

APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NO PROCESSO DE MANUTENÇÃO DE MALHAS DE ATERRAMENTO ELÉTRICO

RODRIGO M. S. DE OLIVEIRA E CARLOS LEONIDAS DA S. S. SOBRINHO

*Laboratório de Análises Numéricas em Eletromagnetismo (LANE), Departamento de Eng. Elétrica e de Computação,
Universidade Federal do Pará, Caixa Postal 8619, CEP 66075-907, Brasil*

E-mails: rodrigo@lane.ufpa.br e leonidas@ufpa.br

Abstract — The Finite-Differences Time-Domain Method (FDTD) is employed to simulate the electromagnetic transient responses of grounding grids in conducting ground. Faults (or electrical disconnections) on ground grid, which are usually seen in the grid nodes due to electrochemical reactions, were introduced in the simulated structure and their transient responses are the fingertips of specific faults. In order to determine the point where the fault is located with no ambiguities, two neural networks were used. The estimation of the fault location is obtained by a combination of both responses. The networks were trained by the Marquardt-Levenberg algorithm.

Keywords — Two Neural Networks Employment, Ground Grid Faults Location, Pattern Recognition, FDTD Method.

Resumo — O método das Diferenças Finitas no Domínio do Tempo (FDTD) é empregado na simulação de transientes eletromagnéticos de sistemas de aterramento em solo com condutividade finita. Falhas, ou descontinuidades elétricas, que freqüentemente ocorrem nos nós da malha devido a reações eletroquímicas, foram introduzidas na simulação de forma que cada situação apresenta respostas transitórias próprias, que funcionam como impressões digitais da estrutura. Dessa forma, um método utilizando duas redes neurais, trabalhando em cooperação, é proposto para identificar a partir dessas respostas transitórias, o local da descontinuidade sem ambigüidades. O algoritmo Marquardt-Levenberg foi utilizado para treinar as redes.

Palavras-Chave — Uso de Duas Redes Neurais, Localização de Falha em Malha de Terra, Reconhecimento de Padrões, Método FDTD.

1 Introdução

Sistemas de aterramento são partes fundamentais dos sistemas de proteção elétrica. Durante os últimos anos, sua importância vem crescendo de forma cada vez mais marcante, devido ao fato de pessoas físicas e empresas necessitarem de proteção adequada para os seus equipamentos elétricos, e mais recente e especialmente dos sensíveis componentes eletrônicos. Todavia, os sistemas de aterramento também precisam de cuidados especiais para conservar suas características originais ao longo do tempo.

Em sistemas reais, as descontinuidades elétricas podem surgir na estrutura de aterramento devido a interações eletroquímicas entre o metal e a terra. Essas falhas abrem parte do circuito, afetando o desempenho do sistema de proteção. Este problema requer métodos para determinar, ao menos de forma aproximada, a região física onde a falha está localizada, como parte dos procedimentos de inspeção e manutenção da malha. Neste trabalho, um método baseado em Redes Neurais Artificiais, treinadas para localizar essas falhas a partir de respostas transitórias das estruturas, é apresentado. A metodologia foi testada através de simulações numéricas.

Métodos no domínio da frequência para solucionar as equações de Maxwell são bastante utilizados para o estudo de estruturas de aterramento. No entanto, o problema de obtenção das respostas transitórias deve ser tratado por métodos no domínio do tempo, como por exemplo, o método das Diferenças Finitas no Domínio do Tempo (*Finite Difference Time Domain* - FDTD)

[Yee,1966] [Taflove,2000], que foi empregado neste trabalho.

Dois redes neurais foram treinadas utilizando o Algoritmo Marquadt-Levenberg [Hagan,1994] (uma modificação do método Backpropagation [Rumerhart,1986] baseada no método de Newton). Trabalhos anteriores sobre o assunto [Oliveira,2006] [Dias,2006] mostraram que o algoritmo Backpropagation original não é adequado para este tipo de problema. Em [Oliveira,2006], uma rede neural foi treinada para informar o quadrante da malha no qual as falhas estavam localizadas. Em [Dias,2006] e [Miranda,2006], nós defeituosos da malha eram localizados por uma única rede neural. Todavia, ambas as metodologias podem responder de forma ambígua devido ao fato de as classes (nós defeituosos) não serem linearmente separáveis.

