



Imminent Fault Detection in High Voltage Capacitive Bushings: a Machine Learning-Based Approach

Daniel Carrijo, Gabriel Gomes, Rafael Fehlberg, Sofia Lopes,
Rogério Flauzino, Marcos Alves, Mário Alves, Renan Rosa and
Iony Patriota de Siqueira

EasyChair preprints are intended for rapid
dissemination of research results and are
integrated with the rest of EasyChair.

October 26, 2023

Detecção de Falhas Iminentes em Buchas Capacitivas de Alta Tensão: Uma Abordagem Baseada em Machine Learning^{*}

Daniel Carrijo Polonio Araujo^{*} Gabriel de Souza Pereira Gomes^{*}
Rafael Prux Fehlberg^{*} Sofia Moreira de Andrade Lopes^{*}
Rogério Andrade Flauzino^{*} Marcos Eduardo Guerra Alves^{**}
Mário Luiz Pereira Alves^{***} Renan Ferreira Santa Rosa^{****}
Iony Patriota de Siqueira[†]

^{*} *Esc. Eng. de S. Carlos - EESC, Univ. de S. Paulo - USP, SP, Brasil*
(e-mail: carrijo@usp.br)

^{**} *Radice Technology, Atibaia, SP, Brasil*

^{***} *Furnas, Rio de Janeiro, RJ, Brasil*

^{****} *Treetech Tecnologia, Atibaia, SP, Brasil*

[†] *Tecnix Engenharia e Arquitetura Ltda. Recife, PE, Brasil*

Abstract:

Bushings are one of the primary causes of failures in power transformers, and that's why several offline and online predictive maintenance techniques have been developed to evaluate the state and condition of bushings. This paper will demonstrate the capability of an Autoencoder network to act as an anomaly detector, indicating in real time failures in high voltage capacitive bushings, using statistical parameters of the leakage current vectors as input for the model. The results obtained by this study show that anomaly detection techniques are promising for the online diagnosis of condensing bushings.

Resumo:

As buchas são uma das principais causas de falhas em transformadores de potência, e é por isso que várias técnicas de manutenção preditiva offline e online foram desenvolvidas para avaliar o estado e a condição das buchas. Este artigo demonstrará a capacidade de uma rede Autoencoder de atuar como detector de anomalias, atuando na indicação de falhas iminentes em buchas capacitivas de alta tensão, de maneira online, utilizando como entrada para o modelo parâmetros estatísticos dos vetores das correntes de fuga. Os resultados obtidos por este estudo mostram que as técnicas de detecção de anomalias são promissoras para o diagnóstico online de buchas condensivas.

Keywords: bushings; transformers; machine learning; fault detection

Palavras-chaves: buchas; transformadores; aprendizado de máquina; detecção de falhas

1. INTRODUÇÃO

Os transformadores de potência são um dos componentes mais caros e estratégicos em qualquer sistema elétrico. Uma falha grave desses ativos pode gerar custos substanciais de reparo e perdas financeiras devido a interrupções de energia [Araujo \(2009\)](#). A monitoração online de transformadores e seus componentes é uma necessidade crescente para as concessionárias que visam o aumento da disponibilidade dos transformadores, facilitando a transição da manutenção baseada em tempo para a manutenção baseada em confiabilidade, melhorando a gestão da vida útil do ativo [Chu and Lux \(1999\)](#). As buchas são um dos componentes essenciais dos transformadores de potência e estão entre as causas mais comuns de falha desses ativos e equipamentos adjacentes. A maioria das buchas tem a

mesma idade que os transformadores e, portanto, a necessidade de monitorar a condição de operação das buchas se torna ainda mais séria [Setayeshmehr et al. \(2006\)](#).

