. Nos resultados, foram testados cinco tipos de ajustes (linear, quadrático, exponencial, gaussiano e soma de senos), e as expressões analíticas que melhor modelaram os dados foram determinadas. O critério do pior caso foi considerado para calcular os intervalos de tempo de cada classificação. A validação foi realizada com divisões de dados de treinamento/teste, utilizando a Raiz do Erro Quadrático Médio (RMSE) como métrica de desempenho. Conclui-se que o ajuste polinomial de segundo grau é o melhor ajuste para modelar os índices de desempenho, comprovando a originalidade deste trabalho<sup>5</sup>.

---

<sup>5</sup>Este capítulo é baseado no artigo publicado no periódico *Brazilian Journal of Production Engineering* [1].

**Palavras-chave:** ajuste, índice de desempenho, predição, manutenção, transformador de potência.

## A.2 Introdução

Os transformadores de potência são equipamentos estratégicos e essenciais no sistema elétrico de potência, representando grande parte dos investimentos realizados para implantação desse sistema [2]. Nesse sentido, a inferência da confiabilidade dos equipamentos que integram esse sistema está relacionada, principalmente, à frequência com que eles são submetidos a inspeções, manutenções preventivas ou, quando necessário, corretivas [3].

O conceito de índice de saúde, denominado neste artigo como índice de desempenho, representa uma metodologia de análise para auxiliar nas ações de avaliação da condição de transformadores em serviço e no agendamento da sua manutenção [4–6]. Ele consiste na combinação de resultados observacionais da operação, inspeções e ensaios de campo e de laboratório, pontuando, objetiva e quantitativamente, cada resultado [4, 5].

Dessa forma, neste trabalho, apresenta-se uma ferramenta para determinar as curvas de melhor ajuste ao índice de desempenho de transformadores de potência do sistema elétrico por meio de estudos de casos reais, a fim de prever o intervalo de tempo para cada ação recomendada em função da classificação do índice de desempenho previsto pelas curvas de melhor ajuste para cada técnica preditiva não invasiva. Destacando assim, a sua contribuição para a eficiência energética e para os estudos de otimização e de modelagem aplicados na gestão e na manutenção preventiva correlacionados às atividades efetivas da área de Engenharia de Produção.

Neste estudo, destacam-se as técnicas preditivas de manutenção referentes à avaliação do sistema isolante (óleo-papel) do transformador de potência, a saber: análise de gases dissolvidos em óleo (AGD), ensaio físico-químico (FQ) do óleo e grau de polimerização (GP)/2FAL-Furfuraldeídos do papel celulósico. Essas técnicas são descritas como:

- **Análise de gases dissolvidos:** está entre as principais técnicas preditivas não invasivas e que não demandam, para sua aplicação, desligamento do transformador de potência, o qual é um elemento fundamental e evita altos custos e transtornos ao sistema de fornecimento de energia elétrica [2]. Esse método é considerado confiável no setor elétrico para a detecção de falhas incipientes em transformadores imersos em óleo mineral isolante, sendo amplamente usado [3]. Ele fornece informações sobre os gases que são produzidos devido à degradação do óleo e de materiais isolantes sólidos do transformador [4, 5, 7];
- **Ensaio físico-químico:** possibilitam verificar o estado da isolamento líquida do equipamento em análise, definindo a necessidade de intervenção no óleo mineral

isolante que o compõe, como, por exemplo, se este deve ser submetido a tratamento por termovácuo ou, em casos extremos, regeneração ou substituição, para assegurar a robustez dielétrica e qualidade do sistema isolante [3]; e

- **Grau de polimerização (GP)/2FAL-Furfuraldeídos:** medir o grau de polimerização (GP) do isolante sólido de um transformador a fim de diagnosticar o envelhecimento da sua isolação sólida, requer a retirada de várias amostras de papel isolante do seu enrolamento, o que só pode ser feito após o desligamento e retirada do óleo da unidade [5]. Isso implica, além de grandes despesas para a empresa detentora, em risco de dano ao equipamento [5]. Dessa forma, utiliza-se para a determinação do GP um método indireto, por meio da análise de óleo, que correlaciona a concentração de furfuraldeído (2FAL) dissolvido no óleo com o grau de polimerização (GP) do papel [2, 3].

Os trabalhos publicados na literatura apresentam diferentes metodologias para o cálculo do índice de saúde de transformadores de potência [7–12] e para previsões [9, 12–21]. Porém, destaca-se a originalidade deste artigo em relação à nova metodologia prática com o desenvolvimento de uma ferramenta integrando três técnicas preditivas e validada por meio de estudos de casos reais de manutenção preventiva em transformadores de potência do sistema de energia brasileiro.

Outras metodologias abordam sistemas às vezes complexos e limitados a algumas técnicas preditivas específicas, como redes neurais artificiais (RNA) para prever falhas em transformadores de potência [20], que utilizaram três cenários simulados, demonstrando que o aumento de variáveis de entrada reduz a vida útil dos transformadores. Entretanto, o modelo apresentou a limitação de necessitar de uma maior abrangência, considerando mais equipamentos nos testes.

Em [19], abordou a técnica *Learning To Rank* para prever falhas com base em uma série histórica mensal de dados, exigindo maior rigor na escolha dos modelos-base e seus hiperparâmetros. Outro estudo foi o uso de regressão [15], que visou prever a temperatura dos transformadores de acordo com diferentes parâmetros operacionais; e a utilização de lógica *fuzzy* para analisar dados históricos de ensaios físico-químicos, propondo uma ferramenta sobre o análise do óleo isolante [16], com a validação limitada a um número considerado pequeno de transformadores. Modelos de incerteza com previsão de vida útil em transformadores em usinas nucleares foram integrados por [13]; e redes neurais para prever concentrações de gases em transformadores foram analisadas por [17].

