Sistema Preditivo para Diagnóstico de Transformadores a Seco Baseado em Escala de Degradação de Isolamento

Mateus Caruso * **André Lucas F. N. de Souza** * **Marília N. e Silva** * **Cauê S. C. Nogueira** * **Flávio G. R. Martins** * **Vitor Hugo Ferreira** * **Guilherme G. Sotelo** * **Bruno W. França** *

* *Departamento de Engenharia Elétrica, Universidade Federal Fluminense, RJ (e-mail: mateuscaruso@id.uff.br)*

Abstract: The aging of power transformers is a natural operational effect, mainly due to insulation degradation caused by heating and mechanical stresses. Additionally, power transformers are subject to short circuits and overvoltages, which increase the dielectric stress on the insulation materials. Partial Discharges (PDs) are directly related to the degradation of winding insulation, which can evolve into Inter-Turn Short-Circuits (ITSC). This study proposes a monitoring and diagnostic system based on periodic PDs and ITSC measurements to infer a dry-type transformer's operational state. The methodology uses Machine Learning (ML) algorithms to correlate these events and predict possible failures. A hypothetical scale of insulation system degradation levels is proposed to allocate the operational state of the transformer, supporting the decision-making system. The system prototype is validated in a relevant industrial environment, indicating that the integration of online detection methods of PDs and ITSC with ML techniques shows promise for continuously monitoring transformer conditions.

Resumo: O envelhecimento dos Transformadores de Potência (transformadores) é um efeito natural de sua operação, principalmente pela degradação do isolamento causada por aquecimento e esforços mecânicos. Além disso, os transformadores estão sujeitos a curtos-circuitos e sobretensões, que aumentam a solicitação dielétrica dos materiais isolantes. Descargas Parciais (DPs) estão diretamente ligadas à degradação do isolamento dos enrolamentos, podendo evoluir para curtos-circuitos entre espiras (CEE). Este estudo propõe um sistema de monitoramento e diagnóstico baseado em medições periódicas de DPs e CEE para inferir o estado operativo de transformadores a seco. A metodologia envolve o uso de algoritmos de Aprendizado de Máquina para correlacionar esses eventos e prever possíveis falhas. Uma escala hipotética de níveis de degradação do sistema de isolamento é proposta para alocar o estado operativo do transformador, fundamentando o sistema de suporte à decisão. O protótipo do sistema é validado em ambiente industrial relevante, indicando que a integração de métodos de detecção online de DPs e CEE com técnicas de inteligência artificial mostra-se promissora para o monitoramento contínuo da condição dos transformadores.

Keywords: Decision Support System; Dry-type Transformer; Insulation Degradation; Inter-turn Short Circuit; Partial Discharges; Preventive Maintenance.

Palavras-chaves: Curto-circuito entre Espiras; Degradação do Isolamento; Descargas Parciais; Manutenção Preventiva; Sistema de Suporte à Decisão; Transformador a Seco.

1. INTRODUÇÃO

Assim como em qualquer equipamento, o envelhecimento do transformador de potência é uma consequência normal da operação. Segundo Wang et al. (2020), seu efeito mais notável é a degradação do sistema de isolamento devido ao aquecimento e aos esforços mecânicos oriundos da interação eletromagnética entre as espiras. Além desses ofensores, um transformador também está sujeito à ocorrência de curtos-circuitos, que levam a eventuais esforços eletromecânicos de grande intensidade nos enrolamentos, e sobretensões oriundas de manobras (energização de linhas, cargas indutivas ou capacitivas) que resultam no aumento da solicitação dielétrica dos materiais isolantes e ligações, podendo exceder a suportabilidade prevista em projeto.

Segundo Kavanagh et al. (2020), no contexto de operação e manutenção de equipamentos, a ocorrência de Descargas Parciais (DPs) está diretamente relacionada com a degradação do isolamento dos condutores que compõem as espiras dos enrolamentos. Com o passar do tempo, a ocorrência das DPs se intensifica e esta degradação natural se desenvolve em curtos locais, chamados curtos-circuitos entre espiras (CEE) (Metwally (2011)). A solução desenvolvida por Martins et al. (2023) é capaz de inferir

⋆ Este estudo foi financiado pela PETROBRAS por meio da ANP P&D 2021/00088-1.

o estado operativo do sistema de isolamento através de medições periódicas, simultaneamente de DPs e CEE, na tentativa de traçar um diagnóstico que correlaciona os dois eventos ou ainda de comprovar um processo de avanço de probabilidade de sua ocorrência ao longo do processo de degradação, como forma de validar a predição de falha do transformador. Devido à natureza aleatória das DPs, até o momento, não foi encontrada na literatura uma técnica que possa mapear a evolução do processo de degradação até a ocorrência de CEE. Portanto, fica evidente que o desenvolvimento do dispositivo é condição necessária para a investigação do processo de degradação e consequente comprovação do processo de diagnostico do estado operativo do transformador.