De acordo com as estatísticas apresentadas pelo Cigre no Technical Brochure 642, [Tenbohlen et al. \(2015\)](#) sobre a confiabilidade do transformador de potência, as buchas ocupam o terceiro lugar entre as causas de falha deste ativo, representando aproximadamente 14% das falhas. Além disso, em transformadores com uma tensão entre 500 e 700 kV, as buchas ocupam o primeiro lugar e representam aproximadamente 30% do total das causas de falha. Para tornar a situação ainda mais séria, as falhas causadas por buchas são classificadas como "Falhas Graves", já que sempre é necessário trocar a bucha. Além disso, aproximadamente 50% das falhas nas buchas resultam em explosões ou incêndios [Tenbohlen et al. \(2015\)](#).

Devido a isso, várias técnicas de manutenção preditiva offline e online foram desenvolvidas para avaliar o estado e

^{*} Esta pesquisa é suportada pelo PD-00394-1708/2017 ANEEL, desenvolvido por Furnas e Radice, com a colaboração da Treetech e do SEL-EESC-USP.

a condição das buchas. Entre as técnicas offline, podemos mencionar principalmente as medições de capacitância e de fator de potência. As técnicas de manutenção preditiva online são muito semelhantes às técnicas offline. Os monitores online de buchas informam constantemente os valores de capacitância e da tangente delta da bucha. Se qualquer um desses valores exceder os limites pré-estabelecidos, um alarme é acionado informando as equipes de manutenção e gestão de ativos.

Essa forma de monitoramento, mesmo que tenha mostrado bons resultados ao longo do tempo e prevenido várias falhas de buchas Araújo et al. (2013), gera um grande volume de dados quando usada em larga escala. Isso requer análise de especialistas humanos para detalhar o diagnóstico, determinar a gravidade do problema, prognosticar a evolução futura e definir as ações aplicáveis. Assim, com os avanços na tecnologia, novas metodologias foram desenvolvidas para avaliar a condição dos ativos e reduzir a necessidade de análise de especialistas. Algumas delas ainda estão no início, como o monitoramento de descargas parciais Natrass (1993); Damiao et al. (2020). Entre essas novas tecnologias, destaca-se a aplicação de técnicas de Machine Learning para detecção de anomalias. A Detecção de Anomalias, ou Detecção de Outliers, é a identificação de dados anômalos que diferem significativamente da maior parte do conjunto de dados. Normalmente, a causa desses eventos nos dados está conectada a alguma variação no processo padrão analisado, como um defeito estrutural ou falha no equipamento. Essa detecção de anomalias no conjunto de dados é uma ferramenta poderosa do ponto de vista do diagnóstico da máquina, pois possibilita identificar falhas anteriormente não vistas.

Neste trabalho, serão utilizadas diversas bibliotecas *Python* para fins de Machine Learning e Data Science. Algumas das bibliotecas de Machine Learning incluem *TensorFlow*, *scikit-learn* e *Keras*. Para Data Science, temos bibliotecas como *pandas*, *NumPy*, *SciPy*, *HDF5* e *matplotlib*.

2. DESCRIÇÃO DOS DADOS UTILIZADOS

Dados de 20 conjuntos compostos por três buchas trifásicas foram utilizados, das quais 10 conjuntos possuíam uma bucha com defeito e 10 conjuntos estavam normais. O defeito dos 10 conjuntos ocorre em determinado instante de tempo para apenas uma bucha, de modo que é possível visualizar o instante no tempo no qual a bucha estava boa e o momento em que ela estava ruim.

Cada conjunto possuía como atributos os seguintes parâmetros:

- Corrente medida nas fases A, B e C;
- Ângulo medido entre as correntes das buchas, nas fases A/B e A/C utilizando a fase A como referência.

Durante o processo de geração de uma amostra, o período de amostragem do sensor é de 1 s. Contudo, o sensor trata e compacta as informações das amostras e as disponibiliza em seu banco de dados a cada 233 s, sendo este o período de amostragem considerado neste estudo. A Figura 1 apresenta um exemplo das medidas de corrente extraídas de uma bucha normal. No eixo vertical temos a corrente de fuga, em mA e no eixo horizontal, a amostra.

