

ESTUDO PARA RECONHECIMENTO DE CURTO-CIRCUITO INTERNO PRÓXIMO AO NEUTRO EM TRANSFORMADORES DELTA-ESTRELA UTILIZANDO INTELIGÊNCIA ARTIFICIAL

Elias Junio Muller Coelho¹, Murilo da Silva²

RESUMO: O sistema elétrico de potência tem como objetivo gerar e fornecer energia elétrica de forma segura e confiável. Em uma subestação, o transformador de potência é o equipamento de maior custo e de difícil reposição, necessitando de uma proteção confiável e precisa para evitar danos. A proteção diferencial destaca-se dentre os demais tipos de proteção de transformadores, sendo eficaz na detecção de faltas (curtos-circuitos) internas. Contudo, em transformadores com conexão delta-estrela aterrada, faltas monofásicas próximas ao ponto neutro da ligação estrela não são detectadas. Este trabalho visa a aplicação de redes neurais artificiais para identificação destas faltas, cuja proteção diferencial não detecta. O conjunto de dados para treinamento e validação da rede neural foram obtidos por meio da simulação de um sistema de distribuição de energia elétrica utilizando o software de simulação de transientes eletromagnéticos PS Simul. Foi gerado um banco de dados com 50432 casos diferentes, considerando faltas internas e externas, variando-se tipo de falta, resistência de falta, ângulo de incidência, desequilíbrio de carga e energização do transformados. A rede neural artificial adotada foi o Perceptron de Múltiplas Camadas, recebendo um ciclo com 16 pontos de 7 correntes medidas, totalizando 112 entradas. A rede é composta por 2 camadas ocultas com 57 neurônios em cada camada oculta, retornando se a proteção deve ou não atuar. A metodologia proposta apresentou uma precisão média de 99,76% (desvio padrão de $3,57 \times 10^{-4}$) com base em 30 avaliações com validação cruzada. Os resultados indicam um baixo desvio padrão, mostrando que o processo de aprendizagem ocorreu de maneira correta e com uma precisão relativamente alta, apontando uma aplicação promissora para solução do problema delineado, podendo servir como um módulo auxiliar para a proteção diferencial, ajudando na detecção deste tipo de falta.

Palavras-chave: Proteção diferencial de transformadores, Redes neurais artificiais, Aprendizagem profunda

1 INTRODUÇÃO

O sistema elétrico de potência (SEP) tem como objetivo gerar, transmitir e distribuir energia elétrica para os consumidores de forma segura e dentro de padrões de conformidade (Rush, 2011). Na operação do sistema surgem com certa frequência falhas em seus componentes, sendo a mais comum o curto-circuito. Esta falha eleva a corrente do sistema e pode trazer danos irreparáveis aos equipamentos e unidades consumidoras. Desta forma, surge então a necessidade de uma proteção para o SEP cuja

¹ Afiliações (Graduando, Universidade Tecnológica Federal do Paraná, eliasjunio@alunos.utfpr.edu.br)

² Afiliações (Doutor, Universidade Tecnológica Federal do Paraná, murilosilva@utfpr.edu.br)

principal função é desconectar do sistema (seja totalmente ou parcialmente) em qualquer anormalidade que o faça operar fora dos seus limites (Filho; Mamede, 2013).

No contexto de uma subestação, o elemento de maior responsabilidade e maior custo financeiro é o transformador de potência. Este componente necessita utilizar proteções adequadas para que sua integridade e permanência em operação seja mantida (Filho; Mamede, 2013). Segundo Gers e Holmes (2011), o sistema de proteção diferencial pode proteger um transformador de potência de forma eficaz, onde o funcionamento deste tipo de proteção se dá através da diferença vetorial de duas ou mais grandezas (neste caso, correntes) e sua atuação acontece quando a diferença excede um valor predeterminado.

Embora a proteção diferencial seja muito confiável, os enrolamentos dos transformadores de potência nem sempre são totalmente protegidos (Gers; Holmes, 2011). Considerando um transformador de potência ligado em delta-estrela com uma falta (falha) espira-terra sendo aplicada no seu enrolamento do lado estrela, a corrente gerada por esta falta no lado delta dependerá da resistência de aterramento, bem como da distância que esta falta é aplicada em relação ao ponto neutro do transformador. Se esta falta ocorre no terço inferior do enrolamento estrela (em relação ao ponto neutro), pouca corrente no enrolamento é produzida, não gerando então uma diferença vetorial entre as correntes, e conseqüentemente, a não atuação da proteção diferencial (Rush, 2011). Desta forma, faz-se necessário a análise de outros métodos de detecção deste tipo de falha para que este equipamento não fique desprotegido.