Para eliminar essas restrições no processo de localização das falhas, uma metodologia aprimorada é apresentada. Em síntese, são utilizadas duas redes neurais de forma que, para cada uma, as classes são linearmente separáveis, permitindo a elas responder da forma esperada. Tanto o algoritmo FDTD quanto o Marquadt-Levenberg foram implementados utilizando a linguagem Fortran 77, em ambiente Linux (GNU g77).

O trabalho está organizado da seguinte maneira: o Tópico 2 descreve os algoritmos implementados (FDTD e o Marquadt-Levenberg), no Tópico 3 são descritos os detalhes relacionados à configuração e à solução do problema, no Tópico 4 são apresentados os resultados obtidos e, finalmente, são apresentadas as conclusões em 5.

2 Teoria

A. O algoritmo de Yee

As Equações que descrevem os fenômenos eletromagnéticos em escala macroscópica são as equações de Maxwell. Para meios isotrópicos, não dispersivos e com perdas elétricas, o conjunto de equações pode ser escrito, em sua forma diferencial, da seguinte maneira

$$\nabla \times \vec{E} = -\mu \frac{\partial \vec{H}}{\partial t} \quad (1)$$

e

$$\nabla \times \vec{H} = \epsilon \frac{\partial \vec{E}}{\partial t} + \vec{J}, \quad (2)$$

nas quais \vec{E} é o vetor intensidade de campo elétrico (V/m), \vec{H} é o vetor intensidade de campo magnético (A/m), ϵ e μ são, respectivamente, a permissividade elétrica (farad/m) e permeabilidade magnética (henry/m) e \vec{J} é o vetor densidade de corrente elétrica (A/m²). É importante notar que as Leis de Gauss estão implícitas nas equações (1) e (2) (basta aplicar o operador divergente em ambas para demonstrar).

Expandindo (1) e (2) em coordenadas retangulares, são obtidas as seguintes equações escalares:

$$\frac{\partial H_x}{\partial t} = \frac{1}{\mu} \left(\frac{\partial E_y}{\partial z} - \frac{\partial E_z}{\partial y} \right), \quad (3)$$

$$\frac{\partial H_y}{\partial t} = \frac{1}{\mu} \left(\frac{\partial E_z}{\partial x} - \frac{\partial E_x}{\partial z} \right), \quad (4)$$

$$\frac{\partial H_z}{\partial t} = \frac{1}{\mu} \left(\frac{\partial E_x}{\partial y} - \frac{\partial E_y}{\partial x} \right), \quad (5)$$

e

$$\frac{\partial E_x}{\partial t} = \frac{1}{\epsilon} \left(\frac{\partial H_z}{\partial y} - \frac{\partial H_y}{\partial z} - \sigma E_x \right), \quad (6)$$

$$\frac{\partial E_y}{\partial t} = \frac{1}{\epsilon} \left(\frac{\partial H_x}{\partial z} - \frac{\partial H_z}{\partial x} - \sigma E_y \right), \quad (7)$$

$$\frac{\partial E_z}{\partial t} = \frac{1}{\epsilon} \left(\frac{\partial H_y}{\partial x} - \frac{\partial H_x}{\partial y} - \sigma E_z \right), \quad (8)$$

nas quais E_x , E_y , E_z e H_x , H_y , H_z são as componentes cartesianas dos vetores \vec{E} e \vec{H} , respectivamente. Estas componentes são funções do tempo e do espaço.

A Lei da Faraday (1) mostra que variações temporais do vetor $\vec{B} = \mu \vec{H}$ geram circulação de campo elétrico em torno de tal variação. Por outro lado, a lei de Ampère (2), complementada por Maxwell, é dual a (1). Com tais observações, é possível perceber o funcionamento do mecanismo de propagação das ondas eletromagnéticas em escala macroscópica [Jackson,1962], nas quais Yee [Yee,1966] se baseou ao propor sua unidade de discretização espacial, conhecida hoje como Célula de Yee (Fig.1). A célula é composta pelas seis componentes de campo descritas por (3)-(8), de forma a satisfazer as leis de circulação discutidas anteriormente.

