

APLICAÇÃO DE AUTOENCODERS EM IMAGENS TÉRMICAS PARA O RECONHECIMENTO DE FALHAS INCIPIENTES EM TRANSFORMADORES DE POTÊNCIA

*Instituto de Energia Elétrica,, Departamento de Engenharia Elétrica, Universidade Federal do Maranhão
Av. dos Portugueses, 1966 – Vila Bacanga, São Luis-MA, 65080-805
E-mails: shigeaki.lima@ufma.br*

Abstract— Energy substation equipment, and particularly power transformers, represent a significant percentage of energy company maintenance revenue. Given the constant changes in the electrical sector and the need to invest in the basic network, the maintenance of substation equipment is a priority and the use of non-invasive methods allows real-time monitoring of equipment evolution, regarding the operation and the appearance of failures that are likely to occur. In this work, the main objective is the identification of incipient faults (that is, that are in the process of formation) in power transformers. In order to do that, it was used the concept of neural networks or self-encoders and thermal images, so that it could be allowed the extraction of the manifold of information that represents the thermal state of the equipment. Based on the use of the thermography technique, a database was generated containing thermal images of power transformer, which allowed to train and validate the proposal, with the identification of fault patterns.

Keywords— self-encoders, thermography, thermal images, points of failure, power transformers.

Resumo— Equipamentos de subestações de energia e particularmente os transformadores de potência, representam um percentual significativo da receita de manutenção das empresas de energia. Com as constantes mudanças no setor elétrico e a necessidade de investimento na rede básica, a manutenção de equipamentos das subestações é prioritária e o uso de métodos não invasivos permite acompanhar em tempo real a evolução dos equipamentos, com relação a operação e ao surgimento falhas que possam vir a ocorrer. Neste trabalho é proposto como objetivo principal a identificação de falhas incipientes (ou seja, que estão em processo de formação) em transformadores de potência. Para isso utiliza o conceito de redes neurais autoassociativa ou *autoencoders* e imagens térmicas, de forma que possibilite a extração do *manifold* de informações que representa o estado térmico do equipamento. Fundamentado na utilização da técnica de termografia, foi gerado uma base de dados contendo imagens térmicas de transformadores de potência, o qual permitiram treinar e validar a proposta, com a identificação de padrões de falhas.

Palavras-chave— *autoencoders*, termografia, imagens térmicas, pontos de falha, transformadores de potência.

1 Introdução

Com a crescente busca por desenvolvimento e ascensão econômica entre as diferentes nações, é comum notar-se o interesse pela expansão energética. O foco de maior parte dos estudos referentes ao tema faz alusão ao crescimento energético de um modo sustentável. Entretanto, além de concentrar-se na preservação do meio ambiente, faz-se também necessário dedicar-se à prevenção de problemas e proteção de sistemas elétricos, dada a enorme contribuição, mesmo que de forma indireta, ao desenvolvimento sustentável.

No que diz respeito às atividades direcionadas ao sistema elétrico, segundo Amarante, Pontes e Michaloski (2016), “um dos principais riscos está no rompimento de conexões, cabos e componentes que podem expor condutores energizados, ou ocasionar abertura do circuito com carga, ocorrendo arco elétrico”. Com a poluição e o meio ambiente acelerando o processo de desgaste das estruturas e componentes dos sistemas elétricos de potência, há a formação de possíveis pontos de rompimento (ou de risco), que possuem uma maior resistência elétrica, e, por consequência, dissipam mais energia por efeito Joule, elevando a temperatura nesses locais. Assim, torna-se essencial a criação de estratégias que consigam visualizar tais pontos de rompimento e evitar a ocorrência de acidentes decorrentes de problemas dessa natureza.

Dentre as várias técnicas abordadas como parte da prevenção de problemas relacionados a redes elé-

tricas, está a termografia, que consiste em determinar a temperatura de um corpo a partir da emissão de irradiação infravermelha (radiação térmica). Basicamente, os objetos são examinados à distância e sem contato, sendo possível tanto a medição quanto a visualização da distribuição de temperatura em um ou mais pontos desses objetos. Assim, de acordo com Amarante, Pontes e Michaloski (2016), a técnica da termografia, “possibilita a medição de temperaturas e a observação dos padrões de distribuição de calor”, sendo mais utilizada onde a variação de temperatura em um dado dispositivo (como transformadores) indica uma condição atípica do sistema.

Partindo desse pressuposto, o presente estudo teve como objetivo a aplicação de técnicas computacionais, através do software MATLAB, para a criação de redes neurais autoassociativas, cujo objetivo principal foi a análise de imagens térmicas para identificar possíveis pontos de falha, decorrentes de superaquecimento, em transformadores de alta tensão.

