



Recebido em: 06/09/2024.

Aceito em: 30/12/2024.

Revista SODEBRAS – Volume 19  
Nº 222 – SETEMBRO/ DEZEMBRO - 2024

## **PREDIÇÃO OTIMIZADA DO ÍNDICE DE DESEMPENHO DE TRANSFORMADORES DE POTÊNCIA COM APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL**

### *OPTIMIZED PREDICTION OF POWER TRANSFORMER PERFORMANCE INDEX USING ARTIFICIAL INTELLIGENCE*

Vinícius Faria Costa Mendanha<sup>1</sup>  
André Pereira Marques<sup>2</sup>  
Yuri Andrade Dias<sup>3</sup>  
Cacilda de Jesus Ribeiro<sup>4</sup>

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

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

**Abstract** - Power transformers are essential equipment for the operation of the electrical system, requiring maintenance with accurate and efficient diagnoses. Therefore, the objective of this work is to present the development of a tool with the application of artificial

<sup>1</sup>Mestrando em Engenharia Elétrica e de Computação na Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás. Contato: [vinicius.fcfariacosta@gmail.com](mailto:vinicius.fcfariacosta@gmail.com).

<sup>2</sup>Doutor em Engenharia Elétrica pela Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás. Docente Titular do Instituto Federal de Goiás – campus de Goiânia. Contato: [ap.marques@ifg.edu.br](mailto:ap.marques@ifg.edu.br).

<sup>3</sup>Doutor em Engenharia Elétrica pela Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás. Contato: [yuriadias@gmail.com](mailto:yuriadias@gmail.com).

<sup>4</sup>Doutora em Engenharia Elétrica pela Escola de Engenharia de São Carlos da Universidade de São Paulo. Docente Titular da Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás. Contato: [cacilda@ufg.br](mailto:cacilda@ufg.br).

*intelligence to predict the operational status based on the Performance Index, through the use of predictive techniques. The combination of these techniques with Artificial Intelligence algorithms enables an adequate and individualized analysis, optimizing maintenance resources. The methodology used includes the calculation of this performance index and the corresponding recommended actions, which range from monitoring to the immediate removal of the equipment from operation, in conjunction with the Elbow Curve (Elbow Method) and Local Outlier Factor algorithms (Local Outlier Factor), which are used to identify and exclude outlier samples, ensuring data consistency. Validation was carried out through case studies and the results were satisfactory, concluding that this tool provides failure prevention, contributing to assertive management of this equipment and assisting maintenance teams in making decisions regarding the appropriate time of intervention.*

**Keywords:** *performance index, prediction, power transformer.*

## I. INTRODUÇÃO

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

As avaliações deste índice de desempenho baseiam-se, em geral, na condição momentânea/atual do ativo (Dias, 2023). Por sua vez, em diferentes trabalhos da literatura

(Idrees et al., 2019; Freitag e Sperandio, 2021; Góes et al, 2021), apresentam-se abordagens que fazem avaliações de condições dos equipamentos baseando-se em modelos de confiabilidade e probabilidade de falha, fazendo uso de estatísticas de falha de um certo espaço amostral de um determinado universo de equipamentos. Esses trabalhos apresentam também previsões baseadas em conjuntos de amostras, que em condições operativas distintas, poderão incorrer em grande perda de sensibilidade analítica. Isso proporciona uma limitação para equipamentos com características construtivas muito distintas e quando se possui poucos dados históricos de manutenções preventivas disponíveis, como é a realidade dos transformadores de potência de subestações de energia elétrica em muitas empresas.

Assim, este artigo tem como originalidade o desenvolvimento de uma ferramenta com aplicação de inteligência artificial para excluir resultados discrepantes dos resultados das técnicas preditivas obtidas em campo, predizendo, de forma otimizada, a condição momentânea do equipamento (individualmente), por meio do índice de desempenho e do histórico destes equipamentos.

Observando-se que em algumas situações podem ocorrer equívocos nas obtenções dos resultados destas técnicas, resultantes das condições ambientais, das condições preparatórias dos executores ou do próprio equipamento de medição, dificultando a observação de tendências. Dessa forma, este trabalho se justifica por apresentar uma ferramenta que auxilia na identificação incorreta de falhas, eliminando pontos discrepantes (*outliers*) por meio de recursos de inteligência artificial, evitando intervenções desnecessárias e tendo como objetivo principal predizer o índice de desempenho durante a vida útil destes equipamentos importantes para o sistema elétrico de potência.

