

Programas de CAD/ANN para Dispositivos Planares com Resultados Eletromagnéticos Incorporados

Paulo H. da F. Silva¹, Marcos A. B. de Melo¹ e Adrião D. D. Neto²

¹Dept. Eng. Elétrica-CCT-UFPB, CP10020, Campina Grande, PB – 58109-970

²Dept. Eng. Elétrica-UFRN, Campus Universitário, Lagoa Nova, Natal/RN – 59072-970

E-mails: henrique@dee.ufpb.br, marcos@dee.ufpb.br, adriao@leca.ufrn.br

Abstract

For device models, the accuracy of physics-based/electromagnetic (EM) simulations is required for computer aided design (CAD) software, but is at the expense of much increased computational cost. Accurate and efficient electromagnetically trained artificial neural network (ANN) models have been developed for planar components. The objective of this paper is to incorporate EM results for CAD software, with the use of ANNs, avoiding excessive computations. The Multilayer Perceptron (MLP) and Radial Basis Function (RBF) were investigated to the mapping geometrical and electrical features: electrical ac resistance of microstrips, inductance of planar spiral inductors (square and circular), and the dc characteristic of planar Field Effect Transistors (FETs).

1. Introdução

A partir da década passada, aplicações das redes neurais para a engenharia de microondas têm sido reportadas, em tópicos como: radar, modelização de dispositivos, projetos de circuitos, casamento de impedância, antenas, etc., [1]-[9].

Em particular, a modelização de dispositivos através de redes neurais, tem-se mostrado uma alternativa bastante atrativa para a implementação de ferramentas de CAD. Principalmente, quando um dispositivo é mal conhecido, ou, cujos modelos são ineficientes do ponto de vista computacional (o que inviabiliza a implementação em programas de CAD), as redes neurais surgem como modelos alternativos, tipo caixa preta, bastante úteis.

Em geral, o desenvolvimento de um programa de CAD para dispositivos de microondas requer simplificações numéricas de seus modelos EMs. Por exemplo, aproximações analíticas interpoladoras ou tabelas de consulta podem ser usadas para contornar computações excessivas. Um compromisso entre tempo de computação e precisão dos resultados é a questão principal no uso destas ferramentas computacionais. As

redes neurais possuem características, como será visto, que as tornam fortes candidatas para a implementação de ferramentas de CAD/ANN para a modelização de dispositivos. Estas são numericamente eficientes enquanto mantêm a precisão do modelo EM.

As redes MLP e RBF, descritas na seção 2, são treinadas para a modelização de dispositivos planares, seção 3. Estas redes são utilizadas no mapeamento das características elétricas e geométricas: resistência elétrica ac de uma fita metálica, indutâncias de indutores espirais e a característica dc de FETs. Na seção 4, um estudo comparativo é feito entre as redes MLP e RBF, em termos de convergência.

2. Redes Neurais Artificiais Utilizadas

Na definição das redes neurais, escolhemos a configuração com uma camada oculta para a rede MLP e a rede RBF, Figura 1. Estas redes e seus algoritmos de treinamento são bem conhecidos, [10]-[11]. Contudo, convém detalhar a computação utilizada.

2.1. Rede MLP

A rede MLP treinada pelo algoritmo da backpropagation é o modelo neural mais popular para a solução de problemas na área de microondas. Aqui, consideramos os neurônios com funções de ativação sigmoidais, eq. (5). A propagação do sinal através da rede no sentido direto é descrito pelas expressões:

$$net_h = \sum_{m=0}^M w_{hm} x_m \quad (1)$$

$$y_h = \varphi(net_h), \quad h = 1, 2, \dots, H \quad (2)$$

$$net_o = \sum_{h=0}^H v_h y_h \quad (3)$$

$$z = \varphi(net_o) \quad (4)$$

$$\varphi(net) = \frac{1}{1 + e^{-net}} \quad (5)$$




Figura 1: Configuração das redes neurais

onde $\mathbf{x}^T = [x_0, x_1, \dots, x_M]$, são as entradas da rede ($x_0 = \theta$), $\theta = \pm 1$ é um potencial de polarização, w_{hm} , $h = 1, 2, \dots, H$, e v_h , $h = 0, 1, 2, \dots, H$, são os pesos da rede, net_h e net_o são os potenciais de ativação, ϕ é a função sigmoideal associada a cada neurônio, $\mathbf{y}^T = [y_0, y_1, \dots, y_H]$ são as saídas dos neurônios ocultos ($y_0 = \theta$), e z é a saída da rede.