O sistema de monitoramento proposto e detalhado por Martins et al. (2023) tem a capacidade de diagnosticar CEE nos enrolamentos de alta tensão de transformadores a seco. Neste artigo é apresentada a proposta de um sistema preditivo para diagnosticar o estado de isolamento de transformadores a seco, classificando-o em uma escala hipotética de níveis de degradação. A alocação do estado atual da degradação do equipamento nesta escala serve como um indicador para auxiliar na tomada de decisão por profissionais de manutenção. Como metodologia, este trabalho visa aprofundar a discussão sobre o processo de degradação do isolamento, fornecendo uma estimativa inicial do caminho. Após esta introdução, o artigo está estruturado da seguinte forma: Na Seção 2 é abordada a revisão bibliográfica, que contextualiza o tema na literatura e fundamenta a criação da escala de degradação proposta. Em seguida, na Seção 3 é descrita a metodologia do sistema de diagnóstico, incluindo o tratamento de dados, os modelos de aprendizado de máquina implementados e a descrição da escala utilizada como parâmetro para a predição. Os detalhes da configuração experimental e os resultados obtidos até o momento são apresentados na Seção 4. Por fim, na Seção 5, são apresentadas as conclusões do estudo.

2. REVISÃO BIBLIOGRÁFICA

A literatura apresenta estudos escassos sobre o ciclo completo de vida do sistema de isolamento de transformadores a seco. Esta seção visa revisar o estado atual do conhecimento sobre as etapas de degradação e os sistemas de monitoramento e diagnóstico de transformadores a seco nesta abordagem.

O isolamento elétrico dos enrolamentos do transformador se deteriora ao longo do tempo devido principalmente ao envelhecimento térmico (Metwally (2011)), aquecimento ou carregamento cíclico e arranhões no isolamento elétrico devido às partículas associadas a impactos na área circundante. Em Hussain et al. (2021), um efeito comum que se desenvolve lentamente ao longo do tempo e pode levar à falha total do transformador é a descarga parcial. A norma internacional IEC60270 (2000) define descargas parciais como descargas elétricas localizadas que curto-circuitam parcialmente um material isolante entre dois condutores e que pode ou não acontecer adjacente a um dos condutores. Em resumo, as DPs são descargas elétricas ou faíscas que conectam parcialmente uma pequena seção do isolamento quando dois eletrodos condutores emergem da separação de concentrações distintas de cargas positivas e negativas. Ocorrem quando a intensidade do campo elétrico excede a rigidez dielétrica do isolamento e podem levar a um *flashover*. Se não forem percebidas, as DPs podem deteriorar completamente o sistema de isolamento do equipamento. Tozzi (2010) estabelece que níveis de DPs de 100-500 pC podem ser um indicativo de deterioração no isolamento.

A grande vantagem da detecção de DP é a existência, segundo a literatura, de métodos de diagnóstico online, que possibilitam que esta análise seja feita com o equipamento em operação, como os mostrados por Hussain et al. (2021) e Refaat et al. (2018). Estas técnicas são métodos não invasivos de detecção das DPs que podem ser aplicados em quatro vertentes de acordo com os dados necessários: acústica, sinais elétricos, eletromagnéticos e química. Em especial, as detecções por sinais elétricos são baseadas na medição da corrente gerada pela DP nos transdutores de detecção, que podem ser constituídos de acoplamentos capacitivos ou indutivos. O método de sensoriamento mais utilizado é uso de capacitor de acoplamento, que consiste em um capacitor de alta tensão conectado em paralelo com o equipamento. Ao utilizar esse método é possível obter a forma de onda da tensão, necessária para uma medida de DP sincronizada com a fase (Walczak and Sikorski (2021)).

