

MODELAGEM DE LINHAS PLANARES EBG USANDO UMA NOVA TÉCNICA NEUROCOMPUTACIONAL

Everton Notreve Rebouças Queiroz Fernandes, Paulo Henrique da Fonseca Silva, Adaildo Gomes
d'Assunção e Marcos Antonio Barbosa de Melo

Resumo—Estruturas EBG são empregadas para minimizar o efeito de acoplamento entre linhas de transmissão planares; e para eliminar a propagação de modos espúrios em guia de onda de placas paralelas. Neste trabalho, modelos neurais SF-ANN são desenvolvidos de modo a simular estes dispositivos EBG. As simulações realizadas mostram a eficiência e precisão dos modelos propostos, com excelentes aproximações dos valores medidos, além de generalizações para novos valores de parâmetros estruturais.

Palavras-Chave—Estruturas EBG, redes neurais artificiais, linhas planares de transmissão.

Abstract—EBG Structures are developed to minimize the parasitic coupling and crosstalk that arise between neighboring transmission lines and to eliminate the propagation of unwanted parallel plate mode in waveguide. In this work, neural models SF-ANN are used to simulate these EBG devices. The results obtained show the efficiency and accuracy of proposed models, with excellent answers and good generalization ability for new structural parameters.

Index Terms —EBG Structures, artificial neural networks, and planar transmission lines.

I. INTRODUÇÃO

Uma das principais dificuldades no projeto de circuitos integrados monolíticos em alta densidade é o efeito de acoplamento parasita e as interferências (*crosstalk*) entre os sinais [1]. Outra limitação entre circuitos integrados é a questão de interferências entre os dispositivos adjacentes e o contato direto com a atmosfera. As blindagens metálicas eletromagnéticas são amplamente empregadas, entretanto, o uso em alguns casos gera a propagação de modos espúrios.

Recentemente, têm ocorrido inúmeras aplicações de estruturas periódicas, como os materiais com banda de rejeição eletromagnética (EBG, *electromagnetic bandgap*) em dispositivos de telecomunicações, desde a radiofrequência

Este fato é bastante vantajoso em aplicações que exigem supressão de modos indesejáveis e radiação, como filtros, acopladores, amplificadores, antenas, etc [3]-[7].

Neste trabalho, estruturas EBG são analisadas em duas aplicações. Primeiro, em linhas de transmissão acopladas e interceptadas, de modo a reduzir as interferências e o *crosstalk* entre os dispositivos. Segundo, em linhas de transmissão com blindagem metálica, neste caso, a introdução da matriz EBG reduz a propagação do modo de placas paralelas.

Devido à complexidade destas estruturas, uma análise precisa requer métodos de onda completa, como o método das diferenças finitas no domínio do tempo (FDTD, *finite difference in time domain*). Estes métodos exigem a formulação teórica apurada do dispositivo, além de um esforço computacional considerável.

Para superar estas limitações e fornecer outras vantagens, o emprego de redes neurais artificiais tem ressurgido com grande intensidade em aplicações de radiofrequência e microondas [8]-[9]. As técnicas neurocomputacionais apresentam características como adaptabilidade, generalização e rápida convergência que contribuem para a sua extensa aplicação.

A modelagem das estruturas EBG é realizada por meio de nova técnica neurocomputacional, denominada Rede Neural Artificial *Sample Function* (SF-ANN, *Sample Function Artificial Neural Network*) [10]. Os modelos SF-ANN para os dispositivos EBG provêm excelentes resultados em concordância com valores medidos disponíveis. Além disso, os modelos SF-ANN generalizam o comportamento eletromagnético destas estruturas para novos valores de frequência e parâmetros estruturais.

II. TÉCNICA NEUROCOMPUTACIONAL

A metodologia geral das técnicas neurocomputacionais é mostrada na Fig. 1.

De uma maneira geral, a metodologia de uma rede neural artificial, ANN, consiste na apresentação de um conjunto de dados de entrada, $\mathbf{x}(n)$, ao modelo neural. Em seguida, aplica-se a estratégia de aprendizagem por meio da correção do erro entre a saída do modelo neural, $\mathbf{y}(n)$, e saída desejada, $\mathbf{d}(n)$, de modo a otimizar a função custo, $\mathbf{e}(n)$,

Everton N. R. Q. Fernandes, Dep. de C. da Computação, Univ. Estadual do Rio G. do Norte - UERN, Mossoró-RN, e-mail: everton@uern.br.

