

Predição de Interrupção em Redes de Baixa Tensão Através de Modelos de Inteligência Artificial

Guilherme P. Castanheira
Daimon Engenharia e Sistemas Ltda.
São Paulo, Brasil
guilherme.castanheira@daimon.com.br

Guilherme Saggioratto
Daimon Engenharia e Sistemas Ltda.
São Paulo, Brasil
guilherme.saggioratto@daimon.com.br

Roger Aguera
Daimon Engenharia e Sistemas Ltda.
São Paulo, Brasil
roger.aguera@daimon.com.br

André G. Nogueira
Daimon Engenharia e Sistemas Ltda.
São Paulo, Brasil
andre.gusson@daimon.com.br

Ricardo H. Guembarovski
RHG Gestão Empresarial
Florianópolis, Brasil
ricardohaus@gmail.com

Carlos F. M. Almeida
Departamento de Energia e Automação
Elétricas
Universidade de São Paulo
São Paulo, Brasil
cfmalmeida@usp.br

Resumo— Interrupções permanentes no sistema de energia elétrica fazem com que consumidores de média e baixa tensão tenham o serviço de fornecimento de energia interrompido, contribuindo negativamente em indicadores de qualidade da distribuidora. Segundo dados obtidos de uma distribuidora brasileira, cerca de 14% das interrupções ocorrem devido à atuação de disjuntores em transformadores MT/BT da rede, deixando consumidores residenciais, rurais, comerciais e industriais de pequeno porte sem energia. No entanto, interrupções na baixa tensão não ferem indicadores de qualidade como faltas na média e alta tensão, além de ser um problema complexo a gestão de ativos de baixa tensão. Dessa forma, para melhor alocação de recursos financeiros destinados ao planejamento de redes de baixa tensão, propõe-se modelos classificadores baseados em inteligência artificial para identificar transformadores críticos. No presente trabalho, foram treinados 03 modelos classificadores, alimentados com resultados de fluxo de potência em 24 instantes processados pelo software comercial ServCalc® da Daimon Engenharia e Sistemas tendo como alvo o histórico de interrupções de transformadores MT/BT, obtidos da distribuidora brasileira e dados abertos da ANEEL, entre abril e junho de 2023. Os modelos apresentaram um desempenho satisfatório para a solução do problema, onde o destaque foi o algoritmo Random Forest, que obteve acurácia de 92%, tendo uma precisão de 88% na identificação de transformadores em estado crítico.

Palavras-chave— *modelos classificadores baseados em inteligência artificial, confiabilidade, incidência de faltas, sistema de distribuição de energia de baixa tensão*

I. INTRODUÇÃO

Os sistemas de distribuição de energia elétrica enfrentam desafios constantes para atender às demandas de consumo, mantendo os padrões de qualidade, confiabilidade e segurança exigidos por órgãos reguladores [1]. Fatores como mudanças climáticas, aumento da carga, penetração de geração distribuída e índices de desenvolvimento, impactam diretamente a operação das redes, exigindo adaptações como a ampliação da infraestrutura, reconfiguração da topologia da rede e a instalação de novos equipamentos. Para cumprir os limites e índices de continuidade estabelecidos pelas agências reguladoras, as distribuidoras devem garantir que a energia fornecida seja confiável, com níveis adequados de tensão, forma de onda e continuidade, atuando corretamente até mesmo diante de falhas operacionais que possam causar interrupções no fornecimento [1][2].

Dessa forma, garantir a correta operação e funcionamento dos dispositivos de proteção ajudam na redução dos índices de confiabilidade, pois minimizam a energia não distribuída (END) na incidência de uma falta permanente, contribuindo também para a redução dos indicadores coletivos de duração equivalente de interrupção por unidade consumidora (DEC) e frequência equivalente de interrupção por unidade consumidora (FEC) [3][4].