Na etapa de treinamento, a cada iteração do algoritmo da backpropagation, o ajuste dos pesos é feito pela retropropagação dos sinais de erro entre a resposta desejada e a saída da rede, $e = d - z$, [10]. O objetivo é minimizar o erro quadrático, $E = e^2 / 2$, através do cálculo dos gradientes locais nas camadas de saída e oculta,

$$\delta_o = -\frac{\partial E}{\partial e} \frac{\partial e}{\partial z} \frac{\partial z}{\partial net_o} = z(1-z)e \quad (6)$$

$$\delta_h = \phi'(net_h) \delta_o v_h = y_h(1-y_h) e v_h, \quad h = 1, 2, \dots, H \quad (7)$$

respectivamente. Os ajustes aplicados aos pesos a cada exemplo apresentado à rede MLP, são dados por:

$$\Delta v_h = \eta \delta_o y_h \quad (8)$$

$$\Delta w_{hm} = \eta \delta_h x_m \quad (9)$$

onde η (taxa de aprendizado) é uma constante que controla a convergência do processo de treinamento.

2.2. Rede RBF

A configuração da Figura 1 também é usada para descrever a rede RBF. Neste caso, com

$\mathbf{x}^T = [x_1, x_2, \dots, x_M]$ e $\mathbf{y}^T = [y_1, y_2, \dots, y_H]$, não incluímos o potencial θ . A cada neurônio oculto está associada uma função radial de base Gaussiana e o neurônio de saída é linear. Por outro lado, cada linha da matriz de pesos entre as camadas de entrada e de RBFs é interpretada como um vetor de centros \mathbf{t}_h da h -ésima RBF Gaussiana, dada por, [10]-[11]:

$$\phi(\mathbf{x}, \mathbf{t}_h) = \exp\left(-\frac{1}{\sigma_h^2} \|\mathbf{x} - \mathbf{t}_h\|^2\right) \quad (10)$$

onde $\|\cdot\|$ é a norma Euclidiana e σ_h é a largura da h -ésima RBF Gaussiana. Os centros, as larguras e os pesos, $\mathbf{v}^T = [v_1, v_2, \dots, v_H]$, são ajustados por um treinamento supervisionado através do método do gradiente. Minimizando o erro quadrático, $E = e^2 / 2$, resulta:

$$\Delta v_h = -\eta_v \frac{\partial E}{\partial v_h} = \eta_v e \phi(\mathbf{x}, \mathbf{t}_h) \quad (11)$$

$$\Delta \mathbf{t}_h = -\eta_t \frac{\partial E}{\partial \mathbf{t}_h} = 2\eta_t e v_h \phi(\mathbf{x}, \mathbf{t}_h) \frac{\mathbf{x} - \mathbf{t}_h}{\sigma_h^2} \quad (12)$$

$$\Delta \sigma_h^2 = -\eta_\sigma \frac{\partial E}{\partial \sigma_h^2} = \eta_\sigma e v_h \phi(\mathbf{x}, \mathbf{t}_h) \frac{\|\mathbf{x} - \mathbf{t}_h\|^2}{\sigma_h^2} \quad (13)$$

Na formulação acima, a fim de simplificar as expressões, o índice das iterações, n , foi suprimido. A cada iteração, um exemplo aleatório retirado do conjunto de treinamento, $s(n) = \{x(n); d(n)\}$, é apresentado a rede neural. Neste contexto, uma época equivale ao conjunto de todos os exemplos de treinamento.

3. ANNs para Dispositivos Planares

No projeto de um circuito integrado monolítico de microondas (MMIC), dispositivos planares discretos, como capacitores interdigitais, indutores espirais e FETs, entre outros, podem ser construídos sob uma mesma pastilha semicondutora. Algumas características comuns dos MMICs são: baixas perdas, tamanho, peso e custo reduzidos. Em seguida, consideramos a modelização via ANN de duas características elétricas importantes para o projeto de indutores espirais: as perdas ôhmicas e a indutância.