Paulo H. da F. Silva, GTEMA, CEFET-PB, João Pessoa- PB.

Adaildo G. d'Assunção, Dep. de Eng. Elétrica, UFRN, Natal-RN.

Marcos A. B. de Melo, Dep. de Eng. Elétrica, UFPB, Campina Grande-PB.

através da implementação dos algoritmos de treinamento supervisionados.

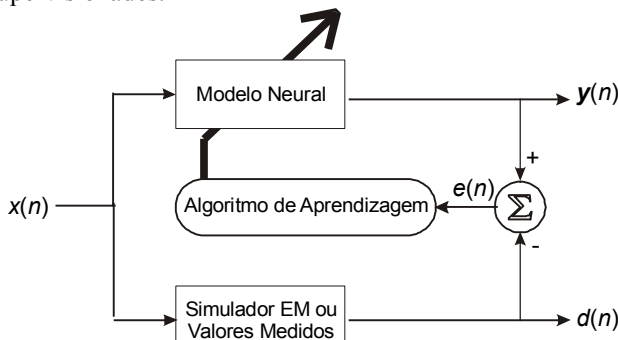


Fig. 1. Metodologia básica de uma ANN

Após o processo de treinamento, é realizada a validação do modelo neural com um conjunto de exemplos diferentes. Com isto, verifica-se a característica de generalização do modelo neural para novos valores de entrada.

Os modelos neurais aprendem, fundamentalmente, o mapeamento de entrada e saída do dispositivo ou circuito. Observa-se que nenhum conhecimento prévio sobre a forma analítica é requerido, ou seja, as relações entre as entradas e as saídas são estabelecidas e a função analítica é representada pela rede, não sendo necessária sua explicitação matemática.

O potencial computacional das redes neurais é resultado da sua estrutura intensivamente paralela e de sua capacidade de aprendizagem e generalização. Neste caso, generalização refere-se à habilidade de uma rede neural de fornecer respostas satisfatórias às novas entradas, ou seja, aos valores que não tinham sido empregados no processo de treinamento.

Uma outra característica valiosa das redes neurais é a capacidade de formular uma aproximação perfeita para qualquer mapeamento não-linear contínuo. Isto permite o desenvolvimento de modelos ANN eficientes e precisos para o uso em projetos auxiliados por computador (CAD).

A. Rede Neural Sample Function - SF-ANN

Os tipos de redes neurais mais comumente empregadas são: Perceptron Multicamadas (MLP, *multilayer perceptron*) e Rede de Funções de Base Radial (RBF, *radial basic functions*). Entretanto, em algumas aplicações, estas técnicas convencionais não oferecem bons resultados.

Um novo paradigma neurocomputacional proposto em [10], a Rede Neural Artificial *Sample Function*, SF-ANN, está fundamentado nas propriedades da função *sample*, na teoria de processamento de sinais, e na configuração geral da rede neural RBF.

Na teoria de processamento de sinais há a propriedade de reconstrução de sinais a partir de uma combinação de funções *sinc*. A função de ativação *sample* está especificada a seguir.

$$sample(x) = \sin c\left(\frac{x}{\pi}\right) = \frac{\sin(x)}{x} \quad (1)$$

O passo seguinte foi a modificação do argumento da

função de ativação, de modo assemelha-se com as rede RBF, que usa centros e larguras. Como resultado, tem-se a função de ativação proposta indicada a seguir

$$g(x) = sample(\sigma\|x-c\|^2) = \frac{sen(\sigma\|x-c\|^2)}{\sigma\|x-c\|^2} \quad (2)$$

onde c é o vetor de centros e σ é a inversa da largura da função *sample*

A configuração básica dos modelos SF-ANN usados nas simulações dos dispositivos EBG está representada pela Fig. 2.