Segundo Leal et al. (2020) e Meira et al. (2018), as falhas mais frequentes nos transformadores consistem em problemas de isolamento nos seus enrolamentos e buchas. A deterioração do isolamento dos enrolamentos do transformador se dá devido a danos no processo de fabricação, baixa qualidade ou envelhecimento do material isolante e pode produzir CEE. Métodos online de diagnóstico de CEE, a partir do monitoramento de grandezas elétricas, podem auxiliar na prevenção de falhas em transformadores. Algumas das estratégias de detecção online de curto-circuito entre espiras que monitoram grandezas elétricas são: a análise da variação dos enlaces de fluxo magnético pelos enrolamentos, como em Kang et al. (2010); A observação dos lugares geométricos V-I em Yao et al. (2014); A aplicação da Transformada de Park nas correntes diferenciais do transformador em Oliveira and Cardoso (2010) e Venikar et al. (2013), que também faz análise da admitância de sequência positiva; e o cálculo da corrente de sequência negativa (Vahedi and Behjat (2011)). Dentre estes, a aplicação da Transformada de Park se mostra como o método mais adequado para este estudo, pela facilidade de obtenção das grandezas necessárias e parametrização das amostras.

Segundo Oleg and Oleksii (2021), o sintoma principal que leva à suspeita de falhas no isolamento é o superaquecimento, com ocorrência de pontos quentes dentro dos enrolamentos quando já há curto-circuito entre espiras, entre enrolamentos e com o núcleo. A propagação das falhas com a operação prolongada sob condição defeituosa leva à perda de regulação e queda no rendimento (Kasikci (2018)) até, finalmente, desencadear em um curto-circuito que leve à parada total com danos severos aos enrolamentos do transformador.

3. METODOLOGIA

O sistema de diagnóstico e suporte à decisão se baseia nas amostras coletadas pela instrumentação no que se diz respeito a dois efeitos fundamentais: DPs e CEE. Estas

duas informações simultâneas serão disponibilizadas pela solução através da interface com o usuário, auxiliando o operador na tomada de decisão segundo a seguinte lógica, mostrada na Tabela 1 a seguir.

Tabela 1. Lógica do Sistema de Diagnóstico.

DP	CEE	Ação sugerida
NÃO	NÃO	Saudável. Nada a fazer
SIM	NÃO	Alerta. Manutenção preditiva
SIM/NÃO	SIM	Defeituoso. Manutenção corretiva.

No estado atual de desenvolvimento, a solução por si só fornece indicativos para apoio à decisão para a equipe de manutenção no sentido de permitir uma predição do estado do sistema de isolamento, sendo ele sadio ou defeituoso, sem risco ou em alerta.

3.1 Detecção de Descargas Parciais

A obtenção das assinaturas de DPs é feita através de um acoplador capacitivo conectado em uma fase do transformador a ser ensaiado, mostrado pelo esquemático da Figura 1. Este consiste em um filtro passa-alta de primeira ordem (resistivo-capacitivo série) ligado em paralelo ao enrolamento de alta tensão do transformador. A ocorrência de DPs produz pulsos de corrente com frequência fundamental da ordem de MHz que são absorvidos pelo filtro e direcionados para o sistema de aquisição, juntamente com o sinal de tensão advindo de um transformador de potencial para identificação do ângulo da incidência da DP.

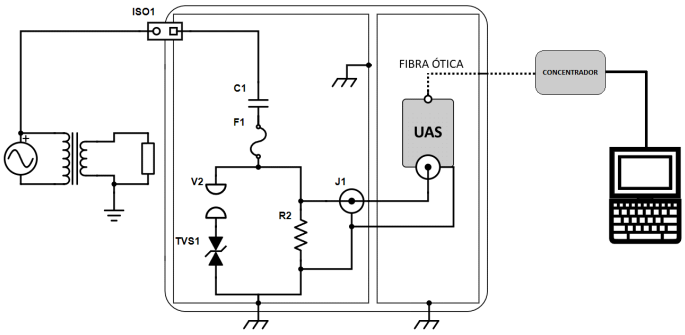

Figura 1. Esquemático do acoplador capacitivo.

O circuito é conectado ao transformador por meio de uma bucha cerâmica de passagem para média tensão (ISO1) com isolamento para até 15 kV. Em série, há um capacitor cerâmico (C1) com isolamento para 21 kV e capacitância de 2000 pF, um fusível de proteção do sistema (F1) com isolamento para 15 kV e corrente de ruptura de 0,5 A. O circuito também inclui um centelhador (V2) e um diodo TVS (TVS1) como parte de um circuito de proteção para altas frequências. Por fim, há um resistor (R2) onde são realizadas as medidas de DP. A tensão em R2 é conduzida para a Unidade de Aquisição de Sinais (UAS) por um cabo coaxial (J1), que transmite o sinal por fibra ótica, garantindo total isolamento do sistema. A Figura 2 mostra o protótipo do acoplador capacitivo montado para testes.