Logo, destaca-se a importância deste trabalho em propor uma nova metodologia e ferramenta prática e eficiente, visando mitigar o impacto das falhas, diminuir os custos altos para as empresas e auxiliar as equipes de manutenção. Desta forma, este estudo apresenta o desenvolvimento de determinação de curvas analíticas de melhor ajuste para

os conjuntos de dados analisados, com uma única variável independente. Essa abordagem é justificada por:

- Complementar por meio de uma nova abordagem, proporcionando uma solução prática e acessível para equipes de manutenção que necessitam de previsões confiáveis, permitindo uma tomada de decisão rápida e assertiva; e
- Modelar, de maneira analítica e numericamente robusta, o estado real de operação de transformadores de potência imersos em óleo mineral isolante, facilitando sua aplicação e replicação em ambientes operacionais reais e oferecendo um custo-benefício favorável às empresas.

Assim, neste trabalho, prioriza-se a aplicabilidade e a robustez, facilitando a predição precisa de falhas com maior agilidade e eficiência, adotando também os critérios de classificação para os índices de desempenho descritos na Tabela A.1 [22], com as respectivas ações recomendadas para auxiliar na tomada de decisão, mediante os conceitos: A (Excelente), B (Bom), C (Suspeito), D (Ruim) e E (Péssimo).

Tabela A.1: Ações recomendadas em função da classificação do índice de desempenho predito

<b>Índice de desempenho projetado</b>	<b>Classificação</b>	<b>Ações recomendadas</b>
$1,0000 \geq y > 0,8000$	A (Excelente)	Continuar a operar o equipamento normalmente
$0,8000 \geq y > 0,6500$	B (Bom)	Continuar a operar o equipamento atento à evolução dos resultados nos próximos registros
$0,6500 \geq y > 0,5000$	C (Suspeito)	Investigar e realizar outros testes a curto prazo para confirmar resultados e tendências
$0,5000 \geq y > 0,3500$	D (Ruim)	Planejar a retirada de operação do equipamento para inspeção interna, localização e correção de defeitos
$0,3500 \geq y > 0,0000$	E (Péssimo)	Remover o equipamento de operação imediatamente para inspeção interna, localização e correção de defeitos

Fonte: DIAS, Y. A. (2022) [22]

### A.3 Metodologia

Neste artigo, utiliza-se cálculo numérico computacional para a determinação das curvas de melhor ajuste ao índice de desempenho relacionado às técnicas preditivas não invasivas relacionadas ao sistema isolante (papel-óleo) do transformador, ou seja, uma ferramenta específica para analisar o conjunto de dados, obtendo curvas de ajuste. Metodologicamente, é importante salientar que não se deve confundir interpolação com melhor ajuste, uma vez que este é um processo de suavização, dado que o número de coeficientes ajustados é muito menor que o número de pontos do conjunto [23].

Na metodologia empregada são desenvolvidos cinco tipos de ajuste ao conjunto experimental de pontos relacionados ao índice de desempenho de transformadores de potência, para análise de gases dissolvidos, ensaio físico-químico e grau de polimerização/2FAL-Furfuraldeídos, sendo  $y(t)$  a variável dependente índice de desempenho e  $t$  a variável temporal independente, a saber:

- **linear** (A.1), sendo  $n = 1$ ,  $c = 0$  e  $a$  e  $b$  os coeficientes calculados para o modelo [9].
- **quadrático** (A.1), sendo  $n = 2$  e  $a$ ,  $b$  e  $c$  os coeficientes calculados para o modelo [9].

$$y(t) = at^n + bt^{n-1} + ct^{n-2} \quad (\text{A.1})$$

- **exponencial** (A.2), sendo  $a$  e  $b$  constantes calculadas para o modelo.

$$y(t) = a \cdot \exp(-bt) \quad (\text{A.2})$$

- **gaussiano** (A.3), sendo  $a$ ,  $b$  e  $c$  constantes determinadas para o modelo.

$$y(t) = a \cdot \exp\left(-\left(\frac{t-b}{c}\right)^2\right) \quad (\text{A.3})$$

- **soma de senos** (A.4), sendo  $a_i$ ,  $b_i$  e  $c_i$  constantes calculadas para o modelo, fazendo-se  $i = 1$ .

$$y(t) = \sum a_i \cdot \sin(b_i t + c_i) \quad (\text{A.4})$$

Para avaliar a qualidade do modelo proposto, utiliza-se o coeficiente de determinação  $R^2$ , em (A.5), sendo  $y_{exp}$ ,  $y_{model}$  e  $y_{av}$ , nessa ordem, o valor experimental do índice de desempenho, o valor calculado do índice de desempenho e o valor médio do índice de desempenho [9].

$$R^2 = 1 - \left[ \frac{\sum (y_{exp} - y_{model})^2}{\sum (y_{exp} - y_{av})^2} \right] \quad (\text{A.5})$$

Para o correto funcionamento da ferramenta, deve-se ter as seguintes condições, como mostra a Figura A.1:

- **Dados de entrada:** valor do índice de desempenho e a data de registro, no formato dia, mês e ano;
- **Processamento:** ferramenta com condições de contorno; e
- **Dados de saída:** a equação da curva de ajuste e o valor do coeficiente de determinação,  $R^2$ , como em (A.5).

