

Fault Classification in Power Transformers by High Frequency Current Sensors and Wavelet Transform

Abdo Youssif Khoury Filho, João Pedro Gouvêa, Marco Aurélio Rocha, Alceu Ferreira Alves, André Luiz Andreoli *Member, IEEE*, and Bruno Albuquerque de Castro *Senior Member, IEEE*

Abstract -- In recent years, interest in power transformer monitoring systems has gradually increased due to the need of diagnose early faults, which allows tighter control of these electrical machines conditions and results in substantial savings in maintenance costs. The most common failures occur due to degradation of the dielectric material and loss of its insulation capacity, and the accurate diagnosis of these failures becomes essential since different failures require different maintenance approaches. This work proposes the use of a high frequency current sensor (HFCT) and digital signal processing techniques combined with Discrete Wavelet Transform to diagnose and to classify faults that may occur in transformers, distinguishing Partial Discharges and Total Discharges. The proposed technique proved to be effective in classifying the analysed failures.

Index Terms--Digital Signal Processing, Fault Diagnosis, HFCT, Power Transformer, Wavelet Transform

I. INTRODUÇÃO

Transformadores são conhecidos por serem um dos equipamentos mais importantes de um sistema elétrico de potência. Deste modo, é de extrema importância garantir uma operação segura e contínua [1]. Em condições normais de operação, os sistemas de isolamento empregados em transformadores de potência encontram-se continuamente expostos a diversos parâmetros críticos provenientes de fontes elétricas, térmicas, mecânicas e ambientais. Tais fatores levam um processo gradativo de deterioração das características físico-químicas do material isolante, podendo estabelecer uma falha completa na capacidade de isolamento desses materiais [2,3]. Desta forma, a melhoria do fornecimento de energia elétrica está intrinsecamente relacionada à capacidade de monitoramento das condições de operação dos transformadores conectados ao sistema elétrico [4].

É frequente que se observe, nas fases anteriores à falha total de um transformador, a ocorrência de descargas parciais ou arcos elétricos nos enrolamentos do transformador que podem ser considerados um importante indicativo da condição da isolamento desta máquina elétrica. Tais falhas relacionam-se com a perda das características físico-químicas dos materiais que

compõe a isolação da máquina, que é geralmente ocasionada por operações de sobrecarga, contaminação dos materiais dielétricos por partículas, umidade, ar e por falhas no processo de fabricação [5].

Uma descarga parcial é definida como uma manifestação de descarga elétrica que não preenche completamente a distância entre dois condutores [6,7]. Essa ocorrência resulta em ondas eletromagnéticas e acústicas, calor e luz [8,9].

Já descargas totais ou arcos elétricos são definidos como fenômenos que se caracterizam pela completa ionização do meio entre dois eletrodos condutores, resultando em uma significativa liberação de energia. Este tipo de falha, muito comum nos enrolamentos do transformador, é uma consequência de pontos sem isolação entre espiras ocasionados pela ação de forças axiais devido a curtos-circuitos, falhas construtivas no bobinamento, excesso de vibração por transporte descuidado dos transformadores etc [10].

Portanto, devido ao interesse em se evitar perdas totais nos transformadores ou mesmo na necessidade de se avaliar a evolução de uma avaria, alguns métodos foram propostos em literatura. Em [12] é proposta uma técnica robusta para classificação de descargas parciais em isolamento de transformadores com base em emissões acústicas detectadas utilizando sensores FBG (*Fiber Bragg Grating*). Já em [13] é proposta uma análise comparativa aplicada à identificação de falhas em transformadores por sensores de efeito Hall e Emissão Acústica. Entretanto, em [14] propõe-se o diagnóstico de descargas parciais com uso de transformadores de corrente de alta frequência (HFCT, do inglês – *High Frequency Current Transformer*) aplicando técnicas que se valem do uso de diagramas de amplitude e fase, conhecidos como PRPD (*phase-resolved partial discharge*). Além dos métodos apresentados, promissoras abordagens tem utilizado transdutores piezelétricos e antenas para a identificação de falhas em transformadores [15, 16].

Dentre os sensores empregados para o monitoramento de transformadores de potência, sensores de corrente elétrica apresentam alta eficácia. Dentre os tipos disponíveis, o uso de transformadores de corrente de alta frequência, conhecidos

This work was supported by São Paulo Research Foundation (FAPESP), Brazil, grant 2022/08656-1, and IPEC Ltd. UK. Abdo Youssif Khoury Filho, João Pedro Gouvêa, Marco Aurélio Rocha, Alceu Ferreira Alves, André Luiz Andreoli, and Bruno Albuquerque de Castro are with the São Paulo State University (UNESP), School of Engineering, Dept. of Electrical Engineering,

17033-360 Bauru, SP, Brazil (e-mails: a.khoury@unesp.br, joao.gouvea@unesp.br, marco.rocha@unesp.br, alceu.f.alves@unesp.br, andre.andreoli@unesp.br, and bruno.castro@unesp.br).

como *High Frequency Current Transformers* (HFCT) [17], é especialmente recomendado para a identificação de descargas elétricas. Esses sensores são aplicados na detecção de falhas devido à sua alta sensibilidade a transitórios de corrente de baixa energia [3, 18]. Apesar de sua eficácia, ainda são muitos os desafios científicos e tecnológicos enfrentados. Por exemplo, é importante o desenvolvimento de um estudo comparativo entre técnicas de diferenciação das avarias, com o intuito de gerar assim uma rotina inteligente e otimizada de manutenção, atendendo as ações exigidas de cada falha. Neste contexto, a aplicação de técnicas de processamento digital de sinais se torna fundamental para a correta interpretação da condição do transformador. Portanto, este trabalho é uma continuação do estudo desenvolvido em [18] e propõe a avaliação da transformada Wavelet na classificação de arcos elétricos e descargas parciais em transformadores por meio do emprego de um sensor HFCT comercial.

