

Diagnóstico de Descargas Parciais em Transformador de Corrente de Alta Tensão: Uma Abordagem com Transformada *Wavelet* e Redes Neurais Competitivas

Gifalli, A.¹, Crivelaro, M. G. S², Souza, A. N.¹, Gonzales, C. G.², Gonçalves, P. J. P.¹ Hublard, A. V. F.¹, Yamaguchi V. H. S.¹, Souza, A. A. Z. N.¹, Neto, E. S.¹, Silva, G. V.³,

Abstract—This article discusses the detection of Partial Discharges (PD) in high voltage Current Transformers (CT) using a combination of the Wavelet Transform and Competitive Neural Networks (CNN) of the Self-Organizing Map (SOM) kind. Partial discharges, as described by the IEC 60270:2015 standard, are electrical phenomena that can cause insulation degradation in high-voltage equipment, leading to major failures. This paper shows the importance of continuous monitoring and investigates both standard and novel detection methods, such as the use of high frequency sensors. The Wavelet Transform is used to reduce noise in PD signals, improving anomaly detection. The work uses real data from CT -145kV measured a high-voltage laboratory to identify and categorize PD, corona, and noise using an CNN algorithm. The results show that the proposed methodology is effective at discovering PD issues in CTs, which contributes to predictive maintenance and electrical power system safety.

Index Terms—Partial Discharges, High Voltage Current Transformers, Competitive Neural Networks, Wavelet Transform.

I. INTRODUÇÃO

A Descarga Parcial (DP) é definida pela norma IEC 60270:2015 [1] como uma descarga elétrica localizada que curto-circuita parcialmente o meio isolante entre condutores e que pode ocorrer tanto nas proximidades quanto afastada de um condutor. As descargas parciais são geralmente causadas por concentrações locais de tensão elétrica no interior do isolante (sólido ou líquido), em sua superfície ou em

Este trabalho foi financiado pela ISA CTEEP através do projeto PD-00068-0060/2022: “Desenvolvimento de uma Metodologia de Ensaio de Descarga Parcial para Diagnóstico de Ativos de Subestações Considerando Diferentes Conexões entre Dispositivos de Rede”, realizado no âmbito do Programa de Pesquisa e Desenvolvimento do Setor Elétrico (P&D), regulado pela Agência Nacional de Energia Elétrica (ANEEL) do Brasil.

¹Os pesquisadores são participantes do Laboratório de Sistema de Potência e Técnicas Inteligentes (LSISPOTI) da Univ. Estadual Paulista (UNESP) Bauru-SP, Brasil, (e-mail: andre.gifalli@unesp.br, andre.souza@unesp.br, paulo.paupitz@unesp.br, andre.von@unesp.br, victor.hs.yamaguchi@unesp.br, antonio.zago@unesp.br, erasmo.silveir@gmail.com).

² Engenheiros especialistas em soluções de engenharia de manutenção e operação de subestações e equipamentos de alta tensão da ISA CTEEP, Brasil, (e-mail: mcivelaro@isactEEP.com.br, gonzale@isactEEP.com.br).

³ Engenheiro especialista da High Voltage Equipments—HVEX, Itajubá, Brazil (e-mail: gustavo.silva@hvex.com.br).

meios gasosos denominados de “Corona”, manifestando-se frequentemente como impulsos de curta duração, inferiores a 1 μ s.

O ensaio de DP é essencial para identificar a degradação do isolamento em equipamentos de alta tensão, como Para-raios, Transformadores de Corrente (TC) e Transformadores de Potencial (TP). O resultado deste ensaio pode fornecer *insight* sobre as falhas no material isolante, que podem levar a problemas graves. Ao monitorar e analisar esses sinais, é possível identificar e corrigir falhas antes que se tornem críticas, prevenindo interrupções indesejadas e o prolongamento da vida útil dos equipamentos. Portanto, o ensaio de DP é vital para garantir a segurança e a confiabilidade dos sistemas elétricos de potência.

As concessionárias de energia utilizam este método padronizado pela NBR IEC 60270:2015 para diagnosticar falhas de DP em equipamentos de alta tensão, garantindo a confiabilidade do sistema. Realizado em ambientes controlados, como laboratórios de alta tensão, o ensaio permite o uso de dispositivos de calibração, capacitores de acoplamento, impedância de medição e medidores de DP. Esse tipo de medição beneficia-se do ambiente controlado do laboratório, onde os ruídos são significativamente atenuados, resultando em dados mais precisos e confiáveis.