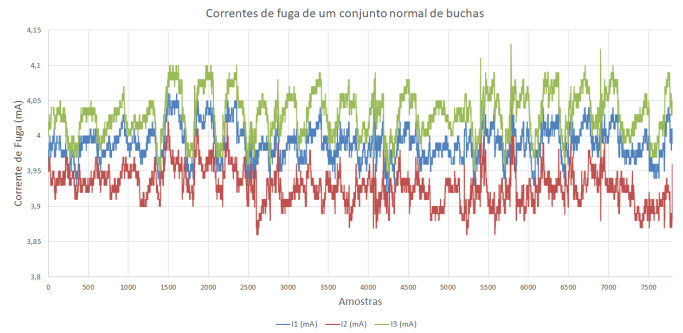


Figura 1. Correntes Conjunto de Bucha Normal



Figura 2. Atributos de buchas com norma de posição e buchas normais

3. ANÁLISE EXPLORATÓRIA

O primeiro passo de um problema de análise de dados é sempre a análise exploratória. Para ela, iremos utilizar apenas o nosso banco de treinamento e o nosso banco de validação, também conhecido como *hold out*. Na validação não podemos utilizar o nosso banco de teste, uma vez que ele traria informações do teste para o treinamento, auxiliando na ocorrência de sobre-ajuste aos dados de treinamento da nossa metodologia.

Inicialmente, convém analisar a distribuição dos valores dos atributos através de um histograma. Para fins exploratórios, serão divididas em dois grupos as amostras com defeito e normais, conforme Figura 2.

A Figura 2 mostra, primeiramente, a distribuição das medições de corrente de conjuntos normais é bem diferente das medições de correntes de conjuntos defeituosos. Isso é demonstrado tanto pelo histograma quanto pelo KDE. Nitidamente, é possível perceber que as amostras com defeito apresentam um viés para a direita, ou seja, possuem maior valor de corrente. Quanto ao ângulo, a diferença é mais sutil. Traduzindo para termos dielétricos, isso é um indicativo do motivo pelo qual defeitos de capacitância (associados à corrente) são mais fáceis de serem percebidos que defeitos associados à tangente delta (relacionados ao ângulo). Outro ponto interessante a ser notado é que a variação da corrente e do ângulo não se comporta como um ruído aleatório, indicando alta variância, isto é alta quantidade de informação tanto nas medições de corrente quanto nas medições de ângulo. Desse modo, ambos atributos devem ser considerados pelo modelo para a realização das predições.

4. DETECÇÃO DE ANOMALIAS EM BUCHAS

A detecção de anomalias se baseia em encontrar comportamentos estranhos em variáveis medidas. Realizar essa identificação é uma ótima abordagem para o problema de diagnóstico de falhas em buchas, uma vez que permite perceber comportamentos estranhos mesmo que esses nunca tenham sido observados por especialistas. Porém, um cuidado deve ser tomado durante a interpretação do resultado de um modelo de detecção de anomalia: uma anomalia nem sempre representa um defeito na bucha. Desse modo, esse método não deve ser utilizado para a definição da remoção de uma bucha de um transformador. Ele deve ser utilizado apenas para que a atenção seja redobrada naqueles equipamentos que apresentarem anomalia e, em algumas circunstâncias, quando problemas de conexão forem descartados, ser um gatilho para a realização de um ensaio offline.

Na identificação de anomalias, ao analisar-se duas ou mais variáveis, a visualização de dados pode ser um bom ponto de partida. No entanto, ao dimensionar isso para dados de alta dimensão (o que geralmente é o caso em aplicações práticas), essa abordagem se torna cada vez mais difícil. Nessa situação, técnicas de detecção de anomalias multivariáveis podem ser utilizadas. Entre eles estão o uso de Autoencoders e Análise de Componentes Principais (Principal Component Analysis).

Autoencoders são redes neurais treinadas com o objetivo de copiar sua entrada em sua saída. Esse interesse pode soar um pouco estranho, mas na prática o objetivo é aprender representações (codificações) dos dados, que podem ser utilizadas para redução de dimensionalidade ou mesmo compactação de arquivos. Junto com o lado da redução, um lado da reconstrução é treinado, onde o autoencoder tenta gerar a partir da codificação reduzida uma representação o mais próxima possível de sua entrada original. A arquitetura de autoencoder mais simples é uma rede neural feedforward, como um perceptron multicamadas (MLP), com pelo menos 3 camadas e com a camada de entrada e saída tendo o mesmo número de neurônios.