II. FALHAS EM TRANSFORMADORES

Apesar de os transformadores de potência serem dispositivos altamente confiáveis para operações contínuas, a prolongada utilização desses equipamentos os coloca suscetíveis à degradação decorrente do estresse operacional [1]. A deterioração dos elementos internos do transformador pode resultar em falhas irreparáveis, ocasionando prejuízos financeiros devido à interrupção do serviço e à necessidade de substituição de um ativo de elevado custo de aquisição [5].

Neste contexto, a maioria das falhas em transformadores de potência são encontradas no sistema de isolamento, nos enrolamentos e nas buchas, representando, respectivamente, 36,74%, 21,30% e 15,70% [5]. Neste cenário, é frequente observar, nas fases anteriores à falha total de um transformador, a ocorrência de descargas parciais ou totais que podem ser consideradas um importante indicativo da condição da isolação de transformadores de potência [5].

Uma descarga parcial (DP) pode ser definida como a existência de uma pequena falha em um isolante, causando alterações na distribuição do campo elétrico dentro do material. A constante dielétrica da pequena região de falha é menor do que a do material isolante circundante, resultando em uma maior intensidade de campo elétrico dentro dessa região em comparação com o material isolante circundante. Em geral, a ocorrência da DP é resultado do acúmulo localizado de estresse elétrico em áreas específicas do isolamento elétrico [19].

DPs podem surgir em uma ampla gama de equipamentos que utilizam diferentes materiais e estruturas de isolamento, incluindo dispositivos isolados a gás, a óleo e sólidos. Qualquer imperfeição no isolamento pode resultar no surgimento de descargas parciais. A natureza das descargas parciais pode variar dependendo do equipamento, apresentando estruturas e materiais de isolamento distintos. Segundo [19], as descargas parciais podem ocorrer devido a diversos fatores como: aumento da intensidade de campo elétrico devido ao elevado estresse elétrico; deterioração gradual de materiais isolantes; sobreaquecimento local, que por reações químicas pode produzir gases; fabricação inadequada, que pode introduzir

impurezas no isolamento etc.

Dessa maneira, as DPs podem acelerar a ruptura total do sistema de isolação de um transformador, e sua identificação e quantificação podem oferecer indicativos acerca da condição da isolação e prevenir potenciais colapsos na máquina elétrica.

Além deste fenômeno, descargas totais ou arcos elétricos também são frequentemente detectadas nos estágios que antecedem falhas totais em transformadores de potência. São caracterizados pela completa ionização do meio entre dois eletrodos condutores, resultando em significativa liberação de energia [10]. Da mesma forma que descargas parciais, transitórios em corrente e arcos elétricos também produzem calor, luz, ondas eletromagnéticas e acústicas, favorecendo, ainda mais, a degradação do material dielétrico [8, 9].

III. SENSOR HFCT

Os sensores de corrente de alta frequência, ou, do inglês, *High Frequency Current Transformers* (HFCT), desempenham um papel crucial na detecção e análise de falhas em sistemas elétricos, especialmente em transformadores. Esses sensores são projetados para detectar correntes transientes de alta frequência e podem operar na faixa de frequência de MHz [20].

O sensor HFCT é baseado em um núcleo magnético e um enrolamento secundário de cobre com n_2 espiras em torno desse núcleo. O núcleo, geralmente, é toroidal e feito de material ferromagnético. A largura de banda de medição de um HFCT depende principalmente do material do núcleo selecionado. Para um bom acoplamento na faixa de alta frequência, materiais de ferrite cerâmico são os mais indicados. Um aprofundamento sobre essa topologia de sensores de corrente pode ser encontrado nas referências [20] e [21].

IV. TÉCNICAS DE PROCESSAMENTO DIGITAL DE SINAIS

A. Transformada Wavelet

A Transformada Wavelet é uma ferramenta de processamento digital de sinais que se provou como uma técnica eficaz para sinais estacionários e não-estacionários, sendo computada em seu modo contínuo ou discreto. De acordo com [22], em comparação com a transformada Wavelet Discreta (TWD), a Transformada Wavelet Contínua (TWC) apresenta uma maior informação do sinal original; entretanto, necessita de um maior esforço computacional do que a TWD. Da mesma forma, para aplicações industriais, necessita-se de processamento digital de sinais com uma velocidade maior e mais robusta, fazendo com que a TWD se torne essencial para este cenário [22].

A TWD é realizada por meio de uma série de filtros passa-altas e filtros passa-baixas para a análise de sinais em altas e baixas frequências do sinal original. Com isso, o sinal é completamente decomposto em coeficientes de detalhe (componentes de alta frequência) e coeficientes de aproximação (componentes de baixa frequência) [22,23].