2 Metodologia

A ideia principal do projeto foi a implementação de uma rede neural artificial, através do software MATLAB, que utilizasse como dados de entrada as imagens térmicas de um transformador de potência (obtidas através da técnica de termografia). Tais imagens seriam divididas em dois grupos básicos: um para treino da rede e outro para teste, de forma a facilitar o desenvolvimento do estudo.

Para que se possa entender o progresso do trabalho, é necessário o conhecimento de alguns elementos e conceitos básicos, tais como o princípio de funcionamento, diagnóstico e manutenção preventiva de um transformador de potência; o processo de formação e as características de uma rede neural artificial, bem como os tipos existentes; as técnicas de termografia e como se dá sua aplicabilidade na detecção de falhas em transformadores.

2.1 Transformadores de Potência

Transformadores de potência são equipamentos cujo princípio básico de funcionamento se dá a partir da conversão de diferentes níveis de tensão entre a fonte, ligada ao primário, e a carga alimentada, ligada ao secundário. Há diversos tipos de transformadores em sistemas elétricos, que podem ser selecionados de acordo com a necessidade da instalação (monofásicos ou trifásicos) e com a classe de tensão e potência na qual se deseja trabalhar (elevador, de transmissão, de subtransmissão e de distribuição).

2.1.1 Diagnóstico e Manutenção Preventiva

Serviços de manutenção preventiva de transformadores abrangem basicamente a realização de análises do óleo isolante e testes de componentes, que definem a necessidade de realização de intervenções, como o tratamento de óleo, trocas de componentes, pinturas das partes externas dentre outros.

Tais serviços tem como objetivo principal a manutenção do bom funcionamento do núcleo e dos enrolamentos do transformador e condições normais de operação, já que uma falha na sua parte ativa poderia acarretar danos com custos elevados de reparo ou mesmo a perda do equipamento.

Com isso, a implementação de sistemas de monitoramento e a realização do diagnóstico periódico em transformadores proporcionam o acompanhamento de suas condições de utilização, identificando anormalidades e consequentemente uma rápida tomada de decisão quanto a medidas para evitar ou minimizar a ocorrência de falhas.

Os principais métodos de diagnóstico e monitoração são:

- Análise do Óleo Isolante

A análise do óleo isolante é o principal e mais utilizado método para avaliar a condição de um transformador, dado a simplicidade no procedimento de coleta, o baixo custo dos testes e as possibilidades de se diagnosticar vários tipos de problemas. Basicamente abrange a análise dos gases dissolvidos e propriedades físico químicas do óleo isolante.

- Temperatura do Óleo e Enrolamentos

Todos os transformadores são dotados de termômetros analógicos ou digitais para a medição da temperatura do óleo e enrolamentos, de forma a permitir que se faça o acompanhamento da temperatura de operação do equipamento.

Para o óleo, o sistema é dotado de sensores imersos no líquido isolante, não apresentando limitações para a correta leitura da temperatura.

No caso dos enrolamentos, a medição é feita através de transformadores de corrente de imagem térmica que, através de dados de projeto, estimam a temperatura das bobinas. Atualmente, existem sistemas mais modernos que utilizam fibras ópticas para essa mesma finalidade, com a vantagem de apresentar dados reais da temperatura do enrolamento.

- Termografia

O teste de termografia é utilizado para verificar a temperatura da superfície de determinadas partes do transformador, principalmente o sistema de refrigeração e pontos de conexão de terminais das buchas.

Trata-se de teste realizado com o transformador em operação, restringindo-se a análise de partes externas do equipamento.

De acordo com os ajustes do aparelho empregado no teste, pode-se verificar quais alterações de temperatura são mais significativas em relação à temperatura de referência e se determinar um plano de ação para corrigir o problema.

Com a combinação da técnica de termografia com o uso de redes neurais artificiais, esse método passa a ser um dos mais eficientes na detecção de possíveis pontos de falhas dos transformadores, de modo que a rede funciona comparando as imagens térmicas do equipamento em tempo real e identifica alterações térmicas significativas, indicando necessidade de reparo. Assim, o processo de manutenção pode ser postergado, já que a rede pode identificar quando se é necessário.