Para detecção de anomalias, o autoencoder é usado para generalizar as leituras do sensor para uma dimensão inferior, que captura as correlações e interações entre as

todas variáveis ou entre diferentes instantes de tempo da mesma variável. O treinamento da rede é feito a partir de dados que representam o estado normal do equipamento, tornando a rede capaz de reconstruir este comportamento. A ideia principal é que à medida que o equipamento monitorado se degrada e os valores medidos pelos sensores refletem essa degradação, a rede passará a apresentar um aumento no erro de reconstrução das variáveis de entrada. Ao analisar a distribuição de probabilidade do erro de reconstrução no conjunto de treinamento, é possível estabelecer um limite para identificar se um conjunto de dados é normal ou defeituoso.

4.1 Dados de Entradas

Esta janela define o intervalo de tempo para procurar uma anomalia. Para este estudo, foi utilizada uma janela de 12 h. Ou seja, cada amostra de dados inserida no modelo corresponde às últimas 12 h dos valores do vetor atual. O valor foi definido com base no conhecimento especializado para um ponto de partida da metodologia, uma vez que é possível detectar defeitos de rápida evolução com uma janela desse tamanho.

4.2 Extração e Normalização

Para a entrada do modelo, uma extração de recurso foi realizada aplicando uma janela deslizante no sinal. Por conhecimento especializado, foi considerado interessante extrair os seguintes recursos:

- Média
- Desvio Padrão
- Valor Máximo
- Valor Mínimo

Consequentemente, cada exemplo teve 5 atributos e 5 recursos para cada atributo extraído das últimas 12 horas do sinal. Assim, cada exemplo de entrada teve dimensão igual a 1×25 , ou seja, uma linha por 25 colunas. Depois de extrair recursos dos exemplos, os dados de treinamento foram normalizados pelo máximo e pelo mínimo. Essa normalização foi realizada para evitar que os atributos com valores maiores tivessem mais impacto no erro do modelo, uma vez que era privilegiado durante o treinamento.

4.3 Treinamento do Modelo e Cálculo do Erro Máximo de Reconstrução

Como o número de atributos disponíveis era pequeno, o autoencoder não precisava ser profundo e, portanto, foi projetado para extrair combinações de recursos na primeira camada, codificador e, em seguida, realizar a compactação desses recursos na camada central. Em seguida, a terceira camada, decodificador, decodifica os dados criptografados. Para que a compressão não causasse muita perda de informação, foram utilizados 20 neurônios na camada central. Assim, a topologia do autoencoder foi mostrada na Figura 3. A métrica usada para treinar o modelo foi o erro quadrático médio e o algoritmo de otimização ADAM Kingma and Ba (2014). Devido à arquitetura do autoencoder da rede neural, os dados previstos tentam reproduzir os dados de entrada. Portanto, eram muito parecidos com os dados de entrada. Depois que o codificador automático

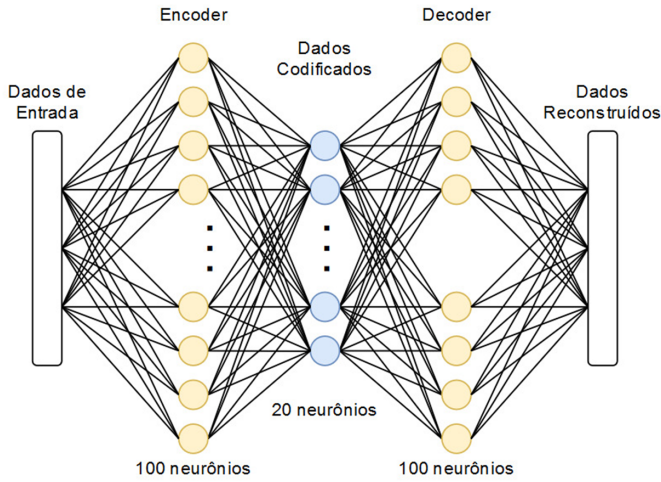


Figura 3. Topologia do Autoencoder para detecção de anomalias.

foi treinado para minimizar a diferença entre a entrada e a saída, a métrica de detecção de anomalias foi definida.