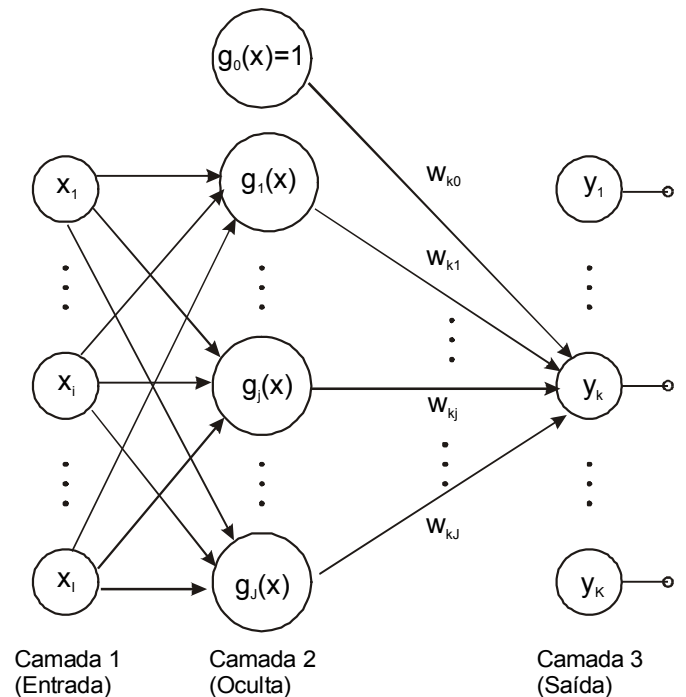


Fig. 2. Arquitetura da SF-ANN.

A computação direta da SF-ANN é definida pelas seguintes expressões:

$$v_j = \sigma_j\|x-c_j\|^2 = \sigma_j(x-c_j)^T \cdot (x-c_j) \quad (3)$$

$$g_j(x) = sample(v_j) \quad (4)$$

$$y_k(x) = \sum_{j=0}^J w_{kj}g_j(x) \quad (5)$$

onde v_j é o j -ésimo potencial de ativação interno, $g_j(\cdot)$ é a j -ésima função *sample* do neurônio oculto, w_{kj} é k -ésimo peso sináptico entre o j -ésimo neurônio oculto e a camada de saída, y_k é o k -ésimo nodo de saída e J é o número de neurônios ocultos.

No processo de treinamento supervisionado da SF-ANN é empregado o método RProg, *Resilient backpropagation*, de modo a ajustar os parâmetros livres do modelo, w , c e σ , para otimizar a seguinte função objetiva quadrática:

$$E(\mathbf{x}) = \frac{1}{2} e^2 = \frac{1}{2} [d_k(\mathbf{x}) - y_k(\mathbf{x})]^2 \quad (6)$$

III. PROJETO EBG E RESULTADOS

A. Linhas de Microfitas Adjacentes EBG

O circuito representado pela Fig. 3, mostra duas linhas de microfita adjacentes de 50Ω separadas por 1 mm [4]. O substrato é do tipo RT/Duroid, constante dielétrica, $\epsilon_r = 2,2$ e espessura de 0.71 mm. O circuito possui um plano de terra composto por uma matriz EBG. Esta estrutura EBG é formada por uma rede quadrada de buracos com raio igual a 2 mm.

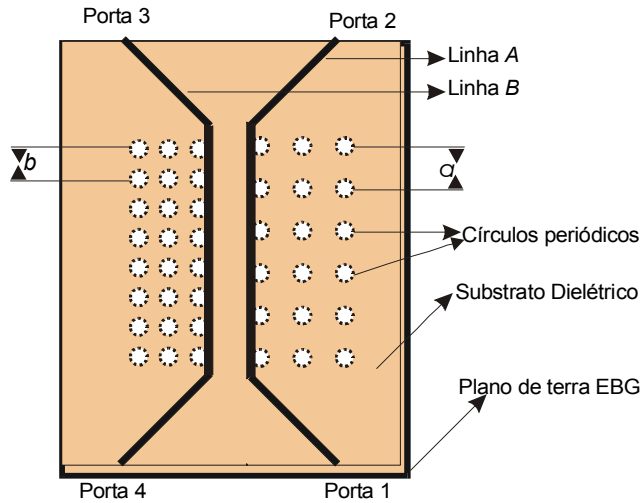


Fig.3. Linhas Acopladas EBG.

Na linha *A* (Portas 1 e 2) objetiva-se propagar sinais da banda-Ku e impedir a propagação dos sinais da banda-X. De forma inversa, ocorre para a linha *B* (Portas 3 e 4).

