



**GRUPO DE ESTUDO DE TRANSFORMADORES, REATORES, MATERIAIS E TECNOLOGIAS EMERGENTES  
- GTM**

**MONITORAMENTO DE EVOLUÇÃO DE GASES DE TRANSFORMADORES DE POTÊNCIA INTEGRANDO  
NANOTECNOLOGIA E TÉCNICAS INTELIGENTES**

**HELEN VELOZO VENDRAMETO (1); ANDRÉ NUNES DE SOUZA (2); DANILO SINKITI GASTALDELLO (3);  
TALITA MAZON (4); EUGÊNIO DE SOUZA MORITA (5); AGNES NASCIMENTO SIMOES (5); WALDIR  
ANTONIO BIZZO (5); JOÃO PAULO PAPA (6); FLORIANO TORRES NETO (7); VAGNER VASCONCELLOS  
(8); CHRISTIAN ROBERTO CAMPIONI DA CRUZ (8); JOÃO CARLOS CARNEIRO (1)  
CPFL PAULISTA (1); UNESP (2); INSTITUTO DAS APOSTOLAS DO SAGRADO CORACAO DE JESUS (3);  
CENTRO DE TECNOLOGIA DA INFORMAÇÃO RENATO ARCHER (4); UNIVERSIDADE ESTADUAL DE  
CAMPINAS (5); UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO" (6); CPFL  
GERAÇÃO DE ENERGIA S.A. (7); CPFL PIRATININGA (8)**

**RESUMO**

Os transformadores de subestações possuem alto valor agregado, tornando o seu correto funcionamento essencial para o sistema. A análise de gases dissolvidos no óleo é uma de diversas ferramentas que são usadas para um diagnóstico do ativo, e novas tecnologias de sensoriamento e ferramentas de inteligência computacional vem sendo implementadas. A proposta deste trabalho é o desenvolvimento de nanosensores resistivos construídos com nanoestruturas, e um sistema de análise de dados embarcado, utilizando classificadores inteligentes para tratamento de dados. Os resultados do sensoriamento possuem boa assertividade e seletividade, e os sistemas inteligentes apresentaram uma boa acurácia e velocidade de processamento.

**PALAVRAS-CHAVE:** Transformador de potência, monitoramento de equipamentos, sensor nanoestruturado, diagnóstico de falha, técnicas inteligentes.

**1.0 INTRODUÇÃO**

O diagnóstico de falhas em equipamentos do setor energético tem atraído cada vez mais importância nos últimos anos, principalmente por conta do surgimento de técnicas cada vez mais precisas de captura e análise de dados, propiciando monitoramentos inteligentes. Mais especificamente, o diagnóstico correto e antecipado acerca do funcionamento de transformadores potência garante a confiabilidade do fornecimento de energia e mitiga o risco de quebra do ativo gerando perdas financeiras, pois a reforma ou manufatura de novos equipamentos é, usualmente, uma tarefa dispendiosa e lenta.

Medidas indiretas da temperatura do óleo e níveis de concentração de gases são bons indicativos da saúde do equipamento e contribuem para diagnósticos incipientes para os principais tipos de falhas que podem ocorrer no interior do transformador. O objetivo é evitar desligamentos não programados destes equipamentos durante sua operação, os quais podem causar transtornos de ordem social, econômica e de segurança tanto para consumidores como para concessionárias.

O  $H_2$  é um importante gás a ser monitorado (SAAD, TENYENHUIS, 2018), pois, trata-se de um indicador da maioria das falhas tais como, degradação térmica do óleo, descarga parciais e arco elétrico. Sua formação ocorre em temperatura a partir de  $150^\circ C$  e sua quantidade aumenta à medida que a temperatura se eleva, logo, conhecer seu gradiente de evolução em tempo real, junto com a temperatura, permitirá estimar precocemente algumas das principais falhas.

O  $C_2H_4$  é o principal gás combustível produzido relacionado à degradação térmica do óleo, o gás  $CO$  relaciona-se com a degradação térmica do papel e  $C_2H_2$  a descargas elétricas de alta intensidade, este último considerado defeito gravíssimo cujo tempo de atendimento deve ser imediato, dependendo do grau de evolução/elevação. A presença dos gases orgânicos voláteis, como etileno e acetileno pode ser relacionada a degradação por efeito térmico e elétrico, respectivamente.

Sob a perspectiva de análise do índice de saúde do transformador, a análise histórica de dados ou informações do equipamento permite fazer o acompanhamento mais detalhado do seu estado, pois, todos os eventos e ocorrências passadas podem servir de base para interpretação e diagnose. Um exemplo que pode ilustrar esta situação é quando

se faz a regeneração do óleo isolante, ou seja, caso as características físico-químicas (por exemplo, rigidez dielétrica, teor de água, tensão interfacial, impurezas elevadas) do óleo estejam inadequadas, faz-se a regeneração do óleo para melhorá-las, no entanto, também ocorre a extração dos gases dissolvidos deixando-os praticamente nulos. Nesse caso, seria algo similar ao equipamento ser ativado naquela data e, portanto, desprezar essa informação levaria a uma análise e diagnóstico do estado do transformador inadequada ou equivocada.