3.1. Resistência ac de uma Fita Metálica

Elementos passivos discretos em MMICs são construídos com seções de linhas de microfita, com largura, w , da ordem de espessura de metalização, t .

Com isto, o cálculo aproximado das perdas, [15], normalmente resultam em fatores de qualidade, Q , que são elevados se comparados aos medidos. O cálculo exato da variação (com relação à frequência) da resistência elétrica de um condutor metálico, Figura 2, é uma tarefa bastante difícil, sendo feita apenas por meio de sofisticados métodos numéricos, [16]. Para uma aplicação em programas de CAD, medidas publicadas, [17], têm sido interpoladas pela fórmula:

$$R_{ac} = \frac{L}{\sigma w t} \left\{ \frac{0,43093x_w}{1+0,041(w/t)^{1,19}} + \frac{1,1147+1,2868x_w}{1,2296+1,287x_w^3} + 0,035(w/t-1)^{1,8} \right\} \quad (14)$$




Figura 2: Fita metálica

onde $x_w = (2f\sigma\mu wt)^{1/2}$ é a frequência normalizada, L é o comprimento, σ é a condutividade elétrica e, μ , a permeabilidade magnética do condutor.

A rede MLP foi utilizada com $H = 17$ neurônios ocultos, como um interpolador alternativo à eq. (14). A rede possui duas entradas: $x_w \in [0,5; 12]$ e $w/t \in [1;18]$. A sua saída é uma aproximação para R_{ac}/R_{dc} , onde $R_{dc} = L/\sigma wt$. Nas Figuras 3 e 4 mostramos as aproximações através da eq. (14) e da rede MLP, bem como os resultados numéricos, [18].




Figura 3: Resistência ac de uma fita metálica (-) Resultados numéricos [18], (+) eq. (14)




Figura 4: Resistência ac de uma fita metálica (-) Resultados numéricos [18], (+) Rede MLP

A interpolação usando a eq. (14) introduz erros em torno de 20% para $w/t = 18$. Na Figura 4, podemos verificar que a rede MLP apresenta maiores erros para os valores de $x_w < 3$. De um modo geral, o modelo neural interpolador apresenta uma aproximação superior àquela dada pela eq. (14) para os valores numéricos de R_{ac} publicados em [18].

3.2. Indutores Espirais

Neste ponto, investigamos o uso de redes neurais para mapear a indutância total de indutores espirais retangulares e circulares, em função de seus parâmetros geométricos, Figura 5. Primeiro, resumimos o modelo EM, onde o indutor sob consideração é apropriadamente segmentado. No tipo retangular, cada espira corresponde a quatro segmentos retos. Para o indutor circular, cada segmento equivale a uma espira. O valor da indutância total leva em conta as contribuições da auto-indutância de cada segmento e da indutância mútua entre cada par de segmentos paralelos.

No indutor retangular, segmentos paralelos que carregam correntes em sentidos iguais (contrários), originam indutâncias mútuas positivas (negativas). O valor da indutância total é dado por:

$$L_T = \sum_{i=1}^{4\text{esp}} L_i + M_+ - M_- \quad (15)$$

onde L_i é a auto-indutância de cada segmento, esp é o número de espiras. Para o indutor circular, pares de segmentos paralelos sempre carregam correntes de mesmo sentido. A indutância total é dada por:

$$L_T = \sum_{i=1}^{\text{esp}} L_i + \sum_{i=1}^{\text{esp}-1} \sum_{j=i+1}^{\text{esp}} M_{ij} \quad (16)$$

onde M_{ij} é a indutância mútua entre os segmentos circulares i e j . A intrincada computação da eq. (15) é dada analiticamente [19]-[20], enquanto a eq. (16) requer o cálculo numérico de integrais elípticas, [18], [20]. Nos dois casos, o esforço de computação é uma função do número de espiras.