Para isto, o dimensionamento dos espaçamentos entre os furos é baseado na conclusão obtida em [3]: o período da rede EBG, ou seja, o espaçamento entre os buracos periódicos deve ser aproximadamente metade do comprimento de onda guiada na frequência do *stopband* [3]. Portanto, os buracos perfurados periodicamente no plano de terra abaixo da linha *A* possuem período, *a*, igual a 9,8 mm, para uma frequência central da faixa de rejeição em torno de 17 GHz. Já para a linha *B*, os buracos periódicos possuem período, *b*, igual a 6,1 mm, correspondendo a uma frequência central da faixa de rejeição em torno de 9 GHz.

A rede neural SF-ANN com uma unidade de entrada, a frequência de operação, com 50 neurônios ocultos e uma unidade de saída, o parâmetro de transmissão S_{34} , foi projetada e treinada para modelar o dispositivo mostrado na Fig. 3.

Para isto, foi empregado um conjunto de 20 valores medidos disponíveis em [4]. Após 1000 épocas de treinamento, o erro quadrático médio foi inferior a $1,0 \times 10^{-5}$. A resposta do modelo SF-ANN para as linhas acopladas EBG é apresentado na Fig. 4.

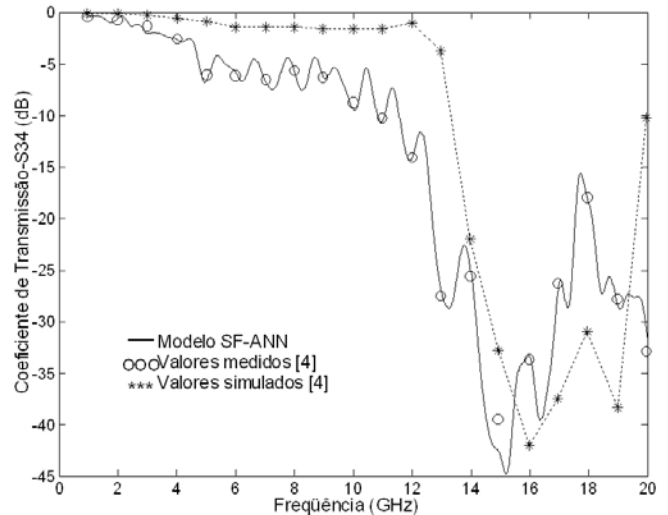


Fig. 4. Validação do modelo SF-ANN para o circuito EBG de linhas acopladas

Para efeito de validação do modelo SF-ANN proposto são adicionados valores medidos que não foram usados no processo de treinamento, e também resultados obtidos utilizando o popular simulador *Sonnet* [4].

Como pode ser observado na Fig. 4, a validação do modelo é satisfatória, uma vez que sua resposta interpola o conjunto teste de valores medidos. Além disso, constata-se uma melhor aproximação da resposta do modelo SF-ANN em relação aos resultados obtidos pelo simulador *Sonnet*.

B. Linhas de Microfita Interceptadas EBG

A Fig. 5 propõe uma alternativa à estrutura multicamada usada em circuitos monolíticos [4]. Este circuito de linhas de microfita interceptadas possui apenas uma camada dielétrica e estrutura EBG no plano de terra, funcionando como seletor de frequências. Na linha *A*, (Portas 1 e 2), objetiva-se a propagação de sinais da banda-X e possui uma matriz EBG projetada no seu plano de terra para eliminar o acoplamento dos sinais da banda Ku propagando-se ao longo da Linha *B* (Portas 3 e 4). Já na linha *B* ocorre o inverso.




Fig. 5. Linhas Interceptadas EBG.

A configuração e o processo de treinamento da rede SF-ANN foi semelhante a da linha de microfita adjacentes. Neste caso, o nodo da camada de saída é o parâmetro de acoplamento S_{23} .

A Fig. 6 mostra a resposta do modelo SF-ANN para as linhas interceptadas EBG juntamente com um conjunto teste de valores medidos e resultados obtidos pelo simulador *Sonnet*.