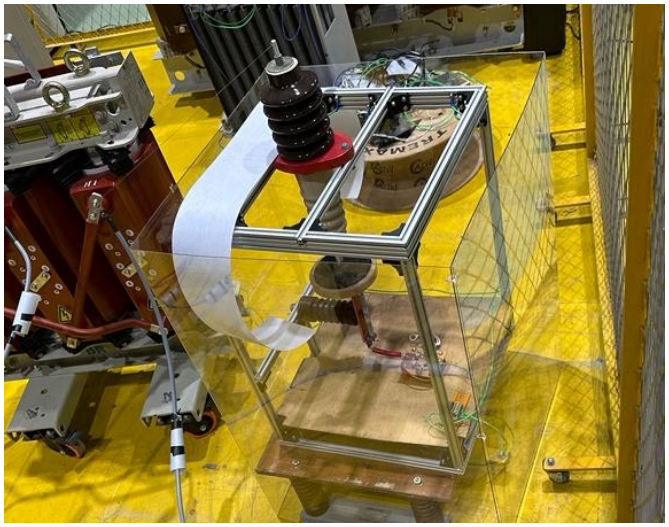

Figura 2. Protótipo de acoplador capacitivo em posição para o teste.

3.2 Diagnóstico de Curto-Circuito entre Espiras (CEE)

O diagnóstico de CEE é feito a partir das oscilografias das correntes de linha primárias e secundárias obtidas a partir de 3 Transformadores de Corrente (TCs) tipo janela em cada lado do transformador. As correntes trifásicas dos lados de baixa e alta são registradas e processadas a fim de se obter as correntes diferenciais no referencial de Park, conforme sugerido por Oliveira and Cardoso (2010) e Venikar et al. (2013). Especificamente para o caso de um transformador abaixador ΔY aterrado, as Equações (1) e (2) descrevem a transformações dos dados obtidos pelo sistema. Nestas equações, $i_{A,B,C}$ e $i_{a,b,c}$ são as correntes do primário e secundário, respectivamente; $i_{dA,B,C}$ e $i_{dD,Q}$ são as correntes diferenciais da amostra nas coordenadas ABC e DQ respectivamente; e α é a relação de transformação.

$$\begin{bmatrix} i_{dA} \\ i_{dB} \\ i_{dC} \end{bmatrix} = \begin{bmatrix} i_A \\ i_B \\ i_C \end{bmatrix} - \frac{1}{\alpha} \begin{bmatrix} 1 & 0 & -1 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} \tag{1}$$

$$\begin{bmatrix} i_{dD} \\ i_{dQ} \end{bmatrix} = \begin{bmatrix} \frac{\sqrt{2}}{\sqrt{3}} & \frac{-1}{\sqrt{6}} & \frac{-1}{\sqrt{6}} \\ 0 & \frac{-1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} i_{dA} \\ i_{dB} \\ i_{dC} \end{bmatrix} \tag{2}$$

A caracterização de uma amostra se dá com base nos parâmetros da elipse gerada pelo traçado de i_dD por i_dQ. Estes são estimados através do algoritmo *EllipseModel* implementado pela biblioteca de processamento de imagem *Scikit-image* do *Python*. Este utiliza um estimador de mínimos quadrados para elipses 2D. A Figura 3 exemplifica graficamente a parametrização de uma elipse pelo algoritmo.

As amostras são analisadas por três algoritmos de aprendizado de máquina em paralelo: O Perceptron de Múltiplas Camadas (MLP), A Máquina de Vetor Suporte (SVM) e a Árvore de Decisão. Estes foram treinados como classificadores binários e configurados para mostrar os rótulos e a probabilidade da amostra ser de cada classe: Sadio ou

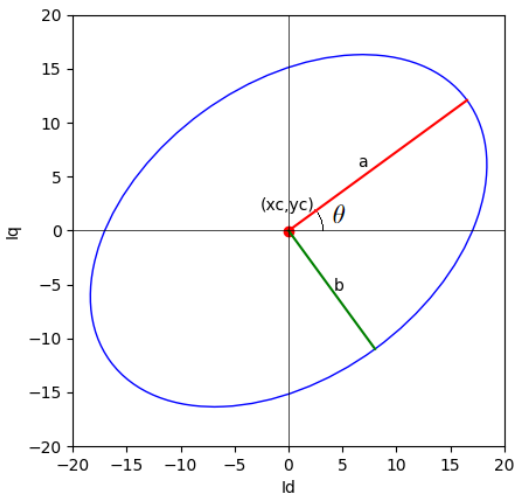

Figura 3. Exemplo da parametrização de uma elipse.