O ensaio de DP pode ser realizado também por meio de métodos não convencionais [2]. Entre os métodos não convencionais, destacam-se os ensaios de alta frequência, que frequentemente utilizam transformadores de corrente de alta frequência, do inglês *High Frequency Current Transformers (HFCT)*. Esse método é interessante por ser não invasivo, permitindo a realização de monitoramento contínuo de equipamentos em operação (“*online*”). Essa abordagem é fundamental para avaliar a integridade do isolamento sem interromper o fornecimento de energia, o que reduz os custos associados a desligamentos.

Diversos estudos têm explorado o uso desses sensores e a aplicação de algoritmos de Inteligência Artificial (IA) para redução de ruídos (*denoising*) e classificação de DP, enfrentando desafios significativos como ruídos sinusoidais, ruídos de pulso periódico, ruídos de pulso estocástico, inter-

ferências aleatórias e ruídos brancos. Por exemplo, [3] desenvolveram uma metodologia para medir DP utilizando *HFCT's*, com foco na separação dos sinais de DP de ruídos externos, incluindo ruídos sinusoidais e estocásticos, por meio de filtros de transformada *Wavelet* e classificadores de pulsos. Em um estudo similar, [4] propuseram uma metodologia que utiliza mapas de energia e algoritmos de agrupamento para identificar fontes simultâneas de DP, mesmo na presença de interferências aleatórias e ruídos brancos, aumentando a precisão da medição em ambientes ruidosos. Esses métodos, ao combinar técnicas avançadas de filtragem com sensores HFCT, demonstram a eficácia na monitorização contínua e não invasiva de ativos elétricos, essencial para a identificação precoce de falhas.

A aplicação de algoritmos de IA, como redes neurais convolucionais (*Convolutional Neural Network - CNNs*) e redes de crença em profundidade (*Deep Belief Networks - DBNs*), tem sido crucial para enfrentar os desafios de ruídos diversos na classificação de sinais de DP. No trabalho desenvolvido por [5] os autores investigaram o uso de aprendizado ativo para distinguir sinais de DP de ruídos, como ruídos de pulso periódico e interferências aleatórias, em tempo real, alcançando alta precisão com mínima rotulagem de instâncias. Em [6] aplicaram DBNs para identificar diferentes tipos de DP, mostrando que essas arquiteturas de aprendizado profundo são capazes de lidar com sinais complexos e ruidosos sem a necessidade de pré-processamento intensivo. Além disso, estudos como os de [7] e [8] destacaram o uso de CNNs para detectar DP em sinais ruidosos, superando métodos tradicionais ao oferecer uma classificação mais robusta, mesmo na presença de ruídos brancos e sinusoidais. Essas pesquisas reforçam o avanço significativo da análise de DP, proporcionando soluções mais eficazes para a manutenção preditiva em sistemas de alta tensão, especialmente em ambientes adversos com elevados níveis de ruído.

Deste modo, este artigo tem o objetivo de implementar um algoritmo de identificação de padrões de DP e ruídos, utilizando Redes Neurais Competitivas (RNC) do tipo *Self-Organizing Map (SOM)* ou Mapa de Kohonen, Transformada *Wavelet* e dados reais medidos em laboratório de alta tensão da ISA CTEEP, para diagnosticar falhas em TC's.

II. MÉTODOS DE ANÁLISE E DIAGNÓSTICO DE DP

A. Phase-Resolved Partial Discharge (PRPD)

Na análise de Descargas Parciais Resolvidas em Fase (PRPD - *Phase-Resolved Partial Discharge*), realiza-se a medição e análise de três parâmetros fundamentais: a fase, a carga, e o número de eventos de descargas parciais que ocorrem em sistemas de isolamento elétrico. A fase refere-se ao ponto específico do ciclo de tensão em que cada descarga parcial ocorre, fornecendo informações sobre a natureza e localização potencial do defeito no material isolante. A carga, medida em picocoulombs (pC), indica a quantidade de carga elétrica liberada durante cada evento de descarga parcial, o que pode ser um indicador do grau de severidade do defeito. O número de eventos de descarga parcial representa a frequência com que esses eventos ocorrem, permitindo uma avaliação

quantitativa da atividade de descarga em um determinado período [9].