Dessa forma, a substituição das derivadas temporais e espaciais das equações (3)-(8) por diferenças centradas, gera equações discretas (aproximadas) para descrever o fenômeno. Para a componente E_x , obtém-se a equação (9), de forma que a posição discreta (i, j, k) é relacionada as coordenadas (x, y, z) por $(x = i\Delta x, y = j\Delta y$ e $z = k\Delta z)$ e a coordenada temporal t é relacionada a n por $t = n\Delta t$. As equações para se calcularem as demais componentes de campo a cada passo temporal são obtidas de forma similar.

$$E_x^{n+1}(i+\frac{1}{2}, j, k) = E_x^n(i+\frac{1}{2}, j, k) \left(\frac{1 - \sigma \frac{\Delta t}{2\epsilon}}{1 + \sigma \frac{\Delta t}{2\epsilon}} \right) + \frac{\Delta t}{\epsilon (1 + \sigma \frac{\Delta t}{2\epsilon})} \left[\frac{H_z^{n+\frac{1}{2}}(i+\frac{1}{2}, j+\frac{1}{2}, k) - H_z^{n+\frac{1}{2}}(i+\frac{1}{2}, j-\frac{1}{2}, k)}{\Delta y} \right] - \frac{\Delta t}{\epsilon (1 + \sigma \frac{\Delta t}{2\epsilon})} \left[\frac{H_y^{n+\frac{1}{2}}(i+\frac{1}{2}, j, k+\frac{1}{2}) - H_y^{n+\frac{1}{2}}(i+\frac{1}{2}, j, k-\frac{1}{2})}{\Delta z} \right], \quad (9)$$




Figura 1 – A Célula de Yee

Para minimizar os efeitos relativos à dispersão numérica, o seguinte critério de estabilidade foi adotado [Taflove, 2000]:

$$\Delta_{x,y,z} \leq \frac{\lambda_{\min}}{10}, \quad (10)$$

ou seja, o mínimo comprimento de onda λ_{\min} deve ser representado por, ao menos, dez células. Para garantir a estabilidade do método numérico, o incremento temporal Δt deve ser limitado pela conhecida condição de Courant, demonstrada por Taflove [Taflove,2000], dada por

$$\Delta t \leq \frac{1}{v_{\max} \sqrt{\frac{1}{\Delta x^2} + \frac{1}{\Delta y^2} + \frac{1}{\Delta z^2}}}, \quad (11)$$

de forma que, neste trabalho, foi adotado o valor de 60% deste limite para Δt .

Como se está trabalhando com problemas abertos, há a necessidade de truncar o domínio numérico de análise. Neste trabalho, implementou-se a formulação U-PML (Uniaxial Perfectly Matched Layers) para meios condutivos [Taflove,2000], para absorver as ondas incidentes nos limites do domínio. A UPML, por sua vez, é truncada por P.E.C.s (*Perfect Electrical Conductors*).

B. Redes neurais

As redes neurais devem “aprender” pares de entradas e saídas, contidos em um banco de dados, denotados por $(\vec{p}_1, \vec{t}_1), (\vec{p}_2, \vec{t}_2), \dots$ (as chamadas amostras de treinamento) e generalizar o conhecimento contido nas

amostras, de forma a responder de forma adequada quando entradas não presentes no conjunto de treinamento forem apresentadas à rede. Isto é possível devido ao fato de que a formulação é baseada numa representação (simplificada) de uma rede real de neurônios.

Dessa forma, problemas relacionados a reconhecimento de padrões podem ser solucionados através da implementação e uso adequados desta técnica. Neste trabalho, as RNAs são aplicadas para a localização de descontinuidades em malhas de aterramento a partir da aplicação de sinais de teste e da coleta de respostas transitórias em pontos estratégicos da estrutura. Este tópico revê de forma objetiva dois algoritmos de treinamento: o *Backpropagation* (ou Retropropagação) e a modificação Marquadt-Levenberg da técnica de Retropropagação.