As interrupções no fornecimento de energia, caracterizadas como a perda total de serviço para um grupo de consumidores, são classificadas de acordo com sua duração, podendo ser momentâneas ou permanentes. Essas falhas impactam diretamente os indicadores de qualidade das distribuidoras, sendo as faltas permanentes as de maior relevância em termos de continuidade [2]. Embora as falhas em transformadores de distribuição contribuam em menor escala para os indicadores de qualidade em comparação aos equipamentos conectados na média tensão (MT), um número significativo de interrupções ocorre na baixa tensão (BT). Com isso, destaca-se a importância de identificar transformadores críticos que possam comprometer os índices de continuidade de fornecimento e orientar ações preventivas para mitigar seus impactos [5].

A priorização da manutenção de transformadores críticos permite minimizar problemas como desequilíbrio de fases, perdas técnicas nos condutores e desvios nos níveis de tensão, além de reduzir a incidência de faltas permanentes que resultam em longos períodos de interrupção para os consumidores [3]. No entanto, a alta densidade das redes de distribuição de baixa tensão, aliada ao grande número de consumidores, torna a detecção de falhas e a identificação das causas das falhas em transformadores um desafio complexo [5][3].

Para enfrentar esse desafio de forma moderna, soluções baseadas em inteligência artificial (IA) têm se mostrado promissoras. Modelos de aprendizado de máquina, alimentados por dados históricos de interrupções e resultados de simulações de fluxo de potência, permitem identificar transformadores com alta probabilidade de falha e alto impacto nos indicadores de qualidade. Nesta abordagem, o software ServCalc®, da Daimon Engenharia e Sistemas Ltda., foi utilizado para processar dados em 24 intervalos

temporais, juntamente com o histórico de interrupções registradas em uma região sob concessão de uma distribuidora brasileira entre abril e junho de 2023. Após o treinamento, espera-se que os modelos de IA ofereçam suporte eficiente aos operadores e profissionais do setor elétrico, possibilitando o direcionamento estratégico de recursos e priorização de ativos com maior risco de falha permanente, contribuindo para a melhoria da continuidade do fornecimento e da qualidade do serviço.

II. FORMULAÇÃO DO PROBLEMA

A diferença entre as redes primárias e secundárias no tratamento de faltas permanentes é justificada pela baixa significância da redução dos indicadores de qualidade que uma falta na rede BT provoca em relação a uma falta na MT, ou seja, uma falta na MT deixa não só unidades consumidoras residenciais de um conjunto de transformadores afetados como também a interrupção do fornecimento de energia de consumidores industriais e prioritários [6].

No sistema primário, a presença de faltas permanentes nas redes faz com que os circuitos operem de maneira restaurativa, tentando isolar o bloco da falha através de manobras para remanejamento de carga em blocos jusantes ao bloco onde ocorreu a interrupção, sendo este um processo que minimiza a END para ter o menor impacto possível nos indicadores de qualidade [1]. No sistema secundário de distribuição, não é comum a realização de remanejamento de energia na incidência de quaisquer tipos de interrupção, sendo assim, todo o circuito que se inicia no secundário de um transformador de distribuição é prejudicado uma vez que é totalmente dependente da atuação do fusível de proteção, atingindo as unidades consumidoras conectadas aquele transformador [6][3].

Baseado nos dados obtidos pela distribuidora, o cenário mais comum para atuação dos fusíveis de proteção dos transformadores é sobrecarga, os níveis de subtenção podem provocar interrupções na média tensão impactando fortemente nos indicadores de qualidade. Além disso, a subtenção pode causar o aumento de corrente nos trechos dependendo do modelo de carga presente no sistema. Sobretensão elevada pode significar que na rede BT existe alta penetração de energia proveniente da presença de geração distribuída, gerando fluxo reverso, do qual muitos dispositivos de proteção não estão preparados, podendo gerar interrupções na BT ou até mesmo atuando em zonas de retaguarda na rede MT.

Este cenário, vem aumentando baseado nos dados obtidos através da distribuidora, onde nas Fig.1 e Fig.2 mostram o crescimento das falhas operacionais e técnicas descritas anteriormente para os anos de 2022 e 2023 respectivamente. Levando em consideração o número de interrupções nas redes BT causadas pelas violações operacionais e técnicas (causadas majoritariamente por motivos que levam a sobrecarga dos transformadores) entre os dois anos, é possível obter um aumento de 43,71%.