Figura A.1: Fluxograma das principais etapas de execução da ferramenta de melhor ajuste proposta



Fonte: próprios autores (2025)

Como condições de contorno das modelagens propostas em (A.1) até (A.4), considera-se que:

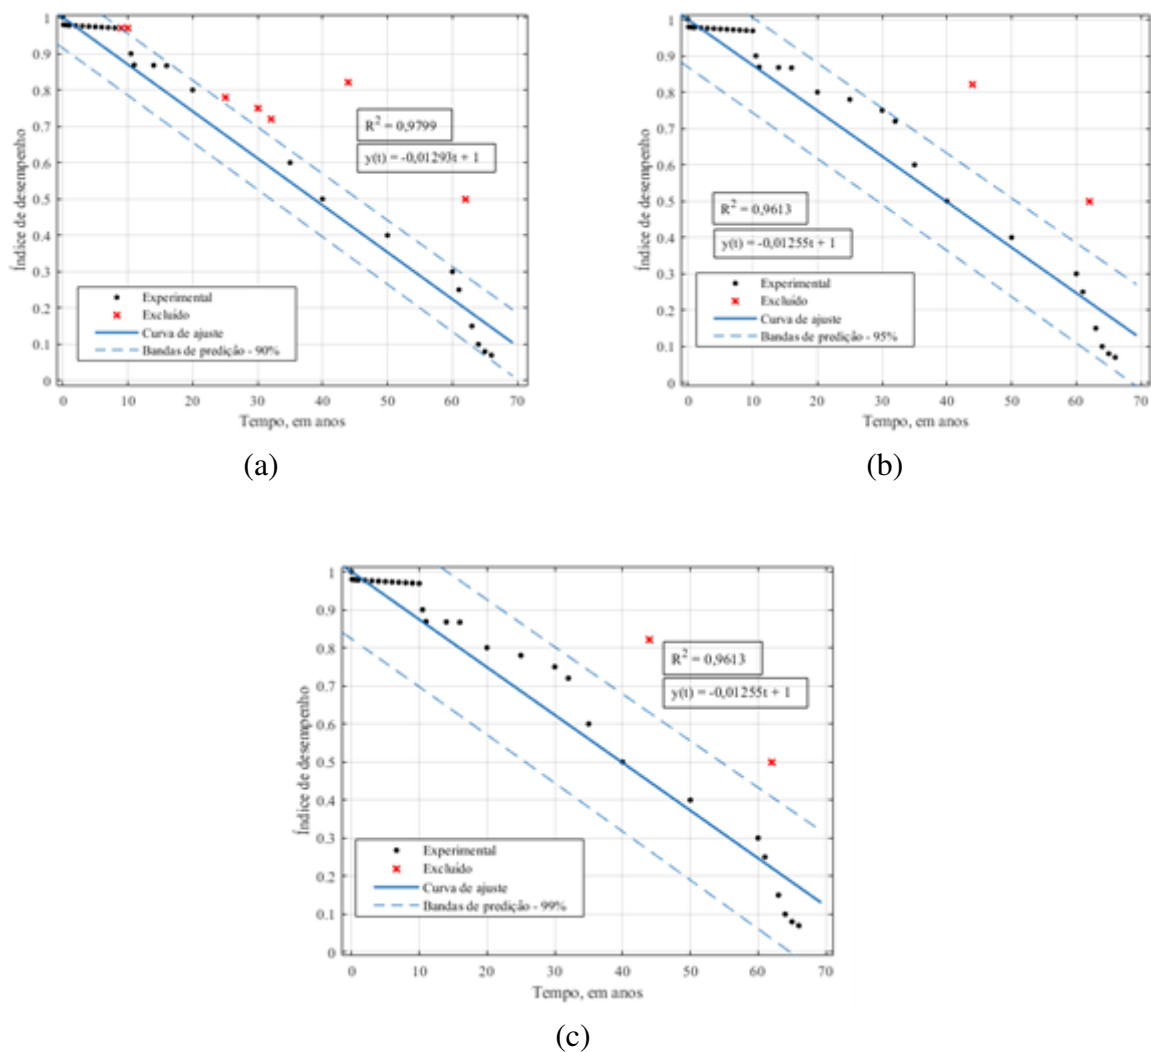
- a curva seja decrescente no intervalo considerado, uma vez que o índice de desempenho do transformador de potência deve diminuir com o passar do tempo de uso se não houver manutenção a fim de evitar que ele falhe; e
- o valor inicial do índice de desempenho seja unitário, uma vez que, para  $t = 0$ , o equipamento deve estar em seu melhor estado de uso, isto é, ser novo. Matematicamente, isso equivale a fazer  $\lim_{t \rightarrow 0^+} y(t) = 1$ .

## A.4 Resultados

### A.4.1 Análise de gases dissolvidos (AGD)

O primeiro modelo de ajuste proposto neste trabalho é o linear, isto é, o índice de desempenho do transformador,  $y(t)$ , é modelado como uma reta decrescente. O intervalo de predição da ferramenta pode ser ajustado em 90%, 95% ou 99%, como ilustrado na Figura A.2.