2.2 Rede Neural Artificial

Redes neurais artificiais são ferramentas amplamente utilizadas no reconhecimento de imagens, análise e processamento de sinais, controle de processos, robótica, classificação de dados, dentre outros. De forma geral, a operação de uma célula de rede neural se resume em sinais apresentados à entrada, com a subsequente multiplicação por um peso (que indica sua influência na saída da unidade), para que então seja feita uma soma ponderada de sinais, a qual produz um nível de atividade. Se tal nível exceder um limite (*threshold*), a unidade produz uma saída.

De um modo análogo ao sistema nervoso, que é formado por bilhões de células nervosas, a rede neural artificial também é constituída por unidades básicas, que são pequenos módulos capazes de simular o funcionamento de um neurônio. Tais módulos devem, deste modo, trabalhar em conformidade com os elementos em que foram inspirados, recebendo e retransmitindo informações.

A composição básica de uma rede neural, portanto, consiste em um sistema de neurônios artificiais ligados por conexões sinápticas e divididos em neurônios de entrada (responsáveis por receber a informação - ou estímulo - do meio externo), neurônios internos ou *hidden* (que formam a camada escondida)

e neurônios de saída (que possuem a finalidade de comunicar-se com o meio exterior).

De acordo com a arquitetura (forma pela qual os neurônios estão interconectados), as redes neurais artificiais, de uma forma geral, podem ser distribuídas em três classes fundamentais: redes *feedforward* de uma única camada, redes *feedforward* de múltiplas camadas e redes recorrentes. Nesse trabalho são usadas *feedforward* de uma camada, na concepção das redes autoassociativas.

2.3 Detecção de Pontos de Falha em Transformadores pelo Uso de Redes Neurais

Para que possam ser utilizadas como informação de entrada em uma rede neural, é mais conveniente que as imagens sejam formatadas à escala de cinza, já que o processo de treinamento se torna mais rápido, sendo possível identificar a falha.

Dentre o banco de imagens a ser utilizado, faz-se mais proveitoso que uma faixa entre 50 % e 75 % das imagens sejam separadas para treino enquanto a outra parte seja usada para teste. As imagens de treino são utilizadas como informação de entrada da rede neural e processadas pixel por pixel até se chegar a um padrão de reconhecimento aceitável. A partir de então, pode-se utilizar a rede neural já treinada para processar as imagens separadas para teste. O resultado pode então ser obtido através da visualização das imagens originais de entrada e comparação com a imagem de saída obtidas através do processo de teste, sendo que os pontos de falha (ou aquecimento) estariam destacados nesse segundo par de imagens.

3 Procedimentos Experimentais

A arquitetura da rede neural escolhida para o presente projeto foi do tipo *feedforward* com uma camada escondida. O formato de imagem a ser processado foi o da escala de cinza. De acordo com a proposta inicial, a imagem térmica (provinda da técnica de termografia, cujo tamanho era de 640x480) seria utilizada em seu tamanho original para ser processada pela rede neural artificial. Contudo, dada sua complexidade e a limitação de processamento e memória do computador utilizado, fez-se necessário sua divisão em quatro outras imagens, que foram reduzidas, agrupadas como uma única imagem e utilizadas para treino e teste da rede neural. A Figura 4 exemplifica essa técnica adotada. Questionou-se, a princípio, sobre a redução direta da imagem a um tamanho suficientemente adequado à capacidade de processamento do computador. Todavia, caso isso fosse feito sem a sua subdivisão em quatro outras imagens, haveria uma perda de informações significativa, a ponto de deixar a imagem original irreconhecível.



Figura 1 - Processo de segmentação da imagem adotada como entrada da Rede Neural Artificial (RNA)

A implementação do código responsável por essa segmentação é mostrada a seguir:

```
I=imread('Imagem.jpg'); % Carrega o arquivo de imagem e o aloca para a variável "I".
save I % Armazena a variável "I".
I=im2double(I);
for i=1:240
    for j=1:320
        Ires1(i,j)=I(i,j);
    end
end
for i=1:240
    for j=321:640
        Ires2(i,j-320)=I(i,j);
    end
end
for i=241:480
    for j=1:320
        Ires3(i-240,j)=I(i,j);
    end
end
for i=241:480
    for j=321:640
        Ires4(i-240,j-320)=I(i,j);
    end
end
Ires1=imresize(Ires1, [60 80]);
Ires2=imresize(Ires2, [60 80]);
Ires3=imresize(Ires3, [60 80]);
Ires4=imresize(Ires4, [60 80]);
[x]=[Ires4 Ires3 Ires2 Ires1];
```

A matriz final "x", como mostrada pelo código, representa a união das 4 outras sub-matrizes (Ires1, Ires2, Ires3 e Ires4), que são as subdivisões das matrizes referentes à imagem inicial.