1) O algoritmo *Backpropagation*

Como mencionado anteriormente, as RNAs devem generalizar um conjunto de dados (amostras de treinamento), de forma a responder adequadamente as entradas p que não constituam os dados de treinamento. Isto é feito a partir do cálculo dos erros e das respostas da rede, que devem ser minimizados.

O conhecimento adquirido pela rede é representado por pesos ω que são associados a cada neurônio da rede. Dessa forma, o objetivo do estágio de treinamento é obter um conjunto de pesos que façam a rede responder de forma desejada, empregando os erros e .

Como pode ser observado pela Fig. 2, que representa uma pequena rede de neurônios (três camadas), a saída $a^{K+1}(I)$, como função da entrada $n^{K+1}(I)$ (neurônio I da camada $k+1$), é dada por

$$a^{K+1}(I) = f^{K+1} \left(\sum_{J=1}^{SK} \omega^{K+1}(I, J) a^K(J) + b^{K+1}(I) \right), \quad (12)$$

na qual: $K = 0, 1, \dots, L-1$; $a^0(I) = p(I)$; b é um termo adicional denominado *bias* e a função f é denominada de função de ativação.

De uma forma geral, (12) pode ser reescrita de forma matricial para uma rede de L camadas da seguinte maneira

$$\bar{a}^{K+1} = \bar{f}^{K+1} (W^{K+1} \bar{a}^K + \bar{b}^{K+1}), \quad (13)$$

$$\bar{a}^0 = \bar{p}, \quad (14)$$

Em (13) W^{K+1} representa o conjunto de pesos ω da camada $K+1$, \bar{a}^K representa o vetor de saída da camada K e \bar{b}^{K+1} é o vetor que contém os termos *bias* da camada $K+1$.

A performance instantânea da rede \hat{V} para uma amostra q apresentada a ela é definida por

$$\hat{V} = \frac{1}{2} \bar{e}_q^T \bar{e}_q, \quad (15)$$

onde $\bar{e}_q = \bar{t}_q - \bar{a}_q^L$, na qual \bar{t}_q é o valor de saída desejado para a amostra q . Nota-se que \hat{V} é uma função quadrática do erro. Dessa forma, é possível obter uma regra de atualização para os pesos de forma que a mesma caminhe na

direção oposta à direção do crescimento do erro. Tal direção pode ser determinada pelo cálculo do gradiente do erro.

Assim, uma sensibilidade δ^K para o índice de performance em relação a variações nas entradas n^K pode ser definida por

$$\delta^K(I) \equiv -\frac{\partial \hat{V}}{\partial n_{(I)}^K}. \quad (16)$$

Pode ser mostrado que os incrementos dos pesos, denotados por $\Delta\omega^k$, e das *bias*, representados por Δb^k , podem ser calculados por

$$\Delta\omega^K(I, J) = -\alpha \delta^K(I) a^{K-1}(J) \quad (17)$$

e

$$\Delta b^K(I) = -\alpha \delta^K(I), \quad (18)$$

respectivamente, onde α é denominado de coeficiente de aprendizado. Como demonstrado em [Rumerlhart, 1986], as sensibilidades δ satisfazem à equação de recorrência

$$\bar{\delta}^K = \hat{F}^K(\bar{n}^K) W^{K+1T} \bar{\delta}^{K+1} \quad (19)$$

na qual $\hat{F}^K(\bar{n}^K)$ é uma matriz diagonal dada por

$$\hat{F}^K(\bar{n}^K) = \frac{d}{dn} \begin{bmatrix} f^{K(n^K(1))} & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & f^{K(n^K(SK))} \end{bmatrix}. \quad (20)$$

Finalmente, $\bar{\delta}^L$ é calculado por

$$\bar{\delta}^L = -\hat{F}^L(\bar{n}^L) \bar{e}_q. \quad (21)$$

2) O Algoritmo Marquadt-Levenberg *Backpropagation*

Para acelerar o processo de convergência da fase de treinamento, a modificação Marquadt-Levenberg emprega uma variante do método de Newton. O procedimento de cálculo é descrito de forma compacta a seguir.