Portanto, o objetivo deste trabalho é simular um sistema de distribuição de média tensão (que contenha um transformador de potência ligado em delta-estrela), aplicar diversas faltas neste sistema, gerando assim um banco de dados que posteriormente é usado para treinamento de um algoritmo de rede neural artificial para que este seja capaz de classificar se existe uma falta interna próxima ao neutro.

2 METODOLOGIA

O passo inicial foi modelar no PS Simul (Software de simulação de transitórios eletromagnéticos) um sistema de distribuição de energia elétrica de média tensão, a partir de dados reais de um sistema de distribuição de 13,8kV de uma concessionária de distribuição de energia elétrica do Brasil, que inclui um transformador de potência (26MVA, 138kV:13,8kV) com conexão delta-estrela mostrado na Figura 1. Este sistema

modelado foi validado utilizando outro software, o ATP, apresentando os mesmos resultados nos dois softwares (Silva, 2021).




Figura 1: Sistema de transmissão de média tensão simulado no software PS Simul. Fonte: modelado com base em Silva, M. Proteção de sistema de Distribuição, notas de aula (2021).

Com o sistema modelado, foi gerado um banco de dados contendo 50432 casos variando os tipos de faltas (internas ou externas), desequilíbrio de carga (de 0 a 30% por fase), energização do transformador (sob falta interna, sem falta, ângulo de energização), localização de falta (3 pontos diferentes), saturação de TCs e resistência de falta (Silva, 2021).

Dos casos simulados, foram obtidos arquivos contendo medições de sete transformadores de corrente (TCs), sendo 3 do lado de alta (IA_P, IB_P, IC_P), 1 no neutro do transformador (IN) e 3 do lado de baixa (IA_S, IB_S, IC_S). Amostrados em uma frequência de 960Hz (significando 16 amostras por ciclo em cada corrente), conforme mostrado na Figura 2.




Figura 2: Exemplo de um ciclo coletado de um caso sem falta. Fonte: autoria própria (2024).

Com isso, foi utilizado um ciclo destas sete correntes como entrada da rede neural artificial, totalizando 112 entradas. Estes sinais não passaram por compensação

fasorial ou de sequência zero visando uma facilitação na implementação, trabalhando com dados que podem ser coletados facilmente em um sistema real (Silva, 2021).

Os dados foram rotulados como: não identificação de falta interna monofásica próxima ao neutro; identificação deste tipo de falta. Considerando como faltas internas monofásicas próximas ao neutro, as faltas aplicadas a uma distância entre 0 a 50% em relação ao ponto neutro nas espiras do lado estrela (Rush, 2011; Gers e Holmes, 2011).

A rede neural adotada foi o *perceptron* de múltiplas camadas (“*Multilayer Perceptron*” ou MLP), contendo uma camada de entrada, duas camadas ocultas e uma camada de saída, com a estrutura de 112-57-57-1 neurônios e implementado a partir da biblioteca Scikit-Learn na linguagem de programação Python (Scikit-Learn Developers, 2024).

Para obtenção da melhor combinação de parâmetros para o MLP foi utilizada a ferramenta GridsearchCV da biblioteca *Scikit-Learn*, a qual realiza diversas combinações de parâmetros do algoritmo de rede neural aplicado ao banco de dados e busca a combinação que traz o melhor resultado. Esta ferramenta utiliza também a validação cruzada (*Cross-Validation*) que divide o banco de dados em k-partes (*k-fold*) e realiza k treinamentos utilizando k-1 partes para treinamento e uma parte para teste, evitando a perda de dados importantes que ficariam perdidas em uma eventual base de teste fixa (Géron, 2019).

Com os melhores parâmetros obtidos, a rede neural foi submetida ao processo de avaliação, onde foi realizado 30 testes com validação cruzada com k-partes igual a 10 no qual foi analisado a precisão média e o desvio padrão dos resultados de precisão. Por fim, foi realizado o último treinamento da rede neural, analisando suas respostas perante a base de dados de testes e armazenando os pesos para que a mesma possa ser usada posteriormente.

3 RESULTADOS E DISCUSSÃO

Com a utilização do GridSearchCV, foi retornado a melhor combinação de parâmetros, de maneira empírica, para este banco de dados, apresentados na Tabela 1. Os demais parâmetros foram utilizados os padrões (*default*) da biblioteca Scikit-Learn.

Os resultados apresentados na Tabela 2 referem-se ao período de avaliação da rede neural, onde contêm a precisão média durante o treinamento e durante o teste, seguidos do desvio padrão entre os resultados de precisão. Um baixo desvio padrão

entre os resultados demonstra consistência da rede em relação às suas previsões e seu desempenho.