O fluxograma representado na Figura 4 apresenta o método aplicado a apenas uma imagem. O raciocínio utilizado para a expansão desse pensamento a várias imagens é o mesmo. As imagens subsequentes, depois de passarem pelo processo de segmentação, seriam posicionadas logo após o segmento imagem simbolizado pelo numero 4.

O código empregado para treino está listado abaixo

```
%treino
t=x;
net=feedforwardnet(64); %64 neuronios na camada escondida
net=train(net,x,t);
y=net(x);
```

Como se pode notar, utilizou-se um numero total de 64 neurônios na camada escondida. Tal número não foi escolhido de forma aleatória, já que é um dos pontos cruciais no que se refere ao desempenho da rede neural. Segundo o professor doutor Siqueira Ruela da Universidade Federal de Ouro Preto, o numero de neurônios na camada intermediária deve possuir, aproximadamente, dois terços do tamanho da camada de entrada somado ao tamanho da camada de saída. Além disso, deve ser menor que duas vezes

o tamanho da camada de entrada. Assim, já que a imagem inicial foi reduzida a uma imagem de 60 por 320 (4 vezes 80), o tamanho da camada de entrada, em um determinado período de tempo é 60. Fazendo-se os cálculos, obtém-se um valor de aproximadamente 64 neurônios para a camada escondida.

É importante ressaltar, também, que os “*targets*” (alvos), representados pela variável “*t*” são os próprios pixels da imagem em processamento.

O procedimento de teste da rede neural artificial foi implementado e o resultado pode ser visualizado através da comparação entre a imagem de entrada e a imagem resultante do teste realizado.

4 Resultados

A imagem inicial de entrada pode ser observada através da Figura 5.



Figura 2 - Imagem utilizada como dado de entrada para a rede neural

Como pode ser observado na figura, os pontos com cores mais quentes representam os locais de maior aquecimento do equipamento, e, consequentemente, são locais mais suscetíveis a falhas. Entretanto, ainda assim a imagem apresenta uma das condições normais de operação, pois o transformador em estudo não está excessivamente aquecido a ponto de interromper-se seu funcionamento para manutenção.

O processo de segmentação da imagem inicial foi realizando, sendo o resultado visualizado por meio da Figura 6.




Figura 3 - Imagem resultante do processo de segmentação da imagem inicial

Analisando-se a figura, pode-se notar a segmentação da imagem inicial em quatro outras imagens, que, de acordo com a proposta dada, foi alocada a um vetor imagem representado pela variável “*x*”.

Para visualizar-se o conteúdo armazenado nessa variável, fez uso das funções do MATLAB e obteve-se como resultado a imagem mostrada na Figura 7, que mostra o artifício utilizado para se conseguir realizar os testes para detecção de falhas em transformadores de potência, de acordo com o fluxograma apresentado pela Figura 4.



Figura 4 - União das partes segmentadas da imagem inicial em um vetor imagem

A Figura 8 ilustra os resultados obtidos através da execução no software MATLAB do código apresentado na seção anterior.



Figura 5 - Imagens antes e após a passagem pela rede neural

Pode-se notar, pela comparação das duas imagens, a proximidade quase que completa de detalhes entre ambas, não sendo, portanto, destacado nenhum ponto de falha no transformador analisado.

Entretanto, a quantidade de informações oferecidas para treino continua insuficiente, já que constituem os dados de uma única imagem. Para se ter uma resposta mais acurada acerca do procedimento, torna-se necessária a utilização de uma quantidade mais significativa de imagens durante o processo de treino. Além disso, mesmo que o reconhecimento da imagem a olho nu ainda seja possível, houve uma perda significativa de informações quando efetuada sua redução para possibilitar os testes executados, o que resultaria numa menor eficiência caso o projeto fosse aplicado a uma situação real, dadas ainda as interferências do meio externo, como variações de luz, calor e umidade.

Houve também, como parte do projeto, o estudo de como adicionar ao processo de treino da rede neural informações tais como a potência aparente obtida através da curva de carga do equipamento.

Para facilitar e aprimorar o processo de treino da rede, partes da imagem que incluem dados desnecessários foram retiradas, de modo a reduzir o número de pixels, e, consequentemente, diminuir o número de dados a serem processados.

O código em MATLAB arquitetado para esse objetivo e para a posterior adição de potência aparente, sendo que o valor correspondente à potência aparente foi distribuído em toda a imagem, pixel por pixel, de modo a se tornar mais um parâmetro analisado no processo de treino. O valor da potência aparente foi normalizado para o valor entre 0 e 255, o qual representa os níveis de brilho diferentes (na escala de branco a preto), sendo que “0” corresponde à cor preta e “255” corresponde a cor branca, conforme apresentado na seção 2.3.1.1.