Figura A.2: Ajuste linear ao conjunto da AGD utilizando bandas de predição de: (a) 90%, (b) 95% e (c) 99%, com pontos excluídos, pelo método de quadrados mínimos linear



Quanto mais próximas de 100% estiverem as bandas de predição, maiores são as margens observadas de ajuste do conjunto, ou seja, mais distantes elas ficam da curva de ajuste. Embora para bandas de predição de 90% o ajuste obtido por  $R^2 = 0,9799$ ,

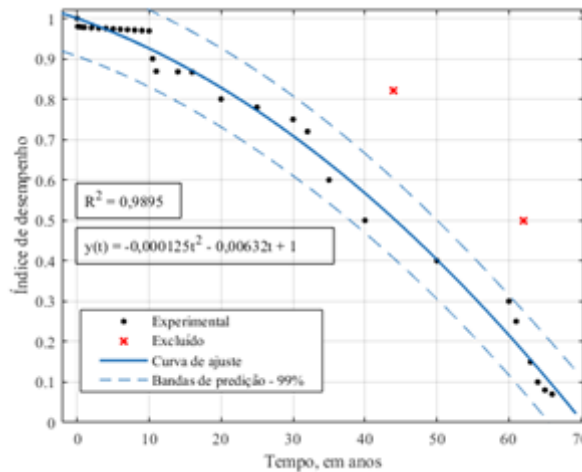
Figura A.4(a), seja melhor do que para bandas de predição de 95% ( $R^2 = 0,9613$ ) e 99% ( $R^2 = 0,9613$ ), Figura A.4(b) e Figura A.2(c), neste trabalho, as escolhidas são de 99%, uma vez que se eliminam menos pontos do conjunto para obtenção da reta de ajuste.

Na realidade, como não são eliminados os pontos que apresentam erros grosseiros de medição, a exclusão de *outliers* é evitada. Dessa maneira, a equação de ajuste linear para AGD encontrada é dada em (A.6) e igual comportamento físico se conduz por  $R^2 = 0,9613$ .

$$y(t) = -0,0125t + 1 \tag{A.6}$$

Em sequência, o ajuste quadrático é apresentado na Figura A.3. Em relação ao ajuste linear, o polinômio do segundo grau modela com maior acurácia o conjunto de pontos de AGD, com  $R^2 = 0,9895$ . O polinômio de segundo grau, em (A.7), que ajusta o conjunto tem validade somente para  $t \geq 0$  e  $y(t) \geq 0$ .

Figura A.3: Ajuste quadrático ao conjunto da AGD utilizando bandas de predição de 99%, com pontos excluídos, pelo método de quadrados mínimos linear



Fonte: próprios autores (2024)

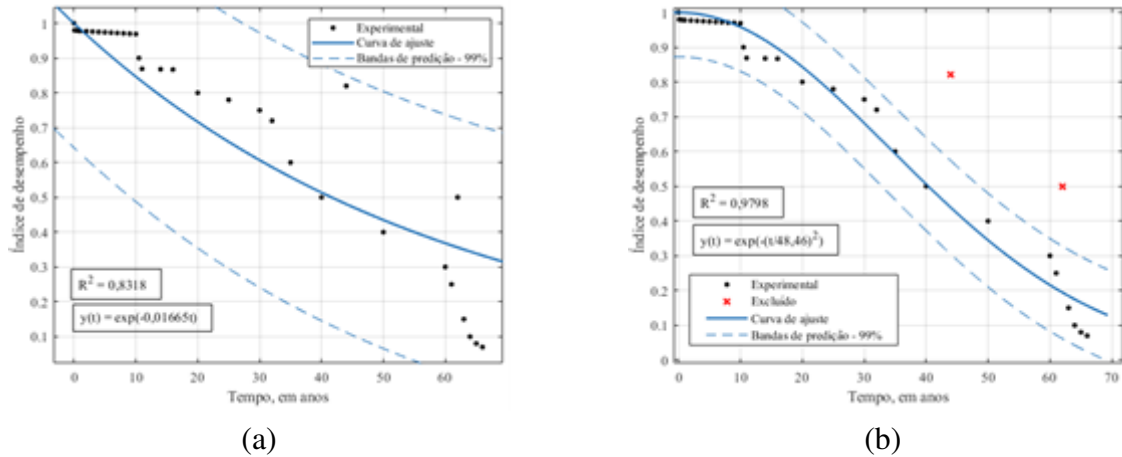
$$y(t) = -0,0001255t^2 - 0,00632t + 1 \tag{A.7}$$

Os ajustes exponencial e gaussiano, Figura A.4(a) e Figura A.4(b), revelam, entre si, qualidades de ajuste distintas: para a primeira curva,  $R^2 = 0,8318$ , enquanto, para a segunda,  $R^2 = 0,9800$ . Ambos os ajustes são muito interessantes para o estudo de caso, uma vez que funções com termos exponenciais são amplamente utilizadas para modelar confiabilidade e tempo de vida útil de transformadores de potência.

As curvas de ajuste exponencial e gaussiana têm validade somente para  $t \geq 0$ , nessa ordem, (A.8) e (A.9). É preciso notar que, em ambas as modelagens,  $\lim_{t \rightarrow \infty} y(t) = 0$ ,

o que faz com que o transformador de potência falhe para um  $t$  muito grande. Na prática, isso não é observado, uma vez que esses equipamentos possuem vida útil limitada.

Figura A.4: Ajuste ao conjunto da AGD utilizando bandas de predição de 99%, com pontos excluídos, pelo método de quadrados mínimos não linear: (a) exponencial e (b) gaussiano



Fonte: próprios autores (2024)

$$y(t) = \exp(-0,01665t) \tag{A.8}$$

$$y(t) = \exp\left(-\left(\frac{t+1,183}{49,76}\right)^2\right) \tag{A.9}$$


O ajuste por soma de senos, Figura A.5, traz uma forma de curva envolvendo função trigonométrica.

