

Emprego de Rede Neural Artificial para Predição de Temperatura de Topo de Óleo em Transformador de Potência

Antônio M. Kaminski*. Leonardo H. Medeiros*. Daniela M. Bueno*. Vitor C. Bender*. Micael M. Oliveira*. Tiago B. Marchesan*. José B. F. Neto**. Helena M. Wilhelm***.

**Instituto de Redes Inteligentes, Universidade Federal de Santa Maria, Brasil
(e-mail: juniorkaminski@hotmail.com).*

***Santo Antônio Energia, Porto Velho, Brasil (e-mail: joseferreira@santoantonioenergia.com.br).*

****VEGOOR, Colombo, Brasil (e-mail: helena@vegoor.com.br).*

Abstract: Top-oil temperature is of great importance for power transformers operating conditions evaluating, where its correct prediction allows better use of transformer's nominal capability and lifetime extension. The present work develops a transformer's dynamic model for top-oil temperature prediction making use of an Artificial Neural Network (ANN) and real monitoring data and proposes utilization of a Non-linear AutoRegressive with Exogenous inputs (NARX) network architecture, not yet used for this purpose. After its development, a network's forecasting capability was performed with a data set that did not participate of the training process. The results obtained show that the developed neural network satisfactorily replicates the dynamic thermal behavior, with acceptable deviation, of the real transformer.

Resumo: A temperatura de topo de óleo é de grande importância para avaliação das condições de operação de transformadores de potência, onde sua predição correta possibilita melhor aproveitamento da capacidade nominal e prolongamento da vida útil do transformador. O presente trabalho desenvolve um modelo dinâmico para predição de temperatura de topo de óleo de um transformador através de uma Rede Neural Artificial (RNA) utilizando dados reais de monitoramento e propõe a utilização de uma arquitetura de rede Non-linear AutoRegressive with Exogenous inputs (NARX), ainda não utilizada para este propósito. Após seu desenvolvimento, foi realizado um teste da capacidade de previsão da rede com um conjunto de dados que não participou do processo de treinamento. Os resultados obtidos demonstram que a rede neural desenvolvida replica de forma satisfatória o comportamento térmico dinâmico do transformador real com níveis aceitáveis de erro.

Keywords: Artificial Neural Network; NARX; Top-oil temperature; Temperature prediction; Power Transformers.

Palavras-chaves: Rede Neural Artificial; NARX; Temperatura de topo de óleo; Predição de temperatura; Transformadores de potência.

1. INTRODUÇÃO

Transformadores estão presentes em todo o sistema elétrico de potência, integrando todos os seus níveis de tensão. Apresentam, portanto, papel essencial em assegurar a transmissão de energia elétrica de forma econômica e confiável ao consumidor final. Estes também são os ativos mais caros em uma subestação, portanto sua integridade é importante em termos financeiros, acrescentando-se ao fato de que sua indisponibilidade causa a interrupção do fornecimento de energia e maiores prejuízos à concessionária.

A vida útil de um transformador é determinada pela sua isolamento sólida que, em termos de envelhecimento é determinada pela temperatura interna de operação do equipamento, cujos indicadores mais comuns para transformadores imersos em óleo isolante são a temperatura de ponto mais quente e a temperatura de topo de óleo. A temperatura de topo de óleo apresenta maior conveniência em

sua medição, enquanto a temperatura de ponto mais quente ocorre no interior dos enrolamentos, e sua medição deve ser feita com a utilização de fibras ópticas, que, além de dispendiosas em termos econômicos, dificultam a manutenção e construção devido a sua sensibilidade. Portanto, o conhecimento da temperatura de topo de óleo é o indicativo mais difundido para avaliar as condições térmicas de transformadores seja em tempo real ou previstas, permitindo a operação dentro dos limites de temperatura estabelecidos por norma (ABNT 2007) (IEC 2011) e um maior aproveitamento de sua capacidade nominal.

Diversos modelos para a predição de temperatura de transformadores foram propostos até hoje, a exemplo dos modelos propostos por normas (ABNT 2017) (IEC 2018) amplamente utilizados. Porém, estes modelos apresentam suas limitações, principalmente devido aos efeitos de variação da temperatura ambiente (Vilaithong et. al. 2007) e pela quantidade necessária de informações. Redes Neurais Artificiais têm-se mostrado uma interessante ferramenta e

objeto de estudos em diversas áreas do conhecimento. Uma de suas aplicações que apresenta bons resultados é a predição de comportamentos não-lineares, incluindo predição de temperatura em transformadores (Su et. al. 2018) (Wei et. al. 2017) (Huang et. al. 2016) (Vilathong et. al. 2007) (He et. al. 2000).