B. Pulse Sequence Analysis (PSA)

A Análise de Sequência de Pulsos (PSA, do inglês *Pulse Sequence Analysis*) é uma metodologia que considera os padrões dos pulsos de DP consecutivos, conforme ilustra a Fig. 1. Esse método parte do princípio de que os pulsos de DP anteriores influenciam diretamente as condições dos pulsos subsequentes. Considerando as correlações entre pulsos, tanto no tempo/fase do sinal ($\Delta\phi$) como na amplitude (ΔU), a PSA permite a identificação de padrões que seriam difíceis de detectar por meio de análises convencionais (PRPD) [10].

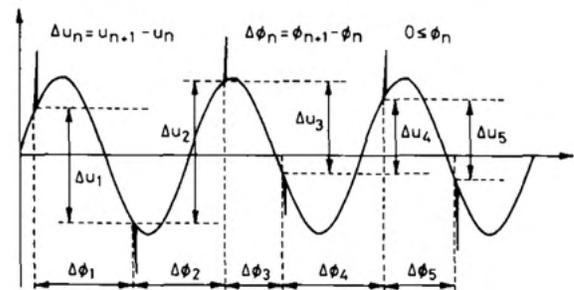


Fig. 1. Sinal de DP para Interpretação com o Método PSA [10].

III. MÉTODO DE REDUÇÃO DE RUÍDO - TRANSFORMADA *Wavelet*

A Transformada *Wavelet*, diferentemente da Transformada de *Fourier*, possibilita a análise simultânea de características no domínio do tempo e da frequência, um aspecto essencial para sinais não estacionários. Os sinais de DP são do tipo não estacionário e, portanto, a escolha da Transformada *Wavelet* Discreta (TWD) para redução do ruído se justifica por suas vantagens específicas. A aplicação deste método em sinais de DP não é recente [11] [12], porém com o avanço computacional têm se tornado cada vez mais viável em aplicações reais para monitoramento contínuo.

A TWD é também mais eficiente em termos computacionais do que a Transformada *Wavelet* Contínua, tornando-a adequada para aplicações em tempo real. Sua capacidade de reduzir ruído melhora a qualidade da detecção de anomalias e sua eficiência em lidar com sinais irregulares.

No caso deste trabalho, foi aplicada a *Wavelet Symlet* de ordem 6 (sym6). Esta escolha foi feita devido à sua boa combinação de simetria e capacidade de análise multirresolução. As *Wavelets Symlet*, uma extensão das *Wavelets* de *Daubechies*, são projetadas para oferecer maior simetria e suavidade na análise de sinais. Essas características são relevantes na detecção de DP em equipamentos de alta tensão, onde sinais de alta frequência e transientes precisam ser identificados com precisão.

IV. METODOLOGIA

O conjunto de dados utilizado neste trabalho foi construído em um laboratório de alta tensão da ISA CTEEP, composta por uma fonte ressonante de 2400 kVA e 600 kV.

Na etapa de coleta dos dados foi utilizado a metodologia descrita na Fig. 2 e Fig. 3, conforme preconiza a norma [1]. Essa configuração é constituída por um medidor de DP (DDX 9121b), impedância de medição, capacitor de acoplamento, HFCT de banda ultralarga (1.5 kHz a 200 MHz), osciloscópio de alta taxa de amostragem, ampla largura de banda, múltiplos canais e alta capacidade de memória e um TC de 145kV que foi retirado de operação por causa de falhas do sistema de isolamento, diagnosticado no ensaio de DP realizado no centro Centro de Especialidades de Inspeção da concessionária.

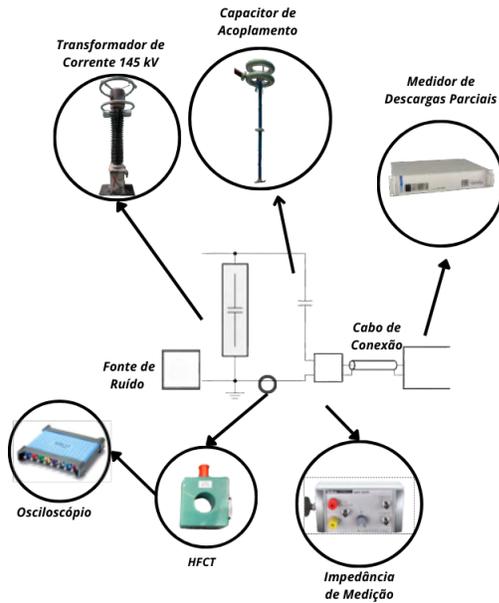


Fig. 2. Metodologia do Ensaio Realizado em Laboratório para Coleta dos Dados.



