



CORREÇÃO DA FORMA DE ONDA SECUNDÁRIA DISTORCIDA DE TRANSFORMADORES DE CORRENTE ATRAVÉS DA UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS

Bruno dos Santos Saraiva Silva

Ricardo Caneloi dos Santos

bru1987@gmail.com

ricardo.santos@ufabc.edu.br

Universidade Federal do ABC

Av.dos Estados 5001, 09210-580, Santo André, São Paulo, Brasil

Resumo. Os sistemas elétricos de potência (SEP) têm como função fornecer energia elétrica de forma segura e confiável aos consumidores. Na ocorrência de eventuais contingências, cabe ao sistema de proteção atuar para minimizar os danos causados, tanto para os consumidores finais como para o próprio SEP. Um dos equipamentos presentes no sistema de proteção, o transformador de corrente (TC), possui a tarefa de fornecer ao relé de proteção uma réplica, em escala reduzida, da corrente primária que flui no SEP durante uma falta. No entanto, os TCs possuem características físicas que os tornam susceptíveis à saturação, provocando a distorção da forma de onda secundária enviada ao relé de proteção, impedindo que uma correta ação seja tomada por parte do relé. Tal evento pode resultar em severos danos aos equipamentos do SEP, provocando perdas financeiras significativas e colocando em risco vidas humanas.

Para evitar uma tomada de decisão incorreta do relé em função da distorção da forma de onda da corrente secundária, vários algoritmos para a correção e reconstrução de formas de onda distorcidas de TCs de proteção são propostos na literatura, sendo grande parte deles relacionados à aproximação de funções. Neste sentido, este artigo propõe o uso de redes neurais artificiais (RNA) para corrigir a forma de onda secundária distorcida proveniente dos TCs, visto que uma das principais características dessa técnica de inteligência artificial é sua capacidade de aproximar funções. A RNA utilizada para desempenhar tal função é do tipo MLP e foi treinada por meio de um processo de treinamento supervisionado. Várias taxas de amostragem e tamanho de janelas de dados foram avaliadas, visando a especificação de uma RNA capaz de oferecer alto desempenho ao algoritmo proposto.

Todos os dados utilizados no processo de treinamento e testes das RNAs são provenientes de uma modelagem clássica de TCs e amplamente utilizada pela comunidade científica (IEEE).

Os resultados observados revelam que uma forma de onda altamente distorcida pode ser totalmente reconstruída pela RNA, fornecendo aos relés de proteção um sinal confiável para a correta tomada de decisão sobre o estado operacional do SEP.

Palavras-chave: transformadores de corrente, saturação, redes neurais artificiais, aproximação de funções, curve-fitting.

1 INTRODUÇÃO


A energia elétrica, no curto período de dois séculos, se tornou indispensável para a vida moderna: nosso lazer, economia, segurança pública, sistema de fornecimento de água e saúde (para citar alguns) dependem de um fornecimento praticamente ininterrupto de energia elétrica.

Os Sistemas Elétricos de Potência (SEP) têm como principal objetivo fornecer energia elétrica de forma confiável, constante e segura aos seus consumidores. Idealmente, este fornecimento deveria ser ininterrupto, porém tal feito se faz impossível, visto que grande parte das quedas de energia são causadas por eventos naturais (condições climáticas como tempestades, nevascas etc.) ou falhas em equipamentos instalados nas subestações (Blackburn, 1987).

O Sistema de Proteção (SP) é responsável pelo monitoramento do SEP. Quando em operação normal, o SP supervisiona o SEP, agindo em casos de falhas de equipamentos e/ou faltas no sistema. O SP deve responder de forma rápida, seletiva, confiável e segura. Um pequeno atraso na atuação do SP pode ter um grande impacto no SEP.



(a) Relé de proteção (fabricante SEL)



(b) Transformador de corrente (TC)

Figura 1: Equipamentos típicos de Sistemas de Proteção instalados em subestações

Os SP evoluíram bastante nas últimas décadas, passando de equipamentos simples com capacidades limitadas a sistemas complexos compostos por equipamentos eletrônicos capazes de realizar processos computacionais extremamente robustos. Um destes equipamentos é o relé de proteção (Figura 1a): é ele quem comanda a abertura de trechos do sistema, garantindo que a operação normal seja reestabelecida em casos de faltas no sistema. O relé, sendo um dispositivo eletrônico que trabalha em níveis de tensão e corrente baixos, não pode ser interligado diretamente ao SEP. Para receber dados do SEP, o relé depende de transformadores de instrumentos: os transformadores de corrente (TC) (Figura 1b) e transformadores de tensão (TP). Estes TC e TP fornecem uma cópia fiel, em menor escala, das correntes e tensões (respectivamente) presentes no SEP em todo momento. A corrente real do SEP é chamada de corrente primária, enquanto que sua cópia em menor escala é a corrente secundária (fornecida ao relé). A Figura 2 ilustra um SEP e seus respectivos TC e relés.