No presente trabalho é apresentado o desenvolvimento de uma rede neural para a predição da temperatura de topo de óleo em um transformador de potência considerando como entradas o carregamento do transformador, a temperatura ambiente e o status dos trocadores de calor, ou seja, quantos conjuntos de aerotermos (ventiladores e bombas de óleo) estão em operação. Cada uma das entradas apresenta um impacto, de forma distinta, na temperatura de operação do transformador. Para a implementação foi escolhido um modelo de rede neural que represente a dinâmica térmica do transformador e seu comportamento não-linear. Este modelo de rede denominado Non-Linear Autoregressive Exogenous Model (NARX) apresenta bom desempenho em diversas aplicações (Khalil 2012) (Ruslan et. al. 2014) (Andrade et. al. 2014), inclusive em estudos químicos do óleo de transformadores (Pereira et. al. 2018). Entretanto, esta arquitetura de rede ainda não foi utilizada para predição de temperatura de transformadores de potência. As principais contribuições deste trabalho também incluem a utilização de uma quantidade elevada de dados reais de operação de um transformador elevador de alta potência, considerando o status dos trocadores de calor.

2. REDES NEURAIS ARTIFICIAIS

Uma Rede Neural Artificial (RNA), é um método matemático que visa simular o processo de aquisição de conhecimento de um cérebro humano, sua aplicação tem apresentado sucesso ao estabelecer padrões de comportamento entre variáveis de entrada e saída, reconhecimento de padrões, classificação e otimização (Pereira et. al. 2018). Assim, são úteis para resolução de problemas em que métodos computacionais mais tradicionais não apresentam uma boa performance.

2.1 Estrutura de uma RNA

Um neurônio artificial é uma representação matemática da estrutura e funcionamento de um neurônio biológico, mesmo que de forma primitiva, e são elementos de processamento divididos em camadas interconectadas, que recebem estímulos e propagam até a camada de saída onde se obtém um novo estímulo. Conforme Fig. 1, um neurônio artificial, que pode ser denominado k , ao receber informações, atribui a entrada x_{km} ao peso sináptico correspondente w_{km} (Oliveira 2005).




Fig. 1 Estrutura de um neurônio artificial (Oliveira 2005).

As entradas já ponderadas pelos pesos sinápticos são combinadas pela ação do somador, resultando em v_k , enquanto a função de ativação F condiciona o sinal de saída. Uma função de ativação é escolhida para satisfazer alguma especificação do problema que os neurônios estão tentando resolver (Hagan 2016), para problemas não lineares geralmente é utilizada a função sigmoide. Essa função de ativação, para qualquer entrada entre menos infinito e mais infinito, apresenta uma saída entre 0 e 1, como pode ser visualizado na Fig. 2. É uma função bastante empregada em redes neurais cujo treinamento é realizado com algoritmo de backpropagation, em parte por ser diferenciável e apresentar um balanceamento entre um comportamento linear e não linear, e pode, virtualmente, aproximar qualquer função desejada (Hagan 2016).




Fig. 2 Função sigmoide.

Uma RNA pode ser estruturada de diversas formas, de acordo com os objetivos para os quais é construída. Em relação ao padrão de conexões e propagação dos dados, Haykin (2009) as classifica em redes de alimentação direta, ou feedforward, e recorrentes, ou feedback.




Fig. 3 Rede de alimentação direta (a) e rede recorrente (b).

As redes de alimentação direta se caracterizam por permitir o fluxo de dados em apenas uma direção, como pode ser visto na Fig. 3 (a), onde cada um dos círculos representa um neurônio. Já as redes recorrentes, Fig. 3 (b), apresentam propriedades dinâmicas, ou memória dinâmica, devido ao laço de realimentação que interliga a camada de saída com a camada de entrada.

Para obter os pesos sinápticos adequados para a representação mais fidedigna à realidade do modelo, e conhecimento do ambiente ao qual a rede será aplicada, a rede neural passa por um processo determinado treinamento, cujo objetivo é estabelecer a intensidade das conexões sinápticas entre os neurônios (Oliveira 2005). Durante este período, de acordo com o conjunto de dados de entrada e saída fornecidos, a resposta da rede é comparada com a resposta desejada, e os pesos sinápticos, ou seja, a intensidade das conexões entre neurônios, são ajustados. Existem diversos algoritmos de treinamento, que se diferenciam pela forma que os pesos sinápticos são ajustados, de forma a minimizar o erro de saída da rede.