Fig. 1. Interrupções em 2022.




Fig. 2. Interrupções em 2023.

Devido ao alto volume de circuitos BT em comparação com circuitos MT, é inviável monitorar e gerenciar redes BT como é feito para redes MT atualmente. Portanto, grande parte das distribuidoras brasileiras realizam a manutenção e inspeção de transformadores com o auxílio de planilhas baseadas na experiência do consumidor, onde as decisões são tomadas, por exemplo, com base em número de reclamações de nível de tensão ou interrupção do fornecimento de energia em uma rede BT. Este tipo de informação é impreciso e contém diversas variáveis instáveis, sendo difícil de se ter um padrão modelado matematicamente afim de evitar interrupções futuras e fazer uma gestão apropriada da manutenção e inspeção dos ativos de rede BT [6].

Recentemente, a consulta pública 032/2024 da ANEEL visa adaptar normas relacionadas a distribuição de energia com foco na melhoria do atendimento dos agentes do setor elétrico durante emergências, estando relacionadas com o aumento da frequência e gravidade de eventos climáticos extremos no Brasil. Além disso, discute-se nas boas práticas sobre resiliência das redes, prevendo compensação dos consumidores a partir de 24 horas sem energia em áreas urbanas e ressarcimento por danos elétricos [7].

Com o interesse dos órgãos reguladores em aumentar a resiliência das redes elétricas, a análise de eventos críticos como as interrupções e faltas causadas por violação de limites

operacionais tem sido foco das recentes pesquisas na área de planejamento de redes de distribuição [10]. Na rede BT, o grande volume de ativos dificulta a gestão, além disso, redes BT são passíveis a mudanças frequentes em sua topologia e estimativas de carga e geração distribuída [6]. Com o grande volume de dados obtidos pelos sistemas de comunicação avançados, o avanço de técnicas de mineração de dados e implementação dos *Advanced Distributed Management Systems* (A-DMS) e modernização dos sistemas SCADA (*Supervisory Control and Data Acquisition*), é possível utilizar modelos classificadores para elencar e gerir os transformadores em situação crítica [8].

Métodos heurísticos e uso de inteligência artificial podem ajudar a contornar as limitações encontradas atualmente para a realização de inspeções e manutenção dos equipamentos da rede de forma mais assertiva [10].

III. MODELAGEM DO PROBLEMA

Em [8], a detecção de faltas nas redes secundárias de distribuição através da rede neural se dá em tempo real. Em [9] são monitorados os parâmetros internos dos gases presentes nos transformadores para prever as falhas. No entanto, se torna inviável instalar equipamentos de monitoramento avançados na realidade das distribuidoras brasileiras, onde o recurso destinado a manutenção das redes BT é escasso. Dessa forma, propôs-se o treinamento de três tipos de classificadores baseados em IA: o Perceptron Multicamadas (*Multi-Layer Perceptron* - MLP), Regressão Logística e *Random Forest*. Todos estes algoritmos conseguem classificar a probabilidade de um evento ser factível ou não. Neste trabalho, a classificação é binária, dessa forma, para qualquer probabilidade acima de 50% de interrupção no transformador, será classificado como crítico (valor igual a 1) e, caso contrário, será classificado como adequado (valor igual a 0).

Para coleta de dados de fluxo de potência, foram processados no software ServCalc® da empresa Daimon Engenharia e Sistemas Ltda. o fluxo de potência em 24 instantes pelo método de *backward sweep* para redes BT que não apresentam malhas e para as redes BT com presença de malha o método de análise nodal, baseados em [11] para uma região de concessão de uma distribuidora de energia elétrica do sul do Brasil. A tolerância para convergência do fluxo de potência pelos métodos de cálculo foi de 10^{-5} entre iterações para a tensão em cada barra BT. A modelagem de cálculo adotada para as redes BT foi o modelo ZIP composto por 50% de potência constante e 50% de impedância constante.

Também, foi fornecido pela distribuidora os dados de interrupções do ano de 2022 e 2023, que foram cruzados com os dados públicos disponibilizados pela ANEEL no portal de dados abertos, cujo período realizado para os testes foi de abril a junho de 2023.