Muito embora diversos trabalhos tenham sido publicados na literatura especializada, a grande maioria é baseada em informações coletadas em campo de forma intermitente, dificultando, assim, um monitoramento contínuo. Neste sentido, o artigo apresenta resultados preliminares da pesquisa em desenvolvimento, com o suporte financeiro do P&D ANEEL (PD – 00063-3067/2019). Este documento contém duas frentes de trabalho, uma com estudo e desenvolvimento de nanossensores resistivos capazes de realizar a detecção dos gases  $H_2$  e  $CO$ , para aquisição das concentrações de gases diluídos no óleo, e um sistema inteligente embutido para processamento dos dados e auxílio na tomada de decisão, utilizando classificadores computacionais inteligentes e avaliando sua acurácia e tempo de treinamento.

## 2.0 METODOLOGIA APLICADA AOS NANOSENSORES

Para os ensaios e avaliação dos nanossensores desenvolvidos foi montada uma bancada de ensaios para simular o ambiente interno dos transformadores, em menor escala, com controle de concentração de gases, uma vez que ensaios de seletividade e assertividade dependem da correta administração dos gases no sistema.

Neste sentido, duas câmaras hermeticamente fechadas com saída e entrada para gases e preenchidas com óleo de transformador foram utilizadas para a realização das medidas de sensor de gás das amostras sintetizadas. Na primeira câmara, onde o gás é injetado, ocorre a dissolução do gás no óleo do transformador. Como há circulação do óleo entre as câmaras, na segunda câmara (câmara da direita na Figura 1) a concentração do gás, temperatura e nível do óleo são equalizados. A segunda câmara possui quatro canais de medidas individuais, possibilitando a realização e aquisição das medidas de quatro amostras simultâneas com o mesmo gás de análise; possui um termopar e manômetro indicador de pressão. O sistema está acoplado a um computador com software desenvolvido para realizar a aquisição de sinais do sensor. Os dados elétricos (resistência) das amostras foram coletados pelo método de duas pontas por meio de uma unidade de aquisição, comutação e registro de dados LXI (DAQ) (Agilent, modelo 34972A) integrada ao módulo (34908A) de comutação multiplexador de até 40 canais.

Para a construção dos nanossensores foi utilizado um eletrodo interdigital (IDE) fabricado através da deposição por pulverização catódica (sputtering) de ouro (intergital) em substratos de alumina. O processo de deposição ocorreu com a utilização do sistema de pulverização catódica DC (corrente contínua) (Denton Vacuum, modelo DV502A DC magnetron Sputter coater).

Para preparar o nanossensor para a detecção de  $H_2$ , nanoestruturas de óxido de zinco (ZnO NRs) foram crescidas sobre os IDE utilizando o método de deposição por banho químico. Após o crescimento dos ZnO NRs, uma suspensão contendo nanopartículas de paládio foi depositada sobre os ZnO NRs com o auxílio de uma micropipeta. Após a deposição o sensor foi preaquecido a  $100\text{ }^{\circ}\text{C}$  por 5 minutos para a eliminação do solvente e tratado termicamente em forno tipo mufla a  $300^{\circ}\text{C}/4\text{hs}$  (GASPAROTTO, et al., 2018).

O nanossensor para detecção de  $CO$  foi preparado a partir da deposição, por *spin-coating*, de uma suspensão de nanopartículas de óxido de estanho ( $\text{SnO}_2$  NPs) sobre os IDE. Em seguida, uma suspensão de nanopartículas de paládio (Pd NPs), de concentração conhecida, foi depositada por spin coating a 1000 rpm por 30 segundos. Após a deposição o sensor foi preaquecido a  $100\text{ }^{\circ}\text{C}$  por 5 minutos para a eliminação do solvente e tratado termicamente em forno tipo mufla a  $300^{\circ}\text{C}/4\text{hs}$  (GASPAROTTO, et al., 2014) e (MORAIS; SUMAN; SILVA; ORLANDI, 2021).




Figura 1 - Montagem experimental.

Os sensores preparados foram caracterizados quanto a microestrutura e morfologia por microscopia eletrônica de varredura (SEM) utilizando um microscópio modelo Mira Tescan. As respostas dos nanossensores foram analisadas utilizando os gases  $H_2$  e CO com concentrações pré-determinadas com relação ao nitrogênio. Nitrogênio foi utilizado como gás de arraste e para diluição dos gases de análise. Os sensores foram alocados em posição ligeiramente acima do óleo, denominada de *headspace*. Os nanossensores foram caracterizados a temperatura ambiente, no intervalo de concentração 25 a 6000 ppm. Ciclos definidos e alternados entre nitrogênio e o gás de análise foram mantidos constantes para todas as medidas.