Considerando que $V(\bar{x})$ seja dado por

$$V(\bar{x}) = \sum_{i=1}^N e_i^2(\bar{x}), \quad (22)$$

na qual $(\bar{x}) = [\omega^1(1,1) \omega^1(1,2) \dots \omega^1(S1,R) b^1(1) \dots b^1(S1) \omega^2(1,1) \dots b^M(SM)]$, ou seja, um vetor composto por todas as variáveis a serem atualizadas, onde $N = Q \times SM$, pode ser mostrado que o incremento para \bar{x} pode ser dado, incluindo-se o termo μI ao método de Newton, por

$$\Delta_{\bar{x}} = [J^T(\bar{x})J(\bar{x}) + \mu I]^{-1} J^T(\bar{x})e(\bar{x}) \quad (23)$$

de forma que o Jacobiano $J(\bar{x})$ é calculado utilizando-se o algoritmo *Backpropagation* original, porém considerando-se todas as amostras de treinamento. Assim, $J(\bar{x})$ é dado por (24). Nesta Equação, tem-se $\mu = \mu\beta$ se $V(\bar{x})$ cresce ou $\mu = \mu/\beta$ se $V(\bar{x})$ decresce (valores usuais: $\mu = 0.01$ como condição inicial e $\beta = 10$), de forma que, na camada L , deve-se utilizar (25).

$$J(\bar{x}) = \begin{bmatrix} \frac{\partial e_1(\bar{x})}{\partial x_1} & \frac{\partial e_1(\bar{x})}{\partial x_2} & \dots & \frac{\partial e_1(\bar{x})}{\partial x_n} \\ \frac{\partial e_2(\bar{x})}{\partial x_1} & \frac{\partial e_2(\bar{x})}{\partial x_2} & \dots & \frac{\partial e_2(\bar{x})}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(\bar{x})}{\partial x_1} & \frac{\partial e_N(\bar{x})}{\partial x_2} & \dots & \frac{\partial e_N(\bar{x})}{\partial x_n} \end{bmatrix}, \quad (24)$$

$$\delta \bar{L} = -\dot{F}^L(\bar{n}^L). \quad (25)$$




Figura 2 – Exemplo de Rede Neural com três camadas ($L = 3$)

Observa-se que cada coluna do Jacobiano (24) pode ser vista como um conjunto de funções das sensitividades de um dado peso em função de todos os erros do conjunto de dados de treinamento. Assim, pode-se dizer que a atualização dos pesos mostrada aqui é mais completa do que o esquema de atualização *Backpropagation* original, requerendo porém uma quantidade consideravelmente maior de memória.

3 A Configuração do Problema

As Figuras 3 e 4 ilustram a configuração básica da estrutura simulada através do código FDTD desenvolvido. Trata-se de uma malha 5×5 hastes ($10\text{m} \times 10\text{m}$) enterrada a meio metro da superfície do solo, alimentada em seu centro por uma estrutura composta por uma resistência, um *gap* de tensão (excitação via componente E_z) e um eletrodo vertical penetrando a UPML (simulando um canal de descarga natural) [Tuma,2005] (Fig.3). As Figuras 5 e 6 mostram o perfil do pulso de excitação nos domínios do tempo e da frequência, respectivamente.

A malha FDTD é formada por células cúbicas, com $\Delta \bar{x} = 0,25\text{m}$. Para modelar os eletrodos metálicos cilíndricos com raio de 10mm (raio menor que $\Delta \bar{x}$), a formulação de fio fino descrita em [Baba,2005] foi implementada. Os eletrodos são considerados condutores perfeitos, com as componentes tangenciais do campo elétrico ajustadas para zero. O solo é caracterizado pelos parâmetros eletromagnéticos $\epsilon_r=50$, $\sigma=0,02\text{ S/m}$ e $\mu=\mu_0$.