Figura 5: Indutores espirais planares
(a) Retangular, (b) Circular

Para cada tipo de indutor, uma rede MLP foi treinada para mapear a indutância total, em termos dos parâmetros geométricos. Os seguintes valores foram usados no treinamento: i. indutor retangular, $w=[5:5:20]$ μm e $a,b=[50:10:100]$ μm ; ii. Indutor circular, $Ri=[50:10:100]$ μm . Nos dois casos, a espessura da fita condutora vale $t=1,2$ μm , $s=5$ μm e $esp=[1:1:20]$ espiras. Assim, os vetores de entrada são: $x^T=[\theta, a, b, w, esp]$ para o indutor retangular e $x^T=[\theta, Ri, w, esp]$ para o indutor circular, incluindo a polarização. Por exemplo, para o indutor retangular, a combinação dos quatro parâmetros geométricos de entrada, nas faixas definidas, resulta um conjunto de treinamento com 8000 exemplos. Na Figura 6, representamos 10% deste conjunto para $a=10$ μm .




Figura 6: Representação de 10% do conjunto de treinamento usado no caso do indutor retangular. O gráfico reúne (lado a lado, com $esp=1, 2, \dots, 20$) os valores de indutância em função dos parâmetros geométricos

Durante a fase de treinamento, o número de unidades ocultas foi escolhido, por tentativa e erro. Observando a convergência deste processo, escolhemos $H=30$ unidades ocultas. A evolução do treinamento

foi verificada para diferentes taxas de aprendizado. Alguns resultados são mostrados através das curvas de erro médio quadrático

$$E_{av} = \sum_{n=1}^N E(n) \quad (17)$$

onde $N=8000$, Figura 7.

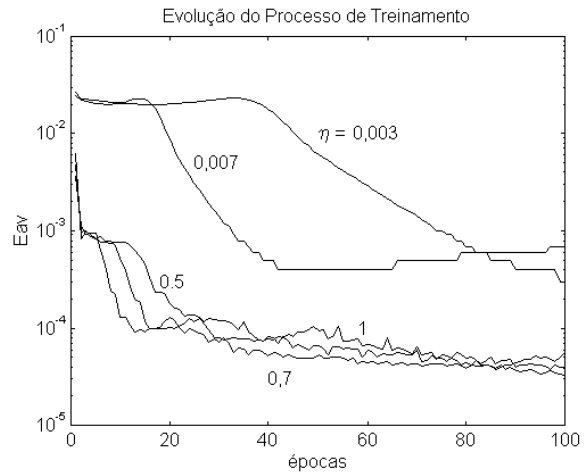


Figura 7: Convergência da rede MLP usada para o indutor espiral retangular

O procedimento acima, com os mesmos parâmetros para o MLP, foi conduzido para o caso do indutor espiral circular, com resultados semelhantes. Após o treinamento, as redes foram intensivamente testadas. Alguns resultados típicos de teste são apresentados nas Figuras 8 e 9.

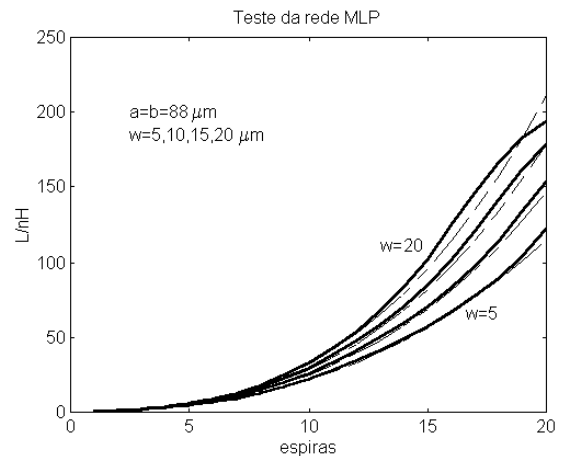


Figura 8: Teste da rede MLP para o indutor retangular: (—) Rede MLP, (---) Modelo EM, eq. (15)

Os resultados desta seção e da anterior, possibilita um eficiente cálculo do fator de qualidade, $Q = \omega L / R_{ac}$, via o uso de redes MLPs. Após treinadas estas redes servem como modelos eficientes em projeto e otimização destes tipos de indutores.