### 3.0 METODOLOGIA APLICADA AOS CLASSIFICADORES INTELIGENTES

Para a realização dos experimentos das ferramentas inteligentes foram utilizados dois conjuntos de dados, ambos contendo histórico de falhas em transformadores de potência a óleo, e a análise de gás dissolvido (*Dissolved Gas Analysis* - DGA), porém, cada banco de dados contendo informações diferentes um do outro:

- Gases\_05: Composto por 1.201 amostras contendo 5 categorias, cada uma descrevendo a análise de gás dissolvido nos transformadores. O conjunto de dados é composto por 3 classes, representando o comportamento normal, falhas térmicas, e falhas elétricas (FILHO, 2012);
- Gases\_07: Semelhante ao conjunto de dados Gases\_05, a diferença está na quantidade de amostras, ou seja, 1.144 ocorrências e o número de categorias aumenta para 7 gases distintos ao invés de 5 (FILHO, 2012).

Como os classificadores inteligentes ficarão junto com a plataforma nanosensora, que está sendo desenvolvida, os experimentos foram realizados em uma placa Raspberry Pi de quarta geração com um processador quad-core de 64 bits com 4 Gb de memória RAM (Memória de Acesso Aleatório - *Random Access Memory*).

Para execução dos classificadores, duas bibliotecas que já possuem parte de suas funções necessárias pré-programadas foram adotadas, sendo; (i) o framework OPF baseado em Python, denominado OPFython (ROSA; PAPA; FALCÃO, 2020) e (ii) Scikit-learn, uma biblioteca desenvolvida para técnicas de aprendizado de máquina com código aberto e que utiliza a linguagem de programação Python.

Buscando avaliar os modelos de ML (*Machine Learning*) utilizado nos experimentos, foi aplicada a técnica de Validação Cruzada (*Cross-Validation* - CV) (PAYAM; LEI; HUAN, 2009), uma técnica estatística de avaliação de métodos que é amplamente utilizada para avaliar a capacidade de generalização de um modelo a partir de um conjunto de dados, muito empregada em problemas de modelagem de dados e técnicas de predição. Foi utilizado neste processo o método *holdout* (SAMMUT; WEBB, 2010), que consiste em dividir o conjunto de dados em frações de subconjuntos exclusivos de treinamento e teste, explicado a seguir.

No que diz respeito ao protocolo experimental, os conjuntos de treinamento e teste foram particionados em diferentes configurações, isto é, 10% para o conjunto de treinamento e os 90% restantes para o conjunto de testes; em seguida, 20% para o conjunto de treinamento e os 80% restantes para o conjunto de testes, e assim sucessivamente até a proporção de 90% para o conjunto de treinamento e os 10% restantes para o conjunto de testes. Este particionamento foi realizado nove vezes de maneira aleatória para fins de cálculo médio das taxas de acerto.

Foram testados quatro diferentes classificadores neste experimento, árvore de decisão (QUINLAN, 1996 e ROKACH; MAIMON, 2004), bayesiano (DUDA; HART, 1973), OPF e SVM (VAPNIK; CHERBONENKIS 1968), sempre seguindo o protocolo experimental estabelecido.

#### 4.0 RESULTADOS ALCANÇADOS DOS NANOSENSORES

Neste capítulo são apresentados os resultados da preparação e ensaio dos nanossensores. A Figura 2 apresenta as imagens obtidas por microscopia eletrônica de varredura (SEM) dos ZnO NRs decorados com Pd NPs. Observa-se o crescimento perpendicular de ZnO NRs e um bom recobrimento do substrato (Figura 2.a). Para a imagem obtida em maior magnificação, Figura 2.b, observa-se a decoração da superfície dos ZnO NRs com Pd NPs. Nos gráficos de resistência versus a concentração de gás  $H_2$ , Figuras 2.c e 2.d, nota-se uma diminuição da resistência conforme a concentração de gás  $H_2$  aumenta, indicando que o nanossensor consegue detectar o gás na faixa de 25 a 6000 ppm a temperatura ambiente.

Como no caso anterior, os nanossensores preparados com  $SnO_2$  NPs decoradas com Pd NPs foram caracterizados por SEM e quanto a capacidade de detectar o gás CO a temperatura ambiente. Observa-se na Figuras 3.a e 3.b um recobrimento uniforme do substrato sensor e que as Pd NPs estão distribuídas homogeneamente sobre as  $SnO_2$  NPs. Nos gráficos de resistência versus a concentração de gás CO, Figuras 3.c e 3.d, nota-se uma diminuição da resistência conforme a concentração de gás CO aumenta, indicando que o nanossensor consegue detectar o gás na faixa de 25 a 6000 ppm a temperatura ambiente.