## II. METODOLOGIA

A metodologia desenvolvida é um modelo híbrido de inteligência artificial, voltado para a predição do estado de transformadores de potência, utilizando o índice de

desempenho. Esse modelo combina dois algoritmos principais com estruturas condicionais para uma análise aprofundada dos dados, a saber:

- **Curva de Cotovelo (*Elbow Method*):** utilizada para determinar o número ideal de vizinhos mais próximos em subconjuntos de dados. De forma geral, ela descreve a distorção medida pela soma do erro quadrático,  $\epsilon_q$ , a cada valor  $k$  testado, referente ao melhor número de vizinhos, conforme (1), sendo  $d_{n,k}$  a distância de cada amostra  $n$  ao seu respectivo centroide  $k$  (Pereira, 2023).

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

De (1), quanto menor for o valor de  $\epsilon_q$ , as amostras estão mais próximas de seus respectivos centroides (Pereira, 2023). Assim, é possível obter um gráfico para análise, em que o eixo das abcissas corresponde ao melhor número de vizinhos testado ( $k$ ), enquanto o das ordenadas representa a soma do erro quadrático.

Desse modo, o algoritmo da curva de cotovelo seleciona o valor ótimo de  $k$ , evitando o fenômeno de *overfitting*. Essa maneira de determinar  $k$  é utilizada com o algoritmo de Fator de *Outlier Local*, neste trabalho.

- **Fator de Outlier Local (*Local Outlier Factor* ou **LOF**):** trata-se do algoritmo de Inteligência Artificial para identificação e desconsideração de amostras da análise, por estarem contaminadas por ruídos excessivos. É uma técnica não supervisionada de aprendizado de máquinas, que localiza os pontos a serem excluídos de determinado conjunto de dados sem a suposição prévia de uma distribuição de dados específica (Qin, 2019; Alghushairy, 2020). A partir de conjunto de dados  $X \in \mathbb{R}^{m \times n}$  e de um conjunto de teste  $x \in \mathbb{R}^m$ , o LOF procede da seguinte forma:

1. Considera-se a amostra  $x$  e os  $k$  vizinhos mais próximos, denotando-se a distância euclidiana por  $N(x) = [x^1, x^2, \dots, x^K]$ , sendo que o parâmetro  $K$  representa a dimensão do conjunto avaliado.

2. Para cada amostra vizinha,  $x^f$ , com  $1 \leq f \leq K$ , a distância  $K$  de  $x^f$ ,  $k_{distance}(x^f)$ , é calculada, sendo a distância euclidiana entre  $x^f$  e seus  $K$ -ésimos vizinhos mais próximos.

3. Obtém-se a distância de alcance,  $reach_d$ , da amostra  $x$ , conforme (2), sendo  $d(x, x^f)$  a distância euclidiana entre  $x$  e seu  $f$ -ésimo vizinho.

$$reach_d(x, x^f) = \max\{k_{distance}(x^f), d(x, x^f)\} \quad (2)$$

4. Calculam-se a densidade local de alcance para a amostra  $x$ ,  $lrd(x)$ , como em (3), e o LOF da amostra  $x$ ,  $LOF(x)$ , dado em (4).

$$lrd(x) = \frac{K}{\sum_{f=1}^K reach_d(x, x^f)} \quad (3)$$

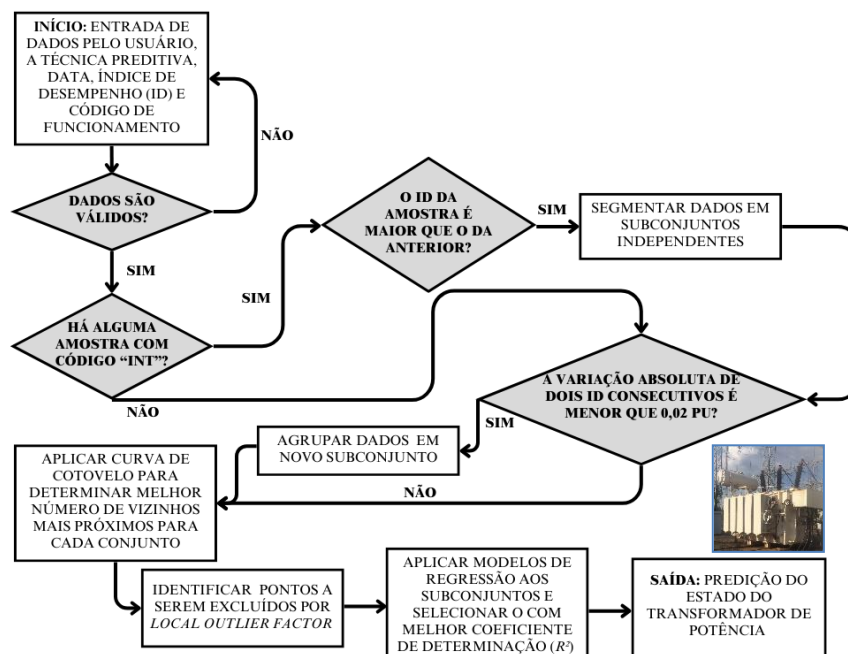
$$LOF(x) = \frac{1}{K} \sum_{f=1}^K \frac{lrd(x^f)}{lrd(x)} \quad (4)$$