Para cada exemplo, o erro de reconstrução foi calculado. Este erro de reconstrução é dado pelo erro médio para cada atributo, exemplificado pela Equação 1

$$error = mean(abs(y_{pred} - y)) \quad (1)$$

Onde erro é o erro médio para cada atributo e y_{pred} e y representam as 25 saídas previstas e os 25 atributos verdadeiros, respectivamente, para cada exemplo. Depois de calcular todos os erros de reconstrução, o limite foi definido como duas vezes o maior erro de reconstrução, conforme Equação 2:

$$Threshold = 2 * max(ERROR) \quad (2)$$

Limite é o limite definido para o modelo classificar um exemplo como uma anomalia e ERROR é o vetor contendo os erros de todos os exemplos usados para treinamento.

4.4 Execução do Modelo

A partir de cada novo dado amostrado, o procedimento de extração e normalização de recursos é executado em uma janela de 12 h. Em seguida, esses dados são alimentados no modelo a fim de prever o resultado e o erro de reconstrução pode ser calculado. O conceito é que uma vez que o autoencoder tenha sido treinado com dados considerados bons, quando dados diferentes ou ruins forem apresentados a ele, ele não o reconstruirá corretamente e o erro excederá o limite.

4.5 Calculando o Erro de Reconstrução para a Amostra Atual e Média Móvel

Em seguida, segue a metodologia com o cálculo do erro de reconstrução para a amostra atual usando a Equação 1. O erro que está sendo calculado passa então por um processo de filtragem de média móvel aritmética simples para remover picos e capturar apenas sua tendência, o que indica um problema real. A média móvel usada nesta aplicação foi de 24 h. Assim, o atraso total gerado pelo modelo é de 36 h (12 h da extração do recurso + 24 h da média móvel do erro), e esse intervalo é suficiente para detectar erros de evolução rápida e evolução mediana.




Figura 4. Corrente de bucha em estado normal




Figura 5. Corrente de bucha em estado de defeito

4.6 Verificação de limite e detecção de anomalias

Após o cálculo do erro da média móvel, é realizada a verificação do limite, que avalia se o erro médio de reconstrução excedeu o valor calculado durante a fase de treinamento. Se sim, o modelo emite um alerta de anomalia. Caso contrário, o modelo espera que uma nova amostra seja inserida para repetir o processo.

5. ANÁLISE DE CASO

Para avaliar a eficácia da metodologia apresentada acima para detecção de defeitos em buchas de condensação, quatro conjuntos de buchas foram avaliados. Dois deles em estado normal e dois com defeito. Os dois conjuntos defeituosos estavam inicialmente em condições normais e o defeito ocorreu com o tempo. Os defeitos da bucha se manifestam como mudanças permanentes nos vetores (módulo e ângulo) das correntes de fuga da bucha. A Figura 4 e a Figura 5 mostram, respectivamente, um exemplo da corrente de fuga da bucha em condição normal e um exemplo da corrente de fuga da bucha em um estado de evolução de defeito.

No entanto, quando a bucha está com defeito, o comportamento da corrente de uma ou mais fases se assemelha ao mostrado na Figura 5. Como pode ser visto, ambos os sinais variam muito ao longo do tempo. Essa variação é muito semelhante a um ruído aleatório e se deve principalmente a alterações nos parâmetros dielétricos da bucha com variações de temperatura, além de variações sistêmicas no ponto elétrico ao qual a bucha está conectada. Dependendo do modelo da bucha e do local onde está instalada, essas variações podem ser maiores e mais duradouras.

Tabela 1. Buchas utilizadas nos experimentos

Conjunto	Classe de Tensão	Estado
A	138 kV	Normal
B	138 kV	Normal
C	230 kV	Defeito
D	230 kV	Defeito




Figura 6. Execução da Metodologia. A linha vertical laranja representa a divisão entre treinamento e teste




Figura 7. Desempenho do modelo para defeito inserido sinteticamente.