Uma variável “Ilinha” descrita no código, armazena os resultados do corte da imagem inicial, com a supressão de dados desnecessários ao projeto e a adição da potência aparente. A imagem após essas alterações é mostrada na Figura 9.




Figura 6 - Corte da imagem inicial e distribuição da potência aparente pixel por pixel

Pode-se perceber, analisando-se a imagem, uma alteração na coloração. Isso se deve ao fato de que cada pixel da imagem foi acrescido do valor normalizado.

Os procedimentos subsequentes são semelhantes aos adotados no método anterior, com a simples diferença de que a variável “I” passou a ser substituída pela variável “Ilinha”, e que os valores das matrizes de imagens foram alterados. É notável a redução de dados do vetor “x” de 60 por 380 para 50 por 308, sendo os dados restantes descartados da análise e treino da rede neural artificial criada.

O processo de treino e teste da rede se dá de maneira completamente igual ao efetuado no procedimento anterior, de modo em que até a quantidade de neurônios da camada escondida da rede se mantém igual, sem representar alguma alteração significativa ou redução da qualidade de treino.

Para alocar cada parte da imagem final (após o treino) ao seu devido local, como na imagem inicial representada pela Figura 5. O resultado dessas alterações é apresentado na Figura 10, de modo em que as partes, outrora separadas para formar o vetor imagem “x”, foram repostas aos locais de origem, como ilustrado a seguir.




Figura 7 - Imagem com alterações referentes a corte e adição de potência aparente após a passagem pela rede neural

Assim, pode-se perceber que o projeto desenvolvido possui aplicações de alta relevância quando se refere ao diagnóstico de possíveis pontos de falha em transformadores de potência.

5 Conclusão

O presente estudo teve como objetivo a abordagem prática de conhecimentos sobre transformadores, técnicas de termografia, processamento digital de imagens e aplicação de redes neurais para a detecção de falhas em transformadores de potência. Partindo-se da ideia inicial, implementou-se uma rede neural que utilizou uma imagem pra treino e teste afim de indicar os pontos críticos no trafo analisado.

A princípio, as informações processadas pela rede faziam menção apenas à análise térmica da imagem, sendo necessário sua subdivisão em quatro outras imagens menores, que seriam consecutivamente alocadas a um vetor para treino e teste da rede. Posteriormente, o estudo foi ampliado para a análise, em conjunto, da potência aparente, de modo que seu valor (referente à imagem estudada) foi igualmente distribuído entre cada um dos pixels da imagem.

De acordo com os resultados, pôde-se concluir que a imagem apresentada ao fim do teste não apresentava pontos de falha ao longo do transformador. Entretanto, faz-se necessário explorar um numero significativamente maior de imagens para treino a fim de se aplicar esse projeto a um ambiente mais prático e generalista. Em um aspecto teórico, as imagens poderiam ser todas subdivididas e consecutivamente sobrepostas uma após a outra, entretanto, para o numero de imagens com o qual desejava-se trabalhar há necessidade de maior esforço computacional.

Agradecimentos

Agradecemos a Companhia de Energia por ceder os dados de imagens térmicas para a realização do trabalho e também a Fundação de Amparo a Pesquisa do Maranhão por possibilitar o auxilio.

Referências Bibliográficas

- Amarante, H., Schenigoski, M., De Pontes, J., & Michaloski, A. (2016). Termografia na prevenção de acidentes no sistema elétrico de potência. 37 (23).
- Andrade, A., & Martins, W. (s.d.). Redes neurais aplicadas ao processamento de imagens de satélite. Universidade Federal de Goiás.
- Brechara, R. (2010). Análise de Falhas de Transformadores de Potência. São Paulo, São Paulo, Brasil: Universidade Federal de São Paulo.
- Haykin, S. (1999). Neural Networks: a comprehensive foundation. New York, New York, USA: McMillan College Publishing Co.
- Ruela, A. (s.d.). Redes neurais Feedforward e Backpropagation . Universidade Federal de Ouro Preto (UFOP).
- Santiago, P., & Da Silva, E. (Outubro de 2016). TERMOGRAFIA APLICADA EM REDES DE DISTRIBUIÇÃO. 7. MG , Brasil: Cemig Distribuição SA.
- Tatibana, C., & Yuki Kaetsu, D. (s.d.). Uma introdução a redes neurais. ERM - Universidade Estadual de Maringá.