O algoritmo de treinamento supervisionado, em que há a avaliação da discrepância entre resposta da rede e resposta desejada, é o de retropropagação, ou backpropagation. Este algoritmo apresenta um comportamento em duas fases, a primeira sendo a propagação das entradas através da rede e a segunda a propagação do erro obtido em um sentido contrário. Neste trabalho foi utilizado uma variação do algoritmo de backpropagation denominada Levenberg-Marquadt. Após o período de treinamento são realizados testes, onde espera-se que a rede neural produza resultados corretos para um conjunto de dados que não constituíram a fase de treinamento.

2.2 NARX

A previsão de eventos requer a utilização de um modelo de rede neural dinâmica. Devido a não-linearidade do comportamento térmico, e a influência da temperatura anterior nas trocas de calor que determinarão o próximo estado, além da influência de grandezas que variam com o tempo na temperatura de um transformador, foi utilizado o modelo de rede NARX. Este modelo apresenta um laço de realimentação conectando suas diversas camadas. Uma vantagem da utilização deste modelo em relação a outros modelos dinâmicos de redes neurais é que outros modelos apresentam dinâmica apenas na camada de saída, enquanto, por possuir entradas externas, o modelo NARX apresenta dinâmica tanto na camada de saída como na camada de entrada. Em resumo, as entradas e as saídas do estado atual têm influência no valor de saída do próximo estado, representando o que ocorre em um transformador real devido a variações da temperatura ambiente ou de seu carregamento. Onde x é o vetor de entradas e y o vetor de saídas. A arquitetura desta rede pode ser visualizada na Fig. 4.




Fig. 4 Estrutura de uma rede NARX (Andrade et. al. 2014).

Apesar de se tratar de uma rede com feedback, ou malha fechada, este modelo de rede pode ser representado em malha aberta se considerado o valor desejado de saída do estado anterior $y(n-1)$, este que se encontra disponível durante o treinamento, como uma nova entrada no lugar do laço de realimentação, conforme Fig.5. Dessa forma, pode-se

considerar a rede como de alimentação direta e utilizar um algoritmo de treinamento backpropagation, melhorando a eficiência e precisão do treinamento, pois a rede baseia-se em um estado de saída anterior $y(n-1)$ sem erro. Após o treinamento é utilizada a rede em malha fechada. Ou seja, o valor de saída fornecido pela resposta da rede é quem terá influência na determinação do próximo valor de temperatura e não mais o valor de saída desejado.




Fig. 5 Arquiteturas de uma rede NARX (Hagan 2016).

2.3 Levenberg-Marquadt

O algoritmo de Levenberg-Marquadt (LM) é uma variação do método de Newton, designado a minimizar a soma dos quadrados de outras funções não-lineares, sendo adequado para o treinamento de redes neurais em que a avaliação de desempenho é feita utilizando o erro quadrático médio (EQM) (Hagan 2016).

Uma particularidade do treinamento com o algoritmo de Levenberg-Marquadt é que o conjunto de dados é dividido em três. O primeiro constitui a parte que será utilizada para o treinamento da rede de fato, realizando o ajuste dos pesos sinápticos. O segundo conjunto, denominado de validação, é o conjunto responsável pela parada antecipada do treinamento melhorando a eficiência e o tempo de treinamento da rede. Ou seja, este conjunto de dados é testado na rede neural e quando o erro passa a aumentar o treinamento é interrompido. O terceiro e último conjunto, denominado de teste, fornece uma estimativa da precisão da rede neural treinada, simulando seu comportamento para conjuntos de dados externos que não participaram de seu treinamento.

2.4 Avaliação de Desempenho

A avaliação de desempenho do treinamento e testes da rede é feita utilizando três parâmetros: erro quadrático médio (EQM), desvio médio absoluto (DMA) e coeficiente de determinação (R^2).

O EQM é representado por (1). Este parâmetro é determinado somando o quadrado dos erros de previsão e dividindo esta soma pelo número de amostras, e é utilizado como medida de desempenho durante o treinamento da rede neural. Uma vantagem da utilização deste parâmetro é, assim como o DMA, tornar diversos pontos ao longo do tempo em apenas uma grandeza. Quanto mais próximo de zero este parâmetro estiver, melhor o desempenho da rede neural.