4 Localização das Falhas

Considerando que o método FDTD é bastante flexível e geral, falhas (ou discontinuidades) em malhas de terra podem ser facilmente implementadas,

bastando não anular as componentes de campo elétrico tangenciais na região do defeito e não aplicando as correções para a modelagem de fio fino, ou seja, utilizando as características eletromagnéticas relativas unicamente solo (ϵ , σ e μ) nas equações de Maxwell.

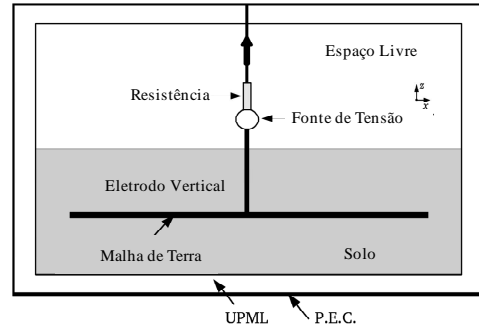


Figura 3 – Configuração física do problema: plano $x-z$




Figura 4 – Representação tridimensional da malha 5×5




Figura 5 - O Pulso de Excitação

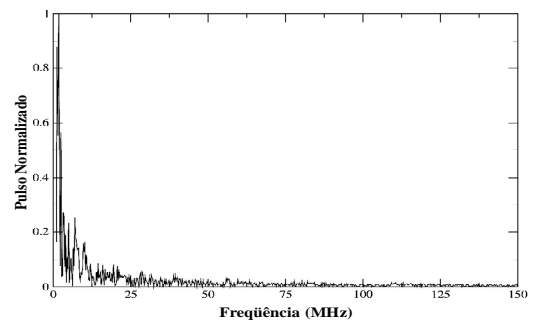


Figura 6 – Espectro do pulso de excitação

Dessa forma, as falhas foram introduzidas nas regiões desejadas, no caso, abrindo os nós da malha, um de cada vez, como mostrado pela Fig. 7. Todas as possibilidades de abertura dos nós similares ao caso da Fig. 7 foram simuladas e utilizadas como dados de treinamento para as redes. Observa-se que cada nó interno da malha tem quatro possibilidades de abertura

(considerando que apenas uma haste é interrompida), os nós presentes nas bordas da malha possuem três possibilidades e os nós dos cantos apenas duas. O nó central, que possui a haste de alimentação tem cinco possibilidades.




Figura 7 – Um exemplo de nó defeituoso

De forma similar aos estudos anteriores [Oliveira,2006][Dias,2006], foram calculadas as correntes nos quatro cantos da malha. Nesses estudos, observaram-se mudanças significativas no transitório dessas respostas, e, conseqüentemente, em seus espectros, de acordo com a falha considerada. Dessa forma, as três harmônicas utilizadas em [Oliveira,2006] e [Dias,2006] foram também utilizadas neste trabalho, como entradas das redes: 5 10 e 25 MHz (note-se que no tempo, cada resposta tem cerca de 10.000 pontos). Em [Oliveira,2006], foi observada a esperada característica de simetria do problema e os quadrantes das malhas eram determinados pela rede. Porém, a técnica não era capaz de identificar com confiabilidade defeitos nas interfaces entre os quadrantes. Para tentar contornar esse problema, em [Dias,2006] e em [Miranda,2006] cada nó recebia um número, e tal identificador era a saída da rede neural. Em [Dias,2006], observou-se que o algoritmo Levenberg-Marquardt é mais adequado para o problema. Porém, quando os defeitos estão presentes entre nós com saltos consideráveis em seus números identificadores, as respostas eram ambíguas.

Assim, para contornar esta limitação, neste trabalho foram empregadas duas redes neurais, que foram treinadas para identificar a linha e a coluna, individualmente, como ilustrado pela Figura 8. Cada linha e coluna recebem um número identificador e, a partir da resposta das duas redes, obtêm-se as coordenadas relativas ao nó mais próximo onde ocorreu o defeito.