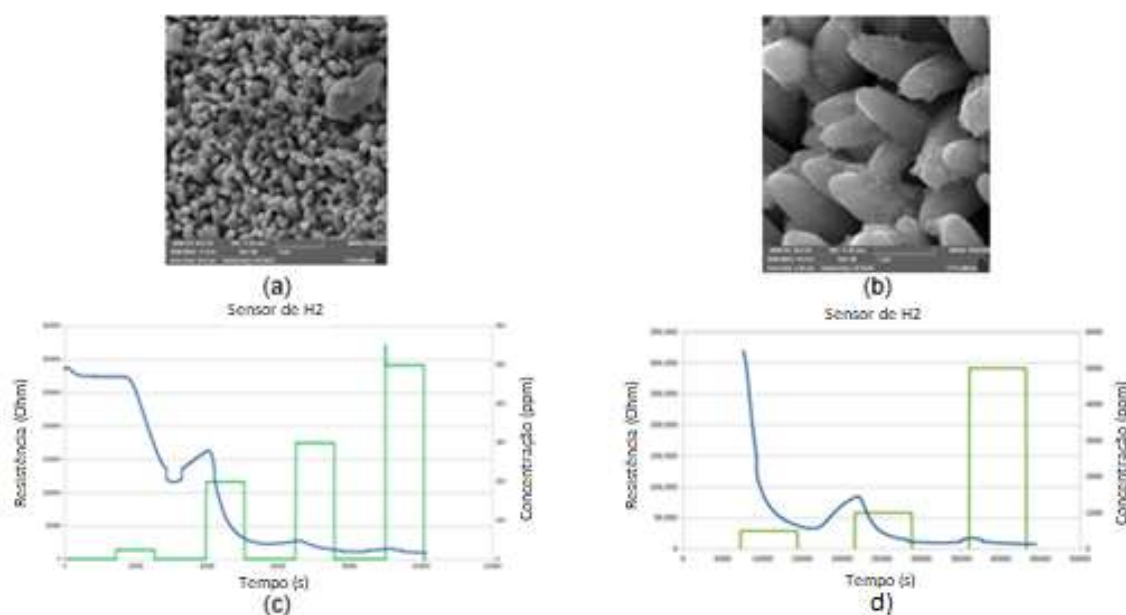


Figura 2 - (a) e (b) Imagens obtidas por SEM dos ZnO NRs decorados com Pd NPs; (c) e (d) Gráficos de resistência e concentração de gás (25 a 6000 ppm) versus tempo para os sensores de  $H_2$ . Medidas realizadas com os sensores no *headspace* a temperatura ambiente.




Figura 3 - (a) e (b) Imagens obtidas por SEM das SnO<sub>2</sub> NPs decoradas com Pd NPs; (c) e (d) Gráficos de resistência e concentração de gás (25 a 6000 ppm) versus tempo para os sensores de CO. Medidas realizadas com os sensores no *headspace* a temperatura ambiente.

Os resultados apresentados são bastante promissores para a correta detecção dos gases selecionados. Os demais gases citados para o diagnóstico dos transformadores estão sendo estudados e novos ensaios estão em curso para definição das melhores configurações para outros gases chaves.

Um dos objetivos deste projeto de P&D é desenvolver um protótipo de uma plataforma nanosensora, composta por sensores, sistema de alimentação própria e circuitos de conversão e tratamento de dados. Os nanosensores estarão em contato com o óleo do transformador através de ajustes feitos na válvula de retirada de óleo na parte inferior do ativo. Circuitos de conversão de sinais e circuitos de transmissão de dados serão responsáveis pelo envio da informação de concentração de gases para a central de gestão dos transformadores.

## 5.0 RESULTADOS ALCANÇADOS DOS SISTEMAS INTELIGENTES

Salienta-se que a escolha do protocolo experimental é de extrema importância para a avaliação das ferramentas experimentadas. O método *holdout*, por exemplo, busca mensurar o quão bom o modelo está se saindo na classificação de amostras que ele ainda não conhece.

Apesar da quantidade de amostras serem poucas e ainda desbalanceadas entre as classes nos conjuntos de dados, os algoritmos utilizados se comportaram bem, alcançando boas taxas de acerto, sendo a melhor acurácia média alcançada pelo algoritmo de árvore de decisão com 94% de acerto, seguido pelo classificador bayesiano com 92%, OPF com 86% e por último SVM com 85%. A Figura 4 (a) apresenta o comportamento dos resultados obtidos de acordo com cada etapa de divisão efetuado pelo *holdout*. Com relação ao tempo de execução na etapa de treinamento, o classificador OPF obteve o melhor desempenho com 19,67 segundos, um tempo relativamente melhor que os demais classificadores, que se mantiveram em uma média de 27,43 segundos, como apresentado na Figura 4 (b). Os tempos de treinamento para as técnicas *Decision Tree*, Naive Bayes e SVM foram muito similares, por isso encontram-se todas na posição que a linha correspondente ao classificador SVM.