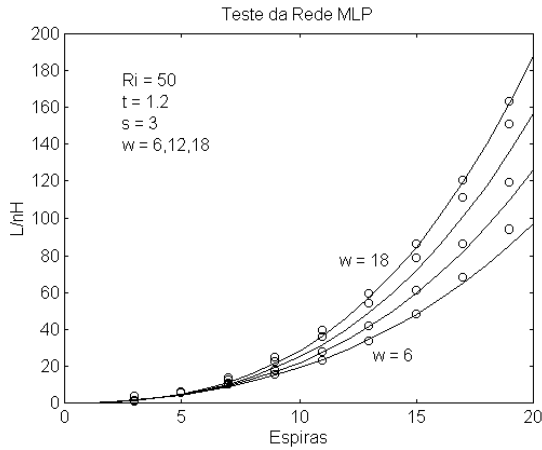


Figura 9: Teste da rede MLP para o indutor circular: (o) Rede MLP, (—) Modelo EM, eq. (16)

3.3. Transistores de Efeito de Campo

Como último exemplo, procuramos modelizar a característica de transferência DC da região ativa de FETs. Seja região sob a porta do MESFET tipo-n, Figura 10, onde supõe-se apenas um tipo de portador (elétrons). O modelo EM neste caso, envolve a solução das equações de transporte de carga nesta região, [21]-[23], o que requer um grande esforço computacional.




Figura 10: Transistor de efeito de campo de junção metal-semicondutor (MESFET)

$$\nabla^2 \psi = -\frac{q}{\epsilon} [N_D - n] \quad (18)$$

$$q \frac{\partial n}{\partial t} = \nabla \cdot \vec{J} \quad (19)$$

$$\vec{J} = -qn\vec{v} + qD\nabla n \quad (20)$$

$$\vec{J}_{tot} = \vec{J} + \epsilon \frac{\partial \vec{E}}{\partial t} \quad (21)$$

$$\vec{E} = -\nabla \psi \quad (22)$$

onde ψ é o potencial elétrico, $n(x, y)$, a densidade de elétrons, \vec{E} , a intensidade de campo elétrico, ϵ , a permissividade elétrica, q , a carga elétrica, N_D , a concentração de impurezas doadoras, \vec{v} , a velocidade de deriva, D , o coeficiente de difusão, \vec{J} , a densidade

de corrente de condução, \vec{J}_{tot} , a densidade de corrente total e, t , o tempo. O modelo EM empregado neste estudo, segue o método de Yamagushi e Kodera, [23], onde assume-se que a distribuição $n(x, y)$ seja conhecida.

A rede MLP (com uma camada oculta) e a rede RBF foram implementadas, com $H=30$ unidades ocultas, para modelizar a característica $I_d(V_g, V_d)$ em função das faixas de parâmetros dados na Tabela 1, onde I_d é a corrente de dreno, V_g a tensão de porta, V_d a tensão de dreno. Supõe-se a configuração fonte comum, $V_s = 0$. A Figura 11 mostra a configuração do modelo neural (caixa preta) indicando suas entradas e saída. As curvas de teste, Figura 12, mostram a boa aproximação pelos modelos MLP e RBF para o modelo EM [23]. A precisão em conjunto com a eficiência computacional, tornam interessante o uso destes modelos neurais.

Tabela 1: Parâmetros de entrada das redes neurais

Parâmetros	Notação	Faixa
Comprimento da porta	l_g	0.5 - 1.5 μm
Largura da porta	w	250 - 350 μm
Altura da região ativa	a	0.4 - 0.5 μm
Tensão de porta	V_G	-1.0 - 0.0 V
Tensão de dreno	V_D	0.0 - 4.0 V
Concentração de Impurezas	N_D	0.4 - 1.0 $\times 10^{22} / \text{m}^3$