O desempenho dos TC é tão fundamental quanto o dos próprios equipamentos de tomada de decisão em um SP (como relés digitais). Os TC têm características construtivas que os tornam susceptíveis a saturação. Um dos mais claros indicadores de uma falta, ou perturbação, no sistema elétrico, é o aumento repentino da corrente do sistema. E é justamente nestas condições que o TC pode, com mais facilidade, entrar em saturação. Caso isso ocorra, sua corrente secundária deixa de ser uma cópia, em menor escala, da corrente de seu primário.




Figura 2: Conexão de um TC em um SEP

Os relés, ao receberem a corrente secundária distorcida, poderão atuar indevidamente ou não atuar quando deveriam, comprometendo a confiabilidade do SP. Podemos verificar através da Figura 3 as formas de onda do secundário do TC sem efeito da saturação (Figura 3a) e com efeito da saturação (Figura 3b). No segundo caso (Figura 3b), o valor RMS calculado pelo relé é significativamente menor que o valor real presente no SEP.

É importante ressaltar também que a janela de tempo na qual um relé deve ler as informações provenientes do TC, processar e atuar é muito pequena. Dessa forma, qualquer verificação ou processo de tomada de decisão que envolva um passo adicional é extremamente indesejado.




Figura 3: Corrente secundária de um TC (a) não-saturado, (b) saturado

O fluxograma da Figura 4 evidencia que a correção da forma de onda do secundário do TC se faz essencial para garantir o bom desempenho do SP.

Pesquisas intensas têm sido conduzidas no sentido de detectar e corrigir a saturação de TC de proteção. No trabalho apresentado por David Yu (2001) o autor utiliza uma RNA com 32 nós de entrada e duas camadas ocultas, sendo a primeira com 10 nós e a segunda com 6 nós. Não é citada a maneira com que a escolha da configuração da rede é feita. Com uma taxa de amostragem de 32 amostras por ciclo, a RNA é capaz de estimar a forma de onda não-saturada com sucesso.

Em (Segatto, E. C., Coury, D. V., 2006) Redes Neurais Artificiais foram utilizadas para a correção de formas de onda secundárias distorcidas dos TC usados na proteção de um transformador de potência. Mediante a variação de diversos parâmetros como potência da carga e porcentagem do enrolamento envolvido na aplicação da falta (para citar alguns), um banco de 1782 vetores de treinamento foi gerado. Diferentes arquiteturas de RNA foram testadas, sendo escolhida a RNA com arquitetura recorrente Elman/Jordan, com 24 neurônios na camada de entrada, 20 neurônios na camada oculta, 24 neurônios na camada recorrente e 24 neurônios na camada de saída. A média quadrática de erros obtida foi de 0,0005 após 7000 épocas de treinamento e o índice de acerto médio da RNA foi de 98,5%.

Em (Khorashadi-Zadeh, H., Sanaye-Pasand, M., 2006) os autores apresentam um algoritmo para a correção da forma de onda saturada no secundário de TCs de proteção. Foram variados parâmetros como fluxo remanescente, magnitude da corrente de falta e *burden* do TC. Diferentes métodos de treinamento de RNA foram inicialmente considerados, porém, através de simulações, ficou claro que a utilização do método de treinamento Marquardt-Levenberg produzia erros substancialmente menores que a arquitetura Backpropagation convencional. Sendo assim, uma rede MLP com camadas ocultas compostas por 12 e 8 neurônios, respectivamente, foi modelada e treinada com os dados provenientes do sistema elétrico adotado. Testes de validação confirmaram a eficácia da RNA, que em seguida foi implementada em hardware (DSP), corrigindo, em apenas 0,5 ms, a corrente saturada presente no secundário do TC de proteção. Na maior parte dos casos, o erro da estimativa do valor RMS pela RNA é menor que 2,5%.