Figura 4 – Experimento com Gases\_05, (a) Acurácia, (b) Tempo de treinamento

Para o conjunto de Gases\_07, o comportamento dos classificadores foi bem similar com relação ao desempenho, tendo o algoritmo de árvore de decisão com a melhor acurácia em 95%, seguida pelo classificador bayesiano com 93%, SVM com 88% e OPF com 76%. Esse desempenho é apresentado na Figura 5 (a) a seguir. Novamente, com relação ao tempo de treinamento o algoritmo OPF obteve o melhor desempenho, alcançando 18,88 segundos em média, já os demais, repetiram o comportamento apresentado no conjunto de dados de Gases\_05, mantendo todos uma média por volta dos 26 segundos. A Figura 5 (b) apresenta esse comportamento demonstrando uma correlação positiva entre o tempo de execução e a etapa do processo de treinamento. Os tempos de treinamento para as técnicas *Decision Tree*, Naive Bayes e SVM foram muito similares, por isso encontram-se todas na posição que a linha correspondente ao classificador SVM.

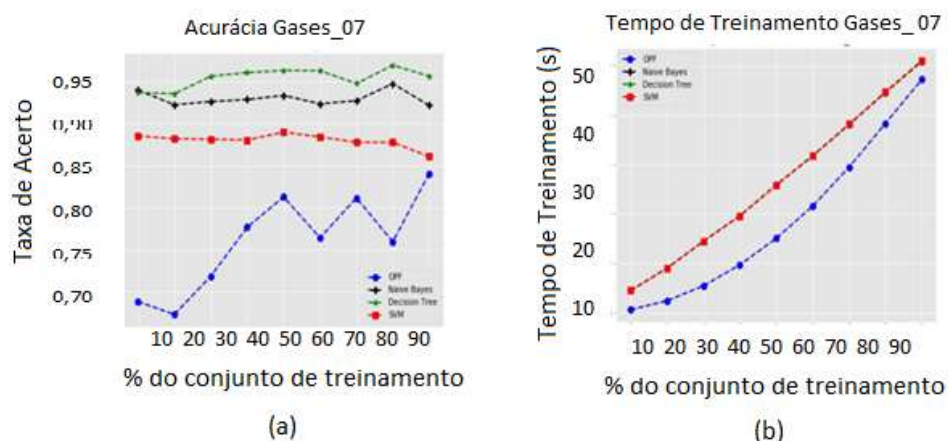


Figura 5 - Experimento com Gases\_07, (a) Acurácia, (b) Tempo de treinamento

Outro objetivo deste projeto de P&D é o desenvolvimento de ferramentas para análise de dados de evolução dos gases, sejam dados da plataforma ou então dados de medições de laboratórios contratados. Neste sentido, ferramentas de inteligência artificial estão sendo estudadas para uma classificação de falha e para estudo de previsão incipiente das falhas, devido ao acompanhamento da concentração dos gases.

## 6.0 CONCLUSÕES

O correto funcionamento do sistema elétrico de energia está diretamente relacionado com a gestão dos ativos presentes na rede elétrica, sendo os transformadores de potência, um dispositivo de alto valor agregado e fundamental para o sistema. O seu monitoramento e acompanhamento da sua vida útil é feita por diferentes processos e ferramentas, e o diagnóstico depende da experiência de um especialista. Neste sentido, o avanço nas tecnologias aplicadas no sensoriamento, bem como, a utilização de ferramentas de tratamento de dados, auxiliam tanto no melhor diagnóstico quanto no melhor planejamento de manutenção destes dispositivos. Este artigo apresenta os resultados parciais do desenvolvimento de nanossensores para medidas de concentrações de gases no óleo isolante, e a aplicação de classificadores computacionais inteligentes para visualização de padrões das amostras de DGA.

O desenvolvimento dos nanosensores é baseado em nanoestruturas de ZnO e SnO<sub>2</sub> funcionalizados com nanopartículas de paládio, ou CuO com estruturas de carbono, como óxido de grafeno. Diferentes configurações foram ensaiadas e os resultados das melhores amostras para os gases de H<sub>2</sub> e CO, foram apresentados. Os sensores foram capazes de detectar 5 a 5.000 ppm de gás dissolvido no óleo de forma direta, imerso no óleo ou indiretamente, utilizando o conceito de *headspace*. Até onde os autores conhecem, a detecção de gases dissolvidos no óleo de forma direta (imerso no óleo), bem como o uso de nanoestruturas de óxidos semicondutores e o tipo do sensor (resistivo) constituem o ineditismo deste trabalho.