A classe de tensão das buchas utilizadas é apresentada na Tabela 1.

5.1 Caso 1: Conjunto de buchas A

No caso 1 foi estudada a aplicação da técnica de detecção de anomalias para o Conjunto de Buchas A, formado por 3 buchas de 138kV. Para garantir que as buchas estavam em boas condições, um especialista analisou previamente os dados. Os dados para esta análise foram adquiridos do sistema de monitoramento online amostrado a cada 15 minutos. Para treinar o autoencoder para o conjunto A, foram utilizados exemplos de 7 meses de dados considerados bons. A Figura 6 mostra o modelo executado para 1000 dias (aproximadamente 3 anos) de dados.

Ressalta-se que o modelo aprendeu o comportamento normal da bucha, pois mesmo durante os três anos seguintes de operação não identificou erroneamente nenhuma falha. Para verificar se o modelo não estava mascarando defeitos, um defeito a partir do dia 510 foi inserido sinteticamente nos dados. Como pode ser visto na Figura 7, após a evolução do defeito, o modelo o detectou corretamente como uma anomalia. Assim, verificamos que o modelo não está mascarando defeitos.




Figura 8. Execução da Metodologia. A linha vertical laranja representa a divisão entre treinamento e teste




Figura 9. Execução da Metodologia. A linha vertical laranja representa a divisão entre treinamento e teste

5.2 Caso 2: Conjunto de buchas B

A mesma quantidade de amostras de treinamento foi usada para treinar o autoencoder para o conjunto de buchas B. Os dados para este conjunto também foram obtidos de um sistema de monitoramento online. Como a quantidade de ruído aleatório no erro de reconstrução foi maior para este modelo, o limiar também acabou atingindo um valor consideravelmente mais alto. Isso tornou a metodologia mais robusta para falsos positivos, como pode ser visto na Figura 8. No entanto, também fez com que o modelo demorasse mais para detectar o defeito, conforme mostrado na Figura 9. Em trabalhos futuros, diferentes maneiras de calcular o limite podem ser analisadas.

5.3 Caso 3: Conjunto de buchas C

Os dados do conjunto C foram obtidos diretamente por meio de sensores de corrente de fuga nas buchas e não por meio de um sistema de monitoramento online. Esses dados foram amostrados a cada 4 minutos, ao contrário dos casos anteriores. Devido a uma quantidade menor de dados disponíveis, uma janela de 5 dias foi usada apenas para o modelo Treinamento. O resultado da aplicação da metodologia para este conjunto de buchas pode ser visto na Figura 10. O modelo teve um desempenho adequado, identificando a anomalia que aparece no gráfico por volta do dia 7. Assim, para casos reais de defeitos mesmo sem uma otimização dos parâmetros do modelo é possível identificar anomalias.

5.4 Caso 4: Conjunto de buchas D

O último conjunto de buchas também teve seus dados adquiridos diretamente do sensor. O modelo também foi




Figura 10. Desempenho do modelo para um defeito real




Figura 11. Desempenho do modelo em um defeito real com um padrão de comportamento com mais variações

treinado com 5 dias de dados. Além disso, o conjunto também estava inicialmente normal e com o tempo passou a apresentar defeito, como pode ser visto na Figura 11. Esse defeito tem um padrão bem diferente do anterior. Mesmo assim, a metodologia foi capaz de identificá-lo desde o início. Isso mostra que a metodologia pode passar por um processo de evolução e refinamento para se tornar uma técnica real de monitoramento de buchas condensivas em tempo real.

6. CONCLUSÃO







Um novo modelo para detecção de falhas (anomalias) em buchas capacitivas foi proposto. Este modelo utiliza como entrada características estatísticas básicas extraídas dos vetores de corrente de fuga da bucha. Essas características são então apresentadas a uma rede neural do tipo autoencoder que aprende a codificar e reconstruir esses dados. O erro de reconstrução é então usado como um parâmetro de limiar para avaliar se o conjunto está se comportando de maneira anômala ou não. Para remover o ruído aleatório da reconstrução, foi utilizado um filtro de média móvel, evitando assim falsos positivos.