A. Regressão logística

Em [12] conceitos sobre regressão são introduzidos. Embora uma regressão possa assumir qualquer valor positivo ou negativo, a regressão logística assume saída binária (igual 0 ou 1) devido ao uso da função sigmoide, também chamada de função logística escrita em (1) sendo útil para problemas

de classificação como o abordado neste trabalho. A Fig. 3 exibe graficamente a função logística.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (1)$$




Fig. 3. Função logística

Assim como um modelo de regressão, a regressão logística calcula a soma ponderada dos atributos de entrada para determinar a saída. Uma vez estimada a probabilidade de uma instancia x pertencer a classe positiva ($\hat{p}$), prediz facilmente a saída $\hat{y}$, conforme escrito em (2).

$$\hat{y} = \begin{cases} 0, & \text{se } \hat{p} < 0,5 \\ 1, & \text{se } \hat{p} \geq 0,5 \end{cases} \quad (2)$$

B. Perceptron multicamadas

O algoritmo perceptron multicamadas tem a função de classificar um objeto dado um número de entradas. Entre a entrada e a saída do modelo, existem camadas ocultas compostas de neurônios artificiais. Ou seja, o perceptron multicamadas nada mais é que multicamadas de neurônios artificiais funcionando em conjunto para gerar um resultado [13][12]. A Fig. 4 exemplifica a estrutura do perceptron multicamadas.




Fig. 4. Ilustração da estrutura de um MLP.

De modo geral, o neurônio artificial é a unidade fundamental do MLP. Dentre as vantagens do algoritmo, está a capacidade de modelar relações complexas, assertividade nas previsões e bom desempenho com relação a outros algoritmos de aprendizado de máquina. No entanto, este algoritmo tem a desvantagem de precisar de um grande volume de dados para o treinamento e configuração correta de seus hiperparâmetros, especialmente o número de neurônios e número de camadas ocultas para a realização das previsões [13].

Em [12], é possível observar que existem diversas funções de ativação do neurônio artificial, no entanto, para este trabalho foi utilizado a função ReLu (*Rectified Linear Unit*), sendo uma das mais comuns para problemas de classificação, na qual assume zero para valores negativos e o próprio valor para valores positivos. Em (3) é mostrado matematicamente a função ReLu, exibida graficamente na Fig. 5.

$$\varphi(x) = \begin{cases} 0, &]-\infty, 0[\\ x, & [0, \infty[\end{cases} \quad (3)$$




Fig. 5. Função ReLu

No MLP, a estrutura para calcular a saída é complexa. Cada um dos neurônios calcula a soma ponderada das entradas ($w_i x_i$), adiciona um viés (chamado de bias, representado por b) e faz uso da função de ativação para determinar a saída do neurônio (h), propagando este resultado para o próximo neurônio até chegar na saída do modelo. Em (4), é equacionado a saída do neurônio artificial.

$$h = \varphi \left(\sum_{i=1}^n w_i x_i + b \right) \quad (4)$$

C. Random Forest

Baseado em [12], o *Random Forest* é um algoritmo poderoso dentre os algoritmos de aprendizado de máquina por sua versatilidade, sendo possível utilizá-lo como repressor ou classificador. Seu funcionamento consiste na criação de várias árvores de decisão, criando uma floresta, onde cada árvore faz uso de um subconjunto dos dados, que neste trabalho é o *bootstrap* (subconjuntos de dados aleatórios atribuídos a uma árvore de decisão). Na Fig. 6, é possível observar a estrutura do algoritmo *Random Forest*, sendo este uma composição de N árvores aleatórias.




Fig. 6. Ilustração da estrutura do *Random Forest*.

Cada árvore de decisão, trabalha dividindo os dados em grupos menores baseados em uma métrica de qualidade da divisão. Neste trabalho, fez uso do Índice de Gini, escrito em (5) para medir a impureza da classificação em relação as classes (transformadores adequados e críticos), onde $p_{i,k}$ é a relação de instâncias da classe k entre as instâncias de treinamento do i -ésimo nó. Desta forma, é possível dividir os atributos mais eficientes do *dataset* em cada nó da árvore.

$$G_i = 1 - \sum_{k=1}^n p_{i,k}^2 \quad (5)$$

Quando aplicado em um *Random Forest*, o resultado da predição é chamado de voto majoritário, ou seja, a classe mais predita entre todas as N árvores de decisão presentes no modelo.