No ajuste por soma de senos, em (A.10), o aumento do número de termos da série produz oscilações entre os pontos experimentais e isso não é desejado. A validade de (A.10) é para  $0 \leq t \leq t_0$ , sendo  $t_0$  a primeira raiz positiva de  $y(t)$ . Para valores maiores que  $t_0$ ,  $y(t)=0$ .

$$y(t) = \sin(0,02283t + 1,571) \tag{A.10}$$

As curvas de ajuste, de (A.6) até (A.10), têm validade para quando o transformador de potência ainda não tiver falhado. O melhor ajuste obtido para a Análise de Gases Dissolvidos foi o quadrático ( $R^2 = 0,9895$ ), seguido pelo gaussiano ( $R^2 = 0,9798$ ), soma de senos ( $R^2 = 0,9731$ ), linear ( $R^2 = 0,9613$ ) e exponencial ( $R^2 = 0,8779$ ).

Figura A.5: Ajuste por soma de senos ao conjunto da AGD utilizando bandas de predição de 99%, com pontos excluídos, pelo método de quadrados mínimos não linear



Fonte: próprios autores (2024)

#### A.4.2 Ensaios físico-químicos

Para o ensaios físico-químicos, foram utilizadas: as curvas de ajuste linear, Figura A.6(a) e em (A.11); quadrático, Figura A.6(b) e em (A.12); exponencial, Figura A.6(c) e em (A.13); gaussiano, Figura A.6(d) e em (A.14); e soma de senos, Figura A.6(e) e em (A.15).

$$y(t) = -0,007933t + 1 \quad (\text{A.11})$$

$$y(t) = -6,865 \cdot 10^{-5}t^2 - 0,00437t + 1 \quad (\text{A.12})$$


$$y(t) = \exp(-0,01005t) \quad (\text{A.13})$$

$$y(t) = \exp\left(-\left(\frac{t}{69,65}\right)^2\right) \quad (\text{A.14})$$


$$y(t) = \sin(0,01748t + 1,571) \quad (\text{A.15})$$

As curvas de ajuste, de (A.11) até (A.15), têm validade para  $y(t) \geq 0$ ,  $t \geq 0$  e para quando o transformador de potência ainda não tiver falhado. O melhor ajuste obtido para o ensaio físico-químico foi o quadrático ( $R^2 = 0,9749$ ), seguido pelo gaussiano ( $R^2 = 0,9676$ ), linear ( $R^2 = 0,9410$ ), soma de senos ( $R^2 = 0,9314$ ) e exponencial ( $R^2 = 0,9077$ ).

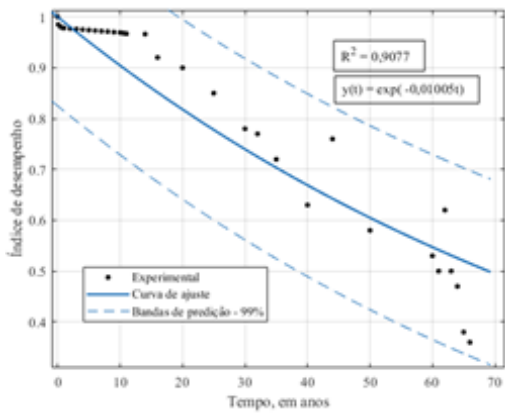
Figura A.6: Ajustes ao conjunto de ensaios físico-químicos utilizando bandas de predição de 99%, com pontos excluídos, pelo método de quadrados mínimos linear e não linear: (a) linear, (b) quadrático, (c) exponencial, (d) gaussiano e (e) soma de senos



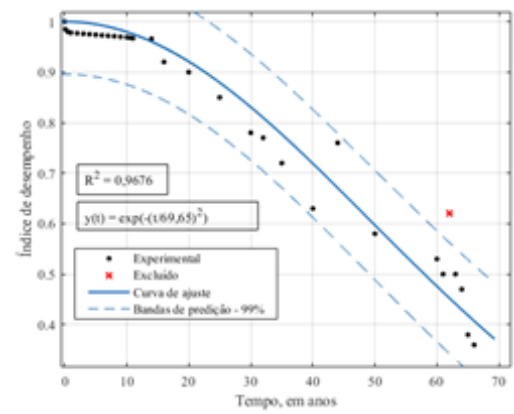
(a)




(b)



(c)



(d)



(e)

Fonte: próprios autores (2024)

### A.4.3 Grau de Polimerização/2FAL-Furfuraldeídos

Para o grau de polimerização (GP)/2FAL-Furfuraldeídos, foram utilizadas: as curvas de ajuste linear, Figura A.7(a) e em (A.16); quadrático, Figura A.7(b) e em (A.17); exponencial, Figura A.7(c) e em (A.18); gaussiano, Figura A.7(d) e em (A.19); e soma de senos, Figura A.7(e) e em (A.20).

$$y(t) = -0,007058t + 1 \quad (\text{A.16})$$

$$y(t) = -0,007058t + 1 \quad (\text{A.17})$$

$$y(t) = -6,323 \cdot 10^{-5}t^2 - 0,00355t + 1 \quad (\text{A.18})$$

$$y(t) = \exp(-0,008676t) \quad (\text{A.19})$$

$$y(t) = \exp\left(-\left(\frac{t}{78,06}\right)^2\right) \quad (\text{A.20})$$

$$y(t) = \sin(0,0164t + 1,571) \quad (\text{A.21})$$


As curvas de ajuste, de (A.16) até (A.21), têm validade para  $y(t) \geq 0$ ,  $t \geq 0$  e para quando o transformador de potência ainda não tiver falhado. O melhor ajuste obtido para o grau de polimerização/2FAL-Furfuraldeídos foi o quadrático ( $R^2 = 0,9508$ ), seguido pela soma de senos ( $R^2 = 0,9242$ ), pelo gaussiano ( $R^2 = 0,9232$ ), linear ( $R^2 = 0,9219$ ) e exponencial ( $R^2 = 0,8893$ ).