Figura 11: Modelo neural para o FET

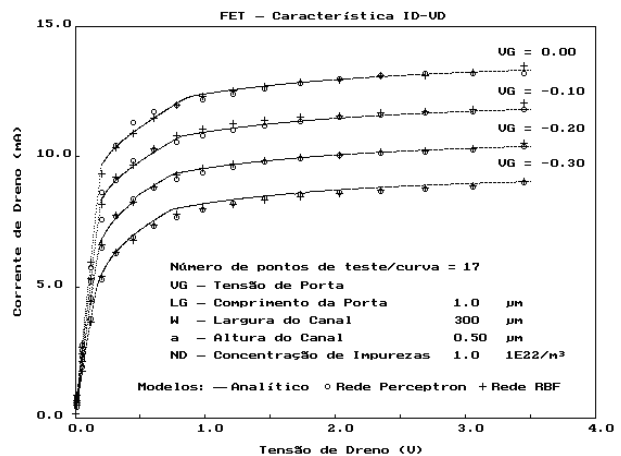


Figura 12: Teste das redes MLP e RBF

4. Implementação das Redes MLP e RBF

As redes MLP e RBF foram implementadas nas linguagens MATLAB e C++. Constatou-se que, em termos do tempo de computação, o programa escrito em C++ é bem mais veloz, sendo então o código utilizado. A evolução do processo de treinamento das redes MLP e RBF, utilizadas para a modelização da corrente de dreno do FET, é mostrada na Figura 13. Verifica-se que a rede RBF converge mais rápido que a rede MLP.

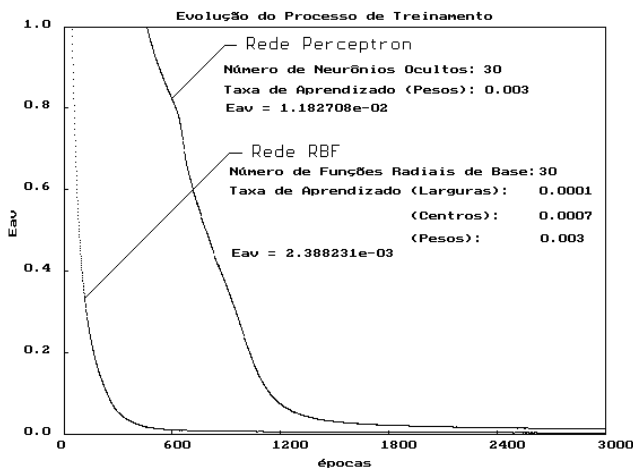


Figura 13: Convergência das redes MLP e RBF

5. Conclusões

A viabilidade do uso de ANNs para modelar as principais características de dispositivos planares encontrados em MMICs, foi verificada. O uso de tais modelos alternativos resulta em algumas vantagens computacionais, tais como podemos citar: baixa ocupação de memória, alta velocidade de computação de mapeamentos não lineares complexos, capacidade de modelização de diferentes dispositivos com a mesma configuração de rede neural. Estas características tornam os modelos através das redes neurais bastante atrativos em implementações de programas de CAD em microondas. Neste sentido, resultados de simulações EMs de diferentes dispositivos podem ser incorporados em programas de CAD via ANNs. Funcionando como modelos tipo caixa preta, este tipo de aproximação associa desempenho computacional e precisão nos resultados, evitando aproximações analíticas ou o uso de tabelas de consulta, que são recursos comuns em programas de CAD usuais. Uma desvantagem das ANNs é o grande esforço computacional requisitado durante a fase de treinamento. Em modelização de dispositivos, contudo, isto não é uma limitação, uma vez que o treinamento é feito "off-line".