Na Figura 1 é apresentada a decomposição do sinal original, por meio da Transformada Wavelet, em três níveis. Os coeficientes $h[n]$ e $g[n]$ são, respectivamente, filtros passa-altas e filtros passa-baixas. Os resultados de tais filtros fornecem os

coeficientes de aproximação (A) e detalhe (D). Este processo pode se repetir sucessivas vezes até o momento em que não se é mais possível decompor o sinal. Os coeficientes de detalhe têm seu comprimento reduzido pela metade, e apenas os coeficientes de aproximação são decompostos [22].

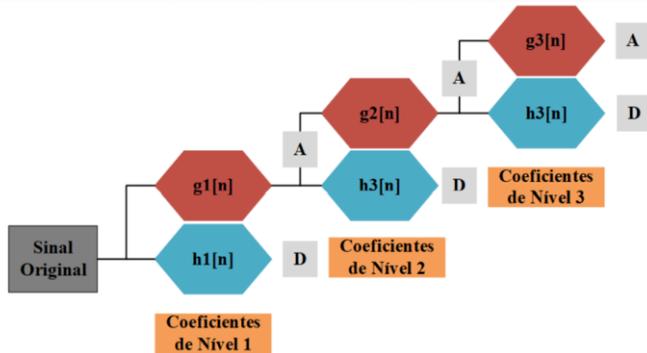


Fig. 1. Decomposição do sinal por meio da TWD de três níveis [22].

A TWD é implementada computacionalmente por meio da transformada rápida de Wavelet. Dessa forma, os coeficientes de detalhes e aproximação são calculados por [24, 25]:

$$a_j[k] = \sum_n g[n] a_{j+1}[2k+n], \quad (1)$$

$$d_j[k] = \sum_n h[n] a_{j+1}[2k+n], \quad (2)$$

onde a e d são, respectivamente, os coeficientes de aproximação e detalhe, h é o filtro passa-alta, g é o filtro passa-baixas e j é o nível Wavelet.

B. Métricas para análise de sinais

Por meio dos coeficientes de detalhe e aproximação obtidos pela Transformada Wavelet, é possível extrair métricas dos sinais, como Energia, Kurtosis e Skewness. O objetivo da aplicação dessas estatísticas foi apontar padrões de cada falha externados nos coeficientes de aproximação e detalhe.

Tomando uma sequência qualquer $x[k]$ oriundo da de um coeficiente de aproximação ou detalhe da Transformada Wavelet, a energia E de $x[k]$ é definida por [26]:

$$E = \sum_{n=0}^{N-1} x[k]^2 \quad (3)$$

onde N é o número de amostras e $x[n]$ é o valor da n -ésima amostra do sinal.

As estatísticas de Skewness e Kurtosis são relativas ao formato da série em análise. O valor de Skewness (S) indica se o pico da distribuição normal está concentrado à direita ($S > 0$) ou à esquerda ($S < 0$) da mediana da distribuição normal relativa à série, e é definida por [28]:

$$S = \sum_{n=0}^{N-1} \left[\left(\frac{|x[k]| - M}{\sigma} \right)^3 \right] \quad (4)$$

em que M e σ são, respectivamente, a média e o desvio padrão

da Transformada Wavelet.

O valor de Kurtosis (K) indica o formato da série em relação ao grau de sua amplitude e é definida por [28]:

$$K = \sum_{n=0}^{N-1} \left[\left(\frac{|x[k]| - M}{\sigma} \right)^4 \right] \quad (5)$$

V. MATERIAIS E MÉTODOS

Com o objetivo de realizar a classificação entre descargas totais (arcos elétricos) nos enrolamentos e descargas parciais em isoladores, foi utilizado um transformador distribuição de 30 kVA, 13,8 kV/220V isolado a óleo. Para isso, a bancada experimental foi montada conforme a Fig. 2 e semelhante a [18].

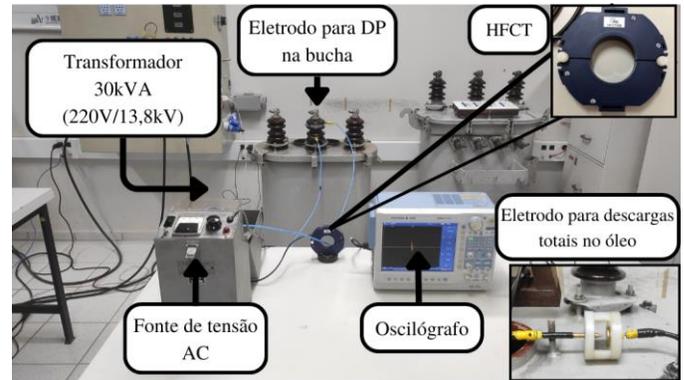


Fig. 2. Bancada Experimental.

Além do transformador de potência, a bancada experimental consiste em um osciloscópio com registro de memória da marca Yokogawa DL850, uma fonte de alta tensão de até 40 kV e o sensor HFCT, modelo 48E IPEC® com largura de banda de 50 MHz.

Para a aplicação das falhas, as descargas totais foram realizadas por meio da aplicação de uma tensão de 3 kV nos terminais de um eletrodo de 3 mm de abertura, submerso no óleo do transformador de potência. O eletrodo utilizado é apresentado na Fig. 2.