No estudo de Koksall Erenturk (2009) o autor apresenta um método de compensação da corrente secundária saturada de um TC baseado em lógica neuro-fuzzy adaptativa. Três funções de transferência triangulares são selecionadas para compensar a corrente secundária saturada do TC e o método dos mínimos quadrados, junto ao *gradient descent*, são usados para treinar a estrutura ANFIS. Todos os testes e modelos são realizados no MATLAB porém com código-fonte próprio do autor. São feitas simulações e testes em tempo real com diversas condições de falta, variando-se parâmetros como nível da corrente de curto circuito, fator de potência e *burden*. O tempo médio de resposta obtido é da ordem de 0,35 ms, sendo que o cálculo do erro RMS foi da ordem de 0,77%. Finalmente, o algoritmo e a solução são validados em um ambiente experimental através de um DSP.

Diferentemente dos trabalhos citados, este estudo propõe uma análise minuciosa para a escolha da RNA com melhor performance entre inúmeras possibilidades. Entre os parâmetros que foram analisados estão a taxa de amostragem do sinal s , o tamanho da janela de amostragem j , o número de camadas ocultas da RNA n e a quantidade de neurônios em cada uma destas camadas ocultas e . Com a escolha dos valores ideais destes parâmetros, ao final de seu treinamento, a RNA será capaz de corrigir a forma de onda secundária de um TC com um MSE (*mean square error*) da ordem de $1,0 \cdot 10^{-7}$. Ainda, por oferecer um excelente desempenho mesmo em casos de não saturação do TC, é possível implementar e interligar a RNA ao SP de maneira ininterrupta através de um hardware especialmente projetado para tal função, como por exemplo um DSP, como mostrado na Figura 2.




Figura 4: Importância da correção da forma de onda secundária do TC

2 REDES NEURAIS ARTIFICIAIS

A utilização de Redes Neurais Artificiais (RNA) é fruto da tentativa de modelar a maneira como o cérebro humano realiza cálculos e toma decisões. Este funciona de forma altamente complexa, paralela e muitas vezes mais rápido que um computador convencional. O cérebro humano é composto por aproximadamente 100 bilhões de neurônios (sua unidade básica de processamento), que interligados formam uma extensa rede com capacidade de aprender baseado em sua "experiência".

Uma RNA é um modelo simplificado do cérebro humano, composto pelas mesmas unidades básicas de processamento (neurônios), com capacidade de aprender quando sujeitos a um processo de treinamento. Na fase de treinamento, as interconexões entre neurônios pode ser reforçada ou enfraquecida, estabelecendo os pesos sinápticos de cada interconexão. Um




Figura 5: Modelo neuronal

dos benefícios das Redes Neurais Artificiais está em sua capacidade de generalização (Haykin, 2008), permitindo que estas sejam ferramentas poderosas na aproximação de funções. A Figura 5 representa o modelo de um neurônio artificial.

2.1 Rede *feedforward*

Neste trabalho foram utilizadas RNA do tipo *feedforward* - redes organizadas em forma de camadas onde a entrada é projetada em uma só direção. Assumindo a convenção utilizada por alguns autores, a entrada não será considerada uma camada. Assim, serão denominadas camadas da RNA os pontos onde realmente há processamento envolvido. Uma rede *feedforward* pode ter um número bastante variado de camadas ocultas, onde quanto maior o número de camadas ocultas, maior será sua capacidade de representação de regiões complexas.

Tipicamente, em uma rede *feedforward*, os neurônios têm como entrada somente os sinais de saída da camada anterior, conforme mostra a Figura 7.

3 METODOLOGIA E SIMULAÇÕES

3.1 Obtenção de dados de treinamento

Para a obtenção de dados de treinamento foram utilizados modelos matemáticos (Figura 6) amplamente adotados pela comunidade científica (IEEE) (Tziouvaras, et. al., 2000). Neste modelo, são levados em conta parâmetros importantes característicos da não-linearidade dos TC, como por exemplo efeitos de seu fluxo remanescente. Os modelos foram amplamente validados com testes feitos em laboratório.