O coeficiente de determinação R^2 indica o quanto o modelo obtido foi capaz de representar os dados selecionados. Neste

caso, quanto as respostas fornecidas pela rede neural se aproximam dos valores de temperatura de topo de óleo desejados, provenientes de medições. Este parâmetro varia entre 0 e 1, e quanto mais próximo de 1 melhor a representação física do modelo desenvolvido através da rede neural.

$$EQM = \frac{1}{N} \sum_{i=1}^N (e_i)^2 \quad (1)$$

O desvio médio absoluto (2) fornece a média dos erros, em módulo, cometidos pelo modelo em um determinado período de tempo. Fornece sempre um valor positivo, por levar em consideração somente a magnitude do erro e é um dos parâmetros mais utilizados para erros de previsão. Quanto menor seu valor melhor é o desempenho do modelo em questão.

$$DMA = \frac{1}{N} \sum_{i=1}^N |e_i| \quad (2)$$

3. METODOLOGIA

A rede neural foi desenvolvida utilizando dados de um transformador elevador de potência nominal de 330 MVA e níveis de tensão de 13,8/500 kV. Este transformador está situado na Usina Hidrelétrica Santo Antônio, no Rio Madeira em Porto Velho – RO.

Os dados selecionados para o desenvolvimento da rede neural são oriundos do sistema de monitoramento em tempo real do transformador e contemplam dois períodos de um ano cada. O primeiro período tem início em Novembro de 2016 e se estende até Novembro de 2017 enquanto o segundo período vai de Abril de 2018 até Abril de 2019, denominados Período 1 e Período 2, respectivamente. Um período será utilizado para o treinamento da rede e o outro será utilizado para testar a capacidade de predição da rede em operação.

A saída da rede neural, ou seja, a variável que deve ser determinada pela rede e se manter próxima em comparação aos dados de monitoramento, é a temperatura de topo de óleo. As variáveis de entrada da rede são constituídas pela temperatura ambiente, carregamento e número de conjuntos de aerotermos em operação. O carregamento do transformador é diretamente responsável pelas perdas no cobre, e conseqüente aquecimento dos enrolamentos e do óleo, enquanto a temperatura ambiente tem influência nas trocas térmicas que ocorrerão entre o transformador e o ambiente ao dissipar o calor das perdas. O número de conjuntos de aerotermos em operação é o status dos trocadores de calor, e tem influência direta na velocidade de escoamento do óleo e na capacidade de dissipar o calor interno para o ambiente externo. O transformador sob estudo possui cinco conjuntos de aerotermos.

A amostragem de todas as grandezas é de 10 minutos, resultando em 52672 amostras para o Período 1 e 52664 para o Período 2. O Período 2 foi utilizado para o treinamento por apresentar uma maior variação das condições de operação do

transformador, visando um melhor desempenho da rede neural.

Utilizando a toolbox de redes neurais do software Matlab, os dados de treinamento foram divididos em três conjuntos os quais constituem 90% de treinamento, 5% de validação e 5% de teste. O número de estados anteriores das entradas e saídas que a rede leva em consideração para o cálculo do próximo valor de temperatura é escolhido pela observação da influência na dinâmica térmica do transformador. Estima-se que 30 minutos seja um tempo adequado, portanto os três estados anteriores são levados em consideração ($d = 3$).




Fig. 6 Desvio média absoluto para diferentes quantidades de camadas ocultas.

O número de camadas ocultas (n), termo que provém do fato de que estas camadas de neurônios não possuem ligação direta com as camadas de entrada e saída da rede, não apresentam um critério específico para sua escolha, a não ser por testes ao implementar a rede. O desempenho da rede em malha fechada, utilizando o erro médio absoluto como parâmetro de avaliação, para diferentes quantidades de camadas ocultas pode ser visto na Fig. 6. Levando em consideração as características citadas, a rede desenvolvida resulta na estrutura que pode ser visualizada na Fig. 7.




Fig. 7 Estrutura da rede neural desenvolvida.

4. RESULTADOS

A rede neural desenvolvida foi treinada utilizando os dados do Período 2, em malha aberta, podendo ser considerada uma rede com estrutura feedforward. O DMA obtido foi de 0,2933 K, enquanto o erro máximo observado, em módulo, foi de 2,4662 K. Aproximadamente 40% dos erros observados encontram-se abaixo de 0,08546, enquanto cerca de 25% encontram-se entre -0,1651 e zero. Isto indica que, durante o treinamento, a rede neural obteve sucesso ao buscar representar o comportamento térmico de acordo com os dados fornecidos. O fato de a resposta da rede estar tão próxima do valor desejado de saída é causado pelo treinamento em malha aberta, que exclui o erro do estado anterior ao determinar o próximo.