O nanosensor preparado para resposta na presença do gás H<sub>2</sub> teve bons resultados, sendo possível detectar concentrações tão baixas quanto 100 ppm a temperatura ambiente. O tempo de resposta deste sensor ficou em torno de 10 minutos e o sinal em torno de 3,54 (3 vezes maior que o obtido na presença dos demais gases), indicando a boa seletividade do sensor.

A configuração nanosensora para resposta na presença do gás CO, obteve excelentes resultados. Este sensor foi capaz de detectar concentrações tão baixas quanto 100 ppm a temperatura ambiente. O tempo de resposta deste sensor ficou em torno de 13 minutos e o sinal em torno de 15. O sensor não apresentou resposta aos demais gases, indicando a boa seletividade dele.

No que diz respeito às técnicas inteligentes, a contribuição do trabalho está no uso do classificador Floresta de Caminhos Ótimos, o qual ainda não havia sido avaliado no contexto de detecção de falhas em transformadores de potência. Experimentos realizados em dois conjuntos de dados distintos (número de informações utilizadas como entrada para os modelos inteligentes) apontam para taxas de acerto de 86% e 76%. No entanto, um fator bastante positivo da abordagem proposta diz respeito ao tempo de detecção de uma falha, que está em torno de 0,018 segundos. Os experimentos foram conduzidos utilizando uma placa Raspberry Pi de quarta geração, que contempla um processador com quatro núcleos de 64 bits e 4Gb de memória RAM.

Como principais conclusões, entende-se como bastante factível a metodologia proposta pelo trabalho, dado que taxas promissoras de identificação de falhas foram obtidas e, principalmente, com baixo custo computacional das ferramentas de classificação. Em relação aos nanosensores desenvolvidos, todos os resultados são promissores e novos ensaios estão em aplicação para definição de novas configurações para identificação de outros gases chave.

## 7.0 AGRADECIMENTOS

Agradecimentos ao Programa de Pesquisa e Desenvolvimento da ANEEL, à CPFL Energia, ao grupo de pesquisa LSISPOTI (Laboratório de Sistemas de Potência e Técnicas Inteligentes) da UNESP, ao apoio CTI-Nano, laboratório estratégico do SisNano, MCTI e financiado pelo CNPq.

## 8.0 REFERÊNCIAS BIBLIOGRÁFICAS

- (1) DUDA, R. O.; HART, P. E. "Pattern Classification and Scene Analysis", John Wiley & Sons, New York, 1973.
- (2) FILHO, G. L. "Comparação entre os critérios de diagnósticos por análise cromatográfica de gases dissolvidos em óleo isolante de transformador de potência" Ph.D. thesis. Universidade de São Paulo. 2012.
- (3) GASPAROTTO, G.; SILVA, R. A.; ZAGHETE, M. A.; PERAZOLLI, L. A.; MAZON, T. "Novel route for fabrication of ZnO nanorods-Au nanoparticles hybrids directly supported on substrate and their application as gas sensors". Materials Research, 21 (4) 2018. <https://doi.org/10.1590/1980-5373-MR-2017-0796>
- (4) GASPAROTTO, G.; MAZON, T.; GASPAROTTO, G.; ZAGHETE, M. A.; PERAZOLLI, L. A.; VARELA, J. A. "Gas sensor properties of ZnO nanorods grown by chemical bath deposition". Advanced Materials Research, v 975, 189-193, 2014. <https://doi.org/10.4028/www.scientific.net/AMR.975.189>
- (5) MORAIS, P. V.; SUMAN, P. H.; SILVA, R. A.; ORLANDI, M. O. "High gas sensor performance of WO<sub>3</sub> nanofibers prepared by electrospinning", Journal of Alloys and Compounds 864 (2021) 158745 <https://doi.org/10.1016/j.jallcom.2021.158745>
- (6) PAPA, J. P.; FALCÃO, A. X.; SUZUKI, C. T. N. "Supervised pattern classification based on optimum-path forest". International Journal of Imaging Systems and Technology n. 19, p. 120–131. 2009.
- (7) PAYAM, R.; LEI, T.; HUAN, L. "Cross-Validation", Encyclopedia of Database Systems, Springer US, p. 532 - 538, 2009.
- (8) QUINLAN, J. R. "Improve Use of Continuous Attributes" Journal of Artificial Intelligence Research, n. 4, p. 77, 1996.
- (9) ROSA, G. H.; PAPA, J. P.; FALCÃO, A. X. "OPFython: A Python-Inspired Optimum-Path Forest Classifier". ArchivePrefix, 2020.

(10) SAAD, M., TENYENHUIS, E. (2018). "On-line gas monitoring for increased transformer protection". 2017 IEEE Electrical Power and Energy Conference, EPEC 2017, 2017–Octob, 1–4. <https://doi.org/10.1109/EPEC.2017.8286169>

(11) SAMMUT, C.; WEBB, G. I. "Holdout Evaluation", Encyclopedia of Machine Learning, Springer US, p. 506 - 507, 2010.