Ademais, as descargas parciais na bucha foram geradas por meio da contaminação da bucha com pó de grafite (Fig. 2), para simular impurezas que se acumulam sobre o material prejudicando as suas propriedades isolantes e propiciando a ocorrência de descargas elétricas. Além disso, foi aplicada uma tensão de 13,8 kV no componente.

Para cada tipo de falha, os sinais de corrente elétrica foram aquisitados pelo sensor HFCT de largura de banda de 50 MHz, apresentado na Fig. 2. Além disso, um osciloscópio foi configurado para uma frequência de amostragem de 100 MHz, satisfazendo o Teorema de Nyquist.

Para cada tipo de falha, 150 sinais de corrente elétrica foram aquisitados, e a análise no domínio tempo-frequência foi realizada pela Transformada Wavelet Discreta. Nove níveis de aproximação e nove níveis de detalhes foram calculados. Além

disso, com o intuito de evitar interferência da intensidade dos sinais, os resultados foram normalizados.

Por meio dos coeficientes de aproximação e detalhe oriundos da TWD, foram calculados a Energia, Kurtosis e Skewness para cada um dos 18 níveis Wavelet. Deste modo, a classificação foi realizada para descargas totais nos enrolamentos e descargas parciais na bucha do transformador. Para o estudo da classificação de falhas, cada estatística se tornou um par cartesiano de modo que cada coeficiente foi reduzido a um ponto no plano cartesiano 2D. Para avaliar a melhor combinação de classificação foi calculada a distância euclidiana normalizada entre os vizinhos próximos formados por cada condição de operação do transformador.

A técnica de processamento digital de sinais é sintetizada pelo fluxograma apresentado na Fig. 3.

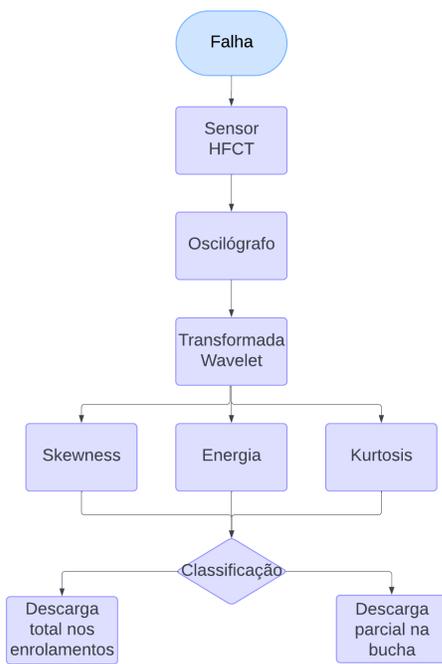


Fig. 3. Fluxograma de metodologia de processamento de sinais.

VI. RESULTADOS E DISCUSSÃO

Na Fig. 4 são apresentadas as distâncias euclidianas externadas por todas as combinações entre as estatísticas. As combinações estão apresentadas no Apêndice do artigo.

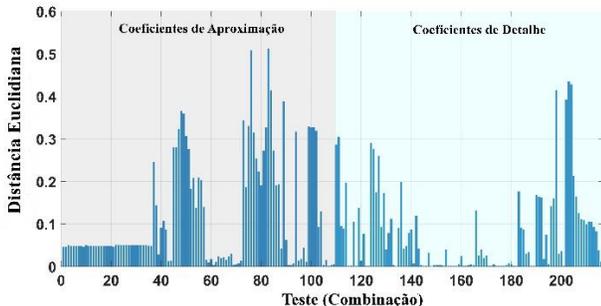


Fig. 4. Distância euclidiana para a análise Wavelet.

Baseado neste resultado, vale destacar que, quanto maior for a distância euclidiana entre os agrupamentos, melhor será a classificação das falhas. Desta forma, os maiores valores encontrados estão ilustrados na Tabela 1.

TABELA I
 MAIORES DISTÂNCIAS EUCLIDIANAS OBTIDAS NA FIGURA 6

Coefficiente	Parâmetro 1	Parâmetro 2	Distância Euclidiana (pu)
Aproximação	Skewness do nível 2	Skewness do nível 5	0,5119
Detalhe	Skewness do nível 4	Skewness do Nível 6	0,4348

Na Fig. 5 se apresenta um gráfico bidimensional da Skewness do coeficiente de aproximação 5 pela Skewness do coeficiente de aproximação 2. Pela análise da Fig. 5 e da Tabela 1 verifica-se que a classificação dos tipos de falha foi realizada, haja vista que a distância euclidiana entre os agrupamentos foi de 0,5119. Entretanto, observa-se que o comportamento da descarga parcial na bucha foi disperso, variando, aproximadamente, de -3 a 1 em relação ao eixo das ordenadas (Skewness do coeficiente de aproximação 5) e de -1,5 a 2,5 em relação ao eixo das abscissas (Skewness do coeficiente de aproximação 2). Já para a ocorrência da descarga total nos enrolamentos do transformador, o agrupamento permaneceu mais coeso, com uma variação de -4 a -2 em relação ao eixo das abscissas e de 2,5 a 3,5 em relação ao eixo das ordenadas.