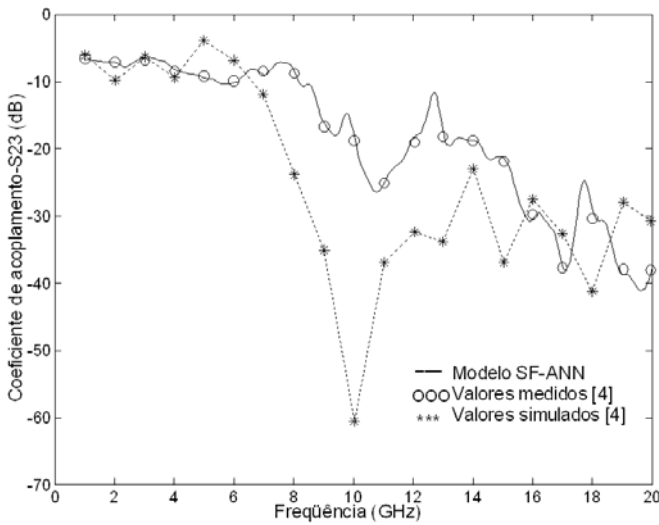


Fig. 6. Validação do modelo SF-ANN para o circuito EBG de linhas interceptadas.

Observa-se uma excelente concordância entre a resposta do modelo SF-ANN e o conjunto teste de valores medidos. Além disso, constata-se uma melhor precisão da técnica neurocomputacional proposta em relação ao simulador eletromagnético *Sonnet*.

C. Guia de Onda de Placas Paralelas EBG

O dispositivo mostrado na Fig. 7 foi proposto para suprimir a propagação de modos espúrios em circuitos de linhas de transmissão blindadas [6]. Este guia é formado por uma linha de microfita com plano de terra e uma blindagem metálica no topo. A estrutura EBG é projetada sobre uma placa metálica por meio de perfurações circulares periódicas de diâmetro, d , período, a , e profundidade p .

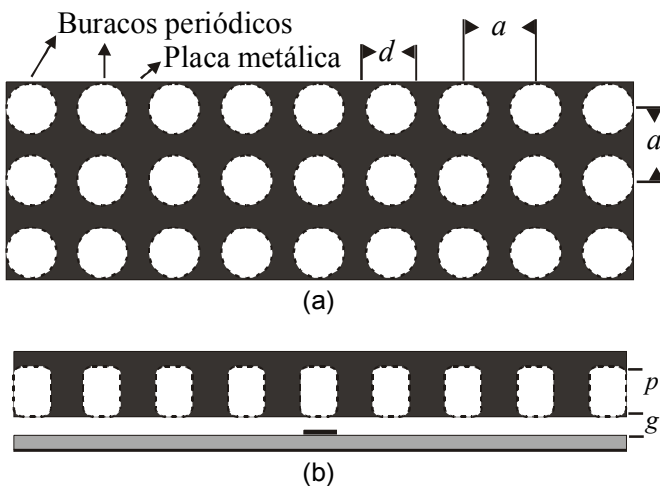


Fig. 7. Guia de placas paralelas EBG. (a) Visão superior (b) Visão da seção transversal.

A configuração SF-ANN é constituída de dois nodos de entrada que representa o diâmetro, d , e a frequência de operação, f . A camada de saída possui um nodo que representa o parâmetro de transmissão, S_{21} . Foram empregados 20 neurônios na camada oculta.

No processo de treinamento foi empregado um conjunto de 60 valores medidos disponíveis em [6] e obtidos por simulação eletromagnética (HFSS) para uma placa metálica com buracos circulares de diâmetro $d=1,2\text{mm}$ e $d=1,4\text{mm}$. Os outros parâmetros foram fixados com $a=1,62\text{mm}$, $p=1,2\text{mm}$, $g=0,5\text{mm}$ e o número de elementos periódicos igual a 9.

Após 1000 épocas de treinamento usando o processo Rprog, o erro final médio obtido foi inferior a $1,0 \times 10^{-5}$ e a resposta do modelo SF-ANN para o dispositivo mencionado está mostrada na Fig. 8. De modo a validar a técnica neurocomputacional proposta, um conjunto adicional de resultados simulados, ou seja, que não foram usados no processo de treinamento, é também exibido na Fig. 8.




Fig. 8. Validação do modelo SF-ANN para o guia de placas paralelas com substrato EBG.