Referências

- [1] Q. Zhao, Z. Bao, "Radar target recognition using a radial basis function," *Neural Networks*, vol. 9, no. 4, pp. 709-720, 1996.
- [2] M. Vai e S. Prasad, "Microwave circuit analysis and design by massively distributed computing network," *IEEE Trans. Microwave Theory Tech.*, vol. 43, no. 5, pp. 1087-1094, Maio, 1995.
- [3] H. L. Southall, J. A. Simmers, e T. H. O'Donnell, "Direction finding in phased arrays with a neural network beamformer," *IEEE Trans. Antennas Propagat.*, vol. 43, no. 12, pp. 1369-1374, Dez. 1995.
- [4] A. H. Zaabab, Q. J. Zhang, e M. Nakhla, "Device and circuit-level modeling using neural networks with faster training based on network sparsity," *IEEE Trans. Microwave Theory Tech.*, vol. MTT-45, no. 10, pp. 1696-1704, Out. 1997.
- [5] P. M. Watson e K. C. Gupta, "EM-ANN models for microstrip vias and interconnects in datasets circuits," *IEEE Trans. Microwave Theory Tech.*, vol. 44, no. 12, pp. 2495-2503, Dec. 1996.
- [6] F. Günes, F. Gürgen, e H. Torpi, "Signal-noise neural network for active microwaves devices," *IEE Proc. Circuits, Devices and Syst.*, vol. 143, no.1, pp. 1-8, Fev., 1996.
- [7] G. L. Greech, B. J. Paul, C. D. Lesniak, T. J. Jenkins, e M. C. Calceira, "Artificial neural networks for fast and accurate EM-CAD of microwave circuits," *IEEE Trans. Microwave Theory Tech.*, vol. 45, no. 5, pp. 712-722, Maio 1997.
- [8] F. Wang e Q. J. Zhang, "Knowledge-based neural models for microwave design," *IEEE Trans. Microwave Theory Tech.*, vol. 45, no. 12, pp. 2333-2343, Dez. 1997.
- [9] A. Patnaik, R. K. Mishra, "ANN techniques in microwave engineering," *IEEE Microwave*, pp. 55-60, Mar. 2000.
- [10] S. Haykin, *Neural Networks: A Comprehensive Foundation*, Prentice-Hall, New Jersey, E.U.A., 1994.
- [11] S. Haykin, *Adaptive Filter Theory*. New Jersey: Prentice Hall, 1996.
- [12] R. A. Pucel, "Design Considerations for Monolithic Microwave Circuits," *IEEE Trans. Microwave Theory Tech.*, vol. 29, no. 6, pp. 513-534, Jun. 1981.
- [13] R. H. Jansen, R. G. Arnold, e I. G. Eddison, "A comprehensive CAD approach to the design of MMIC's up to MM-wave frequencies," *IEEE Trans. Microwave Theory Tech.*, vol. 36, no. 2, pp. 208-219, Fev. 1988.
- [14] D. R. Ch'en e D. R. Decker, "MMIC's the next generation of microwaves components," *Microwave Journal*, Maio, 1980.
- [15] R. A. Pucel, D. J. Massé, e C. P. Hartwig, "Losses in Microstrip," *IEEE Trans. Microwave Theory Tech.*, vol. 16, no. 6, pp. 342-350, Jun. 1968.
- [16] P. Waldow e I. Wolff, "Duals bounds variational formulation of skin effect problems," *IEEE MTT-S Int. Microwave Symp. Dig.*, (Las Vegas), pp. 333-336, 1987.
- [17] S. J. Haefner, "Alternating current of rectangular conductors," *Proc. IRE*, vol. 25, pp. 434-447, 1937.
- [18] E. Pettenpaul, H. Kapusta, A. Weisgerber, H. Mampe, J. Luginsland, e I. Wolff, "CAD models of lumped elements on GaAs up to 18 GHz," *IEEE Trans. Microwave Theory Tech.*, vol. 36, no. 2, pp. 294-304, Fev. 1988.
- [19] H. M. Greenhouse, "Design of planar rectangular microelectronic inductors," *IEEE Trans. on Parts, Hybrids, and Packaging*, vol. 10, no. 2, Jun., 1974.
- [20] Wai-Kai Chen, "The circuits and filters handbook," CRC Press, Inc., 1995.
- [21] M. Reiser, "A two-dimensional numerical FET model for DC, AC and large-signal analysis," *IEEE Trans. Electron Devices*, vol. ED-20, pp. 35-45, Jan. 1973.
- [22] M. A. Khatibzadeh e R. J. Trew, "A large-signal, analytic model for the GaAs MESFET," *IEEE Trans. Microwave Theory Tech.*, vol. MTT-36, no. 2, pp. 231-238, Fev. 1988.
- [23] K. Yamaguchi e H. Kodaera, "Drain conductance of junction gate FET's in the hot electron range," *IEEE Trans. Electron Devices*, vol. ED-26, pp. 476-490, Abr. 1979.