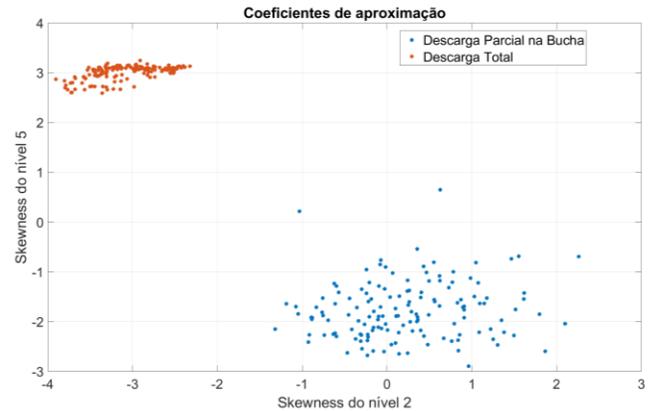


Fig.5. Mapa bidimensional de Skewness dos níveis 5 e 2 dos coeficientes de aproximação.

Na Fig. 6 apresentam-se as métricas Skewness do Nível 6 pelo Nível 4 dos Coeficientes de Detalhe. Verifica-se que a classificação foi eficaz uma vez que os agrupamentos se dispuseram em duas regiões bem definidas relativas às falhas apresentadas, isso é corroborado pela Tabela 1, que apresenta uma distância euclidiana entre os clusters de 0,4348 unidades. Os valores de Skewness para descargas totais são limitados entre -3 e -3,2 para o Nível 6 e, para o Nível 4, ficaram entre 3 e 5. No entanto, para descargas parciais na bucha os valores de Skewness são mais dispersos, assumindo valores na faixa de 3 e 3,5 para o Nível 6 e para o Nível 4 ficaram na faixa de -3 e 2.

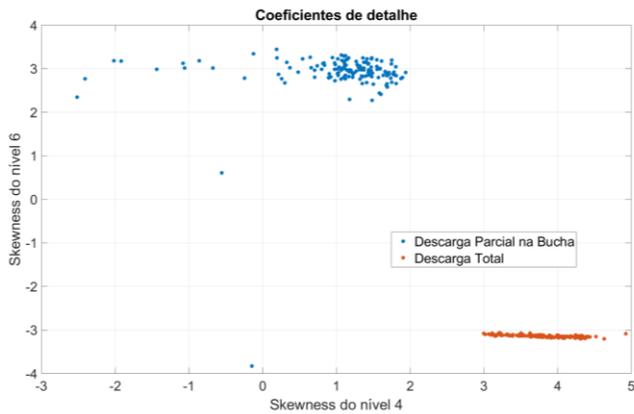


Fig. 6. Mapa bidimensional de Skewness dos níveis 6 e 4 dos coeficientes de detalhe.

Avaliando os mapas bidimensionais de combinações de métricas apresentados, é possível observar duas regiões bem definidas e distantes para as duas falhas, indicando combinações promissoras para a categorização dos sinais de corrente. Além disto, a combinação dos resultados de Skewness dos Níveis 2 e 5 dos Coeficientes de Aproximação da Transformada Wavelet apresentou a maior distância entre os agrupamentos, se mostrando como uma técnica de processamento digital de sinais promissora para a classificação de falhas elétricas em transformadores.

VII. CONCLUSÃO

Este artigo apresenta uma técnica de processamento digital de sinais para a classificação de falhas em transformadores de potência. A técnica proposta é baseada no uso do sensor HFCT para aquisição de sinais de corrente elétrica e o processamento digital de sinais é realizado no domínio tempo-frequência por meio da Transformada Wavelet Discreta. Desta forma, obtiveram-se 9 coeficientes de aproximação e 9 coeficientes de detalhe. Para cada um dos 18 níveis obtidos, aplicaram-se os parâmetros de Energia, Skewness e Kurtosis. Essas estatísticas foram dispostas em mapas bidimensionais e a distância euclidiana entre os agrupamentos foi calculada. Deste modo, foi possível classificar descargas totais, que ocorrem normalmente em enrolamentos dos transformadores, das descargas parciais de isoladores. De acordo com os resultados obtidos, é possível concluir que a métrica skewness aplicada aos coeficientes de aproximação 2 e 5 e aos coeficientes de detalhe 4 e 6 obteve o melhor desempenho, com uma distância euclidiana entre os clusters de 0,5119 e 0,4348, respectivamente. Para trabalhos futuros surge a possibilidade de averiguação da classificação de outras falhas que acometem os transformadores.

VIII. APÊNDICE

TABELA II
 COMBINAÇÕES DE PARÂMETROS PARA COEFICIENTES DE APROXIMAÇÃO (CA)
 E COEFICIENTES DE DETALHE (CD) PARA CADA NÍVEL WAVELET “N”
 REFERENTE AO EIXO DAS ABCISSAS DA FIGURA 9.