A modelagem matemática permite que diversas amplitudes de corrente sejam inseridas no primário do modelo do TC, e a forma de onda de seu secundário seja extraída. Quando o TC não apresenta saturação, a forma de onda da entrada é a mesma da saída (considerada sua relação de transformação), como discutido anteriormente. Porém, em condições de saturação, é possível obter os valores de corrente com o secundário saturado (ou seja, a forma de onda distorcida) e também sem saturação (uma escala da corrente do primário, sem distorção). Estes últimos serão usados como *targets* do treinamento.




Figura 6: Circuito equivalente de um TC (modelo matemático)

3.2 Treinamento no MATLAB

O processo de treinamento de uma RNA envolve o ajuste fino dos pesos e *biases* da rede de modo a "ensinar" a RNA uma tarefa específica. Tipicamente, o MATLAB utiliza como medida de performance o MSE definido segundo a Eq. (1).

$$MSE = \frac{1}{N} \sum_{k=1}^N (i_{RNA} - i_{target})^2 \quad (1)$$

O MSE é a média do erro, ao quadrado, da diferença entre a saída da RNA i_{RNA} e a saída esperada i_{target} .

As simulações e treinamentos da RNA foram feitas utilizando-se o software MATLAB (*Neural Network Toolbox*). O treinamento realizado foi supervisionado, ou seja, utilizou-se valores esperados para o *output* da RNA como *targets*. Para a atualização dos pesos e *biases* da rede foi empregada a otimização *Levenberg-Marquardt*.

Através do modelo obtido em (Tziouvaras, et. al., 2000) foram extraídas as correntes do secundário do TC a uma taxa de 200 amostras por ciclo, num total de 9 ciclos completos, o que totaliza 1800 amostras para cada amplitude de corrente considerada na entrada do TC. Esta taxa de amostragem, 200 amostras por ciclo, é o valor padrão utilizado pelo modelo empregado. Dessa forma, neste trabalho utilizou-se uma taxa de amostragem de 200 amostras por ciclo ou menos, conforme será discutido adiante.

As amplitudes de corrente consideradas na entrada do TC foram de 1000 A a 75000 A, em passos de 1000 A, totalizando 75 níveis de corrente diferentes. Dado que cada uma destas amplitudes possui taxa de amostragem de 200 amostras por ciclo, tem-se $1800 \cdot 75 = 135000$ amostras disponíveis para o treinamento. Para o treinamento, deve-se definir quatro variáveis: a taxa de amostragem que será utilizada s (que não necessariamente precisa ser 200, podendo ser um submúltiplo de 200), o tamanho da janela deslizante j , o número de camadas ocultas da RNA c e o número de neurônios por camada oculta n .

A título de exemplo, considere a Figura 7 para ilustrar o funcionamento de uma RNA com uma camada oculta ($c = 1$) e três neurônios por camada oculta ($n = 3$), cuja entrada é fornecida por uma taxa de amostragem de 8 amostras por ciclo ($s = 8$) e janela de dados de 5 amostras ($j = 5$). Como observado, a RNA especificada recebe 5 amostras de corrente, número que coincide com o tamanho da janela de dados. Uma vez que para este exemplo a




Figura 7: Rede Neural Feedforward com 5 entradas, uma camada oculta com 3 neurônios e uma saída

taxa de amostragem é de 8 amostras por ciclo, tem-se $8 \cdot 9 = 72$ amostras para os 9 ciclos da onda. A janela deslizante, para extrair as 72 amostras, se deslocará de amostra a amostra, sendo que o total de amostras extraídas será de $8 \cdot 9 - 5 + 1 = 68$ amostras. Para cada uma destas 68 amostras existirá um valor de *target*, proveniente da onda não-saturada (ou seja, o valor esperado de resposta da RNA).

Para o caso exemplificado, conforme pode ser visto na Figura 8, o conjunto de treinamento será formado por uma matriz de entrada 5×68 e uma matriz de saída de dimensão 68×1 . A construção da matriz de entrada se dá pelo deslocamento, do início ao fim, da ja-

nela deslizando. A cada janela corresponde um *target* diferente: para o conjunto de amostras $[x_1 \ x_2 \ x_3 \ x_4 \ x_5]^T$, por exemplo, tem-se o *target* $[y_1]$.