Após o treinamento, a rede foi testada para o mesmo conjunto de dados de treinamento, desta vez utilizando sua

característica de retroalimentação. Ou seja, a rede está operando sem conhecer o valor de saída desejado em nenhum momento. O DMA calculado foi de 1,1704 K, enquanto o erro máximo observado foi de 6,8048 K. O histograma de erros da Fig. 8 demonstra que, visualizando as três colunas centrais, mais da metade do número total de ocorrências de erro observados estão abaixo de 0,65 K, em módulo. Mais de 90% das ocorrências de erro se encontram abaixo de 2 K, comprovando uma boa representação do comportamento térmico de um transformador.




Fig. 8 Histograma de erros para teste em malha fechada realizado com os mesmos dados do treinamento (Período 2).

A Fig. 9 demonstra a correlação entre as saídas da rede e valores desejados. Desta vez pode ser observada uma maior quantidade de erros, o que era esperado, entretanto o comportamento da rede permanece próximo ao desejado, resultando em um R^2 de 0,94079.

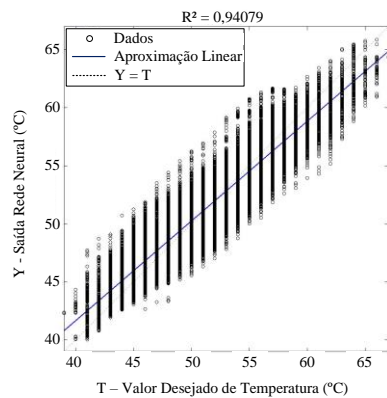


Fig. 9 Correlação obtida no teste com dados do Período 2.

A Fig. 10 ilustra a resposta da rede (em azul) juntamente com o valor de temperatura do monitoramento do transformador (em vermelho) para um período de 14 dias, escolhido para uma melhor visualização do comportamento. A dinâmica da rede neural se adapta muito bem às variações de temperatura do transformador, e mesmo que em praticamente todos os momentos existam erros, estes são de pequenas magnitudes.

Por fim, um teste foi realizado utilizando os dados do Período 1. Este conjunto de dados não participou do treinamento da rede, portanto é desconhecido por ela. Este teste visa simular a operação real da rede. Sendo a rede neural treinada para reproduzir o comportamento térmico de um determinado transformador de potência através da temperatura de topo de óleo, sua resposta deve ser satisfatória para quaisquer

entradas que este transformador possa receber. Isto determina se o conjunto de dados de treinamento foi suficiente e se o processo de treinamento ocorreu bem.




Fig. 10 Teste com dados do Período 2, resposta para 14 dias.

O histograma apresentado na Fig. 11 demonstra que cerca de 32 % dos erros estão entre -0,5836 e 0,8. Sendo que, abaixo de 2,163, em módulo, encontram-se 82 % das ocorrências de erro.




Fig. 11 Histograma de erros para teste em malha fechada realizado com dados do Período 1.

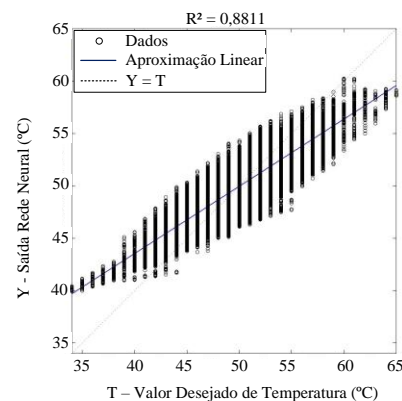


Fig. 12 Correlação obtida no teste com dados do Período 1.

O DMA observado foi de 1,802 K e o caso extremo foi de 7,3144 K. A correlação entre a resposta da rede e dados de monitoramento pode ser visualizada na Fig. 12, apresentando um R^2 de 0,8811. Ou seja, o modelo obtido através da rede neural desenvolvida representa o comportamento do transformador com cerca de 88% de precisão.

Estão ilustrados na Fig. 13, dentro do período total de um ano para o qual foi realizado este teste, um período de comparação entre a operação da rede e os dados de monitoramento do transformador. Ressalta-se novamente que a rede neural desenvolvida demonstra a capacidade de representar o comportamento real do transformador para o qual ela foi treinada, inclusive seu comportamento dinâmico.




Fig. 13 Teste com dados do Período 1, resposta para 28 dias.