Este tipo de modelo reduz possíveis *overfitting* e aumenta a robustez do modelo, por treinar diversas árvores de decisão de uma única vez. No entanto, o custo computacional é grade comparado com os outros modelos classificadores dispostos neste trabalho [12].

D. Dataset para treinamento do modelo

Para o projeto desenvolvido, o *dataset* representa o conjunto de dados exclusivo para o treinamento do modelo, totalizando 2624 registros de uma determinada região sob concessão da distribuidora, onde cada registro representa um transformador em seu patamar máximo de carga para cada mês de processamento. Os atributos que compõem o *dataset* de treinamento são os resultados de fluxo de potência e histogramas montados a partir destes resultados, totalizando 17 atributos. Como são poucos os registros de interrupção em transformadores, no *dataset* foi considerado todos os registros de transformadores que falharam (críticos) e três vezes este número de transformadores que não apresentaram falha (adequados) para potencializar o aprendizado de máquina dos algoritmos classificadores.

A fim de definir os principais atributos para treinamento dos modelos, foi utilizada a matriz de correlação, onde é possível observar a correção entre os atributos existentes no *dataset*, possuindo a diagonal principal com valor igual a 1.

Na Fig. 7, encontra-se um gráfico obtido da matriz de correlação dos atributos, relacionando os atributos com o dado de interrupção.




Fig. 7. Correlação dos atributos com a interrupção.

A partir desta análise, foi selecionado os 10 principais atributos que se correlacionam com o dado de interrupção. Sendo estes: o desbalanceamento, carregamento monofásico, tensão mínima em p.u, porcentagem de perdas da rede BT, corrente máxima dos trechos, comprimento da rede BT, porcentagem de penetração de energia injetada por geradores distribuídos, porcentagem de consumidores residenciais, comerciais e rurais abastecidos pelo transformador.

Uma etapa importante do pré-processamento é a detecção de outliers presente no *dataset*. Para isso, O *dataset* para o treinamento foi submetido a um modelo de detecção de outlier *Isolation Forest* excetuando registros com base em árvores de decisão [12].

Ao final da etapa de pré-processamento, tem-se 536 registros, onde inicialmente se tinha 2624 registros. Devido ao *undersampling* realizado 2028 registros de transformadores adequados foram descartados e 60 registros foram excetuados por serem considerados outliers. Ainda, 10 dos 17 atributos foram considerados.

O objetivo do modelo é detectar transformadores críticos, portanto, todas essas análises realizadas na etapa de pré-processamento são críticas e importantes para potencializar o aprendizado de máquina. Uma vez que se considerado o *dataset* inicial com maior parte de transformadores adequados, o modelo conseguiria classificar melhor transformadores adequados.

IV. RESULTADOS E DISCUSSÕES

O *dataset* pré-processado foi dividido em dados de treinamento e teste, onde 70% dos registros são destinados ao treinamento do modelo, etapa na qual o modelo cria padrões para identificar se um transformador deve ou não ser classificado como crítico e, 30% destinado aos testes, onde verifica-se as métricas e validações do modelo, classificando internamente como 0 os transformadores adequados e 1 como transformadores críticos, sendo estes possíveis transformadores que possam ter interrupção no futuro.

Os três modelos mencionados foram treinados, obtendo métricas satisfatórias para o problema proposto. Na Tabela I, encontra-se os resultados detalhados para cada um dos modelos treinados.