Fig. 9. Generalização do modelo SF-ANN para o guia de placas paralelas com substrato EBG para novos valores de diâmetro dos elementos periódicos.

Constata-se que o modelo SF-ANN aproximar satisfatoriamente o conjunto de valores medidos, comprovando a precisão da técnica empregada.

Na Fig. 9 apresenta o resultado da generalização do modelo SF-ANN para o guia de onda de placas paralelas para novos valores do diâmetro dos elementos periódicos da estrutura EBG, $d = 1,25\text{mm}$ e $d = 1,35\text{mm}$. Constata-se que a resposta do modelo SF-ANN está em acordo com os valores estimados baseados nos valores medidos disponíveis em [6].

IV. CONCLUSÕES

A análise de alguns tipos de linhas de transmissão planares usando estruturas EBG foi efetuada através de uma eficiente e precisa técnica neurocomputacional.

A introdução de estruturas EBG no plano de terra de linhas planares de transmissão reduz o efeito do acoplamento eletromagnético entre linhas adjacentes e interceptadas. Já em linha de microfita blindada, a estrutura EBG permite a redução da propagação indesejada dos modos de placas paralelas.

Em relação à rede neural *Sample Function*, SF-ANN, esta se mostrou eficiente em relação ao tempo de processamento, e precisa quando comparada aos valores medidos e simulados disponíveis na literatura. Além disso, os modelos SF-ANN foram capazes de generalizar para novos valores de dados de entrada, apresentando conformidade com valores estimados.

AGRADECIMENTOS

Os autores aproveitam para agradecer as instituições de ensino onde lecionam, bem como, a CAPES e o CNPq pelo incentivo demonstrado.

REFERÊNCIAS

- [1] R. F. Drayton, R. M. Henderson e L. P. B. Katehi. "Monolithic Packaging Concepts for High Isolation in Circuits and Antennas." *IEEE Transactions on Microwave Theory Techniques*, vol. 46, pp. 900-906, Julho 1998.
- [2] J. D. Joannopoulos, R. Meade e J. Winn. *Photonic Crystals. Molding the Flow of Light*, Princeton University Press, NJ, 1995.
- [3] V. Radisic, Y. Qian, R. Coccioli e T. Itoh, "Novel 2-D Photonic Band-Gap Structures for Microstrip Lines", *IEEE Microwave and Guided Wave Letters*, vol. 8, n° 2 pp. 69-71, Fevereiro 1998.
- [4] K. M. K. H. Leong, A. C. Guyette, B. Elamaram, W. A. Shiroma e T. Itoh, "Coupling Suppression in Microstrip Lines Using a Bi-Periodically Perforated Ground Plane", *IEEE Microwave and Wireless Components Letters*, vol. 12, n° 5 pp. 169-171, Maio 2002.
- [5] V. Radisic, Y. Qian e T. Itoh, "Broad-Band Power Amplifier Using Dielectric Photonic Bandgap Structure", *IEEE Microwave and Guided Wave Letters*, vol. 8, n° 01, pp. 13-14, Janeiro 1998
- [6] D. Dawn, Y. Ohashi, and T. Shimura, "A Novel Electromagnetic Bandgap Metal Plate for Parallel Plate Mode Suppression in Shielded Structures", *IEEE Microwave and Wireless Components Letters*, vol. 12, n° 5 pp. 166-168, Maio 2002.
- [7] R. Gonzalo, P. DE Maagt, M. Sorolla, "Enhanced Patch-Antenna Performance by Suppressing Surface Waves Using Photonic-Bandgap Substrates", *IEEE Transactions on Microwave Theory and Techniques*, vol. 47, n° 11, pp. 2131-2138, Novembro 1999.
- [8] Q. J. Zhang e K. C. Gupta. *Neural Networks for RF and Microwave Design*, Artech House, Boston, 2000.
- [9] C. Christodoulou e M. Georgiopoulos. *Applications of Neural Networks in Electromagnetics*, Artech House, Boston, 2001.
- [10] E. N. R. Q. Fernandes, P. H. F. Silva, M. A. B. Melo e A. G. D'Assunção, "A New Neural Network Model for Accurate Analysis of Microstrip Filters on PBG Structure", in *32nd European Microwave Conference*, Milão-Itália, Setembro 2002.