Não Sadio, visando determinar se há ou não CEE a partir do desequilíbrio entre as componentes das correntes. Como base de treinamento, o algoritmo utiliza um conjunto de assinaturas sintéticas de defeitos produzidas por simulações do transformador utilizando o Método dos Elementos Finitos (MEF). O treinamento e inferência de cada modelo se dão em paralelo e todos os resultados são apresentados ao usuário, sem interdependência entre eles.

Modelos dos algoritmos com diferentes topologias e parâmetros são criados e treinados iterativamente em busca do que melhor se enquadre na base de treinamento em termos de acurácia. O MLP utiliza a tangente hiperbólica como função de ativação, o algoritmo Adam para atualização dos pesos sinápticos e uma camada oculta, testando entre 1 e 20 neurônios nesta camada, buscando a maior acurácia. De maneira análoga, a SVM utiliza a Radial Basis Function (RBF) como função de *kernel* e testa os valores 1, 10, 50, 100 e 1000 para o hiperparâmetro de regularização de custo. Já a Árvore de Decisão busca a melhor acurácia entre três critérios de divisão distintos: índice de Gini, Entropia e Ganho de Informação de Shannon.

3.3 Previsão do Estado Operativo

A capacidade de diagnóstico e previsão do estado operativo do equipamento se baseia na detecção de DPs e CEE como indicadores de ações sugeridas, alocando os dados atuais e históricos na escala proposta pela Figura 4. Esta descreve o ciclo de vida do transformador no que se diz respeito ao estado do isolamento. Cada nível é classificado e definido pelas seguintes características:

- **Nível 1** – Equipamento Novo: Transformador recém-fabricado e em início de operação, projetado e construído com materiais adequados e sob condições controladas para minimizar defeitos e DPs. Apresenta nível extremamente baixo ou nulo de DPs, sem curtos-circuitos entre espiras nem pontos quentes no enrolamento;
- **Nível 2** – Aparecimento de DPs de Baixa Intensidade: Início da deterioração do isolamento, com DPs mensuráveis, porém de intensidade menor que 10 pC (Mukherjee et al. (2023)), sem impacto significativo no funcionamento do transformador. Não requer ação imediata;
- **Nível 3** – Aumento da Intensidade das DPs: Frequência e intensidade das DPs atingem ou ultrapassam os níveis estabelecidos pela norma IEC60270 (2000), indicando a necessidade de atenção para manutenção preventiva;
- **Nível 4** – Surgimento de CEE: Além de elevados níveis de DPs, são identificados CEE, resultando em perda de eficiência, regulação e alterações na relação de transformação. Representa um alerta elevado para a manutenção preventiva;
- **Nível 5** – Surgimento de *Hot Spots* (Pontos Quentes): Agravamento dos CEE gera pontos quentes crescentes nos enrolamentos, representando uma ameaça à integridade física do equipamento e dos operadores. Requer interrupção imediata da operação para manutenção;
- **Nível 6** – Falta de Fase e Destruição do Equipamento: Estágio avançado de deterioração, com falta completa de fase e possível destruição do transformador. Causa danos significativos, levando à interrupção total da operação, danos financeiros substanciais, possibilidade de incêndios e acidentes.

4. SETUP EXPERIMENTAL E RESULTADOS

A validação inicial envolveu a conexão e os testes de suportabilidade do hardware no nível de tensão proposto, além do diagnóstico de uma amostra coletada de um transformador sadio. Pela complexidade de realizar experimentalmente ensaios com transformadores apresentando CEE, estes estudos se darão futuramente. Para esta etapa do desenvolvimento, foram executados testes utilizando transformador a seco novo de fábrica de parâmetros nominais de 13,8 kV:127/220 V, potência de 30 kVA e ligado em ΔY.