Fig. 3. Laboratório de Alta Tensão da ISA CTEEP - Metodologia do Ensaio.

Com o objetivo de implementar um algoritmo para identificação de padrões e classificação de Descargas Parciais

(DP), corona e ruídos, a metodologia deste trabalho foi desenvolvida com base nos estudos publicados por [13]. Utilizando dados reais medidos em laboratório, ruídos adicionais, como os gerados por chaveamento de cargas, foram intencionalmente inseridos na configuração dos ensaios para criar uma base de dados rotulados e uma base dados de teste. A metodologia considera a implementação da Transformada *Wavelet* e a RNC em Matlab. Além disso, também foram inseridos propositalmente condutores no anel de equalização do objeto sob ensaio para ocasionar o fenômeno "Corona".

A RNC do tipo SOM, utilizada neste trabalho, é composta por 20 neurônios e com uma taxa de aprendizagem de 0,1. A rede foi configurada com duas variáveis de entrada dos conjuntos de dados (Ruído, DP e Corona), sendo elas: $\Delta U_n / \Delta T_n$ e $\Delta U_{n-1} / \Delta T_{n-1}$:

- ΔU_n - Representa a variação de amplitude (ou magnitude) da tensão em um ponto específico n do sinal. No caso de sinais de DP, essa variação pode indicar a intensidade da DP em um determinado instante.
- ΔT_n - Representa a variação de tempo correspondente à variação de amplitude ΔU_n em um ponto n do sinal, ou seja, está relacionado ao intervalo de tempo durante o qual a variação de amplitude ocorre.
- ΔU_{n-1} - Refere-se à variação de amplitude da tensão em um ponto anterior $n1$ do sinal. É similar a ΔU_n , mas aplicado ao instante imediatamente anterior, permitindo a comparação de como a amplitude do sinal está mudando ao longo do tempo.
- ΔT_{n-1} - Representa a variação de tempo correspondente à variação de amplitude ΔU_{n-1} no ponto $n1$. Assim como ΔT_n , isso mede o intervalo de tempo durante o qual a variação anterior de amplitude ocorreu.

O algoritmo é executado por meio de um processo de auto-organização, onde os neurônios competem para se ajustarem aos padrões dos dados de entrada. Durante cada iteração, os pesos dos neurônios vencedores, juntamente com os de seus vizinhos no mapa, são ajustados para aproximarem-se das amostras de entrada, refinando a representação topológica dos dados.

O treinamento da rede resultou na redução de dimensionalidade de cada conjunto de dados (Ruído, DP e Corona) em uma amostra de 20 pontos ($\Delta U_n / \Delta T_n$ e $\Delta U_{n-1} / \Delta T_{n-1}$) para cada conjunto, representando os pesos dos neurônios que codificam os padrões presentes nos dados. Para identificar a característica de um sinal específico, a rede neural realiza uma comparação entre a amostra de entrada e os 20 pontos do agrupamento. A Fig. 4 ilustra essa topologia da RNC, considerando os pesos sinápticos (w) que determinam a força da conexão entre as entradas e os neurônios da camada competitiva, e bias (b) que ajusta o limiar de ativação dos neurônios.

Posteriormente, a distância euclidiana é calculada para cada ponto, e a característica do sinal é atribuída ao ponto que apresenta a menor distância em relação à amostra. Esse processo permite uma classificação eficiente dos sinais, preservando a topologia das entradas e garantindo que características

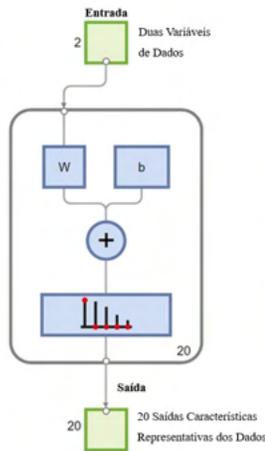


Fig. 4. Topologia da RNC utilizada.

semelhantes sejam mapeadas para regiões próximas no espaço de saída.