TABELA I. MÉTRICAS DOS MODELOS TREINADOS

Modelo	Métrica				
	Acurácia	Classificação do Transformador	Precisão	Recall	F1-score
Regressão Logística	0,90	Adequado (0)	0,94	0,93	0,94
		Crítico (1)	0,74	0,78	0,76
MLP	0,86	Adequado (0)	0,95	0,87	0,91
		Crítico (1)	0,60	0,81	0,69
Random Forest	0,92	Adequado (0)	0,93	0,98	0,95
		Crítico (1)	0,88	0,69	0,77

A partir da Tabela I, é perceptível que embora a acurácia de todos os modelos seja satisfatória, o *Random Forest* se destaca por conseguir maior precisão quando se trata dos transformadores críticos.

As métricas dos modelos podem ser ilustradas por meio de uma matriz de confusão, na qual é possível observar os falsos negativos e falsos positivos de cada treinamento realizado. Na Fig. 8 é apresentada a matriz de confusão do modelo de regressão logística, a Fig. 9 a matriz de confusão do modelo MLP e na Fig. 10 a matriz de confusão do modelo *Random Forest*.

Nota-se, por meio das matrizes de confusão, que o *Random Forest*, mesmo tendo maior precisão quanto aos transformadores críticos é o que menos acertou, em números. Sendo assim, a alta precisão se dá por meio de não classificar transformadores críticos como adequados (falso negativo), tendo apenas 3 registros nesta situação contra 9 e 11 dos modelos de regressão logística e MLP respectivamente.




Fig. 8. Matriz de confusão da regressão logística.




Fig. 9. Matriz de confusão do MLP




Fig. 10. Matriz de confusão do *Random Forest*

Através das análises das métricas e matrizes de confusão, pode-se concluir que o modelo classificador *Random Forest* é o melhor para cumprir o objetivo do problema proposto, por apresentar alta precisão quanto a predição de transformadores críticos e pelo menor número de falsos negativos, apesar de classificar mais registros como falsos positivos, sendo estes 10 comparado com 7 dos modelos anteriores.

Como uma última visualização dos resultados do modelo *Random Forest*, é possível observar cartograficamente os transformadores que apresentaram falha no período de abril a junho de 2023, destacados em vermelho, e as predições realizadas pelo modelo, destacadas em azul na Fig. 11.




Fig. 11. Visualização cartográfica dos transformadores (a) com interrupção e (b) preditos como críticos pelo *Random Forest*.

Observa-se pela Fig. 11 a semelhança entre as imagens cartográficas, sendo este mais um indício da aplicabilidade do modelo em eventual escala global para toda a área de concessão da distribuidora, podendo auxiliar profissionais quanto a identificação de transformadores em estado crítico na rede.

Ainda, discute-se algumas melhorias para a metodologia proposta, sendo elas a possibilidade de coletar a variação dos atributos entre os 24 instantes e uso de variáveis climáticas no modelo, além de executar o cálculo com metodologias de correção de demanda. Dessa forma, o *dataset* para treinamento teria um panorama completo das condições que as redes BT estão expostas, melhorando a precisão e acurácia do modelo, além de ter maior acerto em campo. A utilização de curvas abertas, separadas em dia útil, sábado e domingo também trariam maior grau de realidade em campo.

Técnicas de mineração de dados avançada também poderia ajudar a impulsionar o treinamento dos modelos. Tendo em vista que em um futuro o modelo possa ser implementado como um serviço na distribuidora, identificação de atributos importantes e detecção de outliers através de algoritmos seria possível, bem como o treinamento do modelo automático para calibração.

V. CONCLUSÃO

O problema de interrupção em transformadores de distribuição atualmente não é tratado da mesma forma que interrupções causadas por chaves na rede MT. No entanto, recentes consultas públicas realizadas pela ANEEL, mostram uma tendência em medir índices de qualidade de energia baseados não somente na qualidade da energia fornecida como um todo, mas também no índice de satisfação dos consumidores.

Dessa forma, devido a quantidade de ativos BT presentes nas redes de distribuição é proposto o uso de modelos classificadores para identificar transformadores críticos na rede elétrica, indicando eventuais locais que possam vir ocorrer faltas permanentes em rede BT por causas operacionais.

Os três classificadores treinados apresentaram métricas satisfatórias para a resolução do problema, sendo o *Random Forest* o de melhor desempenho, atingindo uma precisão de

88% na predição de transformadores que tiveram o serviço interrompido.