As duas redes neurais foram implementadas com três camadas de seis neurônios, sendo que todas as camadas utilizam funções do tipo sigmóide, com exceção da última camada que utiliza uma função linear, como de praxe. Todas as doze entradas (harmônicas das correntes) foram normalizadas com relação ao maior pico entre todas as amostras disponíveis para o treinamento, para assegurar a convergência do algoritmo. O treinamento da rede costuma convergir para o erro máximo admissível estipulado de 0.01 (neste trabalho) em menos de 200 épocas (iterações) de treinamento.

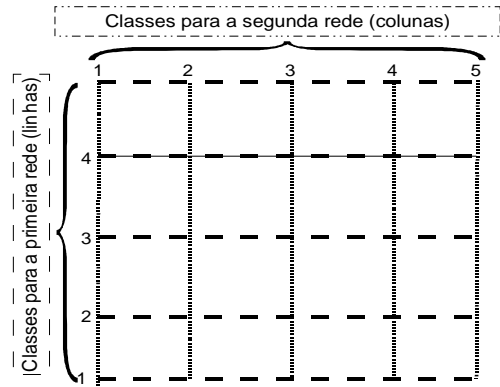


Figura 8 – Classes linearmente separáveis para as duas redes neurais utilizadas: linhas e colunas da malha




Figura 9 – Um exemplo de haste defeituosa

Inicialmente, para fins de validação do algoritmo, defeitos como o mostrado na Fig. 9, que não estavam presentes no conjunto de dados de treinamento, foram implementados. Um total de 25 situações como esta, escolhidas aleatoriamente, foram testadas e os resultados são mostrados pelas Figs. 10(a) e (b), para as duas redes neurais. Observa-se uma concordância satisfatória entre os valores exatos das coordenadas dos nós mais próximos aos defeitos (círculo) com relação aos valores informados pela rede (sinal de soma). Algumas pequenas diferenças são esperadas, já que os defeitos testados não estão exatamente nos nós, além do fato de o algoritmo não ser determinístico.

Por fim, foram realizados testes nos quais mais de um eletrodo, de um determinado nó, são desconectados. Também foi testado o caso em que um eletrodo foi rompido ao meio. Os resultados para o nó com índices (2,2) e para o eletrodo partido ao meio (entre as linhas 2 e 3, na coluna 2) são apresentados na Fig. 11. Nela, os quatro primeiros resultados são correspondentes a primeira situação, e o índice do testes corresponde ao número de eletrodos desconectados. O quinto índice corresponde ao eletrodo partido ao meio. Neste caso, observa-se que a rede responde com um valor entre 2 e 3 para as linhas e com um valor próximo a 2 para a coluna, o que mostra a consistência da metodologia apresentada. Vale ressaltar que foram obtidos resultados semelhantes para casos similares aos apresentados.

5 Conclusões

Neste trabalho, foi apresentada uma nova metodologia para localização de falhas em malhas de aterramento, na qual se utilizam harmônicas obtidas das respostas

transitórias de corrente para treinar duas redes neurais artificiais. As duas redes trabalham de forma independente, mas, em conjunto, fornecem as coordenadas do nó mais próximo ao defeito.

A geração das respostas transitórias foi realizada aqui através da técnica FDTD, que provê soluções numéricas de onda completa das equações de Maxwell, o que gera confiança a respeito dos dados utilizados no treinamento da rede. Todavia, testes reais envolvendo a metodologia serão realizados em breve.

A metodologia apresentada, baseada em duas redes neurais, representa um avanço considerável em relação a trabalhos anteriores, pois elimina ambigüidades nas respostas. Em todos os testes realizados, respostas consistentes foram obtidas.