A construção da base de dados, permitiu avaliar o desempenho da RNC na redução da dimensionalidade e consequentemente classificação e diagnóstico.

V. RESULTADOS E DISCUSSÕES

As Fig. 5 e Fig. 6 ilustram os sinais utilizados nos conjuntos de dados rotulados (dados para comparação) e dados de teste, tanto no domínio do tempo quanto no domínio da frequência, com este último normalizado.

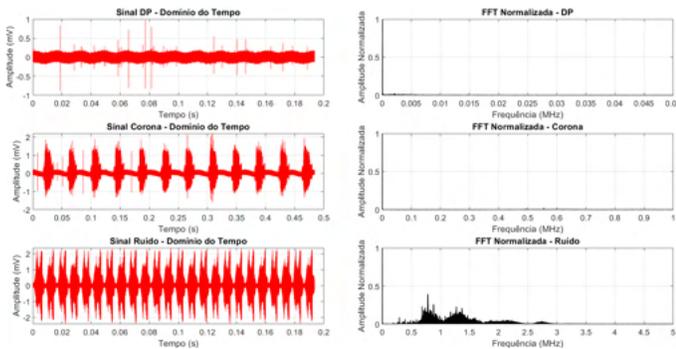


Fig. 5. Sinais de DP, Corona e Ruído no Domínio do Tempo e Frequência, utilizados na etapa de caracterização da RNC.

A faixa de 60 Hz é destacada como a frequência da senoide fundamental, predominante nos sinais de DP e corona. Entretanto, a análise dos sinais no espectro em MHz é crucial, pois as descargas parciais tendem a gerar componentes de alta frequência, evidenciadas pelos picos nessa faixa nos sinais de ruído.

Nota-se que no domínio do tempo, ambos os sinais apresentam variações significativas na amplitude, especialmente nos sinais de DP e de corona, característicos de eventos de descarga. Além disso, nos gráficos da *Fast Fourier Transform* (FFT), observa-se que, para os sinais de DP e corona, há picos distintos em baixas frequências, enquanto o sinal de

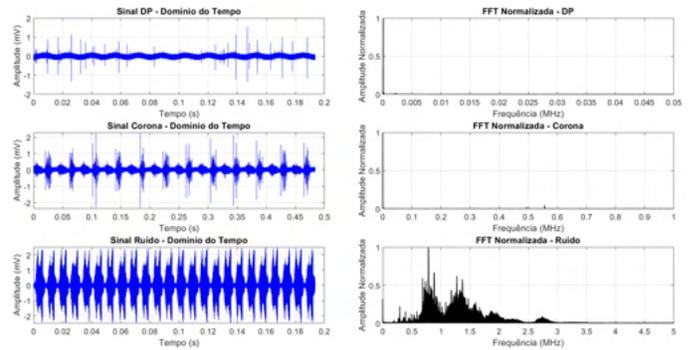


Fig. 6. Sinais de DP, Corona e Ruído no Domínio do Tempo e Frequência, utilizados na etapa de testes da RNC.

ruído apresenta um espectro de frequência mais distribuído, com componentes mais marcantes na faixa de 0,7 a 3 MHz. Esse comportamento é esperado, já que ruídos geralmente têm uma distribuição de energia em uma faixa mais ampla de frequências. A normalização da FFT permitiu uma comparação direta das magnitudes de frequência, facilitando a identificação das características dominantes em cada tipo de sinal.

A análise das FFT's normalizadas indica que as características principais dos sinais (treinamento e teste) foram preservadas entre os conjuntos, sendo essencial para a robustez da RNC utilizada no diagnóstico.

Os *HFCT's* utilizados nos ensaios possuem uma elevada banda de frequência e por isso observa-se nos gráficos no domínio da frequência o valor unitário na faixa de 60 Hz da senoide fundamental. Além disso, observa-se que em todos os casos um ruído ambiente na faixa de 0,2 mV.

Ressalta-se que o conjunto de dados de treinamento e testes foram medidos em tempos distintos. Observa-se que o comportamento no domínio da frequência é semelhante, com frequências dominantes em faixa de MHz para o caso dos sinais ruidosos.