(12) VAPNIK, V. N.; CHERVONENKIS, A. J. "On the uniform convergence of relative frequencies of events to their probabilities", Rep. Academy Sci, USSR, n. 4, p. 181, 1968.

## DADOS BIOGRÁFICOS



(1) HELEN VELOZO VENDRAMETO. Mestrado em Engenharia Elétrica pela Universidade Estadual Paulista - UNESP (até 2023). MBA em Gestão de Ativos e Engenharia de Manutenção (2020). Bacharel em Engenharia Elétrica, pela UNESP (2016). Atuação profissional como Engenheira Eletricista no Departamento de Gestão de Ativos na CPFL Paulista, desde 2016. Experiência na área de Gestão de Ativos, Gestão de Manutenção, Sistemas de Distribuição e Subtransmissão, Investimentos do Sistema Elétrico, Qualidade de Energia e Luminotécnica.

(2) ANDRÉ NUNES DE SOUZA. Professor Titular da UNESP - 2014, Professor Adjunto (UNESP - 2005), Professor Doutor (UNESP - 1999), Mestre e Doutor em Engenharia Elétrica pela Universidade de São Paulo EPUSP (1995-1999). Engenheiro Eletricista pela Universidade Presbiteriana Mackenzie (1991), Engenheiro de Segurança do Trabalho (UNESP-2000), Líder do Grupo de Pesquisa da FEB-LSISPOTI, Coordenador de Laboratório de Pesquisa LSISPOTI (2006). Áreas: Alta Tensão, Transmissão de Energia Elétrica, Distribuição de Energia Elétrica, Eficiência Energética, Nanotecnologia e Inteligência Artificial. Temas: Classificação e Identificação de Padrões, Transformadores, Equipamentos de Alta Tensão, Sistemas Subterrâneos, Microrredes e Sistemas Inteligentes. Coordenador do Curso de Pós-graduação em Engenharia Elétrica da FEB (2021-2025).

(3) DANILO SINKITI GASTALDELLO. Danilo Sinkiti Gastaldello é professor do Centro Universitário Sagrado Coração de Jesus, em Bauru, SP. Possui título de Doutor em Engenharia Elétrica pela Escola Politécnica, USP, e é Mestre em Engenharia Elétrica pela UNESP, Bauru. Pesquisador do Laboratório de Sistemas de Potência e Técnicas Inteligentes (LSISPOTI), grupo cadastrado na CAPES e vinculado à UNESP-Bauru, co-orientador de alunos de mestrado e doutorado no programa de Pós-graduação em Engenharia Elétrica na Unesp-Bauru. Avaliador em diferentes congressos científicos. Sua linha de pesquisa está relacionada a estudos de problemas de sistema de potência e eficiência energética com auxílio de ferramentas computacionais inteligentes.

(4) TALITA MAZON. Possui Bacharelado em Química com Atribuições Tecnológica pelo Instituto de Química de Araraquara da Universidade Estadual Paulista Júlio de Mesquita Filho (1994), mestrado em Química pela Universidade Estadual Paulista Júlio de Mesquita Filho (1997) e doutorado em Química pela Universidade Estadual Paulista Júlio de Mesquita Filho (2001). Atualmente é Tecnologista Senior do Centro de Tecnologia da Informação Renato Archer (CTI). Tem experiência na área de Materiais Avançados atuando principalmente com a síntese de nanoestruturas de óxidos semicondutores, estruturas de carbono e compósitos para aplicação em sensores de gases, biossensores, energy harvesting e dispositivos armazenadores de energia.

(5) EUGÊNIO DE SOUZA MORITA. Graduado em Engenharia Mecânica (2000-2006), Mestrado (2007-2009), Doutorado (2009-2018) em Engenharia Mecânica na área Térmica e Fluidos pela Universidade Estadual de Campinas. Atuação em desenvolvimento e otimização de processos de combustão, pirólise e controle da poluição atmosférica. Avaliação das propriedades de biomassa e e caracterização dos produtos gerados a partir da pirólise de ramas de mandioca IAC-14 em reator de pirólise rápida em parceria com empresa Bioware. Desenvolvimento de plataforma para detecção de falhas incipientes em transformadores de óleo isolante a partir do projeto e teste de nanosensores.

(6) AGNES NASCIMENTO SIMOES. Graduada em Bacharel em Química Tecnológica pela Universidade Estadual de Campinas, com experiência na área de Nanotecnologia, em particular com síntese de óxidos metálicos para aplicação em dispositivos energy harvesting. Além disso, experiência na utilização de biomassas brasileiras, especificadamente bagasso de cana, na utilização para supercapacitores. Mestranda em Engenharia Mecânica na Universidade Estadual de Campinas, focada na área de energia no desenvolvimento de materiais para aplicação em dispositivos energy harvesting com ênfase em óxidos metálicos, biomassas brasileiras com compósitos de grafeno e polímeros. Além disso, desenvolvimento de materiais sensores de gases nocivos em transformadores.