### A.4.4 Índice de desempenho geral do transformador


São calculados os ajustes ao índice de desempenho geral do transformador, analogamente ao desenvolvido para as técnicas preditivas do estudo, obtendo-se as curvas: linear, Figura A.8(a) e em (A.22); quadrática, Figura A.8(b) e em (A.23); exponencial, Figura A.8(c) e em (A.24); gaussiana, Figura A.8(d) e em (A.25); e soma de senos, Figura A.8(e) e em (A.26).

As curvas de ajuste, de (A.22) até (A.26), têm validade para  $y(t) \geq 0$ ,  $t \geq 0$  e para quando o transformador de potência ainda não tiver falhado. O melhor ajuste obtido para o índice geral de desempenho foi o quadrático ( $R^2 = 0,9791$ ), seguido pelo linear ( $R^2 = 0,9727$ ), exponencial ( $R^2 = 0,9463$ ), gaussiano ( $R^2 = 0,9550$ ) e soma de senos ( $R^2 = 0,9325$ ).


Figura A.7: Ajustes ao conjunto de grau de polimerização/2FAL-Furfuraldeídos utilizando bandas de predição de 99%, com pontos excluídos, pelo método de quadrados mínimos linear e não linear: (a) linear, (b) quadrático, (c) exponencial, (d) gaussiano e (e) soma de senos




(a)




(b)



(c)



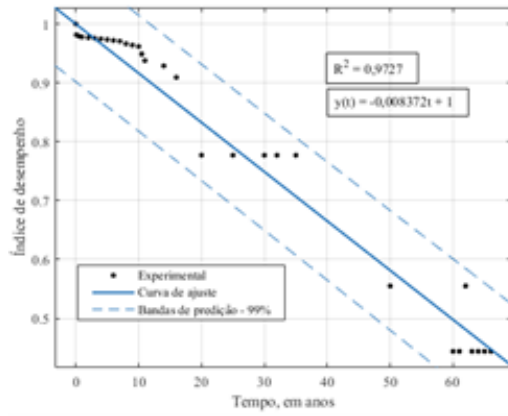
(d)




(e)

Fonte: próprios autores (2024)


Figura A.8: Ajustes ao conjunto do índice de desempenho geral utilizando bandas de predição de 99%, com pontos excluídos, pelo método de quadrados mínimos linear e não linear: (a) linear, (b) quadrático, (c) exponencial, (d) gaussiano e (e) soma de senos




(a)




(b)



(c)



(d)



(e)

Fonte: próprios autores (2024)

$$y(t) = -0,00832t + 1 \quad (\text{A.22})$$

$$y(t) = -3,623 \cdot 10^{-5}t^2 - 0,006314t + 1 \quad (\text{A.23})$$

$$y(t) = \exp(-0,01095t) \quad (\text{A.24})$$

$$y(t) = \exp\left(-\left(\frac{t}{69,37}\right)^2\right) \quad (\text{A.25})$$

$$y(t) = \sin(0,01774t + 1,571) \quad (\text{A.26})$$

Tabela A.2: Intervalo de tempo, em anos, para cada ação recomendada em função da classificação do índice de desempenho predito pelas curvas de melhor ajuste para cada técnica preditiva: análise de gases dissolvidos, ensaios físico-químicos e grau de polimerização/2FAL-Furfuraldeídos

Técnica preditiva	Melhor ajuste	Intervalo, em anos	Classificação
AGD	Quadrático	$0,0 \leq t \leq 22,0$	A
		$22,0 < t \leq 33,3$	B
		$33,3 < t \leq 42,8$	C
		$42,8 < t \leq 51,1$	D
		$51,1 < t \leq 67,6$	E
Ensaio físico-químico	Quadrático	$0,0 \leq t \leq 30,8$	A
		$30,8 < t \leq 46,3$	B
		$46,3 < t \leq 59,3$	C
		$59,3 < t \leq 70,5$	D
		$70,5 < t \leq 93,0$	E
GP/2FAL-Furfuraldeídos	Quadrático	$0,0 \leq t \leq 34,8$	A
		$34,8 < t \leq 51,4$	B
		$51,4 < t \leq 65,2$	C
		$65,2 < t \leq 77,1$	D
		$77,1 < t \leq 100,8$	E
Índice geral	Quadrático	$0,0 \leq t \leq 27,4$	A
		$27,4 < t \leq 44,2$	B
		$44,2 < t \leq 59,1$	C
		$59,1 < t \leq 72,7$	D
		$72,7 < t \leq 100,5$	E

Fonte: próprios autores (2024)

Em face dos ajustes às três técnicas preditivas e ao índice geral de desempenho, propõem-se os intervalos de tempo para cada classificação em função do índice de

desempenho previsto, conforme Tabela A.2, utilizando o melhor ajuste para conjunto analisado.

Como o coeficiente de determinação,  $R^2$ , foi utilizado para tomada de decisão sobre o melhor modelo de ajuste para cada técnica preditiva e para o índice de desempenho geral do transformador, é importante observar se houve grandes diferenças nesse parâmetro em função de cada ajuste proposto. Nesse sentido, compreende-se que, em alguns conjuntos, como o da análise de gases dissolvidos e o índice de desempenho geral, outros ajustes tenham ficado próximos ao melhor (quadrático), como o gaussiano e o linear.