A Fig. 7 apresenta os resultados do método PSA para o conjunto de testes, subdividido em três categorias: A - DP, B - Corona e C - Ruído. Observa-se que os pontos correspondentes aos dados de DP são mais dispersos, enquanto os dados de corona e ruído demonstram uma maior concentração, exibindo, na maioria dos casos, uma linearidade crescente. Além disso, devido à natureza repetitiva e padronizada de alguns pulsos de DP, o gráfico pode dar a impressão de haver menos pontos em comparação aos demais. No entanto, essa característica pode resultar na sobreposição de pontos, o que dificulta a visualização de todos os dados.

Devido à grande quantidade de dados das duas variáveis ($\Delta U_n / \Delta T_n$ e $\Delta U_{n-1} / \Delta T_{n-1}$), foi implementada uma RNC para reduzir a dimensionalidade a 20 pontos que representem as características predominantes de todos os dados de entrada. A partir desse resultado, é possível calcular a distância euclidiana entre os pontos e realizar a somatória para classificar os sinais. A Fig. 8 apresenta o resultado da redução da dimensionalidade (característica extraída da RNC) para os dados rotulados e de teste, organizados nas categorias A - DP,

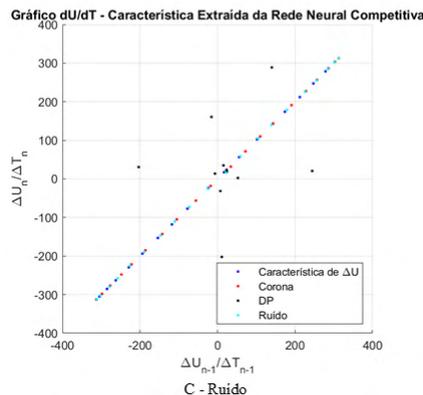
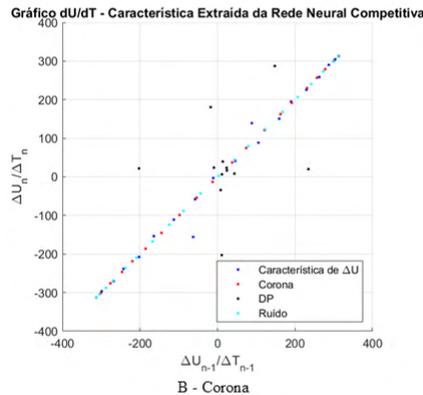
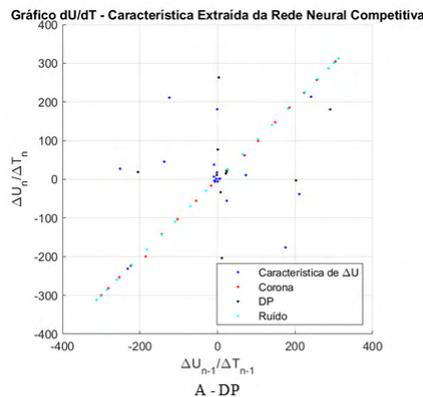
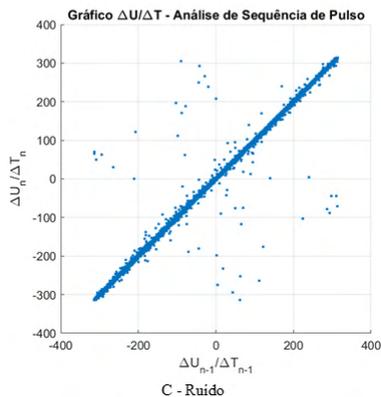
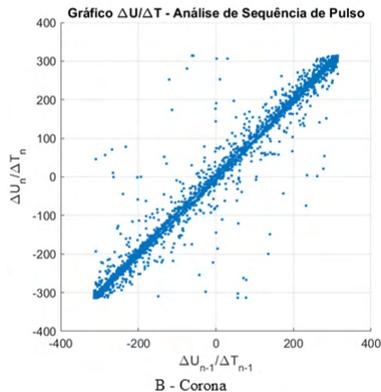
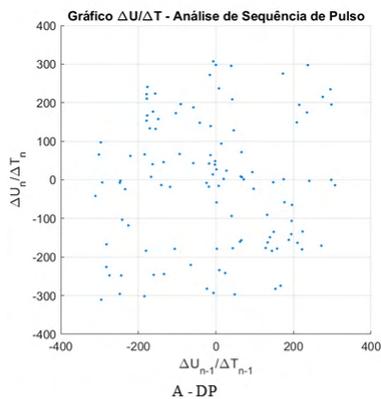


Fig. 7. Resultado do Método PSA - A DP; B - Corona; C - Ruído.