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

Além desses algoritmos, a ferramenta incorpora estruturas condicionais para avaliar a variação absoluta entre duas amostras de datas consecutivas, aprimorando a análise dos dados, como, por exemplo, se houve intervenção (INT). O modelo é aplicado a nove técnicas preditivas do equipamento, que são: Corrente de Excitação (EE\_CE), Fator de Potência (EE\_FP), Relação de Transformação (EE\_RT), Resistência de Isolamento (EE\_RI), Resistência Elétrica (EE\_RE), Ensaios em Buchas (EE\_BU), Análise de Gases Dissolvidos (AGD), Ensaios Físico-Químicos (FQ) e Grau de

Polimerização/2FAL-Furfuraldeídos (GP\_2FAL). O fluxograma das etapas do método desenvolvido está representado na Figura 2.

Figura 2 – Fluxograma com etapas do método desenvolvido neste trabalho.



Fonte: próprios autores (2024).

Com os modelos de regressão e de identificação dos pontos excluídos da análise, realiza-se a predição do estado do transformador de potência com base nos subconjuntos processados. O final do processo inclui duas principais informações: a predição do estado do transformador de potência, conforme Tabela 1, e as ações recomendadas ao usuário, como sugestões sobre intervir ou não no equipamento.

Tabela 1 – Critério de classificação do estado de operação como uma função do índice de desempenho

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

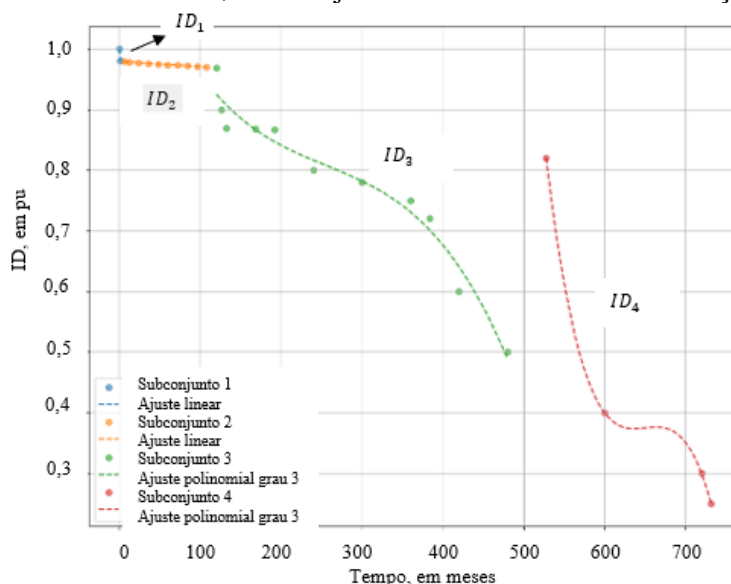
Fonte: adaptado de DIAS (2023).

A classificação utilizada na Tabela 1 é baseada nos resultados da análise e tem como objetivo assegurar que o transformador de potência opere dentro de faixas desejadas, identificando e abordando potenciais problemas de forma técnica. O estado final do equipamento é, portanto, o pior estado predito, considerando a totalidade das técnicas preditivas utilizadas.

### III. RESULTADOS

A ferramenta desenvolvida foi validada com dados factíveis de transformadores de potência considerando as nove técnicas preditivas disponíveis e citadas anteriormente. Desta forma, na Figura 1, ilustra-se um dos estudos de caso com dados históricos concernentes à técnica preditiva de Análise de Gases Dissolvidos (AGD), onde são observados quatro subconjuntos resultantes do processo de segmentação proposta, considerando a efetividade das intervenções executadas no equipamento.

Figura 1 – Análise de Gases Dissolvidos, com representação dos subconjuntos de análise, pontos desconsiderados, reta de ajuste e coeficientes de determinação  $R^2$ .