Em trabalhos futuros, é possível considerar condições climáticas históricas e variação dos atributos coletados através do fluxo de potência nos 24 patamares. Certamente, garantirá maior eficiência no treinamento dos classificadores. Também, faz-se necessário a consideração da demanda corrigida para calcular o fluxo de potência com maior semelhança com a realidade da rede elétrica em campo.

Por fim, conclui-se que a metodologia empregada consegue cumprir o objetivo de direcionar a concessionária na tomada de decisões para realizar manutenções em ativos da empresa para evitar interrupções nas redes BT, podendo ela priorizar manutenção, por exemplo, em transformadores cuja END é maior nos casos de incidência de faltas permanentes.

REFERÊNCIAS

- [1] Castanheira, G. P.; "Alocação otimizada de chaves de manobras em redes de distribuição de energia elétrica na presença de geração distribuída de fontes renováveis". Trabalho de graduação. Universidade Estadual Paulista "Júlio de Mesquita Filho", 2022.
- [2] De Vasconcelos, F.M., Rocha, C.H.S., Almeida, C.F.M., Pereira, D.D.S., Rosa, L.H.L., & Kagan, N. "Methodology for inspection scheduling in power distribution networks based on power quality indexes". *IEEE Transactions on Power Delivery*, 36(2), 1211–1221, 2021.
- [3] Todesco, J.L., Teive, R.C.G., Guembarovski, R.H., Velozo, S., De Miranda, L.A., Fascin, T.M., Candemil, D. "Gestão da Distribuição Secundária de Energia Elétrica Utilizando um Sistema Especialista". XXIV Encontro Nacional de Engenharia de Produção, 2004.
- [4] Todesco, J.L., Sell, D., Anciutti, I., Rodrigues, M.C., Almeida, R., Pimentel, F.J.S., Guembarovski, R.H., De Miranda, L.A. "Uma Plataforma de Gestão para Redes de Distribuição de Baixa Tensão". XXIV Encontro Nacional de Engenharia de Produção, 2004.
- [5] Costanzi, J.E., Guembarovski, R.H. "Aplicação de Técnicas de Mineração de Dados para Aprimoramento da Gestão do Sistema Elétrico de Baixa Tensão". Seminário Nacional de Distribuição de Energia Elétrica, 2023.
- [6] Cyrillo, I.O. "Qualidade de Energia na Distribuição de Energia Elétrica: Contribuições para o Aprimoramento da Regulação no Setor Elétrico Brasileiro". Tese de Doutorado. Escola Politécnica da Universidade de São Paulo, 2022.
- [7] Regulação ANEEL. "Consulta pública da ANEEL prevê ampliar direitos do consumidor em interrupção da energia em situações de emergência". Dezembro, 2024. Disponível em: gov.aneel
- [8] Mnyanghwalo, D., Kundaeli, H., Kalinga, E., Ndyetabura, H. "Faults Detection and Classification in Electrical Secondary Distribution Network Using Recurrent Neural Network". *IEEE International Energy Conference*, 2020.
- [9] Saravanan, D., Hasan, A., Singh, A., Mansoor, H., Shaw, R. N. "Fault Prediction of Transformer Using Machine Learning". *IEEE International Conference on Computing, Power and Communication Technologies*. Galgotias University, India, 2020.
- [10] Viegas, J. L., Vieira, S. M., Melício, R., Matos, H. A., Sousa, J. M. C. "Prediction of events in the smart grid: interruptions in distribution transformers". *IEEE International Power Electronics and Motion Control Conference*, 2016.
- [11] Kagan, N., Barioni de Oliveira, C.C., Schmidt, H.P., Robba, E.J. "Introdução aos Sistemas de Distribuição de Energia". 2º ed., Blucher, São Paulo, 2010.
- [12] Géron, A. "Mãos à Obra: Aprendizado de Máquina com Scikit-Learn, Keras & TensorFlow". 2º ed., O'Reilly, Rio de Janeiro, 2021.
- [13] Faulstich, L.V. "Fundamental of Neural Networks: Architectures, Algorithms and Applications". Pearson Education, 2006.