Fig. 8. Resultado da RNC - A DP; B - Corona; C - Ruído.

B - Corona e C - Ruído.

No gráfico A, observa-se uma maior proximidade dos pontos correspondentes às descargas parciais (DP), representados pela cor preta, em relação às características extraídas do sinal de DP, que estão na cor azul. Isso indica que a distância euclidiana entre esses pontos é menor, resultando em um diagnóstico mais assertivo. Por outro lado, para os sinais de corona e ruído, a distinção visual não revela claramente a proximidade entre os pontos, dificultando a interpretação da distância entre eles.

A Fig. 9 ilustra o resultado da soma da distância euclidiana para cada uma das características analisadas. Essa análise confirma a assertividade no diagnóstico de todos os

sinais, validando a metodologia desenvolvida neste trabalho. A consistência observada na classificação dos sinais sugere que a abordagem adotada não apenas é eficaz, mas também pode ser aplicada em contextos práticos para monitoramento e manutenção preditiva de TCs, contribuindo para a prevenção de falhas e melhoria da confiabilidade operacional destes equipamentos.

VI. CONCLUSÃO

Os resultados apresentados neste artigo demonstram que a combinação de Transformada *Wavelet* e Redes Neurais Competitivas é uma abordagem promissora para o diagnóstico de descargas parciais em transformadores de corrente de alta tensão. A análise dos dados coletados em laboratório

demonstra a capacidade do algoritmo em distinguir entre descargas parciais, corona e ruídos, contribuindo significativamente para a manutenção preditiva e a confiabilidade dos sistemas elétricos. Os resultados obtidos indicam que a utilização de técnicas avançadas de filtragem e aprendizado de máquina não apenas melhora a precisão das medições, mas também possibilita um monitoramento contínuo, não invasivo e automatizado, reduzindo custos operacionais associados à interrupções intempestivas do fornecimento de energia.

Em trabalhos futuros, serão coletados novos dados com foco na identificação dos sinais de descargas parciais em equipamentos energizados, permitindo uma avaliação mais abrangente e realista das condições operacionais. Essa abordagem poderá auxiliar a concessionária na identificação de falhas incipientes, garantindo a segurança e a integridade dos equipamentos de alta tensão.

VII. AGRADECIMENTOS

Os autores agradecem o apoio financeiro do Programa de Pós-graduação em Engenharia Elétrica da Faculdade de Engenharia de Bauru, o apoio financeiro e técnico da empresa ISA CTEEP, a partir do do projeto de Pesquisa e Desenvolvimento (P&D) PD-00068-0060/2022, o apoio técnico da empresa HVEX e a todos os colegas do Laboratório de Sistemas de Potência e Técnicas Inteligentes (LSISPOTI).