Teste (CA)	Teste (CD)	Parâmetro 1	Parâmetro 2
1	109	Energia N1	Energia N2
2	110	Energia N1	Energia N3
3	111	Energia N1	Energia N4
4	112	Energia N1	Energia N5
5	113	Energia N1	Energia N6
6	114	Energia N1	Energia N7
7	115	Energia N1	Energia N8
8	116	Energia N1	Energia N9
9	117	Energia N2	Energia N3
10	118	Energia N2	Energia N4
11	119	Energia N2	Energia N5
12	120	Energia N2	Energia N6
13	121	Energia N2	Energia N7
14	122	Energia N2	Energia N8
15	123	Energia N2	Energia N9
16	124	Energia N3	Energia N4
17	125	Energia N3	Energia N5
18	126	Energia N3	Energia N6
19	127	Energia N3	Energia N7
20	128	Energia N3	Energia N8
21	129	Energia N3	Energia N9
22	130	Energia N4	Energia N5
23	131	Energia N4	Energia N6
24	132	Energia N4	Energia N7
25	133	Energia N4	Energia N8
26	134	Energia N4	Energia N9
27	135	Energia N5	Energia N6
28	136	Energia N5	Energia N7
29	137	Energia N5	Energia N8
30	138	Energia N5	Energia N9
31	139	Energia N6	Energia N7
32	140	Energia N6	Energia N8
33	141	Energia N6	Energia N9
34	142	Energia N7	Energia N8
35	143	Energia N7	Energia N9
36	144	Energia N8	Energia N9
37	145	Kurtosis N1	Kurtosis N2
38	146	Kurtosis N1	Kurtosis N3
39	147	Kurtosis N1	Kurtosis N4
40	148	Kurtosis N1	Kurtosis N5
41	149	Kurtosis N1	Kurtosis N6
42	150	Kurtosis N1	Kurtosis N7
43	151	Kurtosis N1	Kurtosis N8
44	152	Kurtosis N1	Kurtosis N9
45	153	Kurtosis N2	Kurtosis N3
46	154	Kurtosis N2	Kurtosis N4
47	155	Kurtosis N2	Kurtosis N5

48	156	Kurtosis N2	Kurtosis N6
49	157	Kurtosis N2	Kurtosis N7
50	158	Kurtosis N2	Kurtosis N8
51	159	Kurtosis N2	Kurtosis N9
52	160	Kurtosis N3	Kurtosis N4
53	161	Kurtosis N3	Kurtosis N5
54	162	Kurtosis N3	Kurtosis N6
55	163	Kurtosis N3	Kurtosis N7
56	164	Kurtosis N3	Kurtosis N8
57	165	Kurtosis N3	Kurtosis N9
58	166	Kurtosis N4	Kurtosis N5
59	167	Kurtosis N4	Kurtosis N6
60	168	Kurtosis N4	Kurtosis N7
61	169	Kurtosis N4	Kurtosis N8
62	170	Kurtosis N4	Kurtosis N9
63	171	Kurtosis N5	Kurtosis N6
64	172	Kurtosis N5	Kurtosis N7
65	173	Kurtosis N5	Kurtosis N8
66	174	Kurtosis N5	Kurtosis N9
67	175	Kurtosis N6	Kurtosis N7
68	176	Kurtosis N6	Kurtosis N8
69	177	Kurtosis N6	Kurtosis N9
70	178	Kurtosis N7	Kurtosis N8
71	179	Kurtosis N7	Kurtosis N9
72	180	Kurtosis N8	Kurtosis N9
73	181	Skewness N1	Skewness N2
74	182	Skewness N1	Skewness N3
75	183	Skewness N1	Skewness N4
76	184	Skewness N1	Skewness N5
77	185	Skewness N1	Skewness N6
78	186	Skewness N1	Skewness N7
79	187	Skewness N1	Skewness N8
80	188	Skewness N1	Skewness N9
81	189	Skewness N2	Skewness N3
82	190	Skewness N2	Skewness N4
83	191	Skewness N2	Skewness N5
84	192	Skewness N2	Skewness N6
85	193	Skewness N2	Skewness N7
86	194	Skewness N2	Skewness N8
87	195	Skewness N2	Skewness N9
88	196	Skewness N3	Skewness N4
89	197	Skewness N3	Skewness N5
90	198	Skewness N3	Skewness N6
91	199	Skewness N3	Skewness N7
92	200	Skewness N3	Skewness N8
93	201	Skewness N3	Skewness N9
94	202	Skewness N4	Skewness N5
95	203	Skewness N4	Skewness N6
96	204	Skewness N4	Skewness N7
97	205	Skewness N4	Skewness N8
98	206	Skewness N4	Skewness N9
99	207	Skewness N5	Skewness N6
100	208	Skewness N5	Skewness N7
101	209	Skewness N5	Skewness N8

102	210	Skewness N5	Skewness N9
103	211	Skewness N6	Skewness N7
104	212	Skewness N6	Skewness N8
105	213	Skewness N6	Skewness N9
106	214	Skewness N7	Skewness N8
107	215	Skewness N7	Skewness N9
108	216	Skewness N8	Skewness N9

Observações: N1 tem significado “nível wavelet 1”, ou seja, Ni tem significado “nível wavelet i”

IX. ACKNOWLEDGMENT

The authors would like to thank IPEC Ltd UK (<https://ipecek.com/>) for the donation of the HFCT sensors used in this research, and São Paulo Research Foundation (FAPESP), Brazil, grant 2022/08656-1.