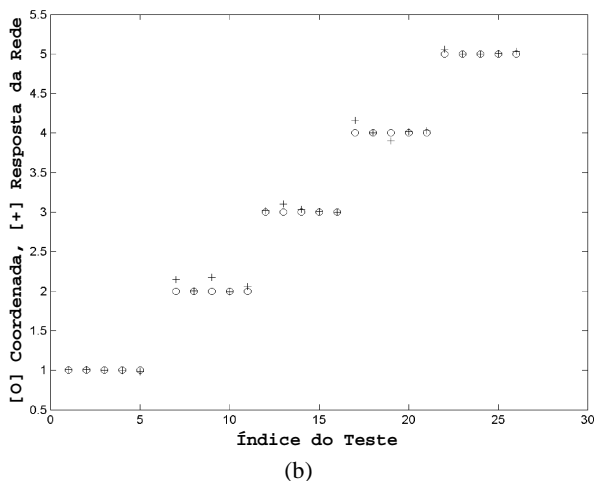
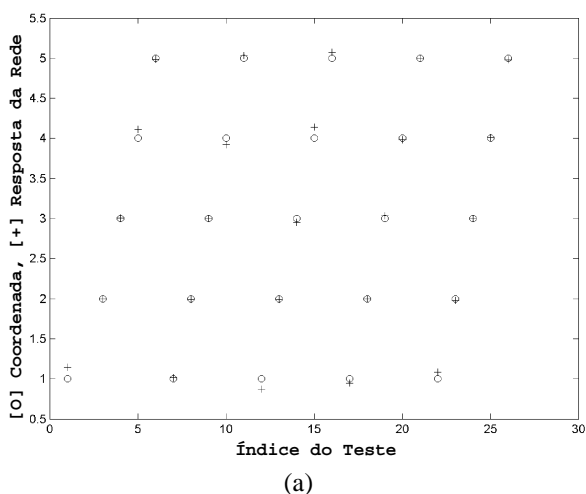


Figura 10 – Respostas das Redes: (a) linhas e (b) colunas para os testes iniciais

Agradecimentos

Os autores são gratos à Eletronorte e ao CNPq pelo suporte a este trabalho.




Figura 11 – Respostas das Redes em testes adicionais

Referências Bibliográficas

- Baba, N. N. Y. and Ametani, A. (2005). Modeling of thin wires in a lossy medium for FDTD simulations, *IEEE Transactions on Electromagnetic Compatibility*, **47**.
- Dias, M. B., Oliveira, R. M. S., e Souza Sobrinho, Carlos L.S.S. (2006). Application of a neural network for classifying faults on grounding grids, *XXVII Iberian Latin American Congress on Computational Methods in Engineering (CILAMCE)*, Belém, Pará, Brasil.
- Hagan, M. T. and Menhaj, M. B. (1994). Training feedforward networks with the Marquardt algorithm, *IEEE Transactions on Neural Networks*, **5**: 989–993.
- Jackson, J. D. (1962). *Classical Electrodynamics*, Wiley, New York.
- Miranda, J. A. and Portela, C.M.J.C. (2006). Application of Neural Networks to Identify Discontinuities in Grounding Grids, *International Conference on Grounding and Earthing (GROUND) & 2nd International Conference on Lightning Physics and Effects*, Maceió, Alagoas, Brasil.
- Oliveira, R. M. S., Dias, M. B. e Souza Sobrinho, Carlos L.S.S. (2006). Application of neural network for classifying faults on grounding grids, *12º SBMO - Simpósio Brasileiro de Microondas e Optoeletrônica e 7º CBMAG - Congresso Brasileiro de Eletromagnetismo (MOMAG)*, Belorizonte, Minas Gerais, Brasil.
- Rumerlhart, G. and Williams, R. (1986). Learning representations by back-propagating errors, *Nature*, **323**: 533–536.
- Taflove, A. and Hagness, S. C. (2000). *The Finite-Difference Time-Domain Method*, Artech House Inc, Second Edition.
- Tuma, E. T., Oliveira, R. M. S. and Souza Sobrinho, C.L.S. (2005). New model of current impulse injection and potential measurement in transient analysis of grounding systems in homogeneous and stratified soils using the FDTD method, *International Symposium on Lightning Protection (SIPDA)*, São Paulo, Brasil.
- Yee, K. (1966). Numerical solution of initial boundary value problems involving Maxwell's equations in isotropic media, *IEEE Trans. Antennas and Propagation*, **14**: 302–307.