Legenda:

$$ID_1 = -0,0167 \cdot Tempo + 1,000$$

$$ID_2 = -1,133 \cdot 10^{-4} \cdot Tempo + 0,979$$

$$ID_3 = -1,740 \cdot 10^{-8} \cdot Tempo^3 + 1,334 \cdot 10^{-5} \cdot Tempo^2 - 3,957 \cdot 10^{-3} \cdot Tempo + 1,234$$

$$ID_4 = -2,514 \cdot 10^{-7} \cdot Tempo^3 + 4,907 \cdot 10^{-4} \cdot Tempo^2 - 0,319 \cdot Tempo + 69,503$$

Fonte: próprios autores (2024)


De forma eficiente, os dados são segmentados em quatro subconjuntos independentes, conforme ilustra a Figura 1. Esse processo produz *clusters* coerentes ao observado pelo especialista em campo. Nesse sentido, são utilizados mais dois tipos de ajuste para os outros subconjuntos, obtidos por regressão, além do linear: os polinomiais de segunda e terceira ordens. Assim, com base nos resultados apresentados, o especialista poderia agendar intervenções seguindo as recomendações fornecidas pela ferramenta. Considerando que o histórico do equipamento é até o mês 792 (equivalente a 66 anos), estima-se quando o transformador atingirá um estado de operação ruim, definido quando o ID for igual ou inferior a 0,35, conforme Tabela 1.

De acordo com a equação do subconjunto **ID<sub>3</sub>**, esse valor seria alcançado após 516,8 meses de operação, ou seja, quando transcorridos 43,1 anos de funcionamento do transformador. No entanto, devido à intervenção realizada após o último ponto de **ID<sub>3</sub>**, por volta dos 500 meses, o índice crítico foi atingido somente após 724,8 meses, conforme **ID<sub>4</sub>**, o que resultou em um prolongamento de 17 anos no período de operação do equipamento. Além disso, ao se analisar, em uma visão holística, no comportamento dos 4 subconjuntos da Figura 1, observa-se que para os subconjuntos **ID<sub>1</sub>** e **ID<sub>2</sub>** os valores são estáveis e elevados, indicando um excelente estado do equipamento.

Entretanto, para o subconjunto ID<sub>3</sub>, tem-se um decaimento bastante acentuado dos índices, o que levou a se realizar a intervenção no equipamento por volta dos 500 meses de operação. No subconjunto ID<sub>4</sub>, ocorre a elevação abrupta do índice de desempenho devido a intervenção realizada, entretanto, os valores voltam a decair de forma ainda mais acelerada do que em ID<sub>3</sub>. Uma análise mais acurada poderia levar a se inferir uma falha iminente e/ou o final de vida útil do equipamento na região à direita de ID<sub>4</sub>.


A fim de avaliar a capacidade do algoritmo desenvolvido para detectar amostras extremamente afetadas por dados espúrios, são inseridos, propositalmente, dois valores a serem desconsiderados pela ferramenta, os quais estão circulados na Figura 2. Constata-se desta forma, que a ferramenta aplicada foi capaz de identificar corretamente todas as amostras inadequadas, sem gerar falsos positivos ou falsos negativos. Além disso, verifica-se que o decaimento de valores dos dois subconjuntos apresenta comportamento semelhante.

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



Complementando a análise, na Figura 3 tem-se o resultado de um dos estudos de caso com dados históricos relativos aos ensaios físico-químicos (EE\_FQ), em que não há pontos a serem excluídos, e a ferramenta, de forma correta, considera todas as amostras de entrada. Neste caso, observa-se que houve uma intervenção no equipamento após o último dado de ID1, o que elevou o índice de desempenho de 0,65 para 0,85 (primeiro dado de ID2), e que, sucessivamente, quando o subconjunto ID2 atingiu valor de 0,65, houve outra intervenção, a qual elevou o índice para 0,8 (primeiro dado de ID3). Além disso, constata-se que os três subconjuntos apresentam decaimentos semelhantes de valores de índices de desempenho.

Figura 3 – Técnica preditiva de ensaios físico-químicos, com representação dos subconjuntos de análise, pontos desconsiderados, retas de ajuste e coeficientes de determinação  $R^2$ .



Legenda:

$$ID_1 = -4,494 \cdot 10^{-5} \cdot Tempo + 1,002$$

$$ID_2 = -4,658 \times 10^{-5} \cdot Tempo + 1,189$$

$$ID_3 = -4,446 \cdot 10^{-5} \cdot Tempo + 1,304$$

Fonte: próprios autores (2024).