Figura 8: Construção das matrizes de entrada através da obtenção de amostras por uma janela deslizando com 5 amostras

Como discutido anteriormente, no treinamento foram variados quatro parâmetros. Na Figura 9 é exibida uma ilustração da variação de três destes: o número de amostras por janela (representado por j), a taxa de amostragem do sinal (representada por s) e a quantidade de neurônios por camada oculta. Neste trabalho, a análise foi feita baseada na variação de 4 parâmetros, o que não permite a criação de uma ilustração. A quarta dimensão corresponde à quantidade de camadas ocultas c na rede. A cada simulação, a performance da RNA (dada pela variável *tr.best_perf* do MATLAB) é armazenada. Ao final, temos inúmeras configurações de RNA com performances distintas.




Figura 9: Variação dos parâmetros da RNA: o caso mostrado ilustra a escolha de uma RNA com taxa e amostragem de $s = 10$ amostras por ciclo, $j = 20$ amostras por janela e $n = 15$ neurônios na camada oculta

As simulações se dividiram em três partes. Na primeira parte, foram feitas todas as varia-

ções de taxa de amostragem (dado que o sinal de origem possuía 200 amostras por ciclo, foram utilizados divisores de 200 a partir de 10), de amostras por janela (de 10 a 400 em passos de 10), de número de neurônios na camada oculta (5 a 30 em passos de 5) e número de camadas ocultas (2, 3 e 4).

Amostras por janela	sampling rate	Camadas ocultas	Neurônios por camada	MSE
50	20	4	29	2.11032E-06
50	20	4	33	2.50077E-06
40	20	4	30	2.97083E-06
50	20	4	26	3.41234E-06
50	20	4	30	7.12186E-06
50	20	4	30	1.14522E-05
50	20	4	31	1.153E-05
50	20	4	27	2.29787E-05
50	20	4	25	2.58654E-05
50	20	3	30	2.61902E-05
40	20	3	30	4.4107E-05
60	20	3	30	6.12031E-05
40	20	4	25	6.22942E-05

Figura 10: Resultados das RNA segundo variações de *sampling rate*, amostras por janela, número de camadas ocultas e número de neurônios em cada camada. Em destaque, a RNA com melhor desempenho, usada para a obtenção dos resultados finais.

Para todos os treinamentos, com exceção do último, o critério de parada utilizado foi o número de épocas, dado que redes neurais com muitas entradas e camadas ocultas treinam com uma velocidade muito menor que redes mais compactas. Dessa forma, pôde-se comparar um grande número de possibilidades de configuração segundo um mesmo critério.

No último treinamento, com os valores ideais já escolhidos, a RNA foi treinada com um critério de parada de 100000 épocas, MSE de $1,0e^{-10}$ e 18000 s como tempo máximo de treinamento. Neste caso, o tempo máximo foi atingido.

Os resultados foram gravados em uma planilha, arranjados em ordem crescente de desempenho. Em seguida, eram avaliados os melhores resultados de modo a refinar ainda mais os parâmetros desta rede. Os passos da variável j (correspondente a amostras por janela) passaram de 10 em 10 para 1 em 1 ao final. Foram 7112 simulações no total, cada uma correspondendo a uma possibilidades de configuração da RNA, com um tempo total de simulações de aproximadamente 100 horas.

Para os testes, foram utilizados valores de corrente diferentes daqueles utilizados no treinamento. Nas Figuras 14 e 13 é possível analisar o desempenho da RNA em duas situações típicas: em caso de não saturação e em caso de saturação. No primeiro caso, a rede neural apenas reproduz a entrada, dado que nenhuma correção se faz necessária. No segundo caso, a RNA corrige a forma de onda secundária do TC devido à sua saturação. Sendo assim, a RNA é capaz de distinguir valores de corrente saturados e não-saturados, permitindo que esta seja implementada em DSP e interligada diretamente ao SP, anteriormente ao relé (como sugerido pela Figura 2).

A performance da RNA pode ser evidenciada pela justaposição das formas de onda da saída

ideal e da saída da RNA na Figura 13. A aproximação do gráfico mostra a precisão obtida.

4 ANÁLISES DE RESULTADOS

Depois de inúmeros testes, a RNA com melhor desempenho possui 50 neurônios na entrada, 4 camadas ocultas com 29 neurônios em cada uma das camadas ocultas. Sua performance (MSE) foi de $5,0937e^{-07}$.

A Tabela 1 ilustra o desempenho da rede neural escolhida (Figura 11) segundo o número de amostras por janela, a taxa de amostragem do sinal, o número de camadas ocultas e a quantidade de neurônios por camada. Como pode ser observado, o MSE da RNA escolhida é bastante reduzido, fazendo com que sua aproximação ao *target* seja bastante eficaz.