(7) WALDIR ANTONIO BIZZO. Professor associado da Faculdade de Engenharia Mecânica da UNICAMP.



Engenheiro mecânico (1978) e Doutor na área de Engenharia Térmica e de Fluidos (1997). Já atuou em empresa privada na área de projeto e construção de equipamentos térmicos, no setor público na área de Gestão de Resíduos. Foi pesquisador no CIRAD Centre de coopération internationale en recherche agronomique pour le développement (Montpellier-França) no grupo de pesquisa Biomasse-Energie. Atua nas áreas de pesquisa de combustão de biomassa, pirólise rápida, aerodinâmica da combustão e formação de poluentes, geração de energia por biomassa, leiteo fluidizado.

(8) JOÃO PAULO PAPA. João Paulo Papa é professor associado junto ao Departamento de Computação da Faculdade de Ciências da Universidade Estadual Paulista "Júlio de Mesquita Filho" - Unesp, Bauru-SP. Possui pós-doutorado pela Universidade de Harvard, bem como é Doutor em Ciência da Computação pela Unicamp, Mestre em Ciência da Computação pela Universidade Federal de São Carlos e Bacharel em Sistemas de Informação pela Unesp. Possui atuação em aprendizado de máquina, visão computacional e otimização por metaheurísticas. É membro sênior da IEEE, Research Fellow da Função Alexander von Humboldt (Alemanha) e representante brasileiro junto à Associação Internacional de Reconhecimento de Padrões.

(9) FLORIANO TORRES NETO. Graduado em Engenharia Elétrica pela UFMS em 2007 com ênfase em sistemas de potência. E mestre, pela UNICAMP em 2010, na área fluxo de potência de energia elétrica. Com passagens pela Alstom Grid e GE na área de automação de subestações, atualmente está na CPFL Geração a fazer o O&M de subestações de rede básica.

(10) VAGNER VASCONCELLOS. Vagner Vasconcellos. Nascido em 1973 em Sorocaba, SP possui graduação em Engenharia Elétrica pela Faculdade de Engenharia de Sorocaba FACENS (1998), Mestrado (2007) e Doutorado (2016), ambos em Sistemas de Potência pela Escola Politécnica da USP, e MBA em Gerenciamento de Projetos FGV Campinas (2019). Experiência de 25 anos no Setor elétrico e desde 2016 atua como Engenheiro da Área de Normas e Padrões do Grupo CPFL Energia.

(11) CHRISTIAN ROBERTO CAMPIONI DA CRUZ. FORMAÇÃO ACADEMICA - 2012 Graduação em Engenharia Elétrica Faculdade Anhanguera Sorocaba ATUAÇÃO PROFISSIONAL - Companhia Piratininga de Força e Luz - CPFL - Atual Engenheiro de Gestão de Ativos - Gestão em processos de manutenção do sistema da Subtransmissão; Investimentos em melhoramentos; Operação otimizada do sistema com rentabilidade econômica; Gerir contratos e projetos de obras de subestações e linhas de subtransmissão; Reserva técnica de equipamentos em recomposição e utilizações; Reformas de trafos de potencia de subestações; Plano de manutenção de subestações e linhas de subtransmissão; Controles internos e baixas de ativos; Analisar taxa de falha; Manutenir a base sistema de dados; Seguros e sinistros.

(12) JOÃO CARLOS CARNEIRO. Formado em 1980 na Faculdade de Engenharia Elétrica pela Fundação Educacional de Bauru - Estado de São Paulo - SP - Brasil (atual UNESP) e especialização em Curso Avançado em Gestão de Energia pela Fundação Getúlio Vargas de São Paulo em 1997/1998. Mestre em Geofísica Espacial - Eletricidade Atmosférica pelo Instituto Nacional de Pesquisas Espaciais INPE (Instituto Nacional de Pesquisas Espaciais de São José dos Campos - SP - Brasil), com foco na Interação das Descargas Atmosféricas e o Sistema Elétrico em 2009. Entre outras atribuições, participa de Grupos de Trabalho CIGRÉ e ABNT, envolvendo subestações e equipamentos (manutenção centrada em confiabilidade de transformadores, monitoramento de transformadores e para-raios, guia de manutenção de transformadores, riscos de explosão e incêndio de transformadores, coordenação de isolamento de sistemas elétrico, técnicas de ensaios de alta tensão). Colaborador da CPFL desde 1981, atuando no universo de subestações e equipamentos associados desde prospecção de novas tecnologias, estudos, projetos e ensaios de recebimento. Atualmente é engenheiro Especialista de soluções de manutenção, normas e padrões.