#### A.4.5 Validação da ferramenta

Para a validação da ferramenta, os conjuntos de dados são divididos em dois: um destinado ao treinamento e outro ao teste. A amostra é distribuída de acordo com as seguintes proporções: 50% para treinamento e 50% para teste (50%/50%), 60% para treinamento e 40% para teste (60%/40%), 70% para treinamento e 30% para teste (70%/30%), 80% para treinamento e 20% para teste (80%/20%), 90% para treinamento e 10% para teste (90%/10%), conforme Tabela A.3. O parâmetro utilizado para avaliar a qualidade da validação é RMSE (Raiz do Erro Quadrático Médio) [24], dado em (A.27). Assim, a curva de ajuste quadrático determinada ao conjunto treinamento é usada para os pontos dos conjuntos de validação, calculando-se o desvio (erro) ponto a ponto.

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_{\text{exp}} - y_{\text{model}})^2}{n}} \quad (\text{A.27})$$

Tabela A.3: Raiz do Erro Quadrático Médio (RMSE) considerando o ajuste quadrático para cada técnica preditiva estudada (treino/teste)

Técnica preditiva	Métrica	50%/50%	60%/40%	70%/30%	80%/20%	90%/10%
AGD	RMSE	0,2742	0,4371	0,3473	0,0855	0,0686
Ensaio físico-químico	RMSE	0,2193	0,1112	0,2286	0,0693	0,0645
GP/2FAL-Furfuraldeídos	RMSE	0,2365	0,3487	0,3625	0,1803	0,1219
Índice geral	RMSE	0,2944	0,3887	0,0705	0,0640	0,0144

Fonte: próprios autores (2024)

Em face da validação proposta, a taxa de acerto máxima da ferramenta é 98,56% para o índice geral e, considerando as técnicas preditivas estudadas, é superior a 87,81%, quando consideradas as relações treinamento e validação iguais a 90%/10%.

## A.5 Considerações finais

Este trabalho traz uma contribuição aos estudos de índice de saúde de transformadores de potência, por meio da obtenção de curvas de melhor ajuste, utilizando o ajuste quadrático  $R^2$  como indicador de melhor modelo. A ferramenta funciona com a inserção, pelo usuário, da data e do índice de desempenho do transformador, e devido à sua versatilidade, ela pode ser usada vastamente para qualquer conjunto de interesse. Como saídas, ela fornece o  $R^2$  calculado e as equações analíticas das curvas de ajuste. Neste estudo, para as três técnicas preditivas relacionadas ao óleo do transformador, a saber análise de gases dissolvidos, ensaio físico-químico e grau de polimerização/2FAL-Furfuraldeídos, o ajuste quadrático foi o que obteve maior  $R^2$ , respectivamente, de 0,9895, 0,9749 e 0,9508.

Os intervalos de tempo previstos para cada classificação nas ações recomendadas mostram, nos estudos de casos abordados, que é esperado que o transformador de potência entre em condições de operação ruins (classificação D) a partir de, aproximadamente, 42 anos de uso, se consideradas técnicas preditivas relacionadas ao óleo do equipamento, ainda que nenhuma técnica preditiva deva ser usada isoladamente para se obterem conclusões gerais sobre o transformador.

Na etapa de validação, utilizando o ajuste quadrático, o qual possui o maior coeficiente de determinação para todas as técnicas estudadas, verificou-se que a raiz do erro quadrático médio (RMSE) máxima foi 36,25% (acurácia mínima de 63,75%) para o grau de polimerização/2FAL-Furfuraldeídos (relação 70%/30%), enquanto a mínima foi 1,44% (acurácia máxima de 98,56%) para o índice geral (relação 90%/10%).

Portanto, diante dos resultados, conclui-se que a ferramenta desenvolvida neste trabalho, sobre predição do estado de transformadores de potência imersos em óleo mineral isolante por modelos matemáticos de ajuste aplicados, proporciona contribuições práticas às áreas de otimização, modelagem, gestão e eficiência, auxiliando as equipes de manutenção nas tomadas de decisões assertivas, visando a diminuição de interrupções no sistema de energia.

## Referências

- [1] MENDANHA, Vinicius Faria Costa; MARQUES, André Pereira; DIAS, Yuri Andrade; RIBEIRO, Cacilda de Jesus. Estudos sobre predição do estado de transformadores de potência imersos em óleo mineral isolante por modelos matemáticos de ajuste aplicados. **Brazilian Journal of Production Engineering**, Universidade Federal do Espírito Santo, v. 10, n. 4, p. 226–240, dez. 2024. ISSN 2447-5580. DOI: 10.47456/bjpe.v10i4.46503.