As métricas de precisão e *recall* (sensibilidade) foram calculadas de acordo com (5) e (6), respectivamente. E os resultados da precisão e do *recall* foram de 100%, constando que a ferramenta é eficiente na identificação de amostras a serem excluídas dos conjuntos analisados.

$$\text{Precisão} = \frac{\text{Verdadeiros positivos}}{\text{Verdadeiros positivos} + \text{Falsos positivos}} \quad (5)$$

$$\text{Recall} = \frac{\text{Verdadeiros positivos}}{\text{Verdadeiros positivos} + \text{Falsos negativos}} \quad (6)$$

#### IV. CONCLUSÃO

A ferramenta desenvolvida neste trabalho apresenta a predição do índice de desempenho auxiliando a equipe de manutenção de transformadores de potência a intervir no momento adequado.

A integração do uso de inteligência artificial, do Fator de Outlier Local (*Local Outlier Factor* ou *LOF*) e a Curva de Cotovelo, para determinar o número ideal de vizinhos mais próximos e segmentar os dados em subconjuntos significativos, demonstrou uma precisão e *recall* de 100% nas técnicas preditivas avaliadas, evidenciando sua eficácia na identificação correta das amostras a serem excluídas. Esses resultados destacam a alta acurácia da ferramenta na predição do estado dos transformadores e na análise da extensão da vida útil do equipamento, refletindo a efetividade das intervenções realizadas, favorecendo a aplicação de recursos financeiros de manutenção também eficientes.

Este artigo apresenta estudos de casos de transformadores de potência, porém esta ferramenta possui abrangência ampla com aplicações possíveis em outros equipamentos de média e alta tensão também, e em condições operacionais diversas.

Portanto, conclui-se que a abordagem deste trabalho possibilita uma programação acertada da manutenção preventiva, com intuito de otimizar o desempenho dos transformadores de potência de forma individualizada de acordo com o seu histórico. A combinação de modelos de regressão precisos de inteligência artificial



proporcionou uma análise detalhada e segmentada dos dados, fornecendo aos especialistas, informações para o planejamento e implementação de ações corretivas e preventivas nestes equipamentos importantes para o sistema elétrico de potência.

## V. REFERÊNCIAS

ALGHUSHAIRY, Omar et al. A Review of Local Outlier Factor Algorithms for Outlier Detection in Big Data Streams. **Big Data and Cognitive Computing**, v. 5, n. 1, p. 1, 29 dez. 2020. MDPI AG. <http://dx.doi.org/10.3390/bdcc5010001>.

DIAS, Y. A. **Método para previsão dos índices de desempenho de transformadores de potência imersos em óleo mineral isolante e de disjuntores de média e alta tensão**. Tese (Doutorando em Engenharia Elétrica e de Computação) – Escola de Engenharia Elétrica, Mecânica e de Computação, Universidade Federal de Goiás, Goiânia, 2023.

FREITAG, Suelen Cristiane; SPERANDIO, Mauricio. Determining the Reliability of Power Transformers Considering a Five States Markov Model. **IEEE Latin America Transactions**, v. 19, n. 02, p. 335-341, fev. 2021. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tla.2021.9443076>.

GÓES, Helano Oliveira *et al.* Falhas em transformadores de potência: estudo de caso do suf6-03 na uhe samuel. **Research, Society and Development**, v. 10, n. 6, p. 1-10, 2021.

IDREES, M., et al. **Fuzzy Logic Based Calculation and Analysis of Health Index for Power Transformer Installed in Grid Stations**. 2019 International Symposium on Recent Advances in Electrical Engineering (RAEE), Islamabad, Pakistan, pp. 1-6, 2019.

PEREIRA, Leonardo do Nascimento. **Avaliação da degradação de disjuntores de alta tensão por meio de técnicas de *machine learning***. 2023. 72 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade de São Paulo, São Paulo, 2023.

QIN, J. F. *et al.* Outlier detection for on-line monitoring data of transformer based on wavelet transform and weighted LOF. **Iop Conference Series: Earth and Environmental Science**, [S.L.], v. 354, n. 1, p. 012108, 1 out. 2019.

## VI. AGRADECIMENTOS

Ao Programa de Pós-graduação em Engenharia Elétrica e de Computação (PPGEEC) da Universidade Federal de Goiás (UFG), ao Instituto Federal de Goiás (IFG), e ao Laboratório de Pesquisa em Engenharia de Alta Tensão (LAPEAT-UFG) pelos apoios e à Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG) pelo recurso financeiro.

## VII. COPYRIGHT

Direitos autorais: os autores são os únicos responsáveis pelo material incluído no artigo.