X. REFERÊNCIAS

- [1] Zhang, X. et al. A novel partial discharge detection method for power transformers on site adopting its component as ultra-high frequency sensor. *IEEE transactions on power delivery*, v. 34, n. 6, p. 2269–2271, 2019.
- [2] Fuhr, J.; Aschwanden, T. Identification and localization of PD-sources in power-transformers and power-generators. *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 24, no 1, pp. 17-30, 2017.
- [3] Ardila-Rey J. A., Montana J; Castro B. A., et al. A Comparison of Inductive Sensors in the Characterization of Partial Discharges and Electrical Noise Using the Chromatic Technique. *Sensors*, v. 18, p. 1021, 2018.
- [4] Kumar, R. et al. A condition monitoring and fault detection in the windings of power transformer using impulse frequency response analysis. *International Journal of System Assurance Engineering and Management*, p. 1-13, 2022.
- [5] Murugan, R.; Ramasamy, R. Understanding the power transformer component failures for health index-based maintenance planning in electric utilities. *Engineering Failure Analysis*, v. 96, p. 274-288, 2019.
- [6] International Electrotechnical Commission (IEC). *IEC 60270—High Voltage Test Techniques*, 3rd ed.; IEC: Geneva, Switzerland, 2000.
- [7] Thiviyanathan, Vimal Angela et al. Power transformer insulation system: A review on the reactions, fault detection, challenges and future prospects. *Alexandria Engineering Journal*, v. 61, n. 10, p. 7697-7713, 2022.
- [8] Castro, B. A.; Clerice, G. A. M.; Ramos, C. O.; et al. Partial Discharge Monitoring in Power Transformers Using Low-Cost Piezoelectric Sensors. *Sensors*, vol. 16, pp. 1266, 2016.
- [9] Boggs, S. A. Partial Discharge – part III: cavity-induced PD in solid dielectrics. *IEEE Electrical Insulation Magazine*, v.6, n.6, p. 11-20, 1990.
- [10] Zhou, Sheng; Iannuzzi, Davide. Immersion photoacoustic spectrometer (iPAS) for arcing fault detection in power transformers. *Optics letters*, v. 44, n. 15, p. 3741-3744, 2019.
- [11] Mao, Y. et al. Research on partial discharge detection technology for power transformers. 2020 IEEE 4th Conference on Energy Internet and Energy System Integration (EI2). *Anais...IEEE*, 2020.
- [12] Kanakambaran, S; Sarathi R; Srinivasan, B. Robust Classification of Partial Discharges in Transformer Insulation Based on Acoustic Emissions Detected Using Fiber Bragg Gratings. *IEEE Sensors Journal*, v. 18, p. 10018-10027, 2018.
- [13] Castro, B.A. et al New Algorithm Applied to Transformers' Failures Detection Based on Karhunen–Loève Transform. *IEEE Transactions on Industrial Informatics*, v. 19, n. 11, p. 10883-10891, 2023.
- [14] Albarracin-Sanches, R.; Gomes, F. A.; Romero, C. A. V. et al. Separation of Partial Discharge Sources Measured in the High-Frequency Range with HFCT Sensors Using PRPD-teff Patterns. *Sensors*, v. 20, p. 1-18, 2020.
- [15] Rohani, M. N. K. H.; Yii, C. C.; Isa, M.; et al. Geometrical Shapes Impact on the Performance of ABS-Based Coreless Inductive Sensors for PD Measurement in HV 483 Power Cables. *IEEE Sens. Journ.* v.16, p. 6625-6632, 2016.

- [16] Siegel, M.; Beltle, M.; Tenbohlen, S.; Coenen, S. Application of UHF Sensors for PD Measurement at Power Transformers. IEEE Transactions on Dielectrics and Electrical Insulation, vol. 24, no 1, pp. 331-339, 2017.
- [17] Zachariades, C.; Shuttleworth, R.; Giussani, R.; Mackinlay, R. Optimization of a High-Frequency Current Transformer Sensor for Partial Discharge Detection Using Finite-Element Analysis. IEEE Sensors Journal, v. 16, pp. 1558-1748, 2016.
- [18] Gouvêa, J.P., et al. "Techniques for Failures Classification in Power Transformers by High-Frequency Current Transformers." 2023 15th IEEE International Conference on Industry Applications (INDUSCON). IEEE, 2023.
- [19] Alshalawi, A. H.; Al-Ismaïl, F. S. Partial discharge detection based on ultrasound using optimized deep learning approach. IEEE access: practical innovations, open solutions, v. 12, p. 5151–5162, 2024.
- [20] Fritsch, Martin, and Martin Wolter. "High-Frequency Current Transformer Design and Construction Guide." IEEE Transactions on Instrumentation and Measurement p. 1-9, 2022.
- [21] M. Fritsch and M. Wolter, "Saturation of High-Frequency Current Transformers: Challenges and Solutions," IEEE Transactions on Instrumentation and Measurement, vol. 72, pp. 1-10, 2023.
- [22] Cherif, H. et al. Early detection and localization of stator inter-turn faults based on discrete wavelet energy ratio and neural networks in induction motor. Energy, Elsevier BV, v. 212, p. 118684, dez. 2020.
- [23] Konar, P.; Chattopadhyay, P. Multi-class fault diagnosis of induction motor using hilbert and wavelet transform. Applied Soft Computing, Elsevier BV, v. 30, p.341–352, 2015.
- [24] Almounajjed, A.; Sahoo, A. K.; Kumar, M. K. Diagnosis of stator fault severity in induction motor based on discrete wavelet analysis. Measurement, Elsevier BV, v. 182, p. 109780, set. 2021.
- [25] Hafiz, F. et al. Identification of power quality events: selection of optimum base wavelet and machine learning algorithm. IET Science, Measurement & Technology, Institution of Engineering and Technology (IET), v. 13, n. 2, p. 260–271, mar. 2019.
- [26] Tao, X. et al. Bearings fault detection using wavelet transform and generalized gaussian density modeling. Measurement, Elsevier BV, v. 155, p. 107557, abr. 2020.
- [27] Weiss, L.G.: 'Wavelets and wideband correlation processing', IEEE Signal Processing Magazine, v. 1, pp. 13–32, 1994.
- [28] Swedan, Anas; El-Hag, A. H.; Assaleh, K. Acoustic detection of partial discharge using signal processing and pattern recognition techniques. Insight-Non-Destructive Testing and Condition Monitoring, v. 54, n. 12, p. 667-672, 2012.