Para treinamento do sistema, o modelo MEF do equipamento é submetido a uma série de cenários operacionais distintos, abrangendo tanto situações normais de operação quanto casos com CEE, considerando diversas cargas. As amostras são compiladas na base de treinamento ilustrada pelas amostras verdes e vermelhas da Figura 5. São geradas 246 amostras sintéticas para a construção da base de treinamento: 120 amostras sadias de operação; e 126 em situações defeituosas. As amostras sintéticas são gerados a partir das combinações de três cenários de CEE (0, 2 e 4%), variando os níveis de carga elétrica. Estas servem para o treinamento dos algoritmos de diagnóstico. Para este conjunto de dados, o modelo com maior acurácia no conjunto de validação foi definido como a Árvore de Decisão.

Para o processo experimental, foram disponibilizados equipamentos industriais de média tensão (13,8 kV) no pátio fabril do parceiro fabricante BRVAL Electrical. As Figuras 6 e 7 mostram o diagrama unifilar e a montagem dos equipamentos de potência e dos TCs da instrumentação. No ensaio, o transformador sob ensaio (Item 4 nas Figuras 6 e 7) é alimentado em média tensão por um segundo de 220 V:13,8 kV (Item 2) que, por sua vez, é alimentado por um autotransformador variável 1:1 (Item 1) conectado à rede de baixa tensão. A carga (Item 6) é composta por

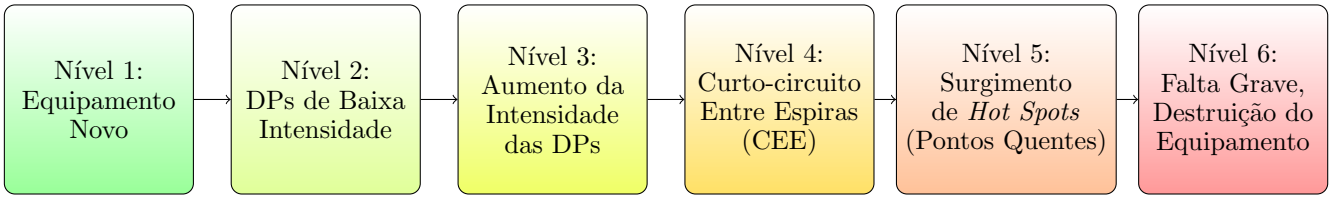

Figura 4. Proposta de estrutura para a deterioração do sistema de isolamento de transformadores.

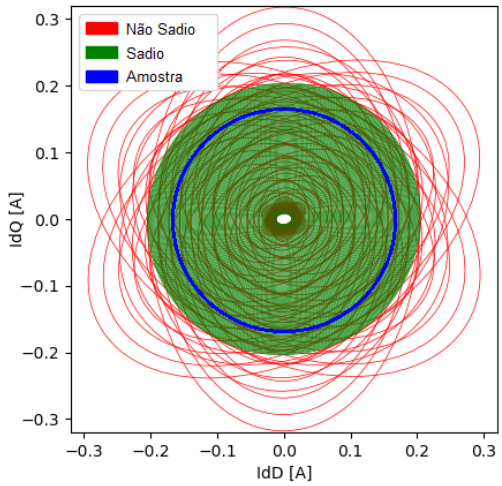

Figura 5. Amostras de casos sadios (verdes), não sadios (vermelhos) e amostra experimental parametrizada (azul) compondo a base de treinamento e a amostra para inferência.

um banco resistivo trifásico 220 V com capacidade de até 17 kW por fase. A instrumentação é composta por 6 TCs, sendo 3 de 250:5 A para o lado de alta tensão (Item 3) e 3 de 1500:5 A para o lado de baixa tensão (Item 5), além da placa de aquisição.

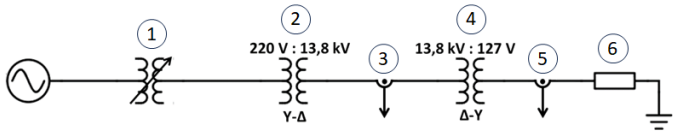

Figura 6. Diagrama unifilar da montagem experimental realizada.

As correntes trifásicas de ambos lados do transformador foram coletadas e transformadas para as coordenadas DQ, produzindo uma representação gráfica gerada pela projeção da corrente i_{dD} em função da corrente i_{dQ}. Essas correntes são utilizadas como amostra em um processo de estimação da elipse que melhor representa os dados, utilizando para tal o método dos mínimos quadrados. A elipse azul na Figura 5 mostra a amostra experimental parametrizada para inferência.