Para validar a metodologia proposta, ela foi aplicada a quatro conjuntos de buchas, sendo os dois primeiros em um estado normal e os dois últimos inicialmente em um estado normal evoluindo para um estado de defeito. Os dois primeiros conjuntos tiveram seus dados adquiridos do sistema de monitoramento online e seus modelos foram treinados com 3 meses de bons dados e avaliados durante 3 anos de dados. Nesses 3 anos, as buchas não sofreram nenhum defeito e o modelo não detectou nenhuma anomalia, provando a robustez do modelo em relação a falsos positivos. Para verificar que o modelo não estava

mascarando defeitos, um defeito sintético foi inserido. Este defeito foi então identificado pelos modelos como uma anomalia, mostrando que o modelo não estava mascarando anomalias. Os dois últimos conjuntos tiveram seus dados adquiridos diretamente dos sensores. Esses conjuntos inicialmente bons mostraram anomalia após aproximadamente 7 dias. Os modelos treinados identificaram as anomalias ocorrendo.

Esses testes demonstraram a viabilidade técnica e científica da detecção de anomalias usando modelos de autoencoder no diagnóstico de buchas condensivas. Estudos adicionais estão sendo desenvolvidos para otimização dos parâmetros do autoencoder e cálculo do limiar de anomalia para a melhoria do método.

7. ORCID IDS DOS AUTORES

Daniel Carrijo Polonio Araujo ; Gabriel de Souza Pereira Gomes ; Rafael Prux Fehlberg ; Sofia Moreira de Andrade Lopes ; Rogério Andrade Flauzino ; Renan Ferreira Santa Rosa .

REFERÊNCIAS

- Araujo, D.C.P. (2009). *Estudo de Metodologia e Técnicas para Execução de Ensaios de Resposta em Frequência em Transformadores de Potência*. mathesis, UFMG - Universidade Federal de Minas Gerais, MG - Brasil. doi:<https://doi.org/10.13140/RG.2.2.34496.84486>. URL <http://dx.doi.org/10.13140/RG.2.2.34496.84486>.
- Araújo, D.C.P., Alves, M.E.G., Teixeira, R.M., and Moreira, C.R.N. (2013). Prevenção de falha em transformador trifásico 525 kv pela monitoração on-line de tangente delta de buchas. In *XXII SNPTEE*.
- Chu, D. and Lux, A. (1999). On-line monitoring of power transformers and components: a review of key parameters. In *Proceedings: Electrical Insulation Conference and Electrical Manufacturing and Coil Winding Conference (Cat. No.99CH37035)*, 669–675. IEEE. doi:10.1109/eic.1999.826290.
- Damiao, L., Guimarães, J., Ferraz, G., Bortoni, E., Rossi, R., Capelini, R., Salustiano, R., and Tavares, E. (2020). Online monitoring of partial discharges in power transformers using capacitive coupling in the tap of condenser bushings. *Energies*, 13(17), 4351. doi:10.3390/en13174351. URL <https://www.mdpi.com/1996-1073/13/17/4351>.
- Kingma, D.P. and Ba, J. (2014). Adam: A method for stochastic optimization. In *ICLR 2015*. arXiv. doi:10.48550/ARXIV.1412.6980.
- Nattnass, D.A. (1993). Partial discharge. xvii. the early history of partial discharge research. *IEEE Electrical Insulation Magazine*.
- Setayeshmehr, A., Akbari, A., Borsi, H., and Gockenbach, E. (2006). On-line monitoring and diagnoses of power transformer bushings. *IEEE Transactions on Dielectrics and Electrical Insulation*, 13(3), 608–615. doi:10.1109/TDEI.2006.1657975.
- Tenbohlen, S., Jagers, J., Vahidi, F., Bastos, G., Desai, B., Diggin, B., Fuhr, J., Gebauer, J., Krüger, M., Lapworth, J., et al. (2015). Transformer reliability survey. *Technical Brochure*, 642.