- [2] MARQUES, A. P. **Diagnóstico otimizado de transformadores de potência mediante a integração de técnicas preditivas**. 2018. Tese (Doutorado) – Universidade Federal de Goiás.
- [3] DIAS, Y. **Rede Bayesiana para Estimativa da Confiabilidade de Transformadores e Potência Imersos em Óleo Mineral Isolante Utilizando Técnicas Preditivas de Manutenção**. 2019. Dissertação (Mestrado) – Universidade Federal de Goiás.
- [4] SILVA, D. G. T. da; BRAGA DA SILVA, H. J.; MARAFÃO, F. P.; PAREDES, H. K. M.; GONÇALVES, F. A. S. Enhanced health index for power transformers diagnosis. **Engineering Failure Analysis**, v. 126, p. 105427, 2021. DOI: 10.1016/j.engfailanal.2021.105427.
- [5] SILVA, D. G. T. da. **Índice de saúde aprimorado para diagnóstico de transformadores de potência**. 2020. Diss. (Mestrado) – Universidade Estadual de São Paulo.
- [6] SUÑE, J.; HEREDIA, L. A. **Guia de Manutenção para Transformadores de Potência**. [S. l.], 2013.
- [7] FERREIRA, A. M. J. **Cálculo de índices de saúde, vida restante e probabilidade de falha de transformadores de potência AT/MT**. 2015. Dissertação (Mestrado) – Universidade do Porto.
- [8] AZMI, A.; JASNI, J.; AZIS, N.; KADIR, M. Z. A. Ab. Evolution of transformer health index in the form of mathematical equation. **Renewable and Sustainable Energy Reviews**, v. 76, p. 687–700, 2017. DOI: 10.1016/j.rser.2017.03.094.
- [9] GOUDA, O. E.; EL DEIN, A. Z. Prediction of Aged Transformer Oil and Paper Insulation. **Electric Power Components and Systems**, v. 47, n. 4–5, p. 406–419, 2019. DOI: 10.1080/15325008.2019.1604848.
- [10] RIBEIRO, V. M. A. **Desenvolvimento e Análise de Indicadores de Condição de Transformadores de Potência**. 2016. Dissertação (Mestrado) – Universidade do Porto.
- [11] SONI, R.; MEHTA, B. Evaluation of power transformer health analysis by internal fault criticalities to prevent premature failure using statistical data analytics approach. **Engineering Failure Analysis**, v. 136, p. 106213, 2022. DOI: 10.1016/j.engfailanal.2022.106213.
- [12] XIE, P. Analysis of fault of insulation aging of oiled paper of a large-scale power transformer and the prediction of its service life. **IEEE Transactions on Electrical and Electronic Engineering**, v. 14, n. 8, p. 1139–1144, 2019. DOI: 10.1002/tee.22911.

- [13] AIZPURUA, J. I.; MCARTHUR, S. D. J.; STEWART, B. G.; LAMBERT, B.; CROSS, J. G.; CATTERSON, V. M. Adaptive Power Transformer Lifetime Predictions Through Machine Learning and Uncertainty Modeling in Nuclear Power Plants. **IEEE Transactions on Industrial Electronics**, v. 66, n. 6, p. 4726–4737, 2019. DOI: 10.1109/TIE.2018.2860532.
- [14] DUTTA, S.; DEY, J.; MISHRA, D.; BARAL, A.; CHAKRAVORTI, S. Prediction of Insulation Sensitive Parameters of Power Transformer Using Detrended Fluctuation Analysis Based Method. **IEEE Transactions on Power Delivery**, v. 37, n. 3, p. 1963–1973, 2022. DOI: 10.1109/TPWRD.2021.3102075.
- [15] FAVERI, R. de. **Modelagem Térmica de Transformadores – Método de Regressão Linear Múltipla para Previsão de Variáveis**. 2021. Dissertação (Mestrado).
- [16] FORTES, M. Z.; JUNIOR, H. D. P. A.; ATAIR CESAR DOMINGUETI JUNIOR; ABRITA, R. M.; ALBUQUERQUE, C. J. M. **Lógica fuzzy como ferramenta para diagnóstico de falhas em transformadores**. [S. l.: s. n.], 2006. DOI: 10.13140/RG.2.1.3446.2242.
- [17] LIN, J.; SU, L.; YAN, Y.; SHENG, G.; XIE, D.; JIANG, X. Prediction Method for Power Transformer Running State Based on LSTM\_DBN Network. **Energies**, v. 11, n. 7, p. 1880, 2018. DOI: 10.3390/en11071880.
- [18] LUO, D.; FANG, J.; HE, H.; LEE, W.-J.; ZHANG, Z.; ZAI, H.; CHEN, W.; ZHANG, K. Prediction for Dissolved Gas in Power Transformer Oil Based On TCN and GCN. **IEEE Transactions on Industry Applications**, v. 58, n. 6, p. 7818–7826, 2022. DOI: 10.1109/TIA.2022.3197565.
- [19] SERRANO, L. F. L.; DE AZEVEDO, V. M.; CARNEIRO LINS, A. J. D. C. Ferramenta de Aprendizado de Máquina para Previsão de Falha de Transformadores de Rede Elétrica. **Revista de Engenharia e Pesquisa Aplicada**, v. 5, n. 2, p. 44–50, 2020. DOI: 10.25286/rep.v5i2.1351.
- [20] SODRÉ, B. R.; SOTELO, G. G.; FERREIRA, V. H. Estimativa do Tempo para Falha de Transformadores de Potência Utilizando Dados do Centro de Operação e Redes Neurais Artificiais. In: ANAIS DO SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS 2020, 2020. **Anais [...]**.
- [21] TAGHIKHANI, M. A.; GHOLAMI, A. Prediction of hottest spot temperature in power transformer windings with non-directed and directed oil-forced cooling. **International Journal of Electrical Power & Energy Systems**, v. 31, n. 7–8, p. 356–364, 2009. DOI: 10.1016/j.ijepes.2009.03.009.
- [22] DIAS, Y. A. **Índice de desempenho em transformador de potência**. [S. l.], 2022.

- [23] PRESS, W. H.; TEUKOLSKY, S. A.; VETTERLING, W. T.; FLANNERY, B. P. **Métodos numéricos aplicados: Rotinas em C++**. 3. ed. Porto Alegre: Bookman, 2011. Tradução técnica: Sílvio Renato Dahmen e Roberto da Silva.
- [24] KARUNASINGHA, D. S. K. Root mean square error or mean absolute error? Use their ratio as well. **Information Sciences**, v. 585, p. 609–629, 2022. DOI: 10.1016/j.ins.2021.11.036.