A amostra experimental sofreu inferência pelo sistema, onde o MLP atribuiu à amostra a classe sadia (93,82% de probabilidade), a SVM a classificou como não sadio (63,60%) e, por fim, a Árvore de Decisão classificou a amostra como sadia (100%). Por essa razão, o sistema como um todo classificou a amostra como pertencente à classe sadia. O sistema é composto por três algoritmos em paralelo com o objetivo de tornar a solução mais

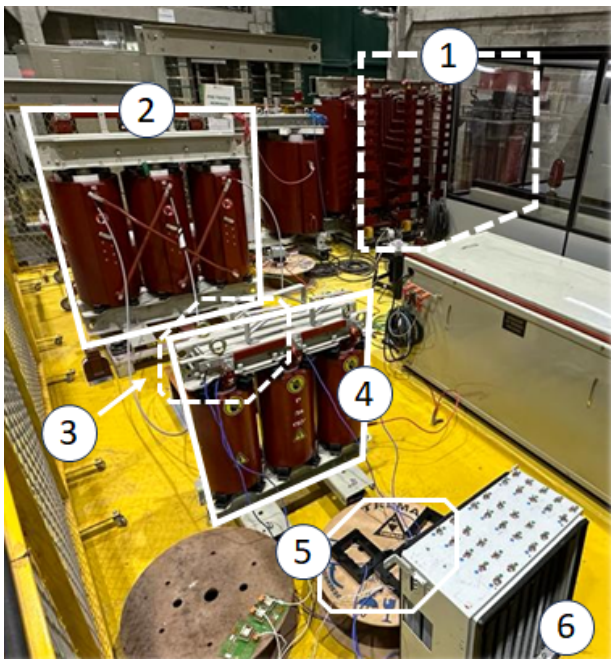

Figura 7. Montagem dos ensaios no pátio da BRVAL.

generalista, já que cada um deles se destaca em diferentes tipos de dados. Portanto, a falha na classificação pelo SVM não é vista como uma falha do método em si, mas sim como uma inadequação específica em relação à base de dados utilizada (Martins et al. (2023)).

Ao mesmo tempo, a avaliação pelo acoplador capacitivo não demonstrou registros relevantes de DPs para o experimento feito. Estes resultados alocam o equipamento estudado no Nível 1 da escala proposta pela metodologia. Esta é a resposta esperada visto que o equipamento foi aprovado nos testes de qualidade previstos em norma executados pelo fabricante.

5. CONCLUSÃO

Este artigo introduziu um método de diagnóstico e monitoramento do estado de isolamento de transformadores a seco. O sistema proposto é preditivo e se baseia em uma escala de seis níveis de degradação. Ele utiliza medições periódicas de DPs e CEE para inferir o estado operacional do transformador, auxiliando na tomada de decisão dos profissionais de manutenção. A metodologia empregada combina três algoritmos de Aprendizado de Máquina em paralelo, aproveitando suas vantagens individuais e fornecendo um diagnóstico múltiplo como indicador de manutenção.

Os resultados preliminares dos testes experimentais em um ambiente industrial relevante foram promissores, indicando que a integração de métodos de detecção online

de DPs e CEE com técnicas de aprendizado de máquina pode oferecer um monitoramento contínuo da condição dos transformadores, contribuindo para a redução de falhas e o aumento da confiabilidade do sistema elétrico. Trabalhos futuros devem focar na validação do sistema em equipamentos em diferentes estágios de degradação e em monitoramentos de longo prazo. Além disso, é fundamental o mapeamento dos padrões de DPs que levam o equipamento ao CEE. Este passo tem grande importância no desenvolvimento do método de análise das DPs, melhorando a precisão das previsões de falhas.

AGRADECIMENTOS

Este estudo foi financiado pela PETROBRAS por meio da ANP R&D 2021/00088-1 intitulada "Sistema de Monitoramento e Diagnóstico para Transformadores a Seco com Invólucro de Proteção IP 23". Os autores agradecem a fabricante BRVAL Electrical pela disponibilização do espaço e equipamentos para validação. Foi financiado, em parte, pelas agências brasileiras Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro – FAPERJ, Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES (cod. 001), Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq, Instituto Nacional de Ciência e Tecnologia em Energia Elétrica (CNPq-INCT INERGE) e a Rede Temática 723RT0150·RIBIERSE-CYTED.

REFERÊNCIAS

Hussain, M.R., Refaat, S.S., and Abu-Rub, H. (2021). Overview and partial discharge analysis of power transformers: A literature review. *IEEE Access*, 9, 64587–64605.

