

Everton Notreve Rebouças Queiroz Fernandes

**MODELAGEM NEUROCOMPUTACIONAL
DE DISPOSITIVOS DE MICROONDAS COM
ESTRUTURAS EBG**

Campina Grande – PB

Abril, 2004.

Everton Notreve Rebouças Queiroz Fernandes

**MODELAGEM NEUROCOMPUTACIONAL
DE DISPOSITIVOS DE MICROONDAS COM
ESTRUTURAS EBG**

Tese submetida ao Programa de Pós-Graduação em
Engenharia Elétrica da Universidade Federal de Campina Grande,
como parte dos requisitos exigidos para a obtenção do título de
Doutor em Ciências no domínio da Engenharia Elétrica.

Áreas de Concentração:
Eletromagnetismo Aplicado e Engenharia de Computação

Orientadores:
Prof. Marcos Antonio Barbosa de Melo, Dr.
Prof. Adaildo Gomes D'Assunção, Dr.

Campina Grande, Abril de 2004.



F363m **Fernandes, Everton Notreve Rebouças Queiroz**
2004 **Modelagem Neurocomputacional de Dispositivos de Microondas**
com Estruturas EBG /Everton Notreve Rebouças Queiroz Fernandes
Campina Grande: UFCG, 2004
155 p.: il.
Inclui Bibliografia
Tese (Doutorado em Eng. Elétrica) - UFCG/CCT

1. Estruturas EBG 2. Dispositivos de Microondas
3. Redes Neurais Artificiais

CDU:621.3.029

MODELAGEM NEUROCOMPUTACIONAL DE DISPOSITIVOS DE MICROONDAS
COM ESTRUTURAS EBG

EVERTON NOTREVE REBOUÇAS QUEIROZ FERNANDES

Tese Aprovada em 27.04.2004

MARCOS ANTONIO BARBOSA DE MELO, Dr., UFCG
Orientador

ADAILDO GOMES D'ASSUNÇÃO, Dr., UFRN
Orientador

HUGO ENRIQUE HERNANDEZ FIGUEIROA, Dr., UNICAMP
Componente da Banca

JOSÉ ALFREDO FERREIRA COSTA, Dr., UFRN
Componente da Banca

ALFREDO GOMES NETO, D.Sc., CEFET-PB
Componente da Banca

FRANCISCO MARCOS DE ASSIS, Dr., UFCG
Componente da Banca

FRANCISCO DE ASSIS FERREIRA TEJO, D.Sc., UFCG
Componente da Banca

CAMPINA GRANDE – PB
Abril - 2004

DEDICATÓRIA

À minha filha, ELOÍSE,
que foi minha maior motivação
para a conclusão deste trabalho.

AGRADECIMENTOS

Aos meus pais, Manoel Queiroz e Geíza Rebouças, e aos meus irmãos, Everlândio e Egna, pela atenção e força dedicadas;

Ao professor Dr. Adaildo Gomes d'Assunção pela orientação, sabedoria, paciência e dedicação demonstrados ao longo desta jornada;

Ao professor Dr. Marcos Antônio Barbosa de Melo, pela orientação; ajuda e estímulo de uma maneira geral;

Ao colega e professor Dr. Paulo Henrique da Fonseca Silva, que também contribuiu substancialmente nesta pesquisa;

Aos demais colegas e em especial, aos atuais professores doutores Antonio Luiz e Sandro Gonçalves pelo companheirismo e sugestões ao longo desta tarefa;

Aos professores Paulo Henrique da Fonseca Silva e Alfredo Gomes Neto e ao aluno Igor Marconi Simas Ramos do GTEMA - CEFET/PB; pelo auxílio e contribuição na confecção e caracterização dos filtros planares com estruturas EBG;

Aos professores e funcionários da COPELE/DEE; pelo trabalho e serviços prestados;

À CAPES, pelo apoio financeiro, através de bolsa, durante estes quatro anos;

Enfim, a todos que, direta ou indiretamente, tomaram parte neste feito;

eu sou profundamente grato.

RESUMO

Recentemente, tem havido estudos intensivos dedicados ao desenvolvimento de estruturas periódicas, como os cristais fotônicos, para aplicações em dispositivos de telecomunicações. As estruturas EBG, *electromagnetic bandgap*, também denominadas estruturas PBG, *photonic bandgap*, podem ser projetadas em materiais dielétricos ou metálicos, através da formação de uma matriz de orifícios dos quais um dos principais objetivos é proibir a propagação de ondas em faixas de frequências específicas. Esta característica tem sido utilizada tanto na confecção de dispositivos na banda óptica como na faixa de microondas e ondas milimétricas. A análise precisa de dispositivos com estruturas EBG requer a utilização de métodos numéricos que demandam um esforço computacional considerável, como o método das diferenças finitas no domínio do tempo (FDTD, finite difference time domain), entre outros.

Nos últimos anos, as técnicas neurocomputacionais têm surgido como ferramentas numéricas poderosas e versáteis para aplicações em diversas áreas do conhecimento. As redes neurais artificiais, ANNs, *artificial neural networks*, possuem características como: adaptabilidade, generalização e não-linearidade, que têm contribuído para enquadrá-las como métodos alternativos e vantajosos para a modelagem de diversos dispositivos de telecomunicações. Outra característica é o aumento significativo na velocidade de processamento, mediante o uso de modelos neurais em simulações de circuitos de microondas quando comparado aos modelos físicos eletromagnéticos.

Neste trabalho, uma nova técnica neurocomputacional é apresentada, com o objetivo de alcançar uma modelagem precisa e eficiente de estruturas EBG aplicadas a diversos dispositivos de microondas, como guias de ondas, linhas de microfita e linhas de transmissão acopladas. Esta técnica, denominado Rede Neural Artificial Modular Função *Sample*, (SF-ANN, *Sample Function Modular Artificial Neural Network*), emprega a função *sample* como função de ativação e possui uma formulação semelhante àquela empregada na rede neural de funções de base radial (RBF-ANN). Uma excelente concordância é observada entre os resultados teóricos obtidos neste trabalho e valores medidos disponíveis na literatura, demonstrando a precisão dos modelos modulares SF-ANNs. Além disso, os modelos modulares SF-ANNs realizam generalizações precisas para regiões de interesse, onde não há resultados disponíveis.

PALAVRAS-CHAVES: Estrutura EBG, dispositivos de microondas, redes neurais, CAD.

ABSTRACT

Lately, there have been intensive studies about the development of periodic structures, such as the photonic crystals, for applications in telecommunication devices. The EBG structures, *electromagnetic bandgap structures*, also denominated PBG structures, *photonic bandgap structures*, can be designed on dielectric or metallic materials, through the formation of a grid of holes of which one of the main objectives is to prohibit the propagation of waves in certain frequency ranges. This characteristic has been frequently used in making devices for the optical band as well as for the microwave and millimetric wave bands. The accurate analysis of devices on EBG structures requires the use of numeric methods that demand a substantial computational effort, as the method of the finite differences in time domain (FDTD), among many others.

In the last few years, the neural-computational techniques have appeared as powerful and versatile numeric tools for applications in several areas of knowledge. The artificial neural networks, ANNs, show features such as: adaptability, generalization and non-linear, that have contributed to elect them as alternative and advantageous methods for the modelling of several devices of telecommunications. Another characteristic is the significant increase in the processing speed through the use of neural models in simulations of microwave circuits, when compared to physical electromagnetic models.

In this work, a new neural computational technique is presented, aiming at reaching an accurate and efficient modelling of EBG structures applied to several devices, such as waveguides, microstrip lines and coupled microstrip lines. This method, denominated Sample Function Modular Artificial Neural Network, SF-ANN modular, makes use of the sample function as an activation function and has a similar configuration to that used in the radial base functions artificial neural networks (RBF-ANN). An excellent agreement is observed between the numerical results obtained in this work and measured values, available in the literature, demonstrating the accuracy of the SF-ANN models. Besides, the SF-ANN models accomplish generalizations for areas of interest, for which there are no available results.

KEY WORDS: *EBG structures, microwave devices, artificial neural network, CAD.*

SUMÁRIO

LISTA DE FIGURAS E TABELAS	X
LISTA DE SIGLAS	XIV
LISTA DE SÍMBOLOS	XV
CAPÍTULO 1	
INTRODUÇÃO	01
CAPÍTULO 2	
ESTRUTURAS EBG	04
2.1 Introdução	04
2.2 Cristal Eletromagnético Artificial	05
2.2.1 Parâmetros Básicos de Redes Cristalinas	07
2.2.2 Equações de Ondas em Cristais Fotônicos	10
2.2.3 Analogia entre os Cristais Fotônicos e os Semicondutores	13
2.3 Materiais EBG na Faixa de Microondas e Ondas Milimétricas	16
2.4 Classificação das Estruturas EBG	19
2.5 Metodologia de Projeto de Estruturas EBG	24
2.6 Fabricação e Caracterização de Dispositivos EBG	27
2.7 Conclusão	32
CAPÍTULO 3	
REDES NEURAIAS ARTIFICIAIS	33
3.1 Introdução	33
3.2 Descrição, Metodologia e Características da ANN	35
3.2.1 Preliminares	35
3.2.2 Unidade de Processamento de Informação da ANN	36
3.2.3 Arquiteturas de Redes Neurais	38
3.2.4 Processos de Aprendizagem	40
3.2.5 Tarefas de Aprendizagem	42
3.2.6 Expressão do Conhecimento por uma ANN	44

3.3 Rede Neurais em Eletromagnetismo	46
3.3.1 Desenvolvimento de Modelos EM-ANN	50
3.4 Rede Neural MLP	52
3.4.1 Configuração e Metodologia da MLP-ANN	52
3.4.2 Algoritmo de Retropropagação do Erro (Backpropagation)	54
3.5 Rede Neural RBF	56
3.5.1 Configuração e Metodologia da RBF-ANN	56
3.5.2 Estratégias de Treinamento das RBF-ANN	58
3.5.3 Algoritmo Geral para Treinamento de uma RBF-ANN	63
3.6 Comparação entre as Redes MLP E RBF	64
3.7 Rede Neural Função Sample	65
3.7.1 Configuração e Metodologia da SF-ANN	65
3.7.2 Processo de Treinamento da SF-ANN	68
3.8 Redes Neurais Modulares	70
3.8.1 Método da Média de Ensemble	71
3.8.2 Método do Reforço	72
3.8.3 Modelo de Mistura de Especialistas	72
3.8.4 Modelo de Mistura Hierárquica de Especialistas	75
3.9 Arquitetura Modular da Rede Neural Função <i>Sample</i>	77
3.10 Conclusão	78

CAPÍTULO 4

APLICAÇÕES DAS ESTRUTURAS EBG EM GUIA DE ONDAS	80
4.1 Introdução	80
4.2 Dispositivos de Microondas Usando Guias de Ondas	81
4.2.1 Arranjos Amplificadores Espacialmente Acoplados	82
4.2.2 Linhas de Transmissão Blindadas	84
4.3 Guia de Ondas Retangular EBG-UC-TP	85

4.4 Guia de Placas Paralelas EBG-TP	101
4.5 Conclusão	106
CAPÍTULO 5	
APLICAÇÕES DAS ESTRUTURAS EBG EM LINHAS DE MICROFITA	107
5.1 Introdução	107
5.2 Dispositivos de Linhas de Microfita	108
5.2.1 Filtros Planares	109
5.2.2 Dispositivos de Ondas Lentas	110
5.3 Linhas de Microfita com Estruturas EBG-GP	111
5.3.1 Filtro EBG-GP	111
5.3.2 Filtro EBG-UC-GP	117
5.4 Linhas de Microfita com Estrutura EBG-D	121
5.4.1 Filtro EBG-D Banda Larga	121
5.5 Conclusão	129
CAPÍTULO 6	
APLICAÇÕES DAS ESTRUTURAS EBG EM LINHAS ACOPLADAS	130
6.1 Introdução	130
6.2 Características das Linhas Acopladas	131
6.3 Linhas de Transmissão Adjacentes EBG-GP	133
6.4 Linhas de Transmissão Interceptadas EBG-GP	138
6.5 Conclusão	144
CAPÍTULO 7	
CONCLUSÕES FINAIS	145
REFERÊNCIAS BIBLIOGRÁFICAS	149

LISTA DE FIGURAS E TABELAS

Fig. 2.1	Exemplos de células unitárias de redes cristalinas. (a) Arranjo cúbico simples. (b) Arranjo cúbico centrado no interior. (c) Arranjo cúbico centrado nas faces.	05
Fig. 2.2	Exemplos de materiais EBG uni, bi e tridimensionais. As diferentes tonalidades indicam meios com diferentes constantes dielétricas.	06
Fig. 2.3	Cristal fotônico constituído por uma rede quadrática de orifícios circulares.	09
Fig. 2.4	Zona irreduzível de Brillouin.	09
Fig. 2.5	Representação espacial real e recíproca de cristais fotônicos bidimensionais constituídos por uma rede triangular de buracos circulares.	10
Fig. 2.6	Meio dielétrico misto (cristal fotônico artificial).	10
Tab. 2.1	Comparação entre a Mecânica Quântica e a Eletrodinâmica.	14
Fig. 2.7	Linha de microfita com estrutura EBG-D bidimensional.	20
Fig. 2.8	Linha de microfita com estrutura EBG-GP.	20
Fig. 2.9	Antena patch de microfita com estrutura EBG-TP.	21
Fig. 2.10	Rede de elementos periódicos gravados sobre substrato dielétrico.	22
Fig. 2.11	Rede de elementos periódicos impressos no plano de terra	23
Fig. 2.12	Esquema da célula unitária EBG-UC-TP	23
Fig. 2.13	Protótipos de filtros planares utilizando a tecnologia EBG-GP	28
Fig. 2.14	Conectores tipo N em suporte de alumínio	29
Fig. 2.15	Detalhe da conexão entre os conectores tipo N e a microfita EBG	29
Fig. 2.16	<i>Layout</i> do experimental para caracterização dos filtros EBG-GP	30
Fig. 2.17	Resultados medidos para os filtros EBG-GP fabricados	31
Fig. 3.1	Metodologia básica de aprendizagem de uma rede neural artificial ANN.	35
Fig. 3.2	Modelo de um neurônio artificial.	37
Fig. 3.3	Rede acíclica como uma camada oculta.	39
Fig. 3.4	Rede recorrente ou com realimentação.	40
Tab. 3.1	Quadro comparativo de metodologias de modelagem de aplicações em microondas.	50
Fig. 3.5	Arquitetura da MLP-ANN.	53

Fig. 3.6	Arquitetura de RBF-ANN.	56
Fig. 3.7	Variações da função <i>sample</i> .	66
Fig. 3.8	Arquitetura da SF-ANN.	68
Fig. 3.9	Máquina de Comitê baseada na técnica da média de ensemble	71
Fig. 3.10	Rede Neural Modular ME	73
Fig. 3.11	Grafo de fluxo de sinal de um neurônio da especialista k	73
Fig. 3.12	Arquitetura da rede de passagem	74
Fig. 3.13	Grafo do fluxo de sinal de um neurônio da rede de passagem	74
Fig. 3.14	Rede Neural Modular MHE	76
Fig. 3.15	Rede Neural Modular Função <i>Sample</i>	78
Fig. 4.1	Guia de ondas retangular: (a) Vista frontal. (b) Vista longitudinal.	81
Fig. 4.2	Linha de transmissão blindada.	84
Fig. 4.3	Guia de ondas com estrutura EBG-UC.	85
Fig. 4.4	Seção transversal do guia de ondas EBG-UC-TP e seu modelo de circuito equivalente	86
Fig. 4.5	Valores medidos (10 dados de treinamento) usados no processo de aprendizagem do primeiro modelo neural SF-ANN do guia de ondas retangular EBG-UC-T para análise da velocidade de fase normalizada	88
Fig. 4.6	Valores medidos (19 dados de treinamento) usados no processo de aprendizagem do segundo modelo neural SF-ANN do guia de ondas retangular EBG-UC-T para análise da velocidade de fase normalizada	89
Fig. 4.7	Resposta do modelo SF-ANN para a análise da velocidade de fase versus a frequência em um guia de ondas retangular EBG-UC-TP Modelo 1 usando apenas 10 dados de treinamento e modelo 2 usando 19 dados de treinamento.	90
Fig. 4.8	Valores medidos (dados de treinamento) usados no processo de aprendizagem do modelo neural SF-ANN do guia de ondas retangular EBG-UC-T para análise da distribuição da intensidade do campo elétrico ao longo da seção transversal.	93
Fig. 4.9	Resposta do modelo SF-ANN para a distribuição da intensidade do campo elétrico no guia de ondas EBG-UC-TP.	94
Fig. 4.10	Resposta e Generalização do modelo SF-ANN para a distribuição da	95

intensidade do campo elétrico no guia EBG-UC-TP em uma nova posição $x = 1/2$.

- Fig. 4.11 Valores medidos (30 dados de treinamento) usados no processo de aprendizagem do modelo neural SF-ANN modular do guia de ondas retangular EBG-UC-T para análise da distribuição da intensidade do campo elétrico 98
- Fig. 4.12 Resposta do modelo SF-ANN modular para a distribuição da intensidade do campo elétrico ao longo da seção transversal de um guia de ondas retangular EBG-UC-TP em função da frequência de operação. 99
- Fig. 4.13 Resposta e generalização do modelo SF-ANN modular para a distribuição da intensidade do campo elétrico ao longo da seção transversal de um guia de ondas retangular EBG-UC-TP em função da frequência. 100
- Fig. 4.14 Guia de ondas com placas paralelas usando estrutura EBG: (a) Vista superior. (b) Vista da seção transversal. 101
- Fig. 4.15 Resposta do modelo SF-ANN modular para o guia de ondas de placas paralelas EBG-TP. 104
- Fig. 4.16 Generalização do modelo modular SF-ANN para o guia de ondas de placas paralelas EBG-TP para novos valores de diâmetro dos elementos circulares periódicos. 105
- Fig. 5.1 Linha de microfita convencional. Vista frontal. 108
- Fig. 5.2 Linha de microfita com estrutura EBG-GP. 111
- Fig. 5.3 Resposta do modelo SF-ANN para o filtro EBG-GP para análise do ganho versus a frequência. 114
- Fig. 5.4 Resposta e generalização do modelo SF-ANN para um filtro EBG-GP com raio de 1,22 mm. 115
- Fig. 5.5 Resposta e generalização do modelo SF-ANN para um filtro EBG-GP com raio de 1,32 mm. 116
- Fig. 5.6 Linha de microfita com estrutura EBG-UC-GP: (a) Vista superior. (b) Vista inferior. 117
- Fig. 5.7 Resposta do modelo SF-ANN para filtro EBG-UC-GP para análise das perdas de retorno versus frequência de operação. 119
- Fig. 5.8 Resposta do modelo SF-ANN para filtro EBG-UC-GP para análise das 120

	perdas de inserção versus frequência de operação.	
Fig. 5.9	Linha de microfita com estrutura EBG-D em cascata.	121
Fig. 5.10	Valores medidos usados no processo de treinamento do modelo neural SF-ANN para filtro EBG-D	124
Fig. 5.11	Resposta do modelo SF-ANN para filtro EBG-D para análise do ganho versus a frequência de operação.	125
Fig. 5.12	Resposta do modelo SF-ANN para filtro EBG-D com três posições diferentes da fita condutora em relação aos elementos periódicos.	126
Fig. 5.13	Resposta do modelo SF-ANN para filtro EBG-D banda larga para análise do ganho versus frequência de operação.	128
Fig. 6.1	Linhas de microfita acopladas e simétricas.	131
Fig. 6.2	Linhas de microfita adjacentes com estrutura EBG-GP.	133
Fig. 6.3	Valores medidos que compõem o conjunto de treinamento (25 exemplos) usado na modelagem neurocomputacional SF-ANN para o circuito EBG-GP de linhas adjacentes.	136
Fig. 6.4	Resposta do modelo SF-ANN para o circuito EBG-GP de linhas adjacentes.	137
Fig. 6.5	Linhas de microfita interceptadas com estrutura EBG-GP.	138
Fig. 6.6	Valores medidos que compõem o primeiro conjunto de treinamento (25 exemplos) usado na modelagem neurocomputacional SF-ANN do circuito EBG-GP de linhas interceptadas.	141
Fig. 6.7	Valores medidos que compõem o segundo conjunto de treinamento (20 exemplos) usado na modelagem neurocomputacional SF-ANN do circuito EBG-GP de linhas interceptadas.	142
Fig. 6.8	Resposta do modelo SF-ANN usando 25 e 20 exemplos de treinamento, respectivamente, para o circuito EBG-GP de linhas interceptadas para análise do coeficiente de acoplamento.	143

LISTA DE SIGLAS

ANN	Artificial Neural Network
CAD	Computer Aided Design
CPW	Coplanar Waveguide
DFT	Discrete Fourier Transform
EBG	Electromagnetic Bandgap
EBG-D	Electromagnetic Bandgap – Dielectric
EBG-GP	Electromagnetic Bandgap – Ground Plane
EBG-TP	Electromagnetic Bandgap – Top Plane
EBG-UC	Electromagnetic Bandgap Uniplanar Compact
EM	Electromagnetic
EM-ANN	Electromagnetic-Artificial Neural Network
FDSMN	Frequency Dependent Space Mapping Neuromodeling
FDPSMN	Frequency Dependent Partial Space Mapping Neuromodeling
FDTD	Frequency Difference Time Domain
FPSMN	Frequency and Partial Space Mapping Neuromodeling
FEM	Finite Elements Method
FSMN	Frequency Space Mapping Neuromodeling
KBNN	Knowledge Based Neural Network
MBH	Método do Balanço Harmônico
MLP	Multilayer Perceptrons
MoM	Method of Moments
PBG	Photonic Bandgap
PBGS	Photonic Bandgap Substrate
PKI	Priori Knowledge Input
RBF	Radial Basis Function
RF	Radio Frequency
Rprop	Resilient Backpropagation
SF-ANN	Sample Function – Artificial Neural Network
SMN	Space Mapping Neuromodeling
SPICE	Simulation Program with Integrated Circuit Emphasis

LISTA DE SÍMBOLOS

a	Período, espaçamento entre os elementos periódicos
b	Vetor de rede recíproca
c	Velocidade da luz no vácuo
c	Centro da função gaussiana
E	Função erro (ou custo)
E	Vetor campo elétrico
e	Erro instantâneo
d	Vetor de saídas dependentes
D	Vetor fluxo elétrico
f	Frequência
f_0	Frequência central da faixa de rejeição
$g()$	Função de ativação
H	Vetor campo magnético
$V(r)$	Potencial elétrico
R	Rede de Bravais
r	Raio dos elementos periódicos
v	Potencial interno do neurônio
w	Vetor pesos sinápticos
x	Vetor de entradas independentes
α	Constante de atenuação
β	Constante de fase
ϵ	Permissividade elétrica
$\bar{\epsilon}$	Tensor permissividade elétrica
ϵ_{eff}	Permissividade elétrica efetiva
λ	Comprimento de onda
λ_g	Comprimento de onda guiada
σ	Desvio padrão
η	Taxa de treinamento
μ	Permeabilidade magnética

ω	Frequência angular
A	Razão de preenchimento
θ	Operador diferencial
$\Psi(r)$	Função de onda

CAPÍTULO 1

INTRODUÇÃO

A área de telecomunicações tem presenciado uma evolução intensa nos últimos anos. Esta evolução apresenta uma característica multidisciplinar que abrange o desenvolvimento de novos dispositivos de menores dimensões e mais eficientes, além do aprimoramento das técnicas de análise e síntese, tornando-as mais precisas e eficientes.

Dispositivos modernos estão sendo desenvolvidos baseados na tecnologia EBG (*electromagnetic bandgap*). As estruturas com banda eletromagnética proibida, estruturas EBG, também denominadas estruturas PBG (*photonic bandgap*), são constituídas por elementos periódicos metálicos e/ou dielétricos, gravados periodicamente no plano de terra ou no substrato dos dispositivos.

Estas estruturas têm permitido grandes avanços no desenvolvimento e aperfeiçoamento de dispositivos para as faixas de microondas e ondas milimétricas.

Os cristais fotônicos/eletromagnéticos artificiais constituem uma nova classe de estruturas periódicas e são os análogos fotônicos dos semicondutores. Estas estruturas controlam a propagação de ondas eletromagnéticas e fótons de maneira semelhante àquela do potencial eletrostático periódico sobre os semicondutores, o qual afeta o movimento dos elétrons impondo bandas permitidas e proibidas para a ocupação dos níveis energéticos. Conseqüentemente, a principal característica dessas estruturas é a exibição de faixas de frequências onde a propagação de ondas eletromagnéticas é suprimida. Esta característica é aplicada em diversos circuitos, tais como antenas, filtros de microondas e amplificadores.

Além das diversas aplicações, novas configurações das estruturas EBG têm sido investigadas. Dentre elas, destaca-se a estrutura EBG uniplanar compacta (EBG-UC). Esta estrutura apresenta características como baixas perdas, impedância moderada e

propriedades uniplanares que são vantajosas em diversas aplicações tais como, guias de ondas, linhas de microfita, linhas coplanares e linhas acopladas, além de antenas planares.

A respeito das técnicas de análise destas estruturas, o método das diferenças finitas no domínio do tempo (FDTD, *finite difference time domain*) tem sido o mais empregado pelos autores de trabalhos recentes. Entretanto, nos últimos anos, surgiram novas metodologias, dentre as quais destacam-se as técnicas neurocomputacionais. Apresentando menor esforço computacional, além de grande adaptabilidade e precisão, estas metodologias se constituíram em novas alternativas para a modelagem de dispositivos e circuitos integrados de microondas.

O objetivo central desta tese é desenvolver modelos eficientes e precisos para analisar os efeitos da utilização de estruturas EBG em dispositivos e circuitos de microondas. Para isto, são empregadas a Rede Neural Artificial Função *Sample* (SF-ANN, *Sample Function Artificial Neural Network*) e a Rede Neural Modular Função *Sample*, proposta nesta Tese, que se mostraram mais vantajosas em relação às existentes em diversos trabalhos (FERNANDES *et al.*, 2002a, 2002b, 2002c, 2003a, 2003b; SILVA, FERNANDES e NETO, 2002).

São apresentados, no Capítulo 2, os conceitos físicos e o comportamento eletromagnético dos cristais fotônicos/eletromagnéticos. As características, tipos, vantagens e desvantagens das estruturas EBG são comentadas.

No Capítulo 3, uma nova técnica neurocomputacional é descrita. A partir da função *sample* como função de ativação e tendo uma configuração semelhante às redes de funções de base radial, RBFs, esta nova metodologia, denominada Rede Neural Artificial Modular Função *Sample* - SF-ANN, apresenta características tais como aplicabilidade geral, adaptabilidade e capacidade de generalização, as quais se constituem em vantagens para a modelagem de circuitos de microondas. Esta metodologia é aplicada na modelagem dos diversos dispositivos e circuitos com estruturas EBG abordados nos capítulos seguintes.

No Capítulo 4, são apresentadas aplicações das estruturas EBG em guias de ondas retangulares e de placas paralelas. A introdução de estruturas EBG em um guia de ondas retangular permite obter uma equalização da intensidade do campo elétrico ao longo da sua seção transversal. Esta característica é adequada para aplicações em amplificadores de potência quase-óptica acoplados espacialmente.

No Capítulo 5, filtros de microondas constituídos por linhas de microfita com estruturas EBG são analisados. Filtros planares padrão e de banda larga, usando estruturas EBG, são modelados através da metodologia SF-ANN e simulados para obtenção de resultados que demonstrem o efeito da aplicação das estruturas EBG.

No Capítulo 6, as linhas de transmissão acopladas usando estruturas EBG são investigadas e modeladas através da metodologia SF-ANN. A introdução de estruturas EBG em circuitos de linhas de microfita acopladas e interceptadas traz benefícios ao projeto de acopladores direcionais planares. Resultados experimentais e valores obtidos pelo método FDTD, disponíveis na literatura, também são apresentados para efeito de comparação e validação das respostas dos modelos SF-ANN desenvolvidos.

As principais conclusões e sugestões para a continuidade deste trabalho são apresentadas no Capítulo 7.

CAPÍTULO 2

ESTRUTURAS EBG

2.1 INTRODUÇÃO

O controle das propriedades eletromagnéticas ou ópticas dos materiais é um dos principais objetos de estudo, atualmente, da comunidade científica. A proibição da propagação da luz, ou a sua permissão somente em certas direções e em determinadas faixas de frequências, traz grandes avanços para a indústria das telecomunicações.

Recentemente, uma nova classe de material periódico tem sido apresentada para desempenhar o controle da propagação de ondas ou da emissão de luz em dispositivos de telecomunicações. Tratam-se dos cristais fotônicos ou eletromagnéticos artificiais, também conhecidos como materiais com banda proibida eletromagnética/fotônica (PBG/EBG, *photonic/electromagnetic bandgap*) (YABLONOVITCH *et al.*, 1991).

Desde então, esforços intensos têm sido realizados no desenvolvimento e aplicações dessas estruturas periódicas. Uma das primeiras configurações de estrutura EBG projetada consiste na perfuração de uma rede periódica de elementos cilíndricos no substrato dielétrico de uma antena planar, de modo a promover um aumento na diretividade deste dispositivo (BROWN *et al.*, 1993).

Atualmente, diversos outros tipos de configurações de estruturas EBG, como a estrutura EBG uniplanar compacta, EBG-UC (YANG F. *et al.*, 1999a), a estrutura EBG com elementos de forma hexagonal (HIGGINS *et al.*, 1999), a estrutura EBG unipolar compacta (SHARMA e SHAFI, 2001), a estrutura EBG paralela (KIM e SEO, 2000), a estrutura com célula EBG (XUE *et al.*, 2000), a estrutura EBG periodicamente carregada, - PL-EBG (*periodic loaded EBG*) (MARTÍN *et al.*, 2002) e a estrutura EBG de placa

metálica (DAWN *et al.*, 2002), têm sido desenvolvidas e aplicadas em um extenso número de dispositivos e circuitos que atuam desde a faixa de radiofrequência, passando pela faixa de microondas e ondas milimétricas, até o domínio óptico.

A caracterização da propagação de ondas eletromagnéticas em materiais EBG é apresentada neste capítulo. As principais vantagens que tornam estes materiais úteis para a fabricação de diversos dispositivos de microondas e ondas milimétricas, bem como, os seus parâmetros de projeto e algumas das suas desvantagens, são descritos e analisados.

2.2 CRISTAL FOTÔNICO/ELETROMAGNÉTICO ARTIFICIAL

Os cristais fotônicos/eletromagnéticos artificiais constituem uma nova classe de estruturas periódicas, que pode ser considerada como a de equivalentes fotônicos dos semicondutores. Ou seja, as ondas eletromagnéticas comportam-se nestes materiais de forma similar aos elétrons nos semicondutores (JOANNOPOULUS *et al.*, 1995).

Para explicar como o material EBG realiza o controle da propagação da luz, deve-se fazer uma analogia com os materiais semicondutores. Um cristal natural é um arranjo de átomos ou moléculas, como exemplificado na Fig. 2.1. Conseqüentemente, uma rede cristalina, que é a repetição simples destes arranjos, apresenta um potencial periódico sobre a propagação de um elétron através dela.




Fig. 2.1: Exemplos de células unitárias de redes cristalinas: (a) arranjo cúbico simples; (b) arranjo cúbico centrado no interior; (c) arranjo cúbico centrado nas faces.

Em particular, a rede cristalina introduz zonas proibidas (*forbidden gaps*) dentro da estrutura de banda de energia do cristal, devido à refração de Bragg dos átomos. Desta forma, os elétrons são proibidos de se propagar com energias específicas, em certas direções. Se o potencial da rede cristalina for suficientemente forte, a faixa de rejeição se estenderá em todas as direções, resultando em uma banda proibida completa (*full*

bandgap). Um material semiconductor possui zona proibida (*bandgap*) entre as bandas de valência e a de condução.

O potencial periódico de um cristal fotônico/eletromagnético artificial é produzido pela utilização de materiais dielétricos periódicos em uma, duas ou três direções, como mostra a Fig. 2.2.




Fig. 2.2: Exemplos de materiais EBG uni, bi e tridimensionais. As diferentes tonalidades indicam meios com diferentes constantes dielétricas (JOANNOPOULUS *et al.*, 1995).

Se as constantes dielétricas dos materiais no cristal forem suficientemente diferentes, e a absorção da luz pelo material é mínima, então a dispersão nas interfaces pode produzir os mesmos fenômenos para fótons que o potencial atômico faz para os elétrons. Ou seja, as interferências construtivas e destrutivas das ondas eletromagnéticas dentro do material EBG geram bandas de transmissão e reflexão. Portanto, o cristal fotônico artificial, um meio dielétrico periódico com baixas perdas, é capaz de realizar o controle da propagação da luz.

Quando uma faixa de rejeição (*stopband*) aparece para ondas eletromagnéticas em todas as direções, este nível energético é denominado de banda proibida completa (*full bandgap*).

Outra característica dos materiais EBG ocorre quando a periodicidade do cristal fotônico artificial é alterada pela remoção ou adição de um meio com diferentes constantes dielétricas, tamanhos ou formas. Neste caso, um estado irregular (*defect*) é originado na banda proibida e o confinamento de energia se estabelece.

2.2.1 Parâmetros Básicos de Redes Cristalinas

Uma breve descrição dos parâmetros básicos de redes que definem uma estrutura cristalina é apresentada a seguir (BRILLOUIN, 1953; GONZALO *et al.*, 1999).

A. Rede Primitiva

A estrutura de todos os cristais pode ser descrita em termos de vetores de rede, com um grupo de átomos ligados a todo ponto da rede chamada de base da rede. A base é repetida no espaço de modo a formar a estrutura cristalina. Esta organização interna dos átomos em um cristal é responsável por uma série de propriedades importantes em aplicações industriais.

Em termos matemáticos, um cristal é descrito por uma rede de pontos geométricos que satisfazem certas operações de simetria, tais como reflexão, translação e rotação. Esta rede é conhecida como Rede de Bravais, em homenagem ao cientista que sistematizou estes conceitos (BRILLOUIN, 1953). Portanto, a Rede de Bravais é um arranjo periódico tal que o conjunto de pontos é exatamente o mesmo quando visto de qualquer ponto, ou seja, os pontos da rede são equivalentes. Os vetores de rede de Bravais descrevem como as unidades repetidas no cristal estão arranjadas (GONZALO *et al.*, 1999). Todos os pontos da rede primitiva podem ser definidos pela rede de Bravais através das posições:

$$\mathbf{R} = n_1 \mathbf{a}_1 + n_2 \mathbf{a}_2 + n_3 \mathbf{a}_3 \quad (2.1)$$

para a qual os vetores primitivos \mathbf{a}_i , não estão no mesmo plano, e as variáveis n_i são inteiras.

B. Rede Recíproca

A rede recíproca é a rede Bravais propriamente dita, entretanto sendo definida no espaço vetorial k (GONZALO *et al.*, 1999). Pode ser definida para todo k que satisfaça a seguinte expressão:

$$\mathbf{k} = m_1 \mathbf{b}_1 + m_2 \mathbf{b}_2 + m_3 \mathbf{b}_3 \quad (2.2)$$

em que \mathbf{b}_i são os vetores recíprocos e m_i são inteiros. Os vetores \mathbf{b}_i são obtidos de modo a satisfazerem a seguinte relação vetorial:

$$\mathbf{k} \cdot \mathbf{R} = (n_1 \mathbf{a}_1 + n_2 \mathbf{a}_2 + n_3 \mathbf{a}_3) \cdot (m_1 \mathbf{b}_1 + m_2 \mathbf{b}_2 + m_3 \mathbf{b}_3) = 2\pi N \quad (2.3)$$

Esta condição é escolhida de tal forma que $\mathbf{a}_i \cdot \mathbf{b}_j = 2\pi \delta_{ij}$, i e $j = 1, 2, 3, \dots$. Desta maneira, os vetores de rede primitiva recíproca são dados por:

$$\mathbf{b}_1 = 2\pi \frac{\mathbf{a}_2 \times \mathbf{a}_3}{\mathbf{a}_1 \cdot (\mathbf{a}_2 \times \mathbf{a}_3)} \quad (2.4)$$

$$\mathbf{b}_2 = 2\pi \frac{\mathbf{a}_3 \times \mathbf{a}_1}{\mathbf{a}_1 \cdot (\mathbf{a}_2 \times \mathbf{a}_3)} \quad (2.5)$$

$$\mathbf{b}_3 = 2\pi \frac{\mathbf{a}_1 \times \mathbf{a}_2}{\mathbf{a}_1 \cdot (\mathbf{a}_2 \times \mathbf{a}_3)} \quad (2.6)$$

Quando a transformada de Fourier de uma função que é periódica em um arranjo é requerida, apenas os vetores recíprocos do arranjo são necessários, como termos para os vetores de onda.

C. Zona de Brillouin

Segundo o princípio proposto por Floquet (BRILLOUIN, 1953), os modos normais em estruturas periódicas podem ser escritos como uma superposição de um conjunto de ondas planas, cujos vetores de onda são relacionados por:

$$\mathbf{k}_n = \mathbf{k}_0 + n\mathbf{G} \quad (2.7)$$

onde \mathbf{k}_0 é o vetor de onda arbitrário inicial, \mathbf{k}_n é o vetor de onda do n -ésimo modo e \mathbf{G} é o vetor da rede recíproca (BRILLOUIN, 1953; GONZALO *et al.*, 1999).

Uma extensão do princípio de Floquet para abranger as estruturas periódicas multidimensionais é escrita na forma de Bloch (BRILLOUIN, 1953; GONZALO *et al.*, 1999), como

$$H_k(\mathbf{r}) = e^{i\mathbf{k}\mathbf{r}} u_k(\mathbf{r}) = e^{i\mathbf{k}\mathbf{r}} u_k(\mathbf{r} + \mathbf{R}) \quad (2.8)$$

Diferentes valores de k não levam necessariamente a diferentes modos. Especificamente, o modo com vetor de onda, k e o modo com vetor de onda, $(k+\mathbf{G})$ são o mesmo modo se \mathbf{G} é o vetor da rede recíproca. Conseqüentemente, há redundância no valor de k e pode-se restringir a atenção à zona finita em espaço recíproco. Esta zona é chamada de zona de Brillouin (BRILLOUIN, 1953; KITTEL, 1996; GONZALO *et al.*, 1999).

A menor região dentro da zona de Brillouin para a qual as direções k não estão relacionadas por simetria é chamada de zona de Brillouin irredutível.

Para melhor explicar a existência da zona irredutível de Brillouin, considere um cristal fotônico com simetria quadrática, com a zona de Brillouin centrada em $k = 0$, como mostra a Fig. 2.3, tendo um vetor arbitrário r (JOANNOPOULUS *et al.*, 1995).

Neste caso, a zona irredutível de Brillouin é a área triangular mostrada na Fig. 2.4, que equivale a 1/8 da área total da zona de Brillouin (JOANNOPOULUS *et al.*, 1995).

Na Fig. 2.4, k é um vetor de onda arbitrário e, Γ , M e X são termos que correspondem aos pontos no centro, no canto e na face da zona irredutível de Brillouin. Além desta faixa triangular, há apenas cópias redundantes dentro da zona de Brillouin.




Fig. 2.3: Cristal fotônico constituído por uma rede quadrática de orifícios circulares.




Fig. 2.4: Zona irredutível de Brillouin na representação espacial recíproca.

As Fig. 2.3 e 2.4 são as representações espaciais real e recíproca para cristais bidimensionais retangulares. Um outro exemplo, desta vez para o caso de cristais fotônicos bidimensionais triangulares, é apresentado na Fig. 2.5.




Fig. 2.5: Representações espaciais real e recíproca de cristais fotônicos bidimensionais constituídos por uma rede triangular de buracos circulares.

2.2.2 Equações de Ondas em Cristais Fotônicos

Tem havido uma investigação intensa sobre a eficiência dos métodos teóricos para avaliar a relação de dispersão em cristais fotônicos. Conseqüentemente, várias técnicas numéricas têm sido propostas (JOANNOPOULUS *et al.*, 1995).

O método de onda plana, uma técnica poderosa e bem sucedida, gera vários tipos de sistemas homogêneos facilmente solucionáveis (JOANNOPOULUS *et al.*, 1995). A matriz formulada é baseada em coordenadas cartesianas, e pode ser estendida para descrever a condutividade, a absorção, e o meio ativo dos cristais fotônicos.

Restringindo-se a um meio dielétrico misto, uma composição de regiões de materiais dielétricos homogêneos, sem cargas ou correntes livres, como mostra a Fig. 2.6, os valores de ρ e J são nulos. Observa-se que a permissividade elétrica possui uma dependência posicional, r .



Fig. 2.6: Meio dielétrico misto (cristal fotônico artificial).

Considerando que o meio dielétrico é macroscópico e isotrópico, os vetores E e D são relacionados pela permissividade elétrica escalar ε . A característica não-isotrópica da estrutura EBG pode ser considerada com a inclusão da anisotropia nas equações através da dependência posicional da permissividade elétrica ε .

A dependência de frequência da permissividade elétrica é desprezada e ε é considerado real, indicando um dielétrico ideal, ou seja, os materiais das inclusões são considerados não dispersivos e sem perdas (JOANNOPOULUS *et al.*, 1995).

Com isso, as equações de Maxwell que são usadas para formular o sistema de equações para valores e vetores homogêneos no cristal fotônico, podem ser escritas como:

$$\nabla \cdot \mathbf{H}(\mathbf{r}, t) = 0 \quad (2.9)$$

$$\nabla \cdot [\bar{\varepsilon}(\mathbf{r}) \cdot \mathbf{E}(\mathbf{r}, t)] = 0 \quad (2.10)$$

$$\nabla \times \mathbf{E}(\mathbf{r}, t) = -\frac{\partial}{\partial t} \mathbf{B}(\mathbf{r}, t) \quad (2.11)$$

$$\nabla \times \mathbf{H}(\mathbf{r}, t) = \frac{\partial}{\partial t} [\bar{\varepsilon}(\mathbf{r}) \cdot \mathbf{E}(\mathbf{r}, t)] \quad (2.12)$$

Em que $\bar{\varepsilon}(\mathbf{r})$ é um tensor e os campos eletromagnéticos são funções complexas de tempo e espaço.

Entretanto, se as equações de Maxwell forem lineares, pode-se separar a dependência do tempo, expandindo-se os campos, E e H , em um conjunto de modos harmônicos. Isto não gera nenhuma limitação, pois através da análise de Fourier, a ser empregada, pode-se obter qualquer solução como uma combinação apropriada destes modos harmônicos.

O uso do teorema de Euler (POZAR, 1990), e da parte real do vetor, permite escrever um modo harmônico como um padrão de campo vezes uma exponencial complexa, como se segue:

$$\mathbf{H}(\mathbf{r}, t) = \mathbf{H}(\mathbf{r})e^{j\omega t} \quad (2.13)$$

$$E(\mathbf{r}, t) = E(\mathbf{r})e^{j\omega t} \quad (2.14)$$

Empregando-se (2.13) e (2.14) em (2.9) a (2.12), tem-se as equações para o padrão de campo de uma dada frequência:

$$\nabla \times \mathbf{H}(\mathbf{r}) = j\omega\epsilon_0 \bar{\bar{\epsilon}}(\mathbf{r}) \cdot \mathbf{E}(\mathbf{r}) \quad (2.15)$$

$$\nabla \times \mathbf{E}(\mathbf{r}) = -j\omega\mu_0 \mathbf{H}(\mathbf{r}) \quad (2.16)$$

$$\nabla \cdot \mathbf{H}(\mathbf{r}) = 0 \quad (2.17)$$

$$\nabla \cdot [\bar{\bar{\epsilon}}(\mathbf{r}) \cdot \mathbf{E}(\mathbf{r})] = 0 \quad (2.18)$$

Multiplicando-se (2.15) por $\bar{\bar{\epsilon}}(\mathbf{r})^{-1}$, e então tomando-se o rotacional, obtém-se:

$$\nabla \times (\bar{\bar{\epsilon}}(\mathbf{r})^{-1} \nabla \times \mathbf{H}(\mathbf{r})) = j\omega\epsilon_0 \nabla \times \mathbf{E}(\mathbf{r}) \quad (2.19)$$

Substituindo-se (2.16) em (2.19), tem-se:

$$\nabla \times (\bar{\bar{\epsilon}}(\mathbf{r})^{-1} \nabla \times \mathbf{H}(\mathbf{r})) = \omega^2 \epsilon_0 \mu_0 \mathbf{H}(\mathbf{r}) \quad (2.20)$$

Sendo $c = \frac{1}{\sqrt{\epsilon_0 \mu_0}}$, tem-se a equação vetorial de onda expressa inteiramente em termos de

$\mathbf{H}(\mathbf{r})$:

$$\nabla \times (\bar{\bar{\epsilon}}(\mathbf{r})^{-1} \nabla \times \mathbf{H}(\mathbf{r})) = \left(\frac{\omega}{c}\right)^2 \mathbf{H}(\mathbf{r}) \quad (2.21)$$

Resolvendo-se (2.21) para um dado cristal fotônico com permissividade elétrica conhecida, determinam-se os modos de $\mathbf{H}(\mathbf{r})$ para uma frequência de operação, sujeita a condição de transversalidade (JOANNOPOULOS *et al.*, 1995).

Para a determinação do campo elétrico, recorre-se a (2.15), como segue:

$$\mathbf{E}(\mathbf{r}) = \left(\frac{-j}{\omega \epsilon_0} \bar{\bar{\epsilon}}(\mathbf{r})^{-1} \right) \nabla \times \mathbf{H}(\mathbf{r}) \quad (2.22)$$

A solução de (2.21) leva a um problema de diagonalização de matriz padrão para valores e vetores homogêneos. Várias técnicas podem ser empregadas, como por exemplo, o Teorema variacional eletromagnético (JOANNOPOULOS *et al.*, 1995). Como solução do sistema de equações lineares, obtém-se a relação de dispersão do cristal fotônico.

2.2.3 Analogia entre os Cristais Fotônicos e os Semicondutores.

A área dos cristais fotônicos artificiais está intimamente relacionada à física do estado sólido e ao eletromagnetismo. Entretanto, no estudo dos cristais fotônicos artificiais, os elétrons são substituídos por ondas eletromagnéticas ou fótons.

Considere a equação de Schrödinger (KITTEL, 1996) para um elétron com massa efetiva m

$$\left[-\frac{\hbar^2}{2m} \nabla^2 + V(\mathbf{r}) \right] \psi(\mathbf{r}) = E \psi(\mathbf{r}) \quad (2.23)$$

onde $V(\mathbf{r})$ é o potencial elétrico, $\psi(\mathbf{r})$ é a função de onda e E é a energia do elétron. Observe que $V(\mathbf{r})$ é uma função periódica com periodicidade \mathbf{R} , como mostra a equação abaixo:

$$V(\mathbf{r}) = V(\mathbf{r} + \mathbf{R}) \quad (2.24)$$

Os autovalores da equação de onda do elétron são também funções periódicas com periodicidade \mathbf{R} . A relação de dispersão, $E(\mathbf{k})$, apresenta bandas proibidas para valores imaginários da energia do elétron, E .

Similarmente, em um meio isotrópico onde ocorre a dependência posicional da constante dielétrica, $\epsilon(\mathbf{r})$, a propagação do fóton ou onda eletromagnética é definida por (2.21) e rerepresentada a seguir

$$\nabla \times (\epsilon(\mathbf{r})^{-1} \nabla \times \mathbf{H}(\mathbf{r})) = \left(\frac{\omega}{c} \right)^2 \mathbf{H}(\mathbf{r}) \quad (2.25)$$

De forma análoga, a permissividade elétrica, $\varepsilon(\mathbf{r})$, é uma função periódica definida por:

$$\varepsilon(\mathbf{r}) = \varepsilon(\mathbf{r} + \mathbf{R}) \quad (2.26)$$

Isto demonstra o paralelismo existente entre a propagação de elétrons em sólidos cristalinos (semicondutores) e fótons ou ondas eletromagnéticas em cristais fotônicos/eletromagnéticos artificiais ou materiais EBG (JOANNOPOULUS *et al.*, 1995).

A equação diferencial (2.25) possibilita uma série de operações sobre a função $\mathbf{H}(\mathbf{r})$. Sendo $\mathbf{H}(\mathbf{r})$ um modo de propagação eletromagnética permitido, a solução de (2.25) será uma constante multiplicada pela função original $\mathbf{H}(\mathbf{r})$. Conhecida como um problema de autovalor, esta situação aparece freqüentemente na Mecânica Quântica, sendo sua solução chamada de autofunção, ou autovetor do operador, e sua constante multiplicadora é denominada de autovalor.

De modo a figurar-se como um problema de autovalor, substitui-se o lado esquerdo de (2.25) pelo operador Θ atuando sobre $\mathbf{H}(\mathbf{r})$, como mostrado abaixo,

$$\Theta \mathbf{H}(\mathbf{r}) = \left(\frac{\omega}{c}\right)^2 \mathbf{H}(\mathbf{r}) \quad (2.27)$$

onde Θ é identificado como o operador diferencial que toma o rotacional, divide por $\varepsilon(\mathbf{r})$ e então, aplica o rotacional novamente, resultando em:

$$\Theta \mathbf{H}(\mathbf{r}) \equiv \nabla \times (\varepsilon(\mathbf{r})^{-1} \nabla \times \mathbf{H}(\mathbf{r})) \quad (2.28)$$

De forma análoga ao caso dos semicondutores, a partir de (2.28), obtém-se uma equação com autovalores operando-se o Hamiltoniano na função de onda, $\psi(\mathbf{r})$. As similaridades entre o formalismo da eletrodinâmica e o da mecânica quântica estão resumidas na Tabela 2.1 (JOANNOPOULOS *et al.*, 1995).

Tabela 2.1 - Comparação entre a Mecânica Quântica e a Eletrodinâmica.

Expressões	MECÂNICA QUÂNTICA	ELETRODINÂMICA
Campo	$\Psi(\mathbf{r}, t) = \Psi(\mathbf{r})e^{j\omega t}$	$\mathbf{H}(\mathbf{r}, t) = \mathbf{H}(\mathbf{r})e^{j\omega t}$

Problema de Autovalor	$H\Psi = E\Psi$	$\Theta H = (\omega/c)^2 H$
Operador Hermitiano	$H = \frac{-(\hbar/2\pi)^2 \nabla^2}{2m} + V(\mathbf{r})$	$\Theta = \nabla \times \left(\frac{1}{\varepsilon(\mathbf{r})} \nabla \times \right)$
Simetria Translacional Discreta	$V(\mathbf{r}) = V(\mathbf{r} + \mathbf{R})$	$\varepsilon(\mathbf{r}) = \varepsilon(\mathbf{r} + \mathbf{R})$
Relações de Comutação	$[H, T_{\mathbf{R}}] = 0$	$[\Theta, T_{\mathbf{R}}] = 0$
Teorema de Bloch	$\Psi_{k\mathbf{n}}(\mathbf{r}) = u_{k\mathbf{n}}(\mathbf{r}) e^{j(\mathbf{k}\cdot\mathbf{r})}$	$H_{k\mathbf{n}}(\mathbf{r}) = u_{k\mathbf{n}}(\mathbf{r}) e^{j(\mathbf{k}\cdot\mathbf{r})}$

Da mecânica quântica vem a notação do operador Θ e algumas propriedades das autofunções do Hamiltoniano; como: possuem autovalores reais, são ortogonais, podem ser obtidas pelo princípio variacional (JOANNOPOULUS *et. al*, 1995) e são classificadas por suas propriedades simétricas. Estas propriedades estão relacionadas ao fato do operador principal ser do tipo Hermitiano (KITTEL, 1996).

Em ambos os casos, os sistemas possuem simetria translacional, na mecânica quântica o potencial, $V(\mathbf{r})$, é periódico, enquanto no caso da eletrodinâmica, a função dielétrica, $\varepsilon(\mathbf{r})$, é periódica.

Observa-se que os autovalores $(\omega/c)^2$ são proporcionais aos quadrados das frequências destes modos, cujos diagramas de campo dos modos harmônicos são representados pelos autovetores $H(\mathbf{r})$. Sendo o operador Θ linear, qualquer combinação linear das soluções será também uma solução. Esta periodicidade permite que o operador translacional discreto, $T_{\mathbf{R}}$, comute com os operadores diferenciais do problema, com o Hamiltoniano ou com Θ .

Uma diferença importante entre estes formalismos é que, na mecânica quântica, o Hamiltoniano é separável, se for possível realizar a fatoração de $V(\mathbf{r})$. Ou seja, se $V(\mathbf{r})$ for definido por um produto das funções $V_x(x)$, $V_y(y)$ e $V_z(z)$, então simplifica-se o problema de autovalor dividindo-o em três situações mais fáceis de solucionar, tendo uma equação para cada direção. Já no caso da eletrodinâmica, a fatoração não é possível, em geral, o operador diferencial Hermitiano, Θ , acopla diferentes direções mesmo se $c(\mathbf{r})$ for separável.

Esta característica torna a obtenção de soluções analíticas para a equação de onda da propagação em cristais fotônicos artificiais mais difícil. Por isso, na maioria dos problemas de formalismo envolvendo os materiais EBG empregam-se métodos numéricos,

como a técnica das diferenças finitas no domínio do tempo (FDTD, *finite difference time domain*) e o método dos elementos finitos (FEM, *finite elements method*).

2.3 MATERIAIS EBG NA FAIXA DE MICROONDAS E ONDAS MILIMÉTRICAS

Materiais com banda proibida eletromagnética, materiais EBG (*electromagnetic bandgap*), são compostos periódicos metálicos ou dielétricos que exibem bandas de transmissão e de reflexão em sua faixa de frequência de operação. Outra característica destas estruturas periódicas é a capacidade de confinamento de modos eletromagnéticos dentro de uma zona proibida (*gap*), por meio da introdução de estados irregulares (*defect*) na rede periódica.

Estas estruturas foram inicialmente empregadas em aplicações ópticas, como por exemplo, em espelhos ópticos de alta qualidade ou microcavidades (JOANNOPOULUS *et al.*, 1995), sendo utilizados no desenvolvimento de *lasers* semicondutores eficientes.

Devido ao grande número de aplicações na região óptica, bem como às semelhanças entre os dispositivos de microondas e ópticos, as estruturas EBG são também denominadas estruturas PBG (*photonic bandgap*), não importando para qual faixa de frequências foram projetadas. A terminologia própria destas estruturas, na faixa de microondas, é ainda motivo de controvérsia e discussão (OLINER, 1999).

A denominação estrutura de banda proibida fotônica, estrutura PBG, pode induzir involuntariamente à idéia de que tais estruturas se aplicam somente a fótons operando na região óptica. Como visto na seção 2.2, esta idéia é falsa, pois, toda a análise do cristal fotônico artificial foi baseada na propagação de ondas eletromagnéticas em meio dielétrico misto. Por isso, preferiu-se estabelecer, ao longo deste trabalho, a denominação estruturas EBG para as aplicações no domínio de microondas e ondas milimétricas e a denominação estrutura PBG para aplicações na região óptica.

Uma das primeiras aplicações do material EBG no regime de microondas, foi como o substrato de uma antena planar (BROWN *et al.*, 1993). As bandas proibidas presentes no material substrato EBG, impedem a penetração da radiação, melhorando a radiação na direção desejada. Outra aplicação vantajosa do material EBG em antenas, está no melhoramento do ganho de circuito impresso de antena por meio da supressão de ondas de superfícies (COCCIOLI *et al.*; GONZALO *et al.*, 1999; YANG H. *et al.*, 1997; YANG e

WANG, 2001; YOUNG *et al.*, 2001), por meio da supressão dos modos superiores (HORII e TSUTSUMI, 1999) e por meio da concentração ou confinamento de energia sobre a antena (AGI *et al.*, 2002). Há ainda aplicações no campo de antenas diretivas, em que, o refletor parabólico utiliza a faixa de frequências de rejeição do material EBG para focalizar ondas eletromagnéticas (THÉVENOT *et al.*, 1999).

As estruturas EBG têm sido empregadas no projeto de filtros, de banda estreita (LENOIR *et al.*, 1998; LENOIR *et al.*, 2001; RADISIC *et al.*, 1998; XUE *et al.*, 2000), de banda larga (KIM e SEO, 2000; RUMSEY *et al.*, 1998), como também, com ajuste multifrequência (LASO *et al.*, 2000), devido à sua inerente faixa de frequência de rejeição.

Em guias de ondas, as estruturas EBG são utilizadas como paredes laterais internas, permitindo uma distribuição mais uniforme da intensidade do campo elétrico ao longo da seção transversal de guias retangulares (HIGGINS *et al.*, 1999; YANG F. *et al.*, 1999b), o que é requerido em projetos de arranjos amplificadores acoplados espacialmente. Também são empregadas em filtros de guia de ondas monolíticos (KYRIAZIDOU *et al.*, 2001), em filtros de guia de ondas dielétrico (CHANG e HSU, 2002) e em comutadores de guia de ondas metálico (DANGLLOT *et al.*, 1999), tornando-os mais compactos e de confecção mais simples. Em guias de ondas de placas paralelas, a introdução de estruturas EBG elimina os modos de placas paralelas indesejados presentes em estruturas blindadas (DAWN *et al.*, 2002).

As estruturas EBG são também incorporadas às mais diversas linhas de transmissão, como as linhas coplanares e linhas de fendas para funcionarem como filtros e ressoadores de microondas (CHEW e ITOH, 2001; FU *et al.*, 2001; MARTÍN *et al.*, 2002; YUN e CHANG, 2001), e como as linhas de microfita adjacentes e cruzadas, reduzindo as interferências e melhorando a comutação entre as portas (LEONG *et al.*, 2002).

Outras aplicações das estruturas EBG produzem o aprimoramento da potência em amplificadores banda larga (RADISIC *et al.*, 1998; YOON e SEO, 2001), o aumento do fator de ondas lentas em linhas de microfita (YANG F. *et al.*, 1998; YANG F. *et al.*, 1999a), na confecção de filtros constituídos por *finlines* (LENOIR *et al.*, 1999), na redução do tamanho e aumento da eficiência em osciladores (XUE *et al.*, 2001) e em linhas de microfita curvadas empregadas na confecção de anéis híbridos de ondas lentas com tamanho reduzido (SHUM *et al.*, 2001).

Além de todos os dispositivos citados, as estruturas EBG começam a ser empregadas em aplicações mais sofisticadas, como as linhas de microfita com camadas

múltiplas e camadas anisotrópicas (CALOZ e ITOH, 2002), e em plataformas de integração entre guias de onda retangulares e linhas de microfita (DESLANDES e WU, 2001).

Acrescenta-se que a principal desvantagem no uso de estruturas EBG está relacionada com a maior complexidade no processo de fabricação dos dispositivos, por conta da presença de arranjos periódicos de elementos com formas diversas.

As técnicas de análise dos dispositivos de microondas com estruturas EBG são, em sua maior parte, técnicas numéricas, devido à complexidade destas estruturas, já mencionadas na seção anterior. Dentre as técnicas analíticas, pode-se citar o método da expansão de onda plana (JOANNOPOULOS *et al.*, 1995) e o método dos modos acoplados (LOPETEGI *et al.*, 2002). Já entre as várias técnicas numéricas, destacam-se: o método da equação integral em conjunção com o método dos momentos (YANG H. *et al.*, 1997; YANG e WANG, 2001), o método das diferenças finitas no domínio espectral (FDFD, *finite difference frequency domain*) (ALVES e SOBRINHO, 2001; YANG H., 1996) e o método dos elementos finitos (FEM, *finite elements method*) (LENOIR *et al.*, 1998, LENOIR *et al.*, 2001).

Entretanto, a maior parte das simulações de dispositivos com estruturas EBG são realizadas por meio da técnica das diferenças finitas no domínio do tempo (FDTD, *finite difference time domain*) (KUNZ e LUEBBERS *et al.*, 1993). Isto se deve à sua grande versatilidade e à sua capacidade de obter a resposta em frequência usando a convencional FFT (*fast Fourier transform*) (ANAYA *et al.*, 2000).

Em geral, os métodos numéricos aplicados na determinação do diagrama de dispersão de dispositivos de microondas requerem um esforço computacional considerável (COCCIOLI e ITOH, 1998). No caso das estruturas EBG que são constituídas, em geral, por elementos (cilíndricos) cravados em superfícies (metálicas ou dielétricas) e dispersos de maneira periódica em uma, duas ou três dimensões; esta tarefa computacional é sensivelmente aumentada, pois precisam ser consideradas várias direções de propagação das ondas eletromagnéticas (MERRILL *et al.*, 1999). Realmente, uma completa caracterização de um meio preenchido periodicamente (estrutura EBG) exige a aplicação de métodos de onda completa (*full-wave analysis*) ao longo das margens da zona de Brillouin dentro do espaço recíproco (COCCIOLI e ITOH, 1998).

Fórmulas analíticas aproximadas podem ser obtidas para estimar o valor da constante de rede do preenchimento periódico, de modo a definir a frequência central da

faixa de rejeição (*bandgap*) de algumas configurações de estruturas EBG (COCCIOLI e ITOH, 1998). Além disso, pode-se utilizar a metodologia do escalonamento para especificar alguns parâmetros estruturais dos substratos EBG de modo a obter as características de dispersão desejadas. Os detalhes destes procedimentos são abordados posteriormente na seção 2.5.

Uma alternativa excelente em relação às laboriosas análises de onda completa e aos imprecisos métodos de projeto empíricos com tentativa e erro, são as técnicas neurocomputacionais. Recentemente, as redes neurais artificiais têm emergido como ferramentas poderosas para modelagem de dispositivos de microondas (CHRISTODOULOU e GEORGIPOULOS, 2001; ZHANG e GUPTA, 2000). Uma nova metodologia neurocomputacional, a Rede Neural Artificial Função *Sample* (SF-ANN, *Sample Function Artificial Neural Network*), é empregada eficientemente na simulação de diversos dispositivos e circuitos de microondas com estruturas EBG (FERNANDES *et al.*, 2002a, 2002b, 2002c, 2003; SILVA *et al.*, 2002), sendo detalhada no Capítulo 3.

2.4 CLASSIFICAÇÃO DAS ESTRUTURAS EBG

As estruturas EBG possuem diversas configurações em dispositivos de microondas e óptica. Os seus elementos periódicos podem ser metálicos, dielétricos, dielétrico-magnéticos, ferromagnéticos, ferroelétricos ou ainda, constituídos por dispositivos ativos; podendo ser implantados no plano de terra, no substrato ou superstrato, em diferentes formatos: esféricos, cilíndricos, triangulares ou mistos. Além disso, as características da faixa de rejeição podem ser controladas por corrente elétrica, tensão de polarização ou emissão de luz (YANG H., 1999).

Devido a esta grande variedade, a classificação das estruturas EBG não é uma tarefa fácil. Uma sugestão é utilizar, como parâmetro de classificação, o lugar ocupado pela matriz de elementos periódicos (KRETLY *et al.*, 2000), nas formas apresentadas a seguir:

A. Configuração EBG-D

Uma das primeiras configurações a serem empregadas (BROWN *et al.*, 1993) consiste na perfuração da matriz de elementos periódicos no substrato do dispositivo ou circuito, EBG-D (*electromagnetic bandgap dielectric*). A Fig. 2.7 exemplifica uma aplicação da estrutura EBG-D, em uma linha de microfita.




Fig. 2.7: Linha de microfita com estrutura EBG-D bidimensional.

Neste caso, foi demonstrado que a utilização da estrutura EBG-D possibilitou a eliminação da propagação de ondas de superfície (YANG H., 1996) e de operação como filtro em circuito de microfita (RUMSEY *et al.*, 1998), entre outras habilidades.

Outro exemplo de aplicação deste tipo de configuração é em antenas planares. Neste caso, a estrutura EBG-D possibilita um aumento no ganho da antena (YANG H. *et al.*, 1997; YANG e WANG, 2001).

B. Configuração EBG-GP

Nas estruturas EBG-GP (*electromagnetic bandgap ground plane*), a matriz de elementos periódicos está implantada no plano de terra dos dispositivos. A Fig. 2.8 exemplifica uma das primeiras aplicações da estrutura EBG-GP em linhas de microfita para funcionar como filtros de microondas (RADISIC *et al.*, 1998).




Fig. 2.8: Linha de microfita com estrutura EBG-GP.

Esta configuração apresenta melhor compatibilidade com a tecnologia empregada na fabricação de circuitos monolíticos quando comparada com as estruturas EBG-D.

Podem-se citar outros exemplos de aplicações das estruturas EBG-GP em linhas de ondas lentas (YANG F. *et al.*, 1998), em filtros de banda larga (KIM e SEO, 2000), em filtros com ajuste multifrequencial (LASO *et al.*, 2000) e em linhas de microfita adjacentes e interceptadas (LEONG *et al.*, 2002).

C. Configuração EBG-TP

Na configuração EBG-TP (*electromagnetic bandgap top plane*) tem-se a matriz de elementos periódicos distribuída no mesmo plano ou no plano superior do dispositivo. Nesta classe de estruturas EBG a variedade de formas dos elementos periódicos é vasta e o número de aplicações é acentuado.

Como exemplos de dispositivos que empregam estruturas EBG no seu plano superior pode-se citar o guia de ondas de filmes finos (YI *et al.*, 1999) e o guia de ondas de placas paralelas (DAWN *et al.*, 2002). Para o caso de dispositivos que utilizam estruturas EBG no mesmo plano tem-se: a estrutura unipolar compacta em antenas de microfita (SHARMA *et al.*, 2001) e a estrutura de células hexagonais empregada em amplificadores quase-ópticos (HIGGINS *et al.*, 1999).

A Fig. 2.9 apresenta um exemplo de uma configuração EBG-TP (SHARMA *et al.*, 2001).




Fig. 2.9: Antena *patch* de microfita com estrutura EBG-TP.

Uma variação dos modelos de estrutura EBG é a promissora estrutura EBG uniplanar compacta (EBG-UC). Este novo tipo de estrutura possui diversas aplicações

como a aplicação a um guia coplanar com plano de terra (CB-CPW, *condutor backed coplanar waveguide*) (YANG F. *et al.*, 1999a). Neste caso, a estrutura EBG-TP reduz a perda de potência por meio da eliminação dos modos superiores.

A estrutura EBG uniplanar compacta, EBG-UC também tem sido empregada em outras configurações, por exemplo, a configuração EBG-D em antenas *patch* (COCCIOLI *et al.*, 1999) e a configuração EBG-GP em filtros de microfita compactos (YANG F. *et al.*, 1999) e em linhas de fita (MA *et al.*, 1999).

A geometria da estrutura EBG-UC-TP consiste de uma rede periódica de células unitárias podendo ser gravada sobre um substrato dielétrico apoiado em uma placa condutora, como mostra a Fig. 2.10, ou ser impressa em um plano de terra, como mostra a Fig. 2.11.

A célula unitária da estrutura EBG-UC-TP é formada por uma chapa metálica quadrada acoplada a 4 ramos estreitos com reentrâncias, como mostra a Fig. 2.12.

A estrutura EBG-UC-TP, representada pela Fig. 2.11, funciona como um circuito LC distribuído com frequência de ressonância específica. Enquanto as fendas entre as células unitárias realizam o acoplamento capacitivo, os ramos condutores respondem pelo comportamento indutivo, que é aumentado pelas reentrâncias. Na frequência de ressonância, que corresponde à frequência central do circuito rejeita-faixa, a carga periódica torna-se um circuito aberto, o que equivale a uma parede magnética.




Fig. 2.10: Rede de elementos periódicos (EBG-UC-TP) gravados sobre substrato dielétrico.




Fig. 2.11: Rede de elementos periódicos (EBG-UC-TP) impressos no plano de terra.




Fig. 2.12: Esquema da célula unitária EBG-UC-TP.

No caso da estrutura EBG-UC-TP, representada pela Fig. 2.10, suas seções estreitas, juntamente com as suas reentrâncias conectadas, introduzem uma indutância adicional, enquanto suas fendas entre as células adjacentes aumentam a capacitância vista pelo dispositivo. Estes elementos reativos em série, combinados com as capacitâncias em paralelo, determinam a constante de propagação, que é claramente mais elevada que em uma microfita convencional.

As vantagens de aumentar a constante de propagação, β , pela adição dos elementos indutivos e capacitivos e que as perdas no condutor não são acrescidas devido à confecção da estrutura EBG-UC-TP no plano de terra, onde não há densidade de corrente, contribuem para que este dispositivo seja empregado na construção de dispositivos de ondas lentas de baixas perdas que são empregados em circuitos integrados de microondas.

Uma outra vantagem da estrutura EBG-UC-TP é a possibilidade de confecção de MICs mais compactos. Uma vez que a frequência central da faixa de rejeição, ou de ressonância, pode ser aproximada pela condição $\beta.a = \pi$, o aumento do valor da constante de propagação permite que a frequência de corte possa ser diminuída sem o aumento do espaçamento entre os elementos periódicos, a , o que acarretaria estruturas maiores.

2.5 METODOLOGIA DE PROJETO DE ESTRUTURAS EBG

Estruturas EBG têm-se tornado muito populares devido ao grande número de aplicações para supressão do modo de transmissão e de radiações indesejáveis, ou seja, devido à sua versatilidade no controle da propagação eletromagnética.

Estes materiais podem ser construídos para uma dada geometria, com dimensões milimétricas para o controle de microondas, ou com dimensões micrométricas para o controle óptico.

Os parâmetros importantes para efetuar o projeto destas estruturas, de modo a controlar o aparecimento das bandas proibidas e a caracterização da operação do dispositivo, são as seguintes variáveis independentes (GONZALO *et al.*, 1999):

- 1) O espaçamento entre os centros dos elementos periódicos da estrutura EBG, a ;
- 2) A forma, o tamanho e a quantidade de elementos periódicos.
- 3) Fator de preenchimento, *fill factor*, que é dado pela razão entre o volume dos elementos na célula unitária e o volume da própria célula. Nos casos de material EBG constituído por elementos circulares em arranjos triangulares e em arranjos retangulares, por exemplo, as razões de preenchimento, Λ , são definidas, respectivamente, como:

$$\Lambda = \frac{2\pi}{\sqrt{3}} \left(\frac{r}{a} \right)^2 \quad (2.29)$$

$$\Lambda = \pi \left(\frac{r}{a} \right)^2 \quad (2.30)$$

em que r é o raio dos orifícios periódicos cravados no dielétrico ou no plano de terra do dispositivo (COCCIOLI e ITOH, 1998).

- 4) Os valores das constantes dielétricas dos materiais constituintes, especificamente, o contraste entre estas constantes dielétricas.

O projeto ideal de um dispositivo EBG em relação à dispersão depende de uma combinação específica dessas variáveis. Estabelecer uma metodologia de projeto para todas as estruturas EBG, não é simples, devido à influência de todos estes parâmetros e das diversas configurações existentes, já mencionadas. Além disso, para uma análise precisa destas estruturas EBG, são necessários métodos de onda completa.

A. Fórmulas aproximadas

Apesar de precisão limitada, algumas fórmulas analíticas para configurações EBG-D e EBG-GP sob certas condições são propostas (COCCIOLI e ITOH, 1998). Estas expressões fornecem valores aproximados para projetos e que podem ser empregados como ponto de partida em análises de onda completa.

Considerando pequenas alterações na estrutura EBG, ou seja, para diminutos valores da razão r/a , a constante de propagação, β , do dispositivo EBG pode ser definida usando a constante de propagação do dispositivo convencional. Esta particularidade é útil devido à dificuldade em obter a constante de propagação em dispositivos com estruturas EBG.

Portanto, uma aproximação para o valor do período, a , de um estrutura EBG pode ser escrito em função da constante de propagação, β , (COCCIOLI e ITOH, 1998), como:

$$a = \frac{2\pi}{\sqrt{3}\beta(f_0)} \quad (2.31)$$

em que f_0 é a frequência central que, no caso de linha de microfita, é o centro da faixa de rejeição, e, no caso de antenas, refere-se ao modo harmônico a ser eliminado.

Em (2.31) β é definido como:

$$\beta = \frac{2\pi}{\lambda_g} \quad (2.32)$$

sendo λ_g o comprimento de onda guiado. Pode-se expressar o período, a , em função do comprimento de onda, λ_g , como descrito a seguir:

$$a = \frac{\lambda_g}{\sqrt{3}} \quad (2.33)$$

A expressão acima é aproximada, em alguns trabalhos (RADISIC *et al.*, 1998; KIM e SEO, 2000; YUN e CHANG, 2001), para a seguinte expressão:

$$a = \frac{\lambda_g}{2} \quad (2.34)$$

O comprimento de onda guiado, λ_g , é dado pela expressão abaixo,

$$\lambda_g = \frac{c}{f \sqrt{\epsilon_{eff}}} \quad (2.35)$$

onde ϵ_{eff} é a constante dielétrica efetiva do meio para o modo considerado e c é a velocidade da onda no vácuo ($3,0 \times 10^8$ m/s).

No caso particular do projeto de estrutura EBG-GP, uma vez que o substrato não é perfurado por elementos periódicos, pode ser considerada a identidade $\epsilon_{eff} = \epsilon_r$, onde ϵ_r é a constante dielétrica real (COCCIOLI e ITOH, 1998).

Como pode ser observado, o valor da frequência central da faixa de rejeição, f_0 , depende basicamente do período, a (RADISIC *et al.*, 1998).

Outras características do diagrama de dispersão do dispositivo, como a largura e a intensidade da faixa de rejeição, dependem do tamanho do raio dos elementos periódicos e do número de elementos periódicos que compõem a estrutura EBG (MAYSTRE, 1994; RADISIC *et al.*, 1998).

B. Escalonamento

Outra técnica empregada com aproximação inicial para projetos de estruturas EBG é o escalonamento (OLIVEIRA, 2001; RUMSEY, 1998).

Na mecânica quântica, os potenciais possuem uma escala fundamental de dimensões, definida como o raio de Bohr (OLIVEIRA, 2001). No eletromagnetismo não existe uma dimensão fundamental mínima, assim todas as grandezas (sistemas) podem ser consideradas macroscópicas. Esta característica possibilita a solução aproximada de problemas eletromagnéticos relacionados realizando a contração ou expansão de grandezas por meio de relações simples.

Este fato facilita o projeto de dispositivos com dimensões micrométricas que trabalham no regime óptico, através da geração de modelos escalonados com dimensões maiores, trabalhando na faixa de microondas. Estes modelos podem ser mais facilmente fabricados e testados, e posteriormente seus resultados e considerações estabelecidas podem ser direcionados para o dispositivo real na região óptica.

Por exemplo, em projetos de dispositivos EBG, a técnica do escalonamento utiliza uma estrutura EBG confeccionada ou com comportamento eletromagnético conhecida, que funcione em uma determinada frequência f_i e realiza-se o escalonamento de suas

dimensões r_1 e a_1 , para uma nova frequência f_2 , obtendo-se as dimensões da nova estrutura EBG, como exemplificado na relação abaixo (RUMSEY, 1998):

$$\begin{bmatrix} a_2 \\ r_2 \end{bmatrix} = \frac{f_1}{f_2} \cdot \begin{bmatrix} a_1 \\ r_1 \end{bmatrix} \quad (2.36)$$

2.6 FABRICAÇÃO E CARACTERIZAÇÃO DE DISPOSITIVOS EBG

Foram desenvolvidos filtros planares usando a tecnologia EBG de modo a verificar a viabilidade de fabricação em laboratório e comprovar as características destas estruturas.

Os filtros planares foram confeccionados e analisados com materiais e equipamentos disponíveis no CEFET-PB, mais precisamente no Laboratório do GTEMA (Grupo de Telecomunicações e Microondas Aplicadas).

O projeto realizado para um filtro de microondas com estrutura EBG-GP foi dividido nas etapas seguintes:

1. Definição das características do substrato.
2. Projeto da linha de microfita.
3. Projeto da estrutura EBG-GP para 5 GHz.
4. Diagrama (*layout*) do circuito impresso.
5. Fabricação: corte, serigrafia e corrosão.
6. Fabricação dos acopladores.
7. Montagem do experimento e medição.
8. Elaboração dos resultados em gráficos.

O material empregado como substrato nas estruturas EBG foi a fibra de vidro. Este material possui $\epsilon_r = 4,5$; $\tan \delta = 0,001$ e espessura $h = 1,6$ mm.

Os filtros planares foram desenvolvidos usando a tecnologia EBG-GP apresentada na seção 2.4 em linhas de microfita. A estrutura EBG consiste de uma rede periódica quadrada bi-dimensional com três filas de nove círculos encravados no plano de terra de linha de microfita (RADISIC *et al.*, 1998). A estrutura EBG-GP foi escolhida por apresentar simplicidade de fabricação.

No dimensionamento das estruturas EBG foram empregadas fórmulas aproximadas indicadas em (2.32) e (2.34). Portanto, para uma frequência de operação em torno de 5 GHz, tem-se o espaçamento entre os orifícios periódicos, a , aproximadamente igual a 16 mm. As dimensões da linha de microfita são 28 mm de comprimento e 2,82 mm de

largura. Foram confeccionadas quatro estruturas EBG-GP em linhas de microfita com raios de 2mm, 4mm, 4mm e 6mm, como mostrado na Fig. 2.13. As duas linhas de microfita centrais, o segundo e o terceiro filtro, possuem estruturas EBG de mesmo raio, mas com posicionamento diferente da microfita em relação aos orifícios periódicos implantados no plano de terra.

Na fabricação dos filtros de microondas foram empregadas técnicas tradicionais de circuito impresso para transferência dos padrões (corrosão seletiva do cobre por cloreto de ferro).

Os conectores tipo N estão fixados em suporte de alumínio como mostrado na Fig. 2.14. Estes são conectados às extremidades da linha de microfita como indicado na Fig. 2.15.

As medidas de parâmetros de espalhamento dos filtros EBG-GP foram realizadas utilizando um analisador de redes escalar HP 8257 Agilent e um gerador de varredura. A utilização deste analisador de redes facilita a medição das estruturas, pois, todo o processo de calibração e medidas é feito automaticamente. O *layout* da montagem do experimento e da obtenção de resultados medidos está apresentado na Fig. 2.16.




Fig. 2.13: Protótipos de filtros planares utilizando a tecnologia EBG-GP. Da esquerda para direita os raios são 2 mm, 4 mm, 4 mm e 6 mm. A segunda e a terceira estrutura diferem

apenas em relação ao posicionamento da fita condutora, centrada e deslocada em metade do raio, respectivamente.




Fig. 2.14: Conectores tipo N em suporte de alumínio.




Fig. 2.15: Detalhe da conexão entre os conectores tipo N e a linha de microfita EBG.




Fig. 2.16: Layout do experimento para a caracterização de filtros EBG-GP.

A. Resultados Medidos para os Filtros Planares EBG-GP

Após as várias etapas do projeto e fabricação dos filtros de microondas, constituídos por linhas de microfita com estruturas EBG-GP, foram obtidos resultados experimentais, como mostra a Fig. 2.17.

Os filtros EBG-GP apresentam uma banda proibida com atenuações que variam de -30 dB a -62 dB, e larguras variando de 1,5 GHz a 3,5 GHz dependendo do raio dos orifícios periódicos formados da estrutura EBG no plano de terra da linha de microfita. Ou seja, quanto maior o raio dos elementos periódicos maior será a atenuação e largura da banda proibida (*bandgap*).

Verificou-se também que a frequência central do *bandgap* imposta pela estrutura EBG-GP que é aproximadamente 5,2 GHz, está muito próxima da frequência central projetada que foi de 5 GHz. Isto foi atribuído ao grau de adequação das fórmulas aproximadas empregadas, apresentadas em (2.33) e (2.35), às estruturas analisadas.




Fig. 2.17: Resultados medidos para os filtros EBG-GP fabricados e apresentados na Fig. 2.13. Resultados experimentais para a estrutura EBG-GP com raio de 2 mm e alimentação centralizada (ooo), com raio de 4 mm e alimentação deslocada em metade do raio (+++), com raio de 4 mm e alimentação centralizada (+++), com raio de 6 mm e alimentação centralizada (***).

De um modo geral, algumas regras de projeto de estruturas EBG que foram pesquisadas na literatura especializada (OLIVEIRA, 2001; RADISIC *et al.*, 1998; YANG F. *et al.*, 2000) podem ser listadas

- A frequência central da banda proibida (*bandgap*) é função do espaçamento dos elementos periódicos, a . Ou seja, quanto maior a menor a frequência central, f_0 ;
- A largura da banda proibida está diretamente relacionada a razão r/a e ao número de elementos periódicos existentes na estrutura. Quanto maior a razão r/a ou o número de elementos maior a largura da banda proibida;
- O grau da atenuação imposta pela estrutura EBG em torno da frequência central da banda proibida é relacionada diretamente ao raio dos elementos periódicos, r . Ou seja, quanto maior o raio, r , maior a atenuação da banda proibida (*bandgap*).

2.7 CONCLUSÃO

Neste capítulo, foi apresentado um detalhamento das características e aplicações das estruturas EBG, objetivando a formação de um cenário geral destas estruturas utilizadas não só na banda óptica, como também em dispositivos e circuitos na faixa de microondas e ondas milimétricas.

Uma análise do comportamento destas novas estruturas periódicas, cristais fotônicos/eletromagnéticos artificiais, foi realizada juntamente com uma analogia aos cristais naturais (semicondutores). Foram destacados alguns parâmetros empregados no dimensionamento destas estruturas para a obtenção de desempenho específico. Dentre eles, o fator de preenchimento, a razão r/a , raio e espaçamento dos orifícios que fundamentalmente definem a região onde se localiza a faixa de rejeição.

Suas principais configurações foram abordadas e classificadas segundo o posicionamento da matriz de elementos periódicos. São elas: a estrutura EBG-D, onde a matriz encontra-se implantada no substrato dielétrico; a estrutura EBG-GP, onde a matriz está cravada no plano de terra; e a estruturas EBG-TP, onde a matriz de elementos periódicos está localizada acima ou no mesmo nível do dispositivo.

A metodologia básica de projeto para estruturas EBG-GP e EBG-D foi apresentada. Os dois métodos consistem na utilização de fórmulas aproximadas ou no emprego do processo de escalonamento.

Além disso, foram fabricados e caracterizados filtros planares usando a tecnologia EBG-GP. Para isto, foram empregados equipamentos e materiais do Laboratório do GTEMA no CEFET-PB. Os resultados medidos concordaram com os valores e parâmetros dimensionados.

CAPÍTULO 3

REDES NEURAIS ARTIFICIAIS

3.1 INTRODUÇÃO

A análise precisa de dispositivos e de circuitos de microondas, geralmente, requer a utilização de técnicas que demandam um esforço computacional considerável, como o método da equação integral, ou a técnica das diferenças finitas no domínio do tempo – FDTD, ou o método dos elementos finito – FEM, entre outras.

Como uma das alternativas viáveis apresentam-se as técnicas neurocomputacionais. A característica de poder ser treinada para aplicações bastante diferentes tem permitido o uso das redes neurais em uma vasta gama de áreas como Engenharia, Computação, Estatística, Biologia, Medicina, Economia e Administração, dentre outras (HAYKIN, 2001).

A técnica de projeto auxiliado por computador (CAD, *computer aided design*), baseada em redes neurais, tem sido introduzida, em meados da década de 90, na a modelagem de circuitos integrados de microondas (VAI e PRASAD, 1995; ZAABAB *et al.*, 1995). Um aumento significativo na velocidade de processamento é alcançado através do uso de modelos neurais para CAD, quando comparado aos modelos físicos eletromagnéticos em simulações de circuitos integrados de telecomunicações.

A intensificação recente da aplicação das redes neurais em várias áreas da engenharia de telecomunicações vem constituindo-se numa excelente opção para a análise e síntese de circuitos e dispositivos, funcionando na faixa de microondas e de ondas milimétricas (CHRISTODOULOU e GEORGIPOULOS, 2001; GUPTA, 1998; ZHANG e GUPTA, 2000; ZHANG e GUPTA, 2003).

As redes neurais possuem como características principais: a aplicação geral, a adaptabilidade e a habilidade de generalização, que têm contribuído para enquadrá-las como técnicas vantajosas e capazes de modelar diversos dispositivos e circuitos de microondas, tais como: linhas de transmissão (PATNAIK *et al.*, 1997; WANG *et al.*, 1998; WATSON e GUPTA, 1996), circuitos CPW (WATSON e GUPTA, 1997), alimentadores de antenas tipo corneta (FEDI *et al.*, 2001), transistores e amplificadores (WANG e ZHANG, 1997), indutores espirais (CREECH *et al.*, 1997), filtros (BANDLER *et al.*, 1999) e antenas (MISHRA e PATNAIK, 1998; SMITH *et al.*, 1996; SOUTHALL *et al.*, 1995; WASHINGTON, 1997).

Nos últimos anos, tem-se observado uma intensa investigação científica das características e vantagens obtidas pelo emprego de redes neurais. Isto contribuiu para o surgimento de novas e avançadas técnicas neurocomputacionais (BANDLER *et al.*, 1999; DEVABHAKTUNI *et al.*, 2001; XU, 2002).

Neste capítulo, são descritas as características, metodologia e aplicações dos mais populares tipos de redes neurais aplicadas na área de microondas. A primeira rede a ser detalhada é o *perceptron* de múltiplas camadas (MLP, *multilayer perceptron*), juntamente com o algoritmo de aprendizagem mais utilizado, a retropropagação do erro (*backpropagation*). A segunda rede descrita é rede neural de funções de base radial (RBF, *radial-basis functions*).

Também é apresentada, neste capítulo, uma variação do tipo de rede neural, a Rede Neural Modular Função *Sample* (SF-ANN, *Sample function artificial neural network*) proposta nesta Tese. O desenvolvimento da metodologia SF-ANN é voltado para a modelagem de circuitos de telecomunicações, em especial, aos dispositivos de microondas usando estruturas EBG (FERNANDES *et al.*, 2002a, 2002b, 2002c, 2003a, 2003b; SILVA, FERNANDES e NETO *et al.*, 2002). Esta se mostra bastante precisa e computacionalmente eficiente quando aplicada nas simulações dos dispositivos EBG analisados neste trabalho.

3.2 DESCRIÇÃO, METODOLOGIA E CARACTERÍSTICAS DA ANN

3.2.1 Preliminares

A rede neural artificial (ANN, *artificial neural network*), ou simplesmente rede neural, é um sistema de processamento de informação constituído por vários processadores

elementares com pequena capacidade de armazenamento agrupados em camadas. Sua metodologia (projeto) é inspirada no funcionamento do cérebro em dois aspectos: a capacidade de adquirir conhecimento através de um processo de aprendizagem e o armazenamento deste conhecimento na forma de intensidade das conexões inter neuronais denominadas pesos sinápticos (HAYKIN, 2001). Entretanto, estas semelhanças são diminutas e servem apenas para uma abordagem inicial, pois o funcionamento do cérebro humano é bem mais complexo e abstrato.

A metodologia básica de aprendizagem de modelos de rede neural artificial está representada na Fig. 3.1.

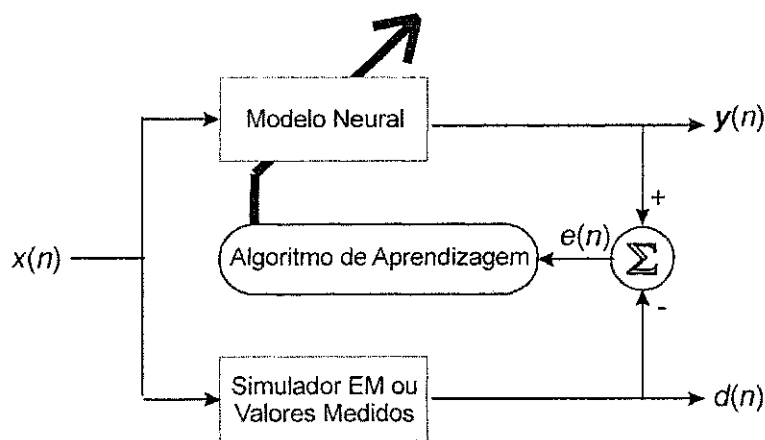


Fig. 3.1: Metodologia básica de aprendizagem de uma rede neural artificial - ANN.

De uma maneira geral, a metodologia de uma rede neural artificial, ANN, consiste na apresentação de um conjunto de dados de entrada, $x(n)$, ao modelo neural. Em seguida, aplica-se a estratégia de aprendizagem por meio da correção do erro entre a saída do modelo neural, $y(n)$, e saída desejada, $d(n)$, de modo a otimizar a função custo, $e(n)$, através da implementação dos algoritmos de treinamento supervisionados (WATSON e GUPTA, 1996).

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.

Uma das características das ANNs é a independência em relação ao conhecimento prévio da forma analítica da relação entre os parâmetros de entrada e saída de um sistema qualquer.

Os modelos usando redes neurais são desenvolvidos a partir de um conjunto adequado de treinamento composto por dados obtidos por simulação eletromagnética, ou por medições experimentais. Após o processo de treinamento, as redes neurais aprendem fundamentalmente o mapeamento de entrada e saída do dispositivo ou circuito. Observe-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 o resultado da sua estrutura intensivamente paralela e sua capacidade de aprendizagem e generalização. Neste caso, a 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 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) de circuitos de microondas e ondas milimétricas (CHRISTODOULOU e GEORGIOPOULOS, 2001; GUPTA, 1998; ZHANG e GUPTA, 2000).

3.2.2 Unidade de Processamento de Informação da ANN

Uma rede neural artificial, ANN, é constituída por várias unidades básicas de processamento de informação, denominadas de neurônios artificiais. O modelo deste neurônio artificial, proposto pelo fisiologista McCulloch e pelo matemático Pitts em 1943, está representado na Fig. 3.2.




Fig. 3.2: Modelo de um neurônio artificial.

Em um neurônio genérico k , representado na Fig. 3.2, podem ser identificados três elementos: um conjunto de pesos sinápticos, $w_{k1}, \dots, w_{kj}, \dots, w_{kJ}$; um somador para a adição dos sinais de entrada, $x_1, \dots, x_j, \dots, x_J$, ponderados pelos respectivos pesos sinápticos; e uma função de ativação, $g(\)$, para limitar a amplitude de saída do neurônio, y_k , dentro de intervalo permissível, tipicamente entre 0 e 1.

Há também no modelo do neurônio genérico k , a aplicação de uma polarização externa ou bias, b_k , que aumenta ou diminui o argumento da função de ativação, ou seja, ajusta o campo local induzido ou potencial interno do neurônio, v_k , dependendo se ele for positivo ou negativo.

Em termos matemáticos, pode-se descrever o funcionamento de um neurônio artificial genérico k de uma rede neural através das seguintes expressões (CHRISTODOULOU e GEORGIPOULOS, 2001):

$$v_k = \sum_{j=1}^J w_{kj} x_j - b_k \quad (3.1)$$

$$y_k = g(v_k) \quad (3.2)$$

A definição do tipo de função de ativação, $g(\cdot)$, é uma das partes mais importantes no projeto de uma rede neural. Conseqüentemente, uma variedade de funções de ativação tem sido proposta no desenvolvimento de redes neurais.

Os três tipos básicos de funções de ativação são:

A. Função de limiar

$$g(v) = \begin{cases} 1: & \text{se } v \geq 0 \\ 0: & \text{se } v < 0 \end{cases} \quad (3.3)$$

B. Função linear por partes

$$g(v) = \begin{cases} 1: & \text{se } v \geq 1/2 \\ v: & \text{se } 1/2 > v > -1/2 \\ 0: & \text{se } v \leq -1/2 \end{cases} \quad (3.4)$$

C. Função sigmóide (logística)

$$g(v) = \frac{1}{1 + \exp(-av)} \quad (3.5)$$

em que a é o parâmetro de inclinação da função sigmóide (logística). Outro exemplo de função sigmóide é a função tangente hiperbólica, $\tanh(v)$.

3.2.3 Arquiteturas de Redes Neurais

A estrutura das ligações entre os neurônios artificiais está estritamente relacionada com o algoritmo de aprendizagem empregado no treinamento da rede. Basicamente, pode-se identificar duas arquiteturas de redes neurais.

A. Redes Neurais Acíclicas ou Alimentadas Adiante

Na sua forma mais simples, constitui-se de uma camada de entrada (nós de fonte) que se projeta sobre uma camada de saída de neurônios. O neurônio de uma camada atua apenas sobre os neurônios da camada posterior, não existindo conexões entre os neurônios da mesma camada. Devido à existência de propagação da informação (computação) apenas no sentido direto, estas redes são denominadas de acíclicas ou alimentadas adiante.

Tipicamente, esta arquitetura é constituída por três camadas, como mostrado na Fig. 3.3, onde todas unidades (neurônios) estão conectadas às unidades adjacentes. Estas camadas são classificadas em três grupos:

- Camada de Entrada: onde os padrões são apresentados à rede (vetor de entrada);
- Camadas Intermediárias ou Ocultas: onde é feita a maior parte do processamento, através das conexões ponderadas, sendo consideradas como extratoras de características;
- Camada de Saída: onde o resultado final é concluído e apresentado.




Fig. 3.3: Rede acíclica como uma camada oculta.

A arquitetura mostrada na Fig. 3.3, é constituída por 3 neurônios de fonte na camada de entrada, por 5 neurônios na camada oculta ou intermediária e por 2 neurônios de resposta na camada de saída.

B. Redes Recorrentes

Neste tipo de arquitetura, os neurônios artificiais atuam tanto sobre as unidades posteriores, como também nas anteriores, incluindo interconexões entre os neurônios da mesma camada. A presença de laços de realimentação em redes recorrentes, como mostrado na Fig. 3.4, intensifica a capacidade de aprendizagem e o desempenho da rede neural.

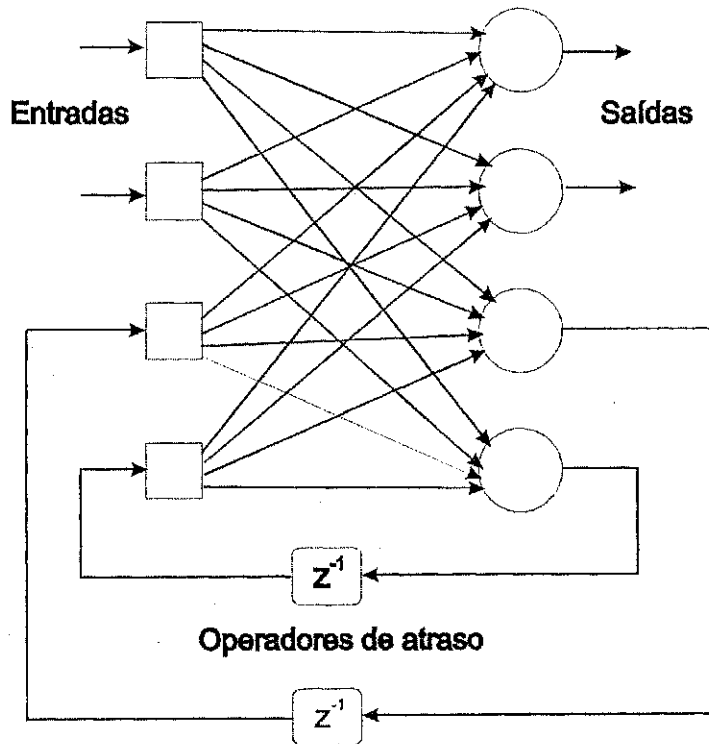


Fig. 3.4: Rede recorrente ou com realimentação.

A existência de elementos de atraso unitário, z^{-1} , indica que os nós de saída realimentam com conexões ponderadas (pesos ajustáveis) as entradas da rede neural recorrente. Isto resulta em um comportamento dinâmico não-linear, o que permite a modelagem de dispositivos não-lineares.

3.2.4 Processos de Aprendizagem

A habilidade de aprender a partir de seu ambiente é a propriedade primordial de uma rede neural artificial. O desempenho satisfatório de uma ANN está intimamente

ligado ao processo de aprendizagem adotado e ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas (HAYKIN, 2001).

A aprendizagem de uma ANN é alcançada através de um processo iterativo de ajuste (treinamento) aplicado aos parâmetros livres do projeto de uma rede neural, como os pesos sinápticos, os níveis de bias e os argumentos da função de ativação. A cada iteração do processo de aprendizagem, a rede se torna mais instruída sobre o ambiente a ser modelado.

Cada iteração do processo de aprendizagem é denominada ciclo ou época de treinamento e consiste de uma apresentação de todos os N pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. O ajuste dos pesos sinápticos numa época de treinamento pode ser executado de dois modos:

A. Modo Padrão

A correção dos pesos acontece a cada apresentação à rede de um exemplo do conjunto de treinamento. Cada correção dos pesos baseia-se somente no erro do exemplo apresentado naquela iteração. Assim, em cada ciclo ocorrem N correções.

B. Modo Batch

Apenas uma correção é feita por ciclo. Todos os exemplos do conjunto de treinamento são apresentados à rede, seu erro médio é calculado e a partir deste erro são efetuadas as correções dos pesos.

Denomina-se algoritmo de aprendizagem a um conjunto de regras preestabelecidas para o treinamento da ANN. Existem muitos tipos de algoritmos de aprendizagem, como por exemplo: a aprendizagem por correção de erro, a aprendizagem baseada em memória, a aprendizagem hebbiana e a aprendizagem competitiva (HAYKIN, 2001). De um modo geral, estes algoritmos de treinamento diferem entre si, principalmente, pelo modo como os pesos sinápticos são ajustados, além do tipo de informação disponível.

A estratégia ou paradigma de treinamento é outro fator importante no projeto de uma ANN. Consiste na maneira pela qual uma rede neural se relaciona com o ambiente; e pode ser agrupada em três categorias:

- **Treinamento Supervisionado:** quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada;

- Treinamento Não-Supervisionado (auto-organização): quando não existe um agente externo indicando a resposta desejada para os padrões de entrada;
- Treinamento Híbrido: quando são empregadas as duas estratégias anteriores, de modo a obter um melhor desempenho da rede neural.

3.2.5 Tarefas de Aprendizagem

As redes neurais têm sido aplicadas com sucesso em uma variedade de tarefas de aprendizagem. Dependendo da missão a ser executada pela ANN, utiliza-se um paradigma de aprendizagem específico, objetivando um melhor desempenho (HAYKIN, 2001).

Algumas das missões mais comuns que as ANN são capazes de executar estão descritas a seguir.

A. Aproximação de função

Considere um mapeamento de entrada-saída não-linear descrito pela relação funcional:

$$d = f(x) \quad (3.6)$$

em que x é um vetor de entrada independente, d é o vetor de saída dependente e f é a função desconhecida.

O objetivo, neste caso, é projetar uma ANN que aproxime a função, f , dado um conjunto de exemplos representados pelos pares de entrada e saída, $(x_1, d_1), (x_2, d_2), \dots, (x_N, d_N)$. O treinamento supervisionado é adequado para a solução deste problema de aproximação, com x_i ($1 \leq i \leq N$) funcionando como o conjunto de entradas para a ANN; e d_i ($1 \leq i \leq N$) servindo de modelo para a resposta da ANN.

A aproximação de funções é bastante freqüente em problemas de modelagem científica e de engenharia.

B. Associação

A tarefa de associação pode ser de duas formas: a auto-associação e a heteroassociação. Na auto-associação, a apresentação de conjunto de padrões (vetores) a ANN é repetida, de modo que esta os armazene. Com isto, pretende-se que a ANN, após

este treinamento não-supervisionado, torne-se hábil a recuperar o padrão original em uma situação prática, onde são apresentados exemplos com descrições parciais ou distorcidas.

Na heteroassociação, apresenta-se à ANN um conjunto de padrões de entrada associado a um outro conjunto arbitrário de padrões de saída. Neste caso, emprega-se o treinamento supervisionado no projeto da rede neural.

Como exemplo da aplicação de associação, pode ser citado um sistema de sonar, onde são distinguidos os alvos de interesse (ex.: submarino) e os alarmes falsos (ex.: animais marinhos).

C. Classificação de padrões

Nesta tarefa, há um número fixo de categorias (classes), onde os padrões de entrada devem ser ordenados. Para obter isto, é aplicado um processo de treinamento supervisionado, em que é apresentado repetidamente à ANN, um conjunto de padrões de entrada, juntamente com a categoria a que cada padrão pertence. Subseqüentemente, um novo padrão que não tenha sido usado no treinamento, mas que pertença a uma das categorias fixadas, é apresentado à rede. Espera-se, então, que a ANN seja capaz de reconhecer este novo padrão, ordenando-o dentro de sua classe correta.

A vantagem de empregar uma ANN para realizar o reconhecimento de padrões está na obtenção de fronteira de decisão não-linear entre as diferentes classes, e conseqüentemente oferecer um método prático para a solução de problemas complexos de classificação de padrões.

Como exemplos, podem ser citados: o reconhecimento de caracteres em sistema de postagem e o reconhecimento de voz em sistemas de segurança.

D. Predição (Generalização)

Considere um problema de processamento de sinal temporal, onde se tem um conjunto de M exemplos anteriores, $x(n-1)$, $x(n-2)$, ..., $x(n-M)$, espaçados no tempo e é requerida a previsão do exemplo presente, $x(n)$. Neste caso, emprega-se um treinamento supervisionado, em que a previsão da rede no tempo presente, $x_{ann}(n)$, é gerada baseada nos valores prévios, $x(n-1)$, $x(n-2)$, ..., $x(n-M)$, e empregando a computação do erro, dado pela expressão:

$$e(n) = x(n) - x_{ann}(n|n-1, \dots, n-M) \quad (3.7)$$

- Observações (medidas) do ambiente, obtidas por meio de sensores inseridos. Estas informações constituem o conjunto de exemplos que é usado para treinar a ANN para modelar um ambiente específico.

Cada exemplo (observação) consiste de um par de entrada-saída, em que um é o sinal de entrada e o outro é a sua correspondente resposta. Um conjunto de exemplos é denominado como amostra de treinamento, e representa o conhecimento sobre o ambiente de interesse.

Considerando que se tem um conjunto suficiente de exemplos sobre um ambiente específico, pode-se treinar a ANN de modo a modelar este ambiente de interesse. Os procedimentos gerais para o projeto de uma rede neural são descritos a seguir:

- O primeiro passo é a escolha de uma arquitetura apropriada para a ANN. É definida a quantidade de nodos de entrada e de saída da rede neural para o problema sob consideração. Uma vez especificada a configuração da ANN, um algoritmo é aplicado sobre um subconjunto de exemplos disponíveis de modo a treinar a ANN. Este algoritmo indica como os parâmetros livres da ANN são ajustados, tais que a ANN produza uma resposta satisfatoriamente precisa, quando excitada por um sinal de entrada do subconjunto de exemplos (conjunto de treinamento). Este processo é denominado fase de treinamento ou de aprendizagem.
- Como segunda etapa do projeto, tem-se a fase de validação, onde o desempenho da rede neural é testado utilizando pares de entrada-saída que não tinham sido empregados anteriormente, ou seja, exemplos fora do subconjunto de treinamento. A precisão da atual resposta da ANN em relação à saída desejada é verificada e depende das escolhas realizadas no processo de treinamento (tipo de configuração, algoritmo e conjunto de exemplos). Considera-se, então, que a ANN adquiriu a capacidade de generalizar, quando ela é capaz de produzir respostas suficientemente precisas para novos sinais de entrada.

A partir dos procedimentos descritos acima, pode-se constatar a diferença fundamental entre o projeto de uma ANN e o projeto clássico de um classificador de padrões. No modo clássico, primeiro formula-se um modelo matemático, em seguida, valida-se este modelo com dados reais (observações do ambiente), modificando-o para

melhor ajustar-se aos dados. Já a rede neural constrói um modelo implícito do ambiente, usando diretamente os dados reais para, em seguida, ajustá-lo, de modo a se obter a precisão requerida.

O conhecimento em uma ANN é armazenado pelos valores dos seus parâmetros livres (pesos sinápticos, bias, argumentos da função de ativação, etc.). Esta representação é bastante complexa, pois cada valor de um peso sináptico é influenciado por várias entradas, e o conhecimento sobre uma entrada simples está distribuído entre as várias conexões sinápticas. Entretanto, pode-se identificar quatro regras para a representação do conhecimento (HAYKIN, 2001):

1. Entradas similares de classes similares produzem geralmente representações semelhantes pela ANN, e devem ser classificadas como pertencentes à mesma categoria.
2. Itens categorizados em diferentes classes devem ter representações bastante diferenciadas dentro da rede.
3. Deve haver um grande número de neurônios envolvidos na representação de uma característica particular que seja considerada importante.
4. Informação prévia e invariâncias devem ser incorporadas no projeto de uma ANN, de modo a simplificá-lo.

3.3 REDES NEURAIIS EM ELETROMAGNETISMO

Dentre as várias aplicações nos mais diversos campos de atuação, como Economia, Administração, Biologia, Estatística e Educação, serão detalhados alguns aspectos de aplicações na área de Eletromagnetismo.

De modo geral, a simulação eletromagnética de um dispositivo exige a solução numérica das equações de Maxwell para os campos eletromagnéticos desta estrutura sob certas condições. As técnicas de análise podem ser agrupadas em dois tipos:

- No domínio espectral: Quando a solução das equações de onda é obtida por excitações senoidais em uma faixa específica de frequência. As técnicas mais comumente usadas são: o método dos momentos (MoM, *momentum method*), e o método dos elementos finitos (FEM, *finite elements method*).
- No domínio temporal: Quando a solução das equações de onda é obtida como função do tempo. Dentre as técnicas do domínio temporal destacam-se: o método

das diferenças finitas no domínio do tempo (FDTD, *finite difference time domain*) e o método da matriz da linha de transmissão (TLM, *transmission line matrix*).

As limitações das simulações eletromagnéticas se devem ao elevado esforço computacional requerido e à grande quantidade de memória de processamento (RAM, *random access memory*) exigida. Por exemplo, simuladores tridimensionais (FDTD, FEM, TLM) exigem as coordenadas cartesianas (*gridding*) dos pontos do espaço onde estão os campos eletromagnéticos apresentados pelo dispositivo. Então, valores para todos os componentes de campo elétrico e magnético de todos os pontos discretizados são computados, o que é um processo computacionalmente intenso (CHRISTODOULOU e GEORGIPOULOS, 2001).

Outra limitação dos simuladores eletromagnéticos está na apresentação de imprecisões nos resultados. Embora, em princípio, a simulação EM, que é baseada nas equações de Maxwell, seja uma análise de onda completa, a implementação prática exige geralmente algumas aproximações em relação: a) à descrição da estrutura a ser analisada, b) às condições de contorno, ou c) ao método numérico em si. Por exemplo, substratos e planos de terra são considerados de extensão infinita, a espessura e a resistividade de condutores são desprezadas, além de aproximações usadas na computação das funções de Green, na utilização do método dos momentos.

Como alternativa para a análise de dispositivos e circuitos na área de eletromagnetismo tem-se a modelagem neurocomputacional. Algumas de suas características já comentadas, como a capacidade de aprender e generalizar a partir de um conjunto de treinamento, de modo a permitir o desenvolvimento de modelos para os dispositivos, mesmo quando as descrições matemáticas não são disponíveis, é um dos fatores chave que justificam seu emprego. Além disso, como mencionados, os modelos de redes neurais são simples e de processamento rápido. Estas propriedades têm contribuído para aplicação das redes neurais em diversos dispositivos e circuitos de microondas (CHRISTODOULOU e GEORGIPOULOS, 2001; GUPTA, 1998; ZHANG e GUPTA, 2000; ZHANG e GUPTA, 2003).

Pode-se identificar, resumidamente, quatro situações (condições) em que as ANNs são propícias e possuem vantagens em relação às outras formas de análise eletromagnética. São elas (CHRISTODOULOU e GEORGIPOULOS, 2001):

1. Quando fórmulas diretas não existem, e métodos empíricos ou procedimentos de tentativa e erro são as principais técnicas para resolver o problema;

Em projeto de superfície seletiva em frequência (FSS, *frequency selective surfaces*), geralmente, não há fórmulas diretas para determinar as dimensões da estrutura para uma resposta específica. Procedimentos de tentativa e erro são repetidos até alcançar a satisfação de um critério de parada. Este procedimento torna-se impraticável à medida que camadas são adicionadas ao projeto da FSS. Uma maneira de evitar este processo laborioso é o uso da ANN. Uma ANN pode ser treinada para prever as dimensões dos elementos periódicos de uma FSS, a distância de separação e a forma necessária para uma resposta de frequência específica.

2. Em aplicações que requerem desempenho (processamento) em tempo real;

Arranjos de antenas adaptativas têm sido empregados para direcionamento do feixe principal e dos nulos em sistemas militares e civis, como GPS e comunicações móveis. O problema central nestes sistemas é a determinação do ângulo de chegada dos sinais de informação, bem como, a direção dos sinais interferentes. Um formador de pulso, *beamformer*, neural, baseado na sua elevada velocidade de computação, pode facilmente permitir à antena controlar mais de um ângulo de chegada em tempo real. A diferença entre a metodologia neurocomputacional e a clássica é que a rede neural pode ser treinada em fora da aplicação, *off-line*, para uma grande quantidade de ângulos dos sinais de informação e das fontes de interferências. Após o treinamento, o modelo neural pode ser usado, em tempo real, para detectar o ângulo de chegada de um sinal e adaptar os pesos sinápticos apropriadamente de modo a receber este sinal, sem qualquer otimização.

3. Quando taxas de convergências mais rápidas são requeridas em grandes sistemas de otimização;

A eficiência de CAD para circuitos de microondas depende intensamente da disponibilidade de modelos precisos para os componentes ativos e passivos. Por exemplo, para alguns dispositivos ativos, os modelos físico-eletromagnéticos são imprescindíveis. De modo geral, as técnicas de otimização exigem esforço computacional intenso e repetições de simulações dos circuitos. A característica inerente da ANN para funcionar como um computador substancialmente paralelo ou distribuído é empregado para acelerar os processos de otimização, tornando-os mais práticos e iterativos. O objetivo é utilizar

uma ANN treinada para representar qualquer dispositivo (transistores, filtros, amplificadores, etc.), evitando os modelos físico-eletromagnéticos e a repetição dos processos de otimização.

4. Quando não há técnicas analíticas e há dados medidos suficientes para o treinamento da ANN para propósitos de generalização.

As ANNs podem ser aplicadas nas áreas de sensoriamento remoto e detecção de objetos ou alvos. Nestas aplicações, as ANNs são treinadas com dados medidos dos modelos padronizados (escalados) presentes nas diversas situações que possam existir no sistema. Em alguns destas situações, não é possível a modelagem analítica, ou mesmo o uso de técnicas numéricas. Nestes casos, as ANNs são projetadas para as tarefas de associação, classificação de padrões e categorização (*clustering*).

A escolha ideal do tipo de ANN a ser usado em um problema eletromagnético específico requer conhecimento sobre as diversas configurações das ANNs, e experiência em aplicações diversas. Trabalhos significativos envolvendo as áreas de eletromagnetismo e neurocomputação começaram a surgir apenas a partir da década de 90. Portanto, a integração entre estes dois campos científicos é relativamente recente, e pode ser intensificada.

Um quadro geral comparativo que mostra alguns aspectos relevantes das três principais técnicas de modelagem utilizadas em aplicações na área de eletromagnetismo e microondas, é mostrado a seguir.

Tabela 3.1: Quadro comparativo de metodologias de modelagem de aplicações em microondas.

	Modelos Físico-EM (Onda Completa)	Modelos Empíricos ou Circuitos Equivalentes	Modelos Neurais
Esforço Computacional	Intenso	Razoável	Reduzido
Velocidade de Processamento	Lenta	Rápida	Rápida

Precisão	Elevada	Restrita	Suficientemente elevada, próxima aos modelos físico-EM
Número de Exemplos	Reduzido	Poucos	Número suficiente, dependente da precisão requerida
Formulação Teórica	Equações de Maxwell	Parcialmente necessária	Simplificada

Espera-se que com o amadurecimento das aplicações, mais pesquisadores possam empregar corretamente as vantagens oferecidas pelas redes neurais na área de comunicações e eletromagnetismo.

3.3.1 Desenvolvimento de Modelos EM-ANN

No desenvolvimento de modelos neurais para projetos em geral, e em especial para dispositivos e circuitos de telecomunicações, aspectos gerais devem ser relacionados (ZHANG e GUPTA, 2000).

A. Seleção das Entradas e Saídas do Modelo Neural

O passo preliminar no desenvolvimento de um modelo é a identificação das entradas e saídas do dispositivo ou circuito a ser analisado, de modo que, o conjunto de dados possa ser gerado. De um modo geral, esta identificação é baseada no propósito da modelagem.

A seleção das entradas dos modelos neurais em aplicações de telecomunicações é relativamente fácil. Em geral, as entradas são parâmetros físicos (geométricos) importantes do dispositivo ou circuito; e/ou parâmetros independentes, como frequência em circuitos passivos, ou tensão de polarização em circuitos ativos.

No caso da identificação das saídas do modelo neural, outros fatores são relevantes, como a facilidade de geração dos dados e de incorporação do modelo neural em outros simuladores. Uma escolha adequada para a saída do modelo neural é a matriz de espalhamento do circuito. A análise de circuitos de telecomunicações, onde, comumente, ocorrem conexões entre dispositivos ativos e passivos, pode ser facilitada pela obtenção

das potências transmitida, S_{21} , e refletida, S_{11} , de cada elemento. Além disso, os parâmetros-S são também convenientes para acoplar os modelos neurais a simuladores comerciais em processos de otimização.

B. Obtenção de Dados para Treinamento

A obtenção de dados (exemplos) para o treinamento e, posteriormente, para a validação do modelo neural é outro fato importante no processo de desenvolvimento da rede neural. De um modo geral, há duas maneiras de obtenção de dados:

1. Obtenção por Medição. Há inúmeras vantagens na utilização de valores medidos para treinamento do modelo neural. Essas medições podem ser obtidas, mesmo, quando a formulação teórica não está disponível, ou é bastante complicada, ou exige um esforço computacional considerável. Além disso, os valores medidos representam o comportamento do dispositivo por inteiro, ou seja, inclui os efeitos secundários como o efeito de bordas e as impedâncias parasitas. Como desvantagens deste tipo de obtenção de dados, pode-se citar a dificuldade na realização de medidas de alguns parâmetros de saída e o custo para as variações dos valores de alguns parâmetros físicos de entrada. Como fator de erro podem-se identificar as tolerâncias dos equipamentos de medição.
2. Obtenção por Simulação Eletromagnética. A formulação teórica é exigida para a implementação dos simulados. Conseqüentemente, para questões mais complicadas, um maior esforço computacional é necessário. Em alguns casos, os valores simulados não levam em consideração todas as características dos circuitos ou dispositivos, como as fontes de alimentação ou perdas, provocando limitações na precisão dos resultados. Em contrapartida, nas simulações eletromagnéticas, os parâmetros físicos de entrada podem ser facilmente variados, uma vez que, não necessitam de ajustes manuais ou confecção de outros dispositivos com novas dimensões.

Resumidamente, pode-se concluir que, a escolha do tipo de obtenção de dados para treinamento depende da aplicação a que se destina o modelo neural.

3.4 REDE NEURAL MLP

A MLP-ANN constitui-se na primeira estrutura a ser intensamente empregada na modelagem de dispositivos e circuitos de microondas e atualmente, ainda é a mais popular entre os vários tipos de redes neurais.

3.4.1 Configuração e Metodologia da MLP-ANN

Na estrutura MLP, os neurônios são agrupados em camadas. A primeira e a última camada são denominadas de camada de entrada e de saída, respectivamente, pois elas representam a entrada e a resposta do modelo neural. Entre estas camadas, existem uma ou mais camadas, denominadas de camadas ocultas, pois são isoladas do ambiente que excita a ANN, por meio das fontes de entradas aplicadas na camada de entrada, e do ambiente que recebe a resposta da ANN por meio da camada de saída.

Uma típica MLP-ANN consiste de três camadas, uma de entrada, uma de saída e uma camada oculta, como mostra a Fig. 3.5. Nas camadas de entrada e oculta têm-se I e J pontos de conexão (*nodes*), respectivamente, e uma bias, $b=1$. Já na camada de saída têm-se K pontos de conexão, sem a presença de polarização externa.

Na arquitetura MLP, as interligações entre os neurônios são do tipo acíclico (*feedforward*), ou seja, ocorre a propagação direta da informação das camadas iniciais até a camada de saída. Outra característica da MLP-ANN é a não existência de conexões entre os neurônios pertencentes à mesma camada.




Fig. 3.5: Arquitetura da MLP-ANN.

Para um entendimento da propagação direta dos sinais ao longo da estrutura MLP-ANN, deve ser detalhada a notação empregada na Fig. 3.5. Os índices i e l representam, respectivamente, um neurônio genérico e a quantidade de neurônios da camada 1 (de entrada). Da mesma forma, acontece com os índices j e J para camada 2 (oculta), e com os índices k e K para a camada 3 (saída). O peso sináptico que interliga a saída do neurônio i à entrada do neurônio j é representado por w_{ji} ; de forma semelhante, o peso sináptico que conecta a saída do neurônio j à entrada do neurônio k é indicado por w_{kj} . A saída do neurônio j , devido à entrada de dados representada pelo vetor x , é denotada por y_j ; enquanto que a saída do neurônio k , é denotada por y_k .

A propagação direta dos sinais em uma MLP-ANN, representada na Fig. 3.5, é indicada pelas seguintes expressões (CHRISTODOULOU e GEORGIPOULOS, 2001):

$$v_j = \sum_{i=0}^l w_{ji} x_i \tag{3.8}$$

$$y_j = g_j(v_j) \quad (3.9)$$

$$v_k = \sum_{j=0}^J w_{kj} y_j \quad (3.10)$$

$$y_k = g_k(v_k) \quad (3.11)$$

em que v é o potencial interno do neurônio e $g(\cdot)$ é a sua função de ativação.

3.4.2 Algoritmo de Retropropagação do Erro (Backpropagation)

A estrutura MLP-ANN foi desenvolvida desde meados da década de 60 (HAYKIN, 2001). Entretanto, sua aplicabilidade ficou limitada por um longo período, devido à ausência de um algoritmo que fosse capaz de treiná-la. Em meados dos anos 1980, um grupo de cientistas produziu um algoritmo de aprendizagem eficiente para o treinamento destas redes neurais, denominada de algoritmo de retropropagação do erro (*backpropagation*).

Considere um conjunto de dados de treinamento formados pelo vetor de entradas representado por x , em que $x = [x_1, x_2, \dots, x_1, \dots, x_1]$, e o vetor de resposta desejado representado por d , em que $d = [d_0, d_1, \dots, d_k, \dots, d_k]$. O objetivo do processo de treinamento é que a saída da MLP-ANN, representada pelo vetor y , onde $y = [y_1, y_2, \dots, y_k, \dots, y_k]$, seja suficientemente próxima ao vetor d . Para isto, aplica-se o algoritmo de retropropagação de erro.

Na iteração n , onde o n -ésimo padrão de treinamento (exemplo), $x(n)$, é apresentado à rede MLP, o sinal de erro na saída do neurônio k é dado por:

$$e_k(n) = d_k(n) - y_k(n) \quad (3.12)$$

Somando-se os valores instantâneos da energia do erro de todos os neurônios da camada de saída, obtém-se o valor instantâneo da energia total do erro, como se segue:

$$E(n) = \frac{1}{2} \sum_{k=1}^K e_k(n)^2 \quad (3.13)$$

A energia média do erro quadrático é obtida somando-se os $E(n)$ para todas as iterações, n , e então normalizando em relação ao número total de iterações (épocas ou exemplos), N , como expressado a seguir:

$$E_{med} = \frac{1}{N} \sum_{n=1}^N E(n) = \frac{1}{2N} \sum_{n=1}^N \sum_{k=1}^K e_k(n)^2 \quad (3.14)$$

A E_{med} , a energia média do erro quadrático, é função de todos os parâmetros livres (pesos sinápticos e níveis de bias) da rede, e representa a função custo como uma medida do desempenho da aprendizagem.

Cada iteração do algoritmo de retropropagação do erro é realizada com o objetivo de minimizar a função custo, ou seja, o vetor dos pesos sinápticos, \mathbf{w} , é ajustado através de um processo de otimização. O método do gradiente decrescente é um dos processos de otimização mais comumente usado na MLP-ANN, e é descrito como se segue:

$$\Delta \mathbf{w} = -\eta \nabla E(n) \quad (3.15)$$

em que η é a taxa de aprendizagem.

A partir dos cálculos dos gradientes locais da função custo, $E(n)$, na camada de saída, k , e na camada oculta, j , obtêm-se as relações para os ajustes dos pesos sinápticos, como mostrado a seguir (HAYKIN, 2001):

$$\Delta w_{kj} = \eta \cdot e_k(n) \cdot g'_k(v_k(n)) \cdot y_j \quad (3.16)$$

$$\Delta w_{ji} = \eta \cdot g'_j(v_j(n)) \cdot \sum_k e_k(n) \cdot g'_k(v_k(n)) \cdot w_{kj}(n) \cdot x_i \quad (3.17)$$

sendo g'_j a derivada da função g_j ; e g'_k a derivada da função g_k .

Como pode ser constatado, o algoritmo de aprendizagem de retropropagação do erro (*backpropagation*) consiste na aplicação do método do gradiente (processo de otimização) sobre a função custo, energia média do erro quadrático.

3.5 REDE NEURAL RBF

A rede neural de função de base radial, RBF-ANN, (*radial-basis function neural network*), constitui-se numa alternativa à MLP-ANN. Sua estrutura é mais simples e o seu processo de treinamento é mais direto. Ambas as redes neurais RBF e MLP são aproximadores universais de funções (HAYKIN, 2001). Entretanto a MLP-ANN trata o problema como um processo de otimização, enquanto a RBF-ANN aborda-o como um processo de ajuste de curva.

3.5.1 Configuração e Metodologia da RBF-ANN

A Fig. 3.6 mostra a arquitetura típica de uma RBF-ANN, constituída por I nodos de entrada, J neurônios ocultos mais uma bias, além de K nodos de saída.

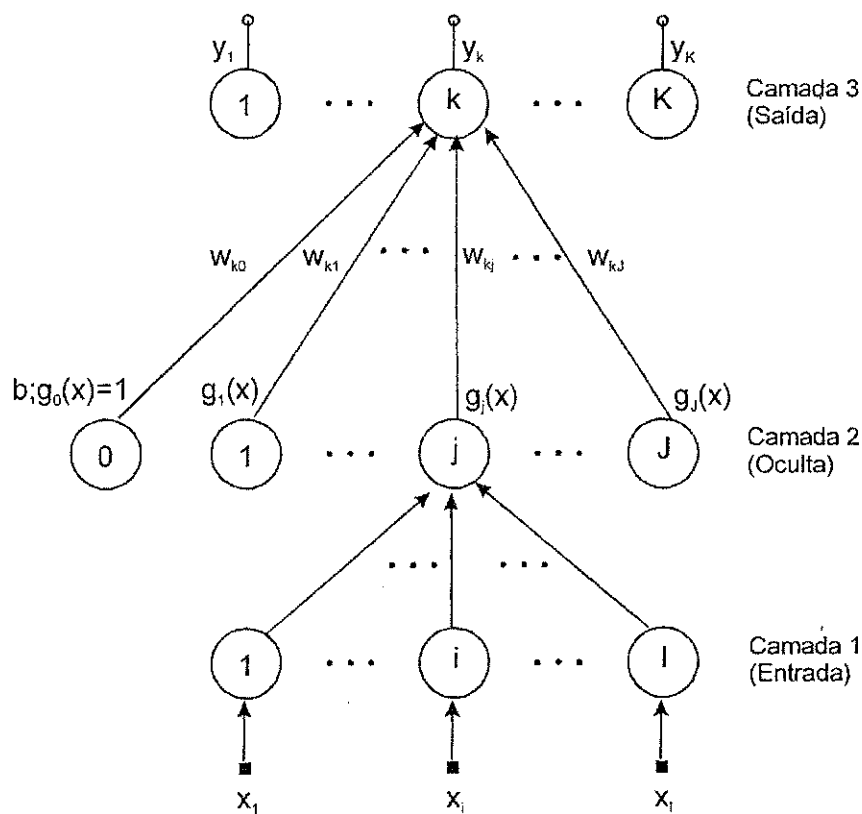


Fig. 3.6: Arquitetura de RBF-ANN.

A RBF-ANN é uma rede do tipo acíclico (não-recorrente) com três camadas de neurônios de funções bem distintas. A camada de entrada é formada por nós de fonte,

onde as entradas do ambiente, x_i , são aplicadas. A camada oculta é constituída por unidades de processamento não-lineares, $g_j(\cdot)$, que aplicam uma transformação não-linear do espaço de entrada para um espaço de maior dimensionalidade. Já a camada de saída é composta por ponderações lineares (pesos sinápticos), w_{jk} , que fornecem a resposta da rede ao padrão de sinal aplicado na entrada.

Para um dado conjunto (vetor) de entradas, \mathbf{x} , a saída de um nodo genérico de uma RBF-ANN, y_k , pode ser expressa como se segue (HAYKIN, 2001).

$$y_k = \sum_{j=0}^J w_{jk} g_j(\mathbf{x}) \quad (3.18)$$

Em (3.18), as funções de ativação, $g_j(\cdot)$, são funções de base radial que realizam a transformação não-linear dos dados de entrada. No contexto de uma rede neural, as unidades ocultas fornecem um conjunto de funções que constituem uma base arbitrária para os padrões de entrada, quando eles são expandidos sobre o espaço oculto de maneira radial.

Há uma grande classe de funções de base radial. As seguintes funções são de particular interesse no estudo de rede neurais (HAYKIN, 2001):

A) *Função Multiquadrática*

$$g_j(\mathbf{x}) = (\|\mathbf{x}\|^2 + c_j^2)^{1/2} \quad (3.19)$$

B) *Função Multiquadrática Inversa*

$$g_j(\mathbf{x}) = \frac{1}{(\|\mathbf{x}\|^2 + c_j^2)^{1/2}} \quad (3.20)$$

C) *Função Gaussiana*

$$g_j(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x}\|^2}{2\sigma_j^2}\right) \quad (3.21)$$

Para $c_j > 0$ e $\sigma_j > 0$. O vetor \mathbf{x} define um ponto em um espaço de dimensão I, chamado espaço euclidiano e representado por \mathfrak{R}^I .

3.5.2 Estratégias de Treinamento da RBF-ANN

Assim como no caso do treinamento da MLP-ANN, o processo de aprendizagem objetiva aproximar suficientemente a saída da RBF-ANN, representada pelo vetor y , onde $y = [y_1, y_2, \dots, y_k, \dots, y_K]$, ao vetor de resposta desejado representado por d , onde $d = [d_1, d_2, \dots, d_k, \dots, d_K]$ para um vetor de dados de entradas representado por x , onde $x = [x_1, x_2, \dots, x_i, \dots, x_I]$. Ou seja, o treinamento busca otimizar a função custo (3.22), especificada novamente abaixo:

$$E(n) = \frac{1}{2} \sum_{k=1}^K e_k(n)^2 \quad (3.22)$$

em que

$$e_k(n) = d_k(n) - y_k(n) \quad (3.23)$$

Uma característica peculiar das RBF-ANN é a existência de camadas que realizam tarefas bastante diferentes. Assim, o processo de aprendizagem pode ser especificado com estratégias de otimização não-linear para a adaptação das funções de ativação não-lineares (funções de base radial) na camada oculta, e de otimização linear para o ajuste dos pesos sinápticos da camada de saída.

As estratégias de aprendizagem das RBF-ANN dependem do tipo de função de base radial empregada como função de ativação na camada oculta. Considerando uma rede neural RBF, mostrada na Fig. 3.6, do tipo gaussiana, ou seja, cuja função de ativação, $g(\cdot)$, é uma função gaussiana multivariada, dada por:

$$g_j(\mathbf{x}) = \exp\left(-\frac{1}{2\sigma_j^2} \|\mathbf{x} - \mathbf{c}_j\|^2\right) \quad (3.24)$$

em que os parâmetros \mathbf{c}_j e σ_j são, respectivamente, o centro e o desvio padrão da função de base radial correspondente ao neurônio oculto j .

Substituindo a função gaussiana como a função de ativação em (3.18), obtém-se a expressão para a saída de rede RBF gaussiana, como se segue:

$$y_k \approx \sum_{j=0}^J w_{jk} \exp\left(\frac{1}{2\sigma_j^2} \|\mathbf{x} - \mathbf{c}_j\|^2\right) \quad (3.25)$$

Em uma forma normalizada e generalizada, a função gaussiana e a saída da RBF-ANN são dadas por:

$$g_j(\mathbf{x}) = \exp\left(-\frac{1}{2}(\mathbf{x} - \mathbf{c}_j)^T \Sigma_j^{-1}(\mathbf{x} - \mathbf{c}_j)\right) \quad (3.26)$$

$$y_k = \sum_{j=0}^J w_{jk} \exp\left(-\frac{1}{2}(\mathbf{x} - \mathbf{c}_j)^T \Sigma_j^{-1}(\mathbf{x} - \mathbf{c}_j)\right) \quad (3.27)$$

em que Σ_j é a matriz de covariância da função gaussiana multivariada correspondente ao neurônio oculto j .

Neste caso, existem três parâmetros que podem ser ajustados no processo de treinamento de uma RBF. São eles: os centros e as matrizes de covariância ou desvios padrão de cada função de gaussiana na camada oculta, além dos pesos sinápticos da camada de saída. Por isso, dependendo de como estes parâmetros livres são especificados, podem-se identificar três estratégias de aprendizagem do projeto de uma RBF-ANN gaussiana.

A. Fixação Aleatória dos Centros e dos Desvios Padrão

Nesta estratégia de aprendizagem, os centros das funções gaussianas são escolhidos aleatoriamente do conjunto de dados de treinamento. A abordagem mais simples, considera as funções de base radial (funções gaussianas) fixas e definidas por:

$$g_j(\mathbf{x}) = \exp\left(-\frac{J}{d_{\max}^2} \|\mathbf{x} - \mathbf{c}_j\|^2\right) \quad (3.28)$$

em que d_{\max} é a distância máxima de J centros escolhidos na camada oculta. Ou seja, as matrizes de covariância são diagonalizadas com cada elemento, sendo σ^2 (desvio padrão) fixo e dado por:

$$\sigma^2 = \frac{d_{\max}^2}{2J} \quad (3.29)$$

A escolha deste valor de desvio padrão assegura que as funções de ativação não sejam pontiagudas ou demasiadamente planas, de modo que prejudique o desempenho da rede (HAYKIN, 2001).

Uma vez que os centros e os desvios padrões das funções gaussianas são escolhidos, apenas o vetor dos pesos sinápticos, w , é ajustado por meio de um processo de otimização. A solução pode ser encontrada usando a pseudo-inversa da matriz de funções de ativação (funções de base radial), como mostrado pela expressão abaixo:

$$w = G^+ d \quad (3.30)$$

onde G^+ é a pseudo-inversa da matriz G que é dada por $(G^T G)^{-1} G^T$.

A estratégia de escolher os centros e os desvios padrões tende a convergir para uma solução mais rapidamente. Entretanto, a capacidade de generalização da rede RBF é prejudicada (HAYKIN, 2001).

B. Seleção Auto-Organizada de Centros

A seleção aleatória dos centros da função gaussiana pode produzir uma rede RBF com baixo desempenho, se as escolhas não forem apropriadas. Uma maneira de superar esta limitação é usar algum tipo de algoritmo de agrupamento (*clustering*) para definir estes centros.

Nesta segunda estratégia, tem-se um processo de aprendizagem híbrido, sendo um estágio não-supervisionado (auto-organizado), para definir a localização dos centros das funções gaussianas, e um estágio supervisionado, para estimar os pesos sinápticos da camada de saída da rede.

Para o estágio de aprendizagem auto-organizada, alguns algoritmos de agrupamento mais comumente utilizados são: o algoritmo de K-médias (*K-means*) proposto por Duda e Hart (1973) e o mapa auto-organizável (SOM, *self-organizing map*) proposto por Kohonen (1990):

1. Algoritmo de agrupamento K-médias. Este procedimento coloca os centros das funções de base radial apenas naquelas regiões do espaço de entrada onde dados

significativos estão presentes. Uma descrição detalhada deste algoritmo pode ser realizada através de cinco fases: inicialização, amostragem, casamento de similaridade, atualização e continuação (até convergir).

2. Mapa Auto-Organizável. O algoritmo de Kohonen pertence a uma classe de processos de aprendizagem competitiva, que pode ser vista como um procedimento para reunir padrões de entrada em grupos de modo inerente aos dados. Também pode-se observar cinco fases na descrição do algoritmo de Kohonen: Inicialização da rede, casamento de similaridade, seleção da distância mínima, adaptação dos pesos e verificação do critério de parada.

C. Seleção Supervisionada dos Centros e Desvios Padrões

Na abordagem supervisionada generalizada, todos os parâmetros livres da rede RBF são ajustados no processo de aprendizagem.

O método do gradiente decrescente pode ser usado num procedimento de correção do erro (HAYKIN, 2001), de modo a ajustar os pesos sinápticos, w_j , o vetor de centros, t_j , a matriz de covariância, Σ^l , ou o desvio padrão, σ^2 da função gaussiana (3.24).

Segundo o método do gradiente, o ajuste dos pesos sinápticos é proporcional ao gradiente negativo da função custo (3.22), como se segue:

$$\Delta w_j = -\eta_w \frac{\partial E(n)}{\partial w_j} \quad (3.31)$$

Substituindo a função custo (3.22) em (3.31), obtém-se:

$$\Delta w_j = -\eta_w \sum_{k=1}^K e_k(n) \frac{\partial y_k^2(n)}{\partial w_j} \quad (3.32)$$

Derivando a saída da RBF-ANN em função dos centros, tem-se a expressão para o ajuste dos pesos sinápticos, como se segue:

$$\Delta w_j = -\eta_w \sum_{k=1}^K e_k(n) g_j(x(n)) \quad (3.33)$$

Para o ajuste dos centros da função gaussiana mais uma vez aplicando-se o método do gradiente, tem-se:

$$\Delta c_j = -\eta_c \frac{\partial E(n)}{\partial c_j} \quad (3.34)$$

Substituindo (3.22) em (3.34), tem-se:

$$\Delta c_j = -\eta_c \sum_{k=1}^K e_k(n) \frac{\partial y_k^2(n)}{\partial c_j} \quad (3.35)$$

Derivando a saída da RBF-ANN em função dos centros, obtém-se:

$$\Delta c_j = -2\eta_c w_j(n) \sum_{k=1}^K e_k(n) g_j(x(n)) \frac{x - c_j}{\sigma_j^2} \quad (3.36)$$

ou de forma generalizada, tem-se:

$$\Delta c_j = -\eta_c w_j(n) \sum_{k=1}^K e_k(n) g_j'(x(n)) \Sigma_j^{-1} (x(n) - c_j) \quad (3.37)$$

De maneira similar, obtém-se a expressão de ajuste da matriz de covariância ou do desvio padrão da função de ativações, definidas abaixo:

$$\Delta \Sigma_j^{-1} = \eta_\Sigma w_j(n) \sum_{k=1}^K e_k(n) g_j'(x(n)) (x(n) - c_j) (x(n) - c_j)^T \quad (3.38)$$

$$\Delta \sigma_j^2 = -2\eta_\sigma w_j(n) \sum_{k=1}^K e_k(n) g_j(x(n)) \frac{\|x - c_j\|^2}{\sigma_j^2} \quad (3.39)$$

A estratégia de aprendizagem supervisionada dos centros e das variâncias exige um esforço computacional mais elevado que as outras estratégias. Entretanto, o desempenho da rede RBF com treinamento supervisionado para a tarefa de aproximador de funções é superior, ou seja, a RBF-ANN generaliza mais precisamente.

3.5.3 Algoritmo Geral para Treinamento de uma RBF-ANN

Todo o processo de treinamento de um RBF-ANN com seleção supervisionada de centros e largura das funções gaussianas pode ser descrito em 5 etapas, a saber (ZHANG e GUPTA, 2000):

1. Inicialização: Selecione os valores iniciais dos parâmetros livres (pesos sinápticos, centros e largura). Os pesos são valores pequenos escolhidos aleatoriamente. Os centros das funções gaussianas são escolhidos aleatoriamente do conjunto de dados de treinamento. As larguras das funções gaussianas são preferencialmente iguais a valores reduzidos.
2. Amostragem: Apresente um padrão de dados de entrada (época ou exemplo) à camada de entrada da rede. Cada apresentação de época é uma iteração, n .
3. Resposta: Calcule a saída da rede RBF de acordo com (3.26) e (3.27), repetidas baixo.

$$g_j(\mathbf{x}) = \exp\left(\frac{1}{2\sigma_j^2} \|\mathbf{x} - \mathbf{c}_j\|^2\right) \quad (3.40)$$

$$y_k = \sum_{j=0}^J w_{jk} \exp\left(\frac{1}{2\sigma_j^2} \|\mathbf{x} - \mathbf{c}_j\|^2\right) \quad (3.41)$$

4. Ajuste: Compare o valor de resposta da rede, y_k , e o valor desejado de saída, d_k . Se o valor da função custo $e(\)$ está suficientemente baixo, vá para o passo 5. Senão, execute as mudanças nos parâmetros livres de acordo com (3.37), (3.38) e (3.39), repetidas aqui para efeito de simplicidade:

$$\Delta w_j = -\eta_w \sum_{k=1}^K e_k(n) g_j(x(n)) \quad (3.42)$$

$$\Delta c_j = -2\eta_c w_j(n) \sum_{k=1}^K e_k(n) g_j(x(n)) \frac{x - c_j}{\sigma_j^2} \quad (3.43)$$

$$\Delta\sigma_j^2 = -2\eta_\sigma w_j(n) \sum_{k=1}^K e_k(n) g_j(x(n)) \frac{\|x - c_j\|^2}{\sigma_j^2} \quad (3.44)$$

em que η_w , η_c e η_σ são definidos de acordo com a velocidade requerida pelo treinamento. Valores elevados das taxas de treinamento fazem a rede convergir mais rapidamente, entretanto, tornam-na mais instável.

5. Incrementação: Se $n = N$ e $E(n)$ é menor que o limiar de parada estabelecido pelo projeto, pode-se considerar o final do treinamento. Se $n < N$, retorne ao passo 2 e reapresente o primeiro padrão de entrada ($n=1$).

3.6 COMPARAÇÃO ENTRE AS REDES MLP E RBF

As redes neurais MLP e RBF pertencem à mesma classe das denominadas redes acíclicas ou alimentadas adiante, em que o fluxo de informação segue em um único sentido, dos nodos de fontes da camada de entrada para os neurônios da camada de saída. Pode-se considerar que tanto a MLP-ANN quanto a RBF-ANN são capazes de realizar a mesma função, a de aproximadores universais (HAYKIN, 2001).

Entretanto, a camada oculta destas redes neurais comporta-se diferentemente. Enquanto, na MLP-ANN o argumento da função de ativação (função sigmóide) é o produto interno do vetor de dados de entrada e o vetor dos pesos sinápticos; a camada oculta da RBF-ANN processa por meio de função de ativação gaussiana a norma euclidiana entre o vetor de entrada e o centro. Isto gera várias propriedades diferentes entre elas.

De um modo geral, a MLP-ANN constrói aproximações globais para um mapeamento de entrada-saída não-linear, enquanto a RBF-ANN constrói aproximações locais utilizando não-linearidades.

Para o propósito de comparação, as redes MLP e RBF foram usadas para modelar um dispositivo eletrônico (ZHANG e GUPTA, 2000). A precisão dos modelos neurais treinados é calculada pelo percentual de erro da resposta da rede MLP e RBF versus o conjunto de teste. Segundo pesquisas realizadas por Zhang e Gupta (2000), pode-se constatar que, quando o conjunto de treinamento é considerável, a RBF-ANN pode alcançar uma melhor precisão do que a MLP-ANN. À medida que o tamanho do conjunto de treinamento é reduzido, o desempenho da RBF-ANN cai mais rapidamente do que o da

MLP-ANN. Em relação ao processo de treinamento, o da RBF-ANN converge mais facilmente do que o da MLP-ANN.

3.7 REDE NEURAL FUNÇÃO *SAMPLE*

Os dois principais tipos de redes neurais empregadas nas modelagens de dispositivos e circuitos de microondas são: a rede neural de *perceptrons* de múltiplas camadas, MLP-ANN e a rede neural de funções de base radiais, RBF-ANN.

Entretanto, em algumas situações, as técnicas neurocomputacionais convencionais não fornecem bom desempenho, devido à presença de faixas de operações com respostas de formas não-lineares, abruptas e planas, oscilações e ruídos.

De um modo geral, as técnicas neurocomputacionais usam alguma representação para a aproximação de funções, tal como a função de ativação sigmóide, na MLP-ANN, e a função de ativação gaussiana, na RBF-ANN. Esta característica contribuiu para a realização de mudanças no modelo neural convencional através da escolha de uma nova função de ativação.

3.7.1 Configuração e Metodologia da SF-ANN

Um novo paradigma neurocomputacional (SILVA, FERNANDES e NETO, 2002), denominado Rede Neural Artificial Função *Sample* (SF-ANN, *Sample Function Artificial Neural Network*) 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 abaixo:

$$sample(x) = sinc(x/\pi) = sen(x)/x \quad (3.45)$$

A função de ativação proposta assemelha-se com as funções de ativação empregadas na rede neural RBF (funções gaussianas, multiquádricas e multiquádricas inversas), que usam centros e larguras. Como resultado, tem-se a função da ativação mostrada abaixo:

$$g(x) = \text{sample}(\sigma \|x - c\|^2) = \frac{\text{sen}(\sigma \|x - c\|^2)}{\sigma \|x - c\|^2} \quad (3.46)$$

em que c é o vetor de centros e σ é o inverso da largura, que é a distância entre os dois nulos mais centrais, da função *sample*.

As inclusões dos parâmetros centros e larguras permitem que a função *sample* possa apresentar diversas formas, como mostrado na Fig. 3.7. Este aspecto é bastante vantajoso, pois expande os tipos de mapeamento de entrada e saída que a SF-ANN é capaz de modelar.




Fig. 3.7: Variações da função *sample*.

A superposição das funções *sample* com larguras estreitas para mapear as respostas não-lineares abruptas e os ruídos, com as funções *sample* com larguras extensas para mapear regiões planas, pode resultar em oscilações indesejáveis na resposta (saída) da SF-ANN.

Para contornar o problema acima, foi então realizada uma última modificação na SF-ANN. Os neurônios ocultos foram classificados de acordo com sua resolução: resolução elevada para funções com larguras estreitas, e resolução baixa para funções com larguras extensas. Neste caso, os neurônios de alta resolução são localizados cuidadosamente em centros pré-fixados, enquanto, os centros dos neurônios de baixa resolução são ajustados durante o processo de aprendizagem.

Para limitar a região de influência dos neurônios de alta resolução na saída da SF-ANN, foram empregadas as seguintes condições:

$$g(\mathbf{x}) = \frac{\text{sen}(\sigma \|\mathbf{x} - \mathbf{c}\|^2)}{\sigma \|\mathbf{x} - \mathbf{c}\|^2} \quad \text{para } \|\mathbf{x} - \mathbf{c}\| < \kappa \quad (3.47)$$

$$g(\mathbf{x}) = \frac{\text{sen}(\sigma \|\mathbf{x} - \mathbf{c}\|^2)}{(\sigma \|\mathbf{x} - \mathbf{c}\|^2)^\xi} \quad \text{para } \|\mathbf{x} - \mathbf{c}\| \geq \kappa \quad (3.48)$$

em que ξ e κ são inteiros positivos.

Usando (3.47) e (3.48), a influência dos neurônios de alta resolução está localizada na vizinhança dos seus centros, enquanto, que o parâmetro ξ atenua a contribuição dos neurônios de alta resolução para entradas distantes, ou seja, para $\|\mathbf{x} - \mathbf{c}\| \geq \kappa$.

A SF-ANN é uma rede neural do tipo acíclica ou alimentada adiante (*feedforward*), ou seja, o fluxo de informação se dá em um único sentido dos nodos de fonte da camada de entrada aos nodos da camada de saída. Sua configuração básica é representada pela Fig. 3.8, mostrada abaixo.

Sendo $g_j(\cdot)$ a j -ésima função *sample* do neurônio oculto, w_{kj} o k -ésimo peso sináptico entre a j -ésimo neurônio oculto e o k -ésimo nodo de saída, y_k o k -ésimo nodo da camada de saída e J a quantidade de neurônios ocultos.

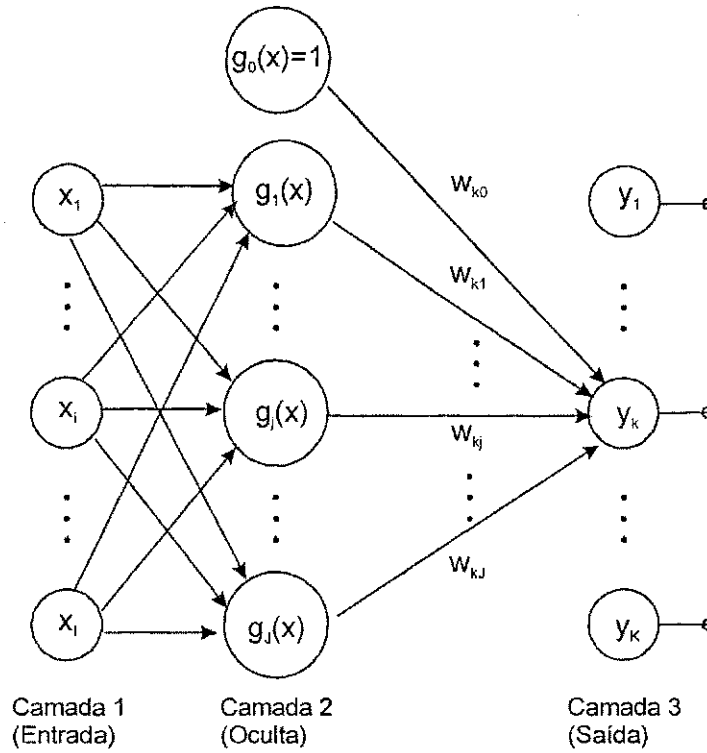


Fig. 3.8: Arquitetura da SF-ANN.

Esta configuração baseia-se na RBF-ANN, ou seja, com três camadas, sendo uma de entrada, uma oculta com transformação não-linear, e uma camada de saída.

3.7.2 Processo de Treinamento da SF-ANN

Considere um vetor de dados de entrada, $\mathbf{x} = [x_1, x_2, \dots, x_i, \dots, x_j]$ apresentado aos nodos da camada de entrada com vetor de resposta desejada, \mathbf{d} , em que $\mathbf{d} = [d_1, d_2, \dots, d_k, \dots, d_K]$. A computação direta da rede SF-ANN é definida pelas seguintes expressões:

$$v_j = \sigma_j \|\mathbf{x} - \mathbf{c}_j\|^2 = \sigma_j (\mathbf{x} - \mathbf{c}_j)^T \cdot (\mathbf{x} - \mathbf{c}_j) \quad (3.49)$$

$$g_j(\mathbf{x}) = \text{sample}(v_j) \quad (3.50)$$

$$y_k(\mathbf{x}) = \sum_{j=0}^J w_{kj} g_j(\mathbf{x}) \quad (3.51)$$

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

No processo de aprendizado supervisionado da rede função *sample*, os parâmetros livres do modelo SF-ANN, w , c e σ são otimizados para minimizar a função custo quadrática:

$$E(\mathbf{x}) = \frac{1}{2} e(\mathbf{x})^2 = \frac{1}{2} [d_k(\mathbf{x}) - y_k(\mathbf{x})]^2 \quad (3.52)$$

Para isto, foi empregado o método do gradiente:

$$\Delta w = -\eta \nabla E \quad (3.53)$$

em que η é a taxa de aprendizado.

No processo de treinamento, utiliza-se a estratégia de seleção supervisionada de centros e larguras de forma análoga à adotada para um RBF-ANN, descrita na seção 3.5.2, no item c. Após manipulações numéricas, as equações de ajustes dos parâmetros livres da rede neural de funções *sample*, SF-ANN, são apresentadas a seguir:

$$\Delta w_w = \eta_w e g_j(\mathbf{x}) \quad (3.54)$$

$$\Delta c_j = 2\eta_c e w_{kj} \sigma_j (x - c_j) (y_k - \cos(v_j)) / v_j \quad (3.55)$$

$$\Delta \sigma_j = \eta_\sigma e w_{kj} (\cos(v_j) - y_k) / \sigma_j \quad (3.56)$$

Os valores iniciais para os parâmetros livres da SF-ANN são fatores importantes para se obter uma rápida convergência do processo de treinamento. De um modo geral, nas modelagens SF-ANN, os pesos sinápticos são iniciados com valor médio inicial $w_{kj0} \leq 0,01$; os centros das funções *samples*, c_j , são selecionados aleatoriamente dos dados de entrada pertence ao conjunto de treinamento; e as larguras, σ_j , são fixadas em um mesmo valor, $\sigma_{j0} \leq 200$.

Reputada de grande importância, no início do processo de treinamento da SF-ANN, é a escolha das taxas de aprendizagem. Nas aplicações subsequentes, as seguintes faixas

de valores foram empregadas: $\eta_w \leq 10^{-1}$, $\eta_c \leq 10^{-3}$ e $\eta_\sigma \leq 10^{-2}$, por serem consideradas adequadas, após um procedimento sistematizado de tentativa e erro.

3.8 REDES NEURAIAS MODULARES

Nas seções anteriores foram discutidas duas abordagens de aprendizagem supervisionada. A primeira, a rede MLP treinada com o algoritmo de retropropagação, apresentada na seção 3.4, conta com uma forma de otimização global. Já a segunda abordagem, a rede RBF, apresentada na seção 3.5, emprega um processo de otimização local. Nesta seção são apresentadas as redes modulares (máquinas de comitê) que se baseiam no princípio de dividir e conquistar, bastante conhecido na área de engenharia.

Este princípio consiste em dividir uma tarefa computacional complexa em um número de tarefas computacionais simplificadas e então, combinar as soluções destas tarefas. No treinamento supervisionado de uma rede neural modular, a tarefa de aprendizagem é distribuída entre um número de especialistas, que, por sua vez, dividem o espaço de entrada em conjunto de subespaços. Então, o conhecimento adquirido por cada especialista é fundido para chegar à decisão global que é supostamente superior àquela alcançável por qualquer um deles atuando isoladamente (HAYKIN, 2001)

As máquinas de comitê podem ser agrupadas em duas classes (HAYKIN, 2001)

1. Estruturas Estáticas. Há um mecanismo na saída que combina as respostas de vários previsores (especialistas). A designação estática é justificada pelo não envolvimento do sinal de entrada no mecanismo (combinador). Os métodos da Média de Ensemble e do Reforço (*boosting*) pertencem a esta categoria.
2. Estruturas Dinâmicas. Nesta categoria, há uma integração entre o sinal de entrada e a atuação do mecanismo que combina as saídas das especialistas individuais em uma saída global. Esta categoria inclui o modelo de mistura de especialistas, ME, e o modelo de mistura hierárquica de especialista, MHE.

Os modelos de mistura de especialista e de mistura hierárquica de especialistas são exemplos de redes neurais modulares. Uma definição formal para a noção de modularidade é proposta por Osherson *et al.*, 1990.

“Uma rede neural é chamada de modular se a computação realizada pela rede pode ser decomposta em dois ou mais módulos (subsistemas) que operam sobre entradas distintas sem comunicação entre eles. As saídas dos módulos são mediadas por uma unidade

integradora que não pode alimentar a informação de volta para os módulos. Em particular, a unidade integradora (1) decide como as saídas dos módulos devem ser combinadas para formar a saída final do sistema e (2) decide quais módulos devem aprender que padrões de treinamento”.

3.8.1 Método da Média de Ensemble

Nesta técnica as saídas de diferentes previsores são combinadas linearmente para produzir uma saída global. A Fig. 3.9 mostra um conjunto de redes neurais treinadas diferentemente (especialistas), que compartilham uma entrada comum, $x(n)$, e cujas saídas, $y_1(n)$, $y_2(n)$, ..., $y_K(n)$, são coligadas por um combinador de modo a gerar a saída global, $y(n)$.

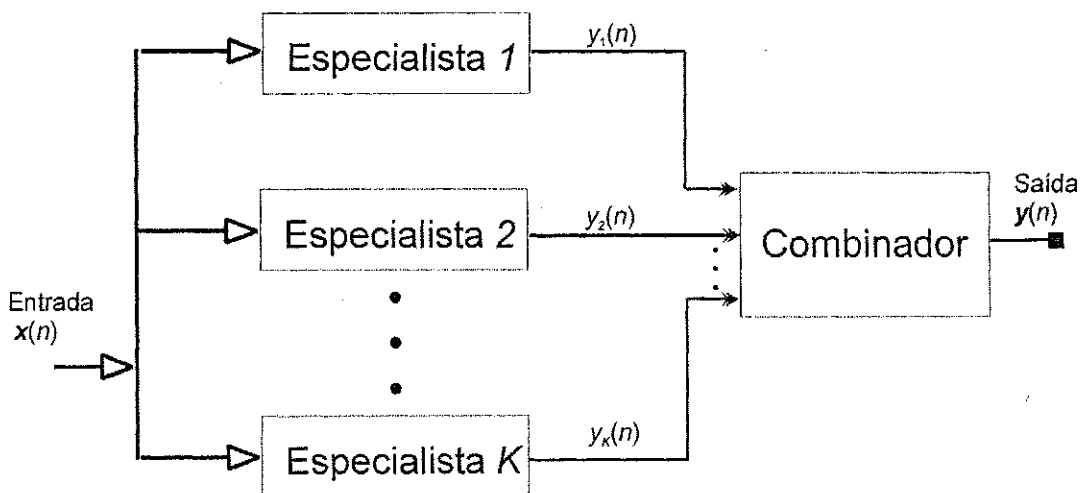


Fig. 3.9: Máquina de Comitê baseada na técnica da média de Ensemble

Há diferentes modos de treinar individualmente as redes especialistas, como também, há diferentes maneiras de combinar as suas saídas. Um exemplo de modos de treinamento é a situação onde as redes especialistas têm configurações idênticas, mas elas são treinadas a partir de condições iniciais diferentes.

Com a expectativa que as diferentes especialistas converjam para diferentes mínimos locais, este tipo de máquina de comitê propõe o aumento do desempenho global com a combinação das saídas de cada especialista (HAYKIN, 2001).

3.8.2 Método do Reforço

Pertencente à categoria estática das máquinas de comitê, o método do Reforço difere da técnica de Média de Ensemble em relação ao conjunto de dados para treinamento. Enquanto na técnica da Média de Ensemble utiliza-se um mesmo conjunto de dados, em uma máquina de comitê por reforço (*boosting*), ao contrário, as redes especialistas são treinadas com conjuntos de dados com distribuições diferentes. Este método que se baseia em estratégia de seleção dos dados é bastante geral, e pode ser empregado para melhorar o desempenho de outros algoritmos de aprendizagem.

Há três diferentes modos de implementação da técnica do Reforço (HAYKIN, 2001):

A. Reforço por Filtragem

Esta abordagem corresponde a filtrar os exemplos de treinamento por diferentes versões de um algoritmo de aprendizagem simples. Considera-se a disponibilidade de uma grande fonte de exemplos, com os exemplos sendo descartados ou mantidos durante o treinamento. A vantagem principal desta abordagem é o uso de pouca memória comparada com as outras duas abordagens seguintes.

B. Reforço por Subamostragem

Neste segundo tipo, o conjunto de treinamento possui tamanho fixo. Ocorrem repetições de amostragem durante o treinamento, de acordo com uma determinada distribuição de probabilidade.

C. Reforço por Ponderação

Esta abordagem também trabalha com um conjunto de treinamento fixo, mas utiliza exemplos ponderados. O erro é calculado em relação a média ponderada das respostas obtidas para cada amostragem.

3.8.3 Modelo de Mistura de Especialistas

O modelo Mistura de Especialistas (ME, *mixture of experts*) constitui uma estrutura dinâmica, ou seja, é um tipo de rede modular. A designação “dinâmica” é usada no sentido de que a integração do conhecimento adquirido pelas redes especialistas é realizada sob a ação do sinal de entrada.

Considere a rede modular ME mostrada na Fig. 3.10. Esta consiste de K módulos supervisionados chamados de redes de especialistas ou simplesmente especialistas, e de uma unidade integradora chamada de rede de passagem, sendo as funções de ativação representadas por g_1, g_2, \dots, g_k . A função desempenhada pela rede de passagem é a de mediadora entre as especialistas.

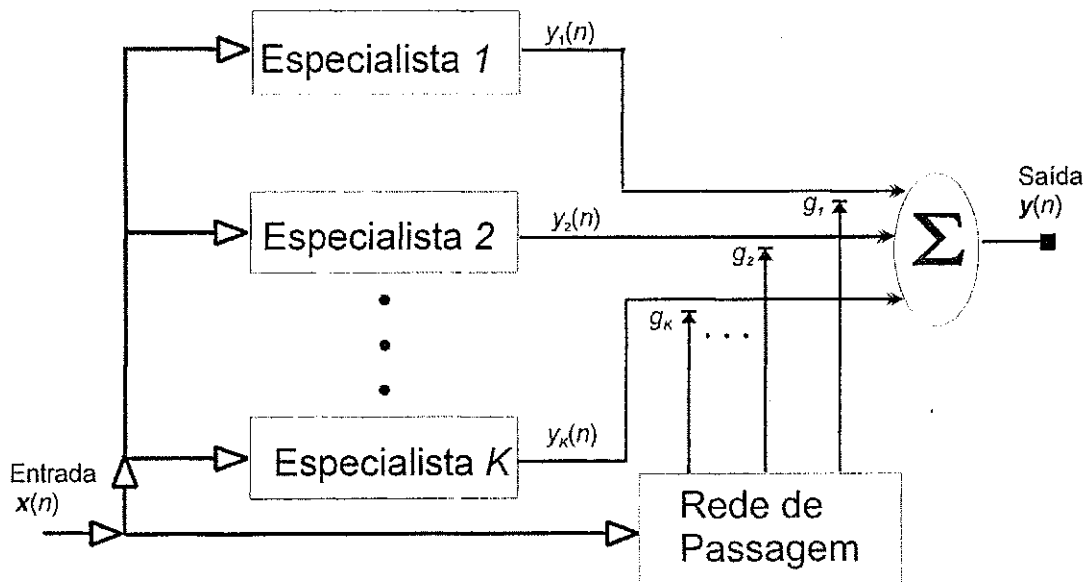


Fig. 3.10: Rede Neural Modular ME (Mistura de Especialistas).

Cada especialista consiste de um filtro linear que funciona melhor em regiões diferentes do espaço de entrada. O grafo do fluxo de sinal de um único neurônio de uma especialista genérica k é mostrado na Fig. 3.11.




Fig. 3.11: Grafo de fluxo de sinal de um neurônio da especialista k .

Observa-se que a saída produzida pelo especialista genérico k , y_k , é o produto interno do vetor de entrada, \mathbf{x} , e o vetor peso sináptico, \mathbf{w}_k , deste neurônio, como mostrado a seguir:

$$y_k = \mathbf{w}_k^T \mathbf{x} \quad k = 1, 2, \dots, K \quad (3.57)$$

Já a rede de passagem consiste de uma única camada de K neurônios, com cada neurônio atribuído a um especialista específico. A arquitetura da rede de passagem e o grafo do fluxo de sinal do neurônio genérico k desta rede estão mostrados nas Figs. 3.12 e 3.13, respectivamente.




Fig. 3.12: Arquitetura da rede de passagem.




Fig. 3.13: Grafo do fluxo de sinal de um neurônio da rede de passagem.

Nas Figs. 3.12 e 3.13 as funções de ativação, g_k , são definidas por:

$$g_k = \frac{\exp(u_k)}{\sum_{j=1}^K \exp(u_j)} \quad k = 1, 2, \dots, K \quad (3.58)$$

sendo u_k o produto interno do vetor de entrada x pelo vetor peso sináptico da rede de passagem a_k , como mostra a expressão abaixo.

$$u_k = a_k^T x \quad k = 1, 2, \dots, K \quad (3.59)$$

A transformação exponencial normalizada de (3.58) pode ser vista como uma generalização da função logística (sigmóide) para múltiplas entradas (BRIDLE, 1990). Observa-se que, diferentemente dos neurônios das especialistas, os neurônios da rede de passagem são não-lineares.

Finalmente a saída global da rede modular modelo mistura de especialista, ME, mostrada na Fig. 3.10, é expressa por:

$$y = \sum_{k=1}^K g_k y_k \quad (3.60)$$

em que y_k é a saída da rede especialista genérica k em resposta ao vetor de entrada x , e g_k é uma função não-linear de x .

3.8.4 MODELO DE MISTURA HIERÁRQUICA DE ESPECIALISTAS

O modelo de mistura hierárquica de especialistas (MHE, *mixture of hierarchal experts*) é uma extensão natural do modelo ME. Na MHE, o princípio de dividir e conquistar é aplicado várias vezes, resultando em uma quantidade equivalente de níveis hierárquicos.

A Fig. 3.14 apresenta um modelo MHE de quatro especialistas e duas redes de passagem intermediárias indicando dois níveis hierárquicos. A arquitetura do modelo

MHE é similar a uma “árvore”, na qual as redes de passagem estão em vários pontos não-terminais e os especialistas se encontram nas “folhas” da árvore (HAYKIN, 2001).




Fig. 3.14: Rede Neural Modular MHE

O modelo MHE se diferencia do modelo ME na medida em que o espaço de entrada é dividido em conjuntos de subespaços, com a informação sendo combinada e redistribuída entre os especialistas sob controle de várias redes de passagem arranjadas em uma forma hierárquica (JORDAN e JACOBS, 1995).

Continuando com aplicação do princípio de dividir e conquistar em uma forma similar à mostrada na Fig. 3.11, pode-se construir um modelo MHE com qualquer número de níveis de hierarquia.

3.9 ARQUITETURA MODULAR DA REDE NEURAL FUNÇÃO *SAMPLE*

As redes neurais MLP e RBF são as mais comumente empregadas nos problemas de modelagens de dispositivos e circuitos de microondas (CHRISTODOULOU e GEORGIPOULOS, 2001; GUPTA, 1998; ZHANG e GUPTA, 2000; ZHANG *et al.*, 2003).

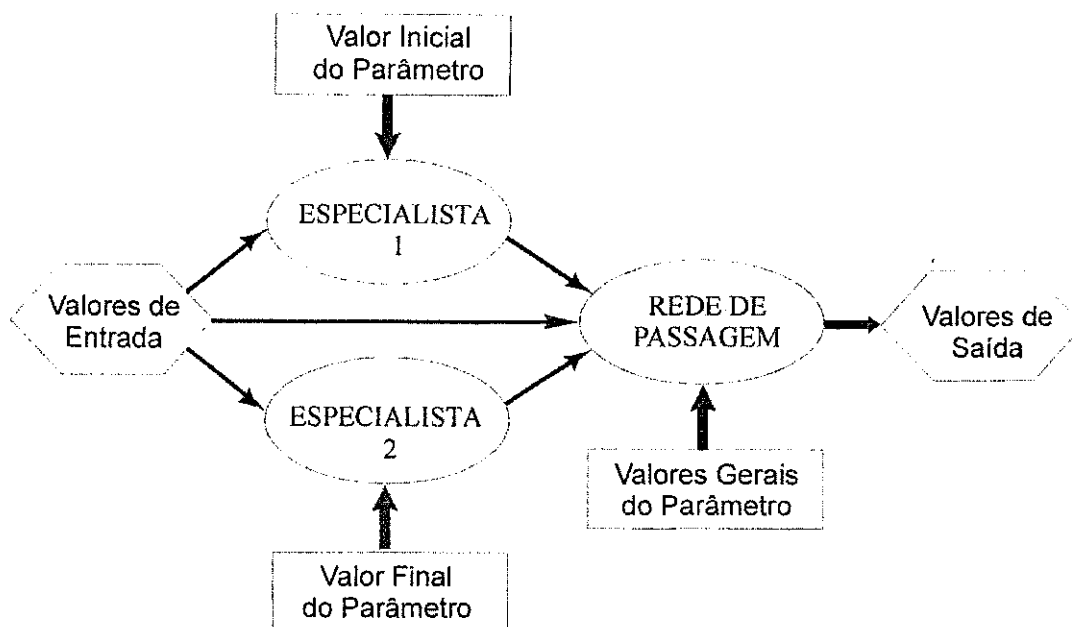
Entretanto, para mapeamento de complexidade elevada ou para modelagem em vasta região de operação, necessita-se de uma grande quantidade de dados para treinamento e um grande número de neurônios. Naturalmente, estes fatores podem