



MODELAGEM DINÂMICA DE TRANSFORMADORES A PARTIR DA APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS

Sabrina Jurach², Taciana Paula Enderle³, Marlon Coletto Machry⁴, Maurício de Campos⁵

¹ Pesquisa produzida durante o Programa Institucional de Bolsas de Iniciação Tecnológica

² Estudante do curso de Engenharia Elétrica da UNIJUÍ. Bolsista do Programa Institucional de Bolsas de Iniciação Tecnológica financiado pela Universidade Regional do Noroeste do Estado do Rio Grande do Sul - PIBITI/UNIJUÍ.

³ Professora do curso de Engenharia Elétrica da UNIJUÍ, Orientadora do Programa Institucional de Bolsas de Iniciação Tecnológica financiado pela Universidade Regional do Noroeste do Estado do Rio Grande do Sul - PIBITI/UNIJUÍ e PIBIC/UNIJUÍ.

⁴ Estudante do curso de Engenharia Elétrica da UNIJUÍ. Bolsista do Programa Institucional de Bolsas de Iniciação Científica financiado pela Universidade Regional do Noroeste do Estado do Rio Grande do Sul - PIBIC/UNIJUÍ.

⁵ Professor do curso de Engenharia Elétrica da UNIJUÍ e Coorientador da Pesquisa.

INTRODUÇÃO

Transformadores são equipamentos utilizados para transformação de valores de tensão e corrente, indispensáveis nos sistemas de transmissão e distribuição de energia, representando grande parte do custo desses sistemas. Segundo Liu (2019), a vida útil de um transformador tem relação direta com as condições de funcionamento, principalmente, com o isolamento do óleo, que é composto por um papel isolante, que se degrada quando exposto a altas temperaturas por um longo período. Dessa forma, operar em temperaturas muito elevadas pode diminuir a vida útil de um transformador (P. WOUTERS; A. VAN SCHIJNDEL; J. WETZER, 2010).

Obter a temperatura do ponto mais quente do enrolamento de um transformador é uma tarefa complexa, uma vez que, o sistema só pode ser instalado durante a fabricação, além de possuir um alto custo. Nesse caso, uma inteligência artificial capaz de obter as temperaturas internas de um transformador, sem a necessidade de instrumentação, traz benefícios às concessionárias e permissionárias. Essas redes são ensinadas pelo exemplo, isso significa, portanto, que é possível planejar e estabelecer uma série de projeções e cenários diferentes (EREMIA, MIRCEA ; LIU, CHEN-CHING ; EDRIS, ABDEL-ATY, 2016).

Dessa forma, pode-se treinar uma rede neural que seja capaz de estimar a temperatura do ponto mais quente do enrolamento, bem como a temperatura do topo do óleo, ambas fundamentais para avaliar a vida útil dos transformadores e o fator de aceleração do envelhecimento.



METODOLOGIA

Para gerar uma rede neural, é necessário utilizar um software matemático com essa funcionalidade. Também são necessários dados reais de funcionamento de transformadores, incluindo tensão, corrente, potência, temperatura ambiente, entre outros, para possibilitar o treinamento da rede, para serem utilizados como entradas e targets da rede neural.

Para início de estudo foram utilizados dados reais de transformadores da rede subterrânea da Equatorial Energia (CEEE), localizados no centro da cidade de Porto Alegre/RS. Utilizando estes dados, foi possível se avaliar e treinar as redes neurais, considerando valores de tensão, corrente, temperatura do topo do óleo e da carcaça do transformador e a temperatura ambiente.

Em paralelo a este trabalho, está sendo desenvolvido o projeto para a aquisição das temperaturas, que será instalado no transformador do campus da UNIJUÍ em Santa Rosa. Estes dados serão enviados para o servidor da UNIJUÍ utilizando a comunicação LoRa disponível. Além da temperatura ambiente, temperatura da carcaça e temperatura do topo do óleo, serão realizadas medições de corrente e tensão utilizando um analisador de energia. Assim, com estes dados, mais testes poderão ser realizados para avaliar a eficiência de uma rede neural em prever as temperaturas de um transformador.