5. CONSIDERAÇÕES FINAIS

O conhecimento da temperatura de operação em transformadores de potência é de suma importância para garantir sua operação segura e o prolongamento de sua vida útil. Em casos em que se tem o conhecimento das condições de operação futuras, como o despacho de energia por usinas geradoras, a utilização de um modelo para predição de temperatura em transformadores pode ser uma ferramenta valiosa para manter o equipamento em suas condições de operação ideais. A rede neural apresentada neste trabalho foi desenvolvida para um transformador elevador de subestação de uma usina hidrelétrica, implementada com a arquitetura NARX e utilizando o algoritmo LM para treinamento. Foram utilizados dados reais de operação e o modelo desenvolvido teve seu funcionamento prático validado através de testes.

Os valores de erro obtidos permanecem durante grande parte do tempo em margens aceitáveis. Os resultados são considerados satisfatórios em comparação a outros modelos térmicos já difundidos na literatura e outros casos de utilização de redes neurais para predição de temperatura em transformadores. Sendo o último teste apresentado uma demonstração da operação real da rede, considerando um período de um ano inteiro, coloca-se em debate a utilização da técnica apresentada neste trabalho para desenvolvimento de modelos que possam ser utilizados em monitoramento em tempo real, detecção de falhas nos sistemas de medição ou predição de temperatura.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES/PROEX) - Código de Financiamento 001. Os autores também gostariam de agradecer a Santo Antônio Energia (Projeto de P&D PD-06683-0318/2018), VEGOOR, Universidade Federal de Santa Maria - UFSM, Programa de Pós-Graduação em Engenharia Elétrica da UFSM e Instituto

Nacional de Ciência e Tecnologia – Geração Distribuída pelo apoio técnico e financeiro deste trabalho.

REFERÊNCIAS

- ABNT (2007). *NBR 5356-2: Aquecimento*. Associação Brasileira de Normas Técnicas.
- ABNT (2017). *NBR 5356-7: Guia de carregamento para transformadores imersos em líquido isolante*. Associação Brasileira de Normas Técnicas.
- Andrade, L. C. M. de et. al. (2014). Very short-term load forecasting based on NARX recurrent neural networks. *Power & Energy Society General Meeting*. Washington DC, EUA.
- Hagan, M. T.; Demuth, H. B. (2016). *Neural network design*. Segunda Edição, Editora Martin Hagan. Stillwater, Oklahoma, EUA.
- Haykin, S. (2009). *Neural networks and learning machines*. Prentice Hall, Terceira Edição. Upper Saddle River, Nova Jersey, EUA.
- He, Q.; Si, J. e Tylavsky, D. J. (2000). Prediction of top-oil temperature for transformers using neural networks. *IEEE Transactions on Power Delivery*, Vol. 15.
- Huang, H. et. al. (2016). Transformer top-oil modeling based on Kernel-based extreme learning machine. *ICEEA 2016*. Kuala Lumpur, Malásia.
- IEC (2011). *Std 60076-2: Temperature rise for liquid-immersed transformers*. International Electrotechnical Commission.
- IEC (2018). *Std 60076-7: Loading guide for mineral-oil-immersed power transformers*. International Electrotechnical Commission.
- Khalil, R. A. (2012). Comparison of four neural network learning methods based on genetic algorithm for non-linear dynamic systems identification. *Al-Rafidain Engineering Vol. 20*.
- Oliveira, A. R. de (2005). Redes neurais artificiais aplicadas na detecção, classificação e localização de defeitos em linhas de transmissão. Dissertação de Mestrado, Departamento de Engenharia Elétrica, Universidade Federal de Juiz de Fora. Juiz de Fora, Minas Gerais, Brasil.
- Pereira, F. H. (2018). Nonlinear autoregressive neural network models for prediction of transformer oil-dissolved gas concentrations. *Energies Vol. 11*.
- Ruslan, F. A. et. al. (2014). Flood water level modeling and prediction using NARX neural network: Case study at Kelang River. *CSPA2014*, Kuala Lumpur, Malásia.
- Su, X. et. al. (2018). Application of Elman neural network in top-oil temperature prediction of transformer. *ICHVE 2018*. Atenas, Grécia.
- Vilaithong, R.; Tenbohlen, S. e Stirl, T. (2007). Neural network for transformer top-oil temperature prediction. *Symposium on High Voltage Engineering*. Ljubljana, Eslovênia.
- Wei, B. G. et. al. (2017). A method of optimized neural network by LM algorithm to transformer winding hot spot temperature forecasting. *NEFES 2017*. Kunming, China.