IEC60270, I.E.C. (2000). IEC60270 high-voltage test techniques – partial discharge measurements. (IEC 60270).

Kang, Y.C., Lee, B.E., Zheng, T.Y., Kim, Y.H., and Crossley, P. (2010). Protection, faulted phase and winding identification for the three-winding transformer using the increments of flux linkages. *IET generation, transmission & distribution*, 4(9), 1060–1068.

Kasikci, I. (2018). *Short circuits in power systems: A practical guide to IEC 60909-0.* John Wiley & Sons.

Kavanagh, D.F., Gyftakis, K.N., and McCulloch, M.D. (2020). Thermal degradation phenomena of polymer film on magnet wire for electromagnetic coils. *IEEE Transactions on Industry Applications*, 57(1), 458–467.

Leal, G., Meira, M., Bossio, G., Álvarez, R., and Verucchi, C. (2020). Detection of inter-turn short circuits in power transformers windings: State of the art. In *2020 IEEE Congreso Bienal de Argentina (ARGENCON)*, 1–8. IEEE.

Martins, F.G., Lopes, Y., França, B.W., Ferreira, V.H., Sotelo, G.G., Augusto, A.A., Colombini, A.C., Pinho, A.C., Mello, M.N., Costa, M.C., Nogueira, C.C., Silva, N., Melo, A., Soares, A.Z., and Fernandes, D. (2023). Monitoring and Diagnostic System for Dry-Type Transformers Using Machine Learning Techniques. volume Day 3 Thu, October 26, 2023 of *Offshore Technology Conference Brasil*, D031S041R007. doi: 10.4043/32700-MS. URL `https://doi.org/10.4043/32700-MS`.

Meira, M., Ruschetti, C.R., Álvarez, R.E., and Verucchi, C.J. (2018). Power transformers monitoring based on electrical measurements: state of the art. *IET Generation, Transmission & Distribution*, 12(12), 2805–2815.

Metwally, I.A. (2011). Failures, monitoring and new trends of power transformers. *IEEE potentials*, 30(3), 36–43.

Mukherjee, S., Evans, T.M., Huitink, D.R., and Mantooth, H.A. (2023). A partial discharge inception voltage modeling approach. *IEEE Open Journal of Power Electronics*, 4, 148–160. doi:10.1109/OJPEL.2023.3241853.

Oleg, S. and Oleksii, K. (2021). Recognition of high-temperature overheating in high-voltage power transformers by dissolved gas analysis. In *2021 IEEE International Conference on Modern Electrical and Energy Systems (MEES)*, 1–6. IEEE.

Oliveira, L.M. and Cardoso, A.M. (2010). A permeance-based transformer model and its application to winding interturn arcing fault studies. *IEEE transactions on power delivery*, 25(3), 1589–1598.

Refaat, S.S., Sayed, M., Shams, M.A., and Mohamed, A. (2018). A review of partial discharge detection techniques in power transformers. In *2018 Twentieth International Middle East Power Systems Conference (MEPCON)*, 1020–1025. IEEE.

Tozzi, M. (2010). Partial discharge in power distribution electrical systems: Pulse propagation models and detection optimization.

Vahedi, A. and Behjat, V. (2011). Online monitoring of power transformers for detection of internal winding short circuit faults using negative sequence analysis. *European Transactions on Electrical Power*, 21(1), 196–211.

Venikar, P., Ballal, M., Umre, B., and Suryawanshi, H. (2013). Condition assessment of transformer by park's vector and symmetrical components to detect inter turn fault. In *2013 IEEE 1st International Conference on Condition Assessment Techniques in Electrical Systems (CATCON)*, 163–168. IEEE.

Walczak, K. and Sikorski, W. (2021). Non-contact high voltage measurement in the online partial discharge monitoring system. *Energies*, 14(18), 5777.

Wang, Y., Feng, C., Fei, R., and Luo, Y. (2020). Thermal-ageing characteristics of dry-type transformer epoxy composite insulation. *High Performance Polymers*, 32(7), 741–752. doi:10.1177/0954008320906439. URL `https://doi.org/10.1177/0954008320906439`.

Yao, C., Zhao, Z., Chen, Y., Chen, X., Li, C., Li, W., and Wang, J. (2014). Detection of internal winding faults in power transformers based on graphical characteristics of voltage and current. In *2014 ICHVE International Conference on High Voltage Engineering and Application*, 1–4. IEEE.