RESULTADOS E DISCUSSÃO

As atividades desenvolvidas se baseiam principalmente em identificar qual o melhor modelo de rede neural para prever o comportamento térmico de um transformador. As redes neurais artificiais (RNAs) são uma forma de *machine learning*, que usa “nós”, ou neurônios interconectados em uma estrutura em camadas, semelhante ao cérebro humano, para resolver problemas complexos. A análise desenvolvida estuda a precisão de diferentes combinações de grandezas físicas nas entradas e targets da rede neural.


Para os treinamentos realizados, foi determinado um número fixo de dez neurônios para a camada oculta, e uma distribuição de dados de 70 % para treinamento, 15 % para validação, e 15 % para teste. Dentre os modelos estudados, segue algumas configurações de redes neurais testadas com valores experimentais de concessionárias e permissionárias de energia, e os resultados obtidos:

- FERRAMENTA NEURAL NET FITTING (NFTOOL)

Essa ferramenta se baseia em uma rede que permite criar, visualizar e treinar uma

rede feed-forward de duas camadas (camada oculta e camada de saída) para resolver problemas de ajuste de dados. Essa ferramenta permite avaliar o desempenho da rede usando erro quadrático médio (MSE) e análise de regressão (R). Nessa ferramenta, foram treinadas duas configurações diferentes de entradas e targets. Na Figura 1 pode-se observar a arquitetura da RNA NFTOOL.

Figura 1 - Arquitetura da RNA NFTOOL



Fonte: Adaptado do Matlab

A primeira configuração possui a temperatura ambiente e o carregamento do transformador como entrada, e temperatura da carcaça do transformador como target. Os resultados obtidos foram de 0.9967 para o R, e de 1.214 para o MSE. Esses resultados são satisfatórios, uma vez que o MSE trata da diferença média quadrada entre os valores estimados e o valor real, ou seja, quanto menor o erro mais próximos os valores estimados pela rede estão dos valores reais, e quanto mais próximo o R estiver de 1, mais próximo dos valores reais foram os valores obtidos pela rede. Dessa forma, entende-se que a temperatura ambiente e o carregamento impactam diretamente na temperatura da carcaça.


A segunda configuração possui a temperatura ambiente e a temperatura da carcaça do transformador como entrada, e o carregamento do transformador como target. Os resultados obtidos foram de 0.7815 para o R, e de 5.8063 para o MSE. Esses valores são pouco satisfatórios, pois o R se afastou significativamente de um, e o MSE possui um valor significativamente alto se comparados com a primeira configuração. Tal rede buscava não a temperatura do transformador, mas buscava estabelecer a relação entre as temperaturas ambiente e da carcaça com o carregamento. Como a relação foi baixa, pode-se concluir que para obter o carregamento do transformador, outros fatores impactam no valor final além das temperaturas ambiente e da carcaça.

- FERRAMENTA NEURAL NET TIME SERIES (NARX)

Essa ferramenta é uma rede dinâmica recorrente, com conexões de realimentação envolvendo várias camadas da rede. O modelo NARX é baseado no modelo linear ARX, que é comumente usado na modelagem de séries temporais. A saída é realimentada na entrada da rede neural feedforward, como parte da arquitetura NARX padrão. A Figura 2 ilustra a

arquitetura da RNA NARX.