REFERENCES

- [1] ABNT. *NBR IEC 60270:2015 - Técnicas de ensaios elétricos de alta-tensão: Medição de descargas parciais*. Rio de Janeiro: Associação Brasileira de Normas Técnicas, 2015.
- [2] GULSKI, E. et al. *Guidelines for Un-conventional Partial Discharge Measurements*. Draft 3.0, Version 17-Oct-07. Prepared on behalf of CIGRE WG D1.33. Reports about the state of the art of non-conventional PD detection methods. A Task Force 03 “Measurements of PD” has been established to prepare for IEC TC 42 “High voltage test techniques” a proposal for a future standard to cover the applications for electromagnetic (HF/VHF/UHF) and acoustic measurements.
- [3] Alvarez, F., Ortego, J., Garnacho, F., Sanchez-Uran, M. A., and Prieto, D. Partial discharge experiences in HV grids applying wideband measurements. In: *ICHVE 2014 - 2014 International Conference on High Voltage Engineering and Application*. 2014. DOI: <https://doi.org/10.1109/ICHVE.2014.7035446>.
- [4] Albarracín-Sánchez, R., Álvarez-Gómez, F., Vera-Romero, C. A., and Rodríguez-Serna, J. M. Separation of partial discharge sources measured in the high-frequency range with HFCT sensors using PRPD-teff patterns. *Sensors (Switzerland)*, vol. 20, no. 2, 2020. DOI: <https://doi.org/10.3390/s20020382>.
- [5] Gomes, J. B., Nguyen, H. L., Wu, M., Cao, J., Krishnaswamy, S. (2016). Active learning for on-line partial discharge monitoring in noisy environments. *Proceedings - IEEE International Conference on Mobile Data Management*, 2016-June, 37–42. <https://doi.org/10.1109/MDM.2016.87>
- [6] Karimi, M., Majidi, M., Mirsaedi, H., Arefi, M. M., Oskuoee, M. (2020). A novel application of deep belief networks in learning partial discharge patterns for classifying corona, surface, and internal discharges. *IEEE Transactions on Industrial Electronics*, 67(4), 3277–3287. <https://doi.org/10.1109/TIE.2019.2908580>
- [7] Raymond, W. J. K., Xin, C. W., Kin, L. W., and Illias, H. A. Noise invariant partial discharge classification based on convolutional neural network. *Measurement*, vol. 177, p. 109220, 2021. DOI: <https://doi.org/10.1016/J.MEASUREMENT.2021.109220>.
- [8] Michau, G., Hsu, C.-C., and Fink, O. Interpretable Detection of Partial Discharge in Power Lines with Deep Learning. *Sensors*, vol. 21, no. 6, pp. 1–14, 2020. DOI: <https://doi.org/10.3390/s21062154>.
- [9] Kreuger, F. H. *Discharge Detection in High Voltage Equipment*. Heywood, London, 1964.

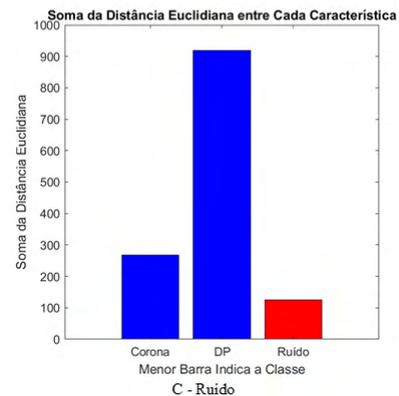
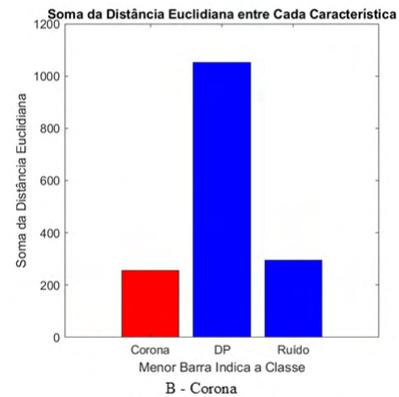
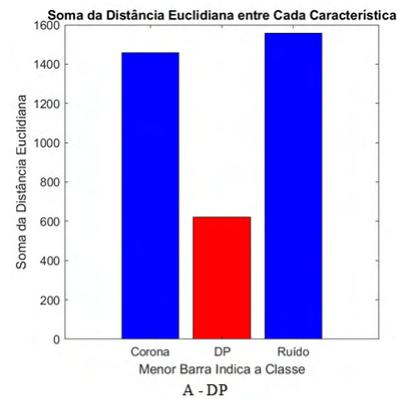


Fig. 9. Classificação dos Dados de Testes - Distância Euclidiana

- [10] Pulse-Sequence Analysis: A new method for investigating the physics of PD-induced ageing. 1989.
- [11] Satish, L., Nazneen, B. (2003). Wavelet-based denoising of partial discharge signals buried in excessive noise and interference. *IEEE Transactions on Dielectrics and Electrical Insulation*, 10(2), 354–367. <https://doi.org/10.1109/TDEI.2003.1194122>
- [12] Ma, X., Zhou, C., Kemp, I. J. (2002). Interpretation of wavelet analysis and its application in partial discharge detection. *IEEE Transactions on Dielectrics and Electrical Insulation*, 9(3), 446–457. <https://doi.org/10.1109/TDEI.2002.1007709>
- [13] Smith, T.J., Mahmoodi, D. (n.d.). Partial Discharge Characterisation by Pulse Sequence Analysis. ELEC6089 High Voltage Engineering, MEng Electronic Engineering, University of Southampton. Retrieved from <http://thesmiff.github.io/ELEC6089-PD-Analysis/>