Figura 11: Diagrama da RNA escolhida

A título de análise, foram feitos dois testes: um, com uma onda saturada (simulando a saturação do TC). Esta é ilustrada na Figura 13a. Ao aproximarmos a segunda crista, podemos observar a precisão do resultado obtido pela RNA escolhida (Figura 13b).






Figura 12: Performance de treinamento da RNA

Da mesma forma, foi inserida uma onda não saturada, simulando a operação normal do SEP. Neste caso, o papel da RNA deve ser o de somente manter a sua entrada, não efetuando qualquer tipo de modificação. Evidencia-se novamente o sucesso do desempenho da RNA através da análise das Figuras 14a (observa-se a reprodução da entrada pela RNA) e 14b (aproximação da segunda crista).

Sendo assim, a RNA pode ser utilizada em tempo real no SEP, não interferindo no desempenho do SP em casos de operação normal.




(a) Saída da simulação




(b) Detalhe da segunda crista

Figura 13: Resposta da RNA para uma onda saturada



(a) Saída da simulação



(b) Detalhe da segunda crista

Figura 14: Resposta da RNA para uma onda não saturada

Amostras por janela	Taxa de amostragem	Número de camadas ocultas	Neurônios por camada	Performance (MSE)
50 amostras	20 amostras por ciclo	4 camadas	29 neurônios	$5,0937e^{-07}$

Tabela 1: Desempenho da RNA escolhida para $I = 37400 A$ (TC saturado)

5 CONCLUSÃO

Este trabalho teve por objetivo especificar uma RNA capaz de corrigir a forma de onda saturada proveniente do secundário de transformador de corrente, equipamento fundamental para o SP, garantindo que os equipamentos que dependem do sinal do TC recebam estes sinais de forma confiável. A partir da modelagem matemática de TC amplamente utilizada, testada e aceita na indústria, foram obtidos os dados de treinamento das RNA. O treinamento foi realizado segundo diversas configurações possíveis da rede. A RNA escolhida foi capaz de corrigir a forma de onda saturada com um MSE de apenas $5,0937e^{-07}$.

Entre as vantagens da proposta sugerida está a análise de diversas configurações possíveis. Foram milhares de testes variando-se quatro parâmetros: a taxa de amostragem do sinal, o tamanho da janela de amostragem, o número de camadas ocultas da RNA e a quantidade de neurônios em cada uma destas camadas ocultas. A precisão da RNA escolhida pôde ser verificado pela ordem de grandeza do erro produzido no treinamento.

A rede obtida pode ser implementada em *hardware* (utilizando uma placa DSP, como ilustrado na Figura 2) e instalada em subestações, de forma que possa ser colocada imediatamente após os TC, garantindo que os relés recebam sinais adequados e aumentando a confiabilidade do Sistema de Proteção.

AGRADECIMENTOS

Os autores agradecem à Universidade Federal do ABC pelo apoio e incentivo na realização deste trabalho.

REFERÊNCIAS

- Blackburn, L. J., 1987. *Protective relaying - Principles and applications*. Marcel Dekker Inc.
- Erenturk, K. ANFIS-Based compensation algorithm for current-transformer saturation effects. *IEEE Transactions on Power Delivery*, Vol. 24, January 2009.
- Haykin, S. *Neural Networks and Learning Machines*. Pearson Prentice Hall, 2008
- Khorashadi-Zadeh, H., Sanaye-Pasand, M. Correction of Saturated Current Transformers Secondary Current Using ANNs. *IEEE Transactions on Power Delivery*, Vol. 21, January 2006.
- Segatto, E. C., Coury, D. V. Redes neurais artificiais recorrentes aplicadas na correção de sinais distorcidos pela saturação de transformadores de corrente. *Revista Controle e Automação* - Vol.17 no.4/Outubro, Novembro e Dezembro 2006.
- Tziouvaras, D. et al. Mathematical models for current, voltage, and coupling capacitor voltage transformers. *IEEE Transactions on Power Delivery*, v. 15, n. 1, p. 62-72, 2000.
- Yu, D. C. et al. Correction of current transformer distorted secondary currents due to saturation using artificial neural networks. *IEEE Transactions on Power Delivery*, v. 16, n. 2, p. 189-194, 2001.