Figura 2 - Arquitetura da RNA NARX

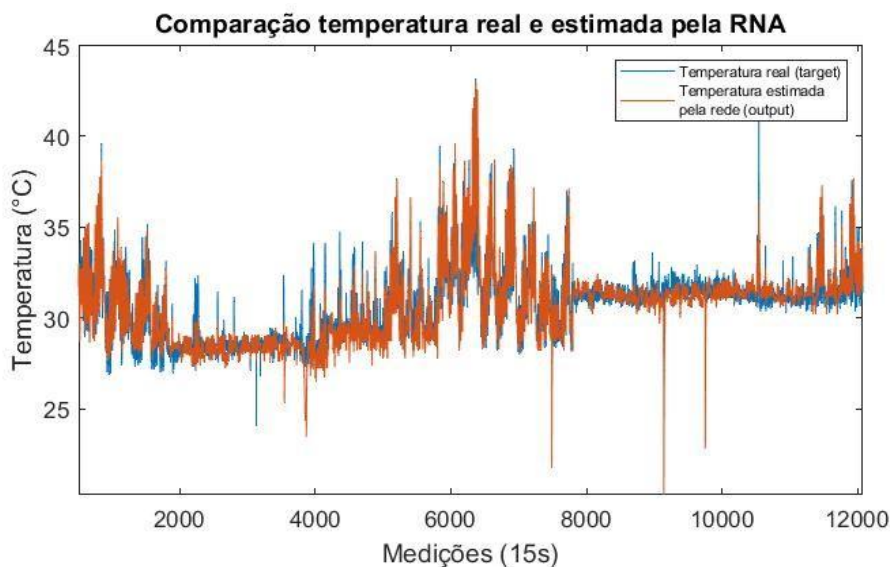


Fonte: Adaptado do Matlab

O teste realizado com essa ferramenta possui a temperatura ambiente e o carregamento do transformador como entrada, e temperatura da carcaça do transformador como target. Os resultados obtidos foram de 0.9847 para o R, e de 1.9785 para o MSE. Esses resultados foram satisfatórios, porém menos precisos que os obtidos com a ferramenta NFTOOL.

Com esses testes preliminares, diante dos dados que haviam disponíveis, conclui-se que a ferramenta NFTOOL foi mais adequada para prever o comportamento térmico do transformador. Na Figura pode-se observar a comparação entre a temperatura real e estimada pela primeira configuração da NFTOOL, que obteve o melhor desempenho, conforme ilustra a Figura 3.

Figura 3 - Comparação entre a temperatura real e estimada pela primeira configuração da NFTOOL



Fonte: Adaptado do Matlab



CONSIDERAÇÕES FINAIS

A pesquisa apresentada teve como objetivo avaliar diferentes configurações de redes neurais artificiais para melhor predição do comportamento térmico de transformadores. Considerando que a grande maioria dos transformadores instalados não prevêem a medição da temperatura do ponto mais quente do enrolamento, e que para novos transformadores esta medição tem um custo elevado, a utilização de RNA torna-se uma alternativa.

Utilizando dados reais de medição de transformadores de uma rede subterrânea de energia, pode-se iniciar os testes, assim estudando e avaliando qual a melhor RNA para o caso em estudo, bem como quais variáveis são fundamentais na predição do comportamento térmico do transformador. A partir dos testes, foi visto que a ferramenta NFTOOL foi a mais adequada, pois apresentou o melhor desempenho diante das mesmas condições de entrada e target.

As informações obtidas com a utilização das RNAs, permitem que as concessionárias e permissionárias de energia avaliem as condições de operação dos transformadores de suas redes, e assim serem mais assertivos na tomada de decisão, seja para manutenção, substituição ou aumento de carga, desta forma, utilizando melhor os recursos e evitando uma falha no fornecimento de energia.

Palavras-chave: Transformadores, Redes Neurais, Temperaturas.

REFERÊNCIAS BIBLIOGRÁFICAS

EREMIA, Mircea ; LIU, Chen-Ching ; EDRIS, Abdel-Aty. “Neural Networks”. Em: **Advanced Solutions in Power Systems: HVDC, FACTS, and Artificial Intelligence**. 2016, pp. 755–783. doi: 10.1002/9781119175391.ch16.

“IEEE Guide for Loading Mineral-Oil-Immersed Transformers and Step-Voltage Regulators - Redline”. Em: **IEEE Std C57.91-2011 (Revision of IEEE Std C57.91-1995) - Redline**. 2012, pp. 1–172.

LIU, Daosheing *et al.* **Investigation on Heating Aging Mechanism of Cellulose Paper for Oil-Immersed Transformer Main Insulation**. 2019. doi: 10.1109/ICDL.2019.8796764.

WOUTERS, Peter ; SCHIJNDEL, van Arjan ; WETZER, Jos Wetzer. **Remaining lifetime modelling of power transformers on individual and population level**. 2010. doi: 10.1109/ICSD.2010.5568112.