Tabela 1 – Resultados da melhor combinação de parâmetros para este banco de dados na rede neural MLP.

	Parâmetros
Função de ativação (<i>Activation</i>)	<i>reLU</i>
Tamanho do Lote (<i>Batch size</i>)	200
Tamanho das camadas ocultas (<i>Hidden layer sizes</i>)	[57, 57]
Número máximo de iterações (<i>Max iter</i>)	1000
Solucionador (<i>Solver</i>)	<i>Adam</i>
Tolerância (<i>Tol</i>)	1e-5

Fonte: Autoria Própria (2024).

Nota: *reLU* refere-se à função unidade linear retificada (*rectified liear unit*); *Adam* refere-se à *stochastic gradiente-based optimizer* proposto por Kingma, Diederik e Jimmy Ba (Scikit-Learn Developers, 2024).

Tabela 2 – Resultados de avaliação da rede neural MLP.

	Precisão Treinamento	Precisão Teste
Média	99,78%	99,76%
Desvio Padrão	3,05e-4	3,57e-4

Fonte: Autoria Própria (2024).

Nota: A precisão (acurácia) mede a taxa de previsões corretas (Géron, 2019).

Após a etapa de avaliação, a rede neural foi treinada de forma definitiva e armazenado suas matrizes contendo os pesos sinápticos. Para este treinamento, foi separado 90% do banco de dados para treinamento e 10% para teste. Os resultados estão representados na Tabela 3, tal que 0.0 representa a não identificação de falta interna próxima ao neutro e 1.0 significa a identificação deste tipo de falta.

Tabela 3 – Resultados referente a base de dados de testes.

	Precisão	Revocação	Casos Analisados
0.0	99,93%	99,98%	6272
1.0	99,86%	99,42%	695

Fonte: Autoria Própria (2024).

Nota: Revocação (*Recall*) é a taxa de instâncias positivas que são classificadas corretamente (Géron, 2019).

Referente ao último treinamento, tem-se na Tabela 4 a matriz de confusão, apresentando resultados das classificações corretas e erradas realizadas pela rede neural.

Tabela 4 – Matriz de confusão referente à parte do banco de dados retirada para teste.

Matriz de Confusão		
0.0	6271	1
1.0	4	691
	0.0	1.0

Fonte: Autoria Própria (2024).

Nota: A diagonal principal da matriz mostra as classificações corretas enquanto a secundária mostra as classificações erradas (Géron, 2019).

Os resultados apresentados na Tabela 2 indicam um baixo desvio padrão entre as médias de precisão, mostrando que o processo de aprendizagem da rede neural ocorreu de maneira correta e com uma precisão real média de 99,76%. Esta constância pode ser observada com o treinamento final da rede neural, na qual apresentou na Tabela 3 precisões dentro do que se era esperado no processo de avaliação e na matriz de confusão, demonstrando a capacidade de generalização da rede neural adotada.

4 CONSIDERAÇÕES FINAIS

Portanto, o MLP é capaz de generalizar o problema delineado e responder com grande precisão e confiabilidade. Os resultados iniciais para o sistema analisado apontam para uma promissora aplicação ao problema em questão, por exemplo, como um módulo auxiliar para a proteção diferencial, ajudando na detecção de faltas internas monofásicas próximas ao neutro em transformadores de potência ligados em delta-estrela.

AGRADECIMENTOS

Agradecer à agência de fomento CNPq, Fundação Araucária, UTFPR.

REFERÊNCIAS

GERS, Juan M.; HOLMES, Edward J. Protection of Electricity Distribution Networks. 3. Ed. London: Institution of Engineering and Technology, 2011.

GÉRON, Aurélien. Mãos à obra: Aprendizado de Máquina com Scikit-Learn e TensorFlow. 1. Ed. Rio de Janeiro: Alta Books, 2019.

FILHO, João Mamede; MAMEDE, Daniel Ribeiro. Proteção de sistemas elétricos de potência. Rio de Janeiro: LTC, 2013.

RUSH, Peter. Proteção e automação de redes: conceito e aplicação. São Paulo: Editora Blucher: Schneider, 2011.

SCIKIT-LEARN, Developers. Supervised learning: Neural network models (supervised). Disponível em https://scikit-learn.org/stable/modules/neural_networks_supervised.html. Acesso em: 8 de setembro de 2024.

SILVA, Murilo. Proteção de Sistema de Distribuição: Notas de aula, Curso de Especialização em Sistemas Elétricos de Potência. UTFPR, campus Cornélio Procopio, 2021.