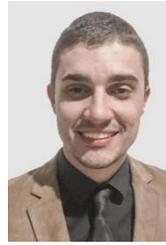
XI. BIOGRAPHIES



Abdo Youssif Khoury Filho nasceu em Alto Alegre – SP, Brasil em 1996. Possui graduação em Engenharia da Computação e em Engenharia Elétrica pela UNILINS - Centro Universitário de Lins, respectivamente em 2019 e 2021. Atualmente, está cursando mestrado na Unesp - Universidade Estadual Paulista, campus de Bauru, Brasil. Sua pesquisa concentra-se na área de sensores e diagnóstico de falhas em transformadores. É membro do Laboratório de Sensores e Processamento de Sinais Aplicado a Dispositivo de Média Tensão (LSPDM).



João Pedro Gouvêa graduando em Engenharia Elétrica pela Universidade Estadual Paulista Júlio de Mesquita Filho (UNESP) de Bauru desde 2019. Foi bolsista de iniciação científica pela Fundação de Amparo Fundação de Amparo à Pesquisa do Estado de São Paulo (Fapesp) no ano de 2022. Morou durante na cidade de Regensburg, Alemanha realizando intercâmbio e estagiando na empresa Vitesco Technologies. Possui pesquisa na área de diagnóstico de falhas em transformadores, processamento digital de sinais, sensores e emissão acústica.



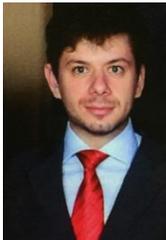
Marco Aurélio Rocha nasceu em Mogi-Mirim, Brasil, em 1993. É doutor em Engenharia Elétrica pela Unesp campus Bauru (2022). Como formação, possui graduação (2016) e mestrado (2018) em Engenharia Elétrica pela Unesp campus Bauru. Atualmente é membro do Laboratório de Sensores e Processamento de Sinais Aplicados a Dispositivo de Média Tensão (LSPDM), onde é pós doutorando.



Alceu Ferreira Alves nasceu em Bauru, SP, Brasil em 8 de junho de 1964. Concluiu sua graduação em Engenharia Elétrica (1986) e Mestrado (1993) na Escola de Engenharia de São Carlos, Universidade de São Paulo, cursou Doutorado na área de energia na Faculdade de Ciências Agrônomicas da UNESP em Botucatu, SP. Atua como Professor Assistente Doutor na Faculdade de Engenharia da UNESP Bauru desde 1989, ministrando disciplinas na área de Eletrônica. Seus principais interesses de pesquisa atualmente se concentram em Energias Renováveis com foco em Energia Solar Fotovoltaica, eficiência energética e máquinas elétricas. Coordena o Grupo de Pesquisa cadastrado no Diretório Nacional do CNPq denominado "Energia Solar Fotovoltaica".



André Luiz Andreoli é graduado em Engenharia Elétrica pela Faculdade de Engenharia de Bauru - Universidade Estadual Paulista - UNESP (1997), mestrado em Engenharia Industrial pela Faculdade de Engenharia de Bauru - Universidade Estadual Paulista (2005) e doutorado em Engenharia Elétrica pela Universidade de São Paulo - USP (2011). Atualmente é professor assistente doutor da Faculdade de Engenharia de Bauru - UNESP - Universidade Estadual Paulista Júlio de Mesquita Filho. Tem experiência na área de Engenharia Elétrica, com ênfase em máquinas elétricas e acionamentos, atuando principalmente nos seguintes temas: diagnóstico de falhas em máquinas elétricas, acionamento de máquinas elétricas, processamento de sinais e automação eletrônica de processos elétricos e industriais.



Bruno Albuquerque de Castro (M'08, SM'21) é doutor em Engenharia Elétrica pela Unesp campus de Bauru (2019) com período de doutorado sanduíche na Universidade de Surrey, Inglaterra. É membro Sênior do IEEE (Institute of Electrical and Electronics Engineers) e atua como Editor Chefe Associado do periódico IEEE Transactions on Instrumentation and Measurement. Como formação, possui graduação (2012) e mestrado (2016) em Engenharia Elétrica pela Universidade Estadual Paulista - Unesp, campus de Bauru. Possui campo de pesquisa na área de sensores, processamento digital de sinais, instrumentação, sistemas inteligentes e técnicas não destrutivas aplicadas ao monitoramento e diagnóstico de falhas em sistemas de energia. Atualmente é Professor Assistente Doutor do Departamento de Engenharia Elétrica da Unesp de Bauru.