

Redes Neurais Originadas em Oscilógrafos com Ajustes de Quantidades para Permitir a Aplicação de RNA em Sistemas Reais

Simone Tatiane do Canto¹

Programa de Pós-Graduação em Engenharia Elétrica, FEEC/UNICAMP, Campinas, SP

Carlos Alberto F. Murari²

FEEC/UNICAMP, Campinas, SP

Marcelo Adorni Pereira³

Research Director at BIOMARKS INNOVATIVE LTDA in Portugal

Resumo. A possibilidade de encontrar falhas incipientes no sistema de distribuição de energia elétrica contribui para a eficiência no consumo. Neste trabalho, propõe-se o uso de redes neurais artificiais (RNAs) para monitorar a rede de distribuição de energia, que será realizado a partir de indicadores extraídos de oscilografia tais como: vetores com amplitudes máximas, transformada Wavelet e transformada de Fourier. A utilização de tais indicadores possibilita identificar e antecipar as diversas situações que podem afetar a qualidade e o fornecimento da energia elétrica.

Palavras-chave. Redes Neurais Artificiais, Detecção, Falhas, Energia

1 Introdução

As interrupções no fornecimento de energia elétrica podem ser identificadas por origem e causa, associadas ao fato de poderem ser de caráter acidental ou previstas [3]. Particularmente, a origem de uma interrupção acidental pode ser devida a uma falha na geração de energia elétrica, nas redes ou na instalação, tendo como principais causas as que são associadas a razões de segurança; a falhas de material e equipamentos; e a fatores naturais/ambientais (tais quais o vento de intensidade elevada, inundações imprevisíveis, descargas atmosféricas, deslizamento de terras, incêndios e animais) [4].

O objetivo deste trabalho está no preditivo, ou seja, antecipar a ocorrência de falta que pode ser detectada [1], como por exemplo: a) a ocorrência de curto-circuito momentâneo quando há contato de galho de árvore com os condutores; b) o aumento/redução de carga em um ramal monofásico podendo gerar um desequilíbrio que resulte em tensões e correntes fora dos limites aceitáveis de operação; c) o centelhamento devido a mau contato em conexões de cabos e equipamentos, causando deteriorações [6]. Portanto, possibilitar que empresas do setor elétrico disponham de uma ferramenta eficaz que monitore as respectivas redes elétricas prevendo a falta na média tensão, será de grande valia, pois ao detectarem um problema e solucioná-lo antes da ocorrência da falta, minimizarão as interrupções no fornecimento de energia [5].

Dentre as diversas ferramentas que auxiliam à tomada de decisão no monitoramento da operação de redes de energia elétrica, os destaques são para aquelas que se fundamentam em metodologias

¹simone.tati@gmail.com

²carlosafmurari@gmail.com

³marcelo@rmengenharia.net

inteligentes que, baseadas em medições que se originam de equipamentos existentes nas redes, dão alicerce para a análise preditiva de possíveis ocorrências de faltas [6]. Sendo assim, a finalidade deste estudo é desenvolver um sistema preditivo de detecção de falta na média tensão com o uso de técnicas de inteligência artificial (IA).

2 Desenvolvimento do modelo

O banco de dados utilizado neste trabalho está disponível na página do Grupo de Trabalho IEEE (Instituto de Engenheiros Eletricistas e Eletrônicos) em Análise de Dados de Qualidade de Energia [2]. Para obter os indicadores a serem utilizados como variáveis de entrada na rede neural artificial determinou-se que os dados deveriam ser normalizados, a fim de a rede neural artificial ter melhor desempenho [7]. Optou-se por assumir como valor padrão, o valor máximo absoluto, ou de tensão ou de corrente, proveniente de oscilografias sem defeitos, acrescido em 10%⁴, tomando-se o cuidado de se substituir por outro valor padrão quando a variação na carga ultrapassar o valor padrão estipulado [4],[1]. Uma necessidade característica da rede neural é que cada entrada apresente a mesma quantidade de valores. Portanto, analisou-se que indicador determinaria essa quantidade, pelo fato de não ser muito flexível em sua formulação e concluiu-se que dentre os indicadores utilizados, o de energia (TDW) estabeleceria tal quantidade, como demonstrado nas seções seguintes.

2.1 Janelamento dos dados normalizados

Como a oscilografia a ser trabalhada possui 13.824.000 valores e cada ciclo da forma de onda (tensão ou corrente) contém 64 valores, diferentes simulações convergiram para a quantidade de 20 ciclos em cada janela de dados, como solução de compromisso entre tempo de processamento e quantidade suficiente de dados para atender aos objetivos da pesquisa. Então o procedimento utilizado para obter o máximo absoluto padrão da oscilografia foi o seguinte: para cada janela de dados determina-se o máximo absoluto, formando-se o vetor coluna de máximos de cada janela, de modo que o número de linhas (dimensão do vetor) será a quantidade de janelas existentes na coluna de dados da oscilografia. Obtido o vetor de máximos absolutos, extrai-se o máximo dentre os máximos absolutos e este valor, acrescido em 10% [4], será aplicado para normalizar os dados das oscilografias.

2.2 Arquitetura da Rede Neural Artificial

2.2.1 Primeira entrada da Rede Neural Artificial : Vetor com os máximos de cada janela (Vmax)

Aproveitando o vetor de máximos absolutos constituído para obter o valor de normalização do banco de dados, optou-se por utilizar este vetor como uma das entradas da Rede Neural Artificial a ser elaborada.

2.2.2 Segunda entrada da Rede Neural Artificial: Transformada Direta de Wavelet (TDW)- Indicador de energia

A área sob a curva descrita pela função matemática que caracteriza o sinal a ser estudado, considera não apenas a amplitude, mas também a sua duração, o que representa a “força de um

⁴No trabalho [4] foi considerado o limiar de máximo valor de pico diário e aplicado um acréscimo de 20%, no presente trabalho após alguns testes verificou-se que ao realizar a adição de 10% os resultados ainda se tornam satisfatórios

sinal”, ou seja, a energia do sinal. Com este alternado têm-se amplitudes positivas e negativas (semiciclos positivos e negativos), o cálculo correto da área sob a curva ocorre pelo quadrado da função, ou seja, para um sinal contínuo $x(t)$, a respectiva energia E_x no intervalo $[t_1, t_2]$ é definida pela expressão (1). [4]:

$$E_x = \int_{t_1}^{t_2} (x(t))^2 dx. \quad (1)$$

A expressão (1) pode ser generalizada para um sinal complexo da seguinte forma:

$$E_x = \int_{t_1}^{t_2} |x(t)|^2 dx. \quad (2)$$

E para um sinal discreto:

$$E_x = \sum_{n=-\infty}^{\infty} |x(t)|^2. \quad (3)$$

Para os dados de uma oscilografia é expressa por:

$$E_s = \sum_{n=1}^N (a_n)^2. \quad (4)$$

Onde a_n corresponde aos dados das amostras das oscilografias de corrente ou tensão e N é a quantidade de amostras .

Seguindo essa linha de raciocínio, a energia dos Coeficientes de Wavelet com borda (E_w) é obtida através de

$$E_w = \sum_{n=1}^{N_{cD1}} (cD1_n)^2. \quad (5)$$

Onde $cD1_n$ corresponde a cada coeficiente de detalhe da primeira decomposição da aplicação da Transformada de Wavelet e N_{cD1} é o número máximo de coeficientes de detalhe da primeira decomposição da Transformada de Wavelet.

2.2.3 Decomposição Wavelet

Os coeficientes de Wavelet são obtidos através da decomposição Wavelet do sinal s analisado no nível j , e possui a seguinte estrutura: $[cA_j, cD_j, \dots, cD_1]$, esta estrutura contém, para $j = 3$, os nós terminais da árvore [4]. O vetor de decomposição Wavelet (c), retornado como outro de valor real, é organizado como no diagrama de decomposição de nível 3 [4].

Obtido o vetor de decomposição Wavelet (c), observou-se que a quantidade de linhas não era possível alterar, pois de acordo com a quantidade de dados fornecidos (x) ocorrerá a decomposição de x , aproximadamente pela metade, pois uma parte irá para $cD1$ (primeiro coeficiente de detalhe) e a outra para $cA1$ (primeiro coeficiente de aproximação), e deste último uma parte irá para $cD2$ (segundo coeficiente de detalhe) e a outra parte para $cA2$ (segundo coeficiente de aproximação), e assim ocorre até o último nível de decomposição.

Diante do que foi descrito para obter-se a segunda entrada da rede neural, utiliza-se o vetor de decomposição de Wavelet (c), e este foi quem determinou o número de linhas dos demais vetores de entrada da rede neural artificial. Para um janelamento de dados com 20 ciclos, após o empilhamento de cada vetor dos coeficientes obteve-se um vetor com 1300 linhas.

2.2.4 Terceira entrada da Rede Neural Artificial: Transformada Rápida de Fourier (TRF) – Indicadores Harmônicos

Um sinal periódico $x(t)$ pode ser matematicamente representado por (6):

$$x(t) = a_0 + \sum_{n=1}^{\infty} [a_n * \cos(n * w_0 * t) + b_n * \sin(n * w_0 * t)]. \quad (6)$$

Onde w_0 é a frequência angular fundamental; a_n e b_n são as amplitudes e n representa a ordem harmônica do sinal $x(t)$.

Os coeficientes da série de Fourier são determinados por:

$$a_0 = \frac{1}{T_0} \int_{T_0} x(t) dx = \frac{2}{T_0} \int_{T_0} x(t) * \cos(n * w_0 * t) dx = \frac{2}{T_0} \int_{T_0} x(t) * \sin(n * w_0 * t) dx. \quad (7)$$

Onde \int_{T_0} representa a integração em um período fundamental T_0 , sendo o inverso da frequência fundamental $f_0 = 60Hz$.

A série de Fourier pode ser escrita na seguinte forma compacta [7]:

$$x(t) = c_0 + \sum_{n=1}^{\infty} c_n * \cos(n * w_0 * t + \theta_n). \quad (8)$$

Onde c_n e θ_n estão relacionados com a_n e b_n por:

$$c_0 = a_0. \quad (9)$$

$$c_n = \sqrt{(a_n)^2 + (b_n)^2}. \quad (10)$$

$$\theta_n = \arctan\left(-\frac{a_n}{b_n}\right). \quad (11)$$

Nas Equações (10) e (11), $n = 1$ corresponde as variáveis que representam o fasor fundamental. Para a formulação discreta, as integrais das equações (7) podem ser substituídas por somatórios, resultando em:

$$a_0 = \frac{1}{N} \sum_{k=0}^{N-1} x(t_k). \quad (12)$$

$$a_n = \frac{2}{N} \sum_{k=0}^{N-1} [x(t_k) * \cos(n * \frac{2\pi k}{N})] = \frac{2}{N} \sum_{k=0}^{N-1} x(t_k) * h_c(k). \quad (13)$$

$$b_n = \frac{2}{N} \sum_{k=0}^{N-1} [x(t_k) * \sin(n * \frac{2\pi k}{N})] = \frac{2}{N} \sum_{k=0}^{N-1} x(t_k) * h_s(k). \quad (14)$$

Onde h_c e h_s podem ser interpretados como os coeficientes dos filtros de Fourier escrito por:

$$[h_c = \frac{2}{N} [1 \cos(n * \frac{2\pi}{N}) \cos(n * \frac{4\pi}{N}) * \cos(n * \frac{2\pi(N-1)}{N})]]. \quad (15)$$

$$[h_s = \frac{2}{N} [1 \sin(n * \frac{2\pi}{N}) \sin(n * \frac{4\pi}{N}) * \sin(n * \frac{2\pi(N-1)}{N})]]. \quad (16)$$

2.2.5 Quarta entrada da Rede Neural Artificial: Vetor com o valor eficaz de cada janela (Vef)

O valor eficaz representa o valor de uma tensão (ou corrente) contínua que produz a mesma dissipação de potência de tensão (ou corrente) periódica [7].

A potência instantânea dissipada em uma resistência é:

$$p(t) = \frac{(v(t))^2}{R} = R * (i(t))^2. \quad (17)$$

Onde $p(t)$ é a potência dissipada, $v(t)$ é a velocidade, t é o tempo, R é a resistência e $i(t)$ é a corrente. A potência média dissipada é

$$P(medio) = \frac{1}{T} * \int_0^T p(t)dt = \frac{1}{T} * \int_0^T R * (i(t))^2 dt = R * \frac{1}{T} * \int_0^T (i(t))^2 dt. \quad (18)$$

Igualando as equações (17) e (18) obtemos a equação que resulta no Root Mean Square (RMS), ou seja, Raiz do Valor Quadrado Médio:

$$V(RMS) = \sqrt{\frac{1}{T} * \int_0^T (v(t))^2 dt}. \quad (19)$$

Neste trabalho, o valor eficaz ou RMS (*Veficaz* ou *Vrms*) foi calculado pela expressão que corresponde à média quadrática das amostras de um ciclo:

$$Veficaz = \frac{\sqrt{\sum_{n=1}^{N_c} (a_n)^2}}{N_c}. \quad (20)$$

Onde a_n corresponde às amostras das oscilografias de tensão e corrente e N_c é a quantidade de amostras por ciclo.

3 Resultados obtidos

Ao obter os 4 indicadores considerados variáveis de entrada da RNA [7], utilizou-se o toolbox em MatLab para o treinamento da rede neural artificial que será utilizada para a leitura dos dados de novas oscilografias. Utilizando-se o algoritmo de aprendizado baseado na estatística bayesiana, uma rede neural perceptron foi gerada com uma camada escondida contendo 10 neurônios[7]. Os algoritmos de aprendizado Bayesiano minimizam o problema sobre treinamento (*overfitting*), e ainda controlam a complexidade do modelo (princípio de *Occam's razor*) e consequentemente obtém-se boa generalização com poucos dados de treinamento[7]. Após a confecção do algoritmo para a detecção de falhas, que consiste na formação dos vetores de entrada da RNA e no treinamento da RNA com dados de oscilografia de uma rede de distribuição de energia elétrica operando em condições normais, ou seja, sem anomalias, o algoritmo é aplicado à mesma rede elétrica ou em outra rede similar objetivando detectar indícios de falhas futuras (incipientes).

Ao realizar este procedimento, verificou-se que utilizando uma RNA sem anomalias nos leva ao resultado desejado, ou seja, a rede neural artificial quando se depara com oscilografias fora de seu padrão consegue apontar os problemas existentes, e além disso a Figura 1 nos mostra que os indicadores de máximo absoluto e valor eficaz⁵ oscilam e isso aponta para queda na intensidade do

⁵De acordo com [4] o valor eficaz quando apresenta variação indica Flutuação de Tensão, dentre diversos distúrbios que esse fenômeno causa se destaca a cintilação luminosa (*flicker*).

fluxo de energia elétrica, consequentemente indicando a possível ocorrência de cintilação luminosa. Nota-se ainda na Figura 1 uma redução no coeficiente de Fourier indicando falta de energia, porém o indicador Wavelet indica um aumento de energia, quando essa instabilidade ocorre pode indicar o caso de fuga de corrente elétrica. Esse fenômeno é considerado um problema comum de acordo com [1] e pode causar diversos danos como pequenos choques ou até mesmo acidentes graves. A fuga de corrente elétrica pode ser causada pela degradação dos equipamentos elétricos, mas também se apresentam em instalações elétrica não realizadas dentro das normas de segurança, ou ainda em falta de manutenção, por exemplo quando existem fios desencapados, isolamento ressecada, ou ainda na exposição a agentes corrosivos, quando a fuga de corrente é mais severa pode gerar danos irreversíveis, por isso identificar a ocorrência desse episódio é de extrema importância.

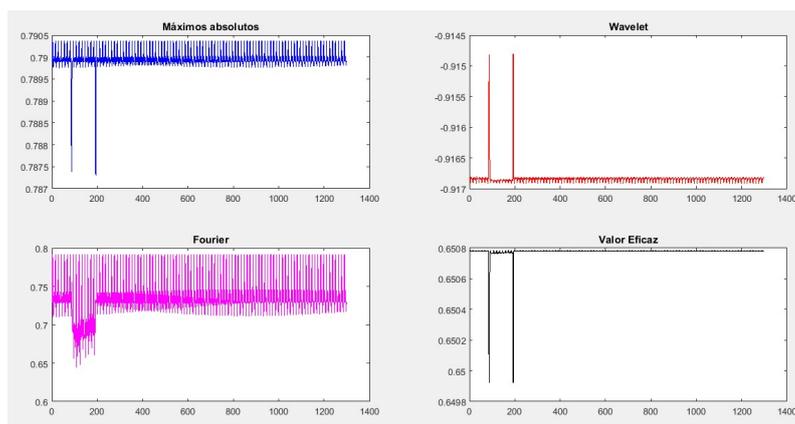


Figura 1: Simulação a partir da janela 9500. Fonte: O autor.

4 Conclusão

A intenção deste trabalho foi confeccionar uma rede neural que não possui anomalias, ou seja, uma rede neural com dados que mostram um cenário sem defeitos e ao inserir dados que podem ou não ter problemas na corrente elétrica a rede neural sem conhecimento identificaria o problema e apontaria qual indicador está fora do padrão adotado.

Os resultados mostram que é possível trabalhar com uma rede neural sem o conhecimento do problema e quando ela percebe que algo está fora do padrão adotado a rede neural artificial aponta qual indicador está diferente do padrão adotado. Trabalhar com uma rede neural sem anomalias, possibilita que diversos tipos de problemas sejam apontados, do contrário, como afirmado em [1], deveríamos confeccionar uma rede neural para cada anomalia deste modo a rede neural que acusasse similaridade a oscilografia inserida apontaria o defeito .

Para confeccionar uma rede neural que realiza a previsão de cada anomalia há a necessidade de um conhecimento prévio do comportamento senoidal de cada problema apresentado pela rede elétrica de energia [7]. Como as concessionárias de energia não tem a preocupação de associar o tipo de defeito ocorrido com a anomalia apresentada na senoide da oscilografia, ou seja, quando ocorre um problema de falta de energia elétrica a concessionária deseja solucioná-lo a fim de reestabelecer a transmissão de energia e não realiza a associação do defeito ocorrido com a anomalia presente na oscilografia apresentada no sistema. Sendo assim, criar RNA para cada tipo de problema que possa ocorrer na rede elétrica fica inviável, pois deveríamos realizar simulações a fim de obter senoides com características singulares para cada defeito e assim obter as diversas redes neurais, porém possivelmente algum defeito não seria analisado. Então diante desta dificuldade propõe-se

o uso de uma rede neural artificial que não tenha defeitos e assim quando surgir algo fora de sua normalidade ela consiga detectar a possível anomalia e informar qual problema poderá ocorrer [7].

Com os resultados promissores obtidos com a rede neural sem anomalias, pode-se poupar o trabalho com simulações de possíveis defeitos, visto que a ocorrência de problemas de transmissão de energia é decorrente não apenas da manutenção da rede elétrica, mas também de fenômenos naturais. Ao utilizar uma rede neural sem conhecimento de problemas na rede elétrica de energia consegue-se abranger defeitos que nem havíamos previsto ainda, isso aumenta o leque de abrangência na detecção de possíveis anomalias que interrompam o fornecimento de energia elétrica.

Referências

- [1] F. S. Avelar, A. S. Paula, F. F. B. Silva, M. T. C. Siqueira e D.F. Gomes. “Utilização de Redes Neurais Artificiais para Recuperação de Falhas em Redes de Distribuição de Energia Elétrica”. Em: **Gestão, Tecnologia e Inovação : Revista eletrônica dos cursos de engenharia** 2.2 (2021). Acessado em 18/03/2024, https://www.opet.com.br/faculdade/revista-engenharias/pdf/v2n2/Utilizacao-de-Redes-Neurais-Artificiais-para-Recuperacao-de-Falhas-em-Redes-de-Distribuicao-de-Energia-Eletrica_v2n2-1.pdf, pp. 1–10. ISSN: 2595-3370.
- [2] W. Freitas. **Grupo de Trabalho IEEE em Análise de Dados de Qualidade de Energia**. Acessado em, 25/03/2024, <https://grouper.ieee.org/groups/td/pq/data/>. 2020.
- [3] N. Kagan, E.J. Robba e H. P. Schmidt. **Estimação de indicadores de qualidade da energia elétrica**. 1a. ed. São Paulo: Blusher, 2009. ISBN: 9788521204879.
- [4] B. B. Machado. “Sistemas preditivos de detecção de faltas em redes de distribuição de energia elétrica”. Acessado em 18/03/2024, <https://doi.org/10.47749/T/UNICAMP.2017.993753>. Dissertação de mestrado. Faculdade de Engenharia Elétrica e de Computação - Unicamp, 2017.
- [5] V. N. Ogar, S. Hussain e K. A.A. Gamage. “The use of artificial neural network for low latency of fault detection and localisation in transmission line”. Em: **Heliyon** 9.2 (2023), e13376. ISSN: 2405-8440. DOI: <https://doi.org/10.1016/j.heliyon.2023.e13376>. URL: <https://www.sciencedirect.com/science/article/pii/S2405844023005832>.
- [6] P. K. Shukla e K. Deepa. “Deep learning techniques for transmission line fault classification – A comparative study”. Em: **Ain Shams Engineering Journal** 15.2 (2024), p. 102427. ISSN: 2090-4479. DOI: <https://doi.org/10.1016/j.asej.2023.102427>. URL: <https://www.sciencedirect.com/science/article/pii/S2090447923003167>.
- [7] I.N. Silva, D.H. Spatti e R.A. Flauzino. **Redes Neurais Artificiais : Para Engenharia e Ciências Aplicadas**. 2a. ed. São Paulo: Artliber, 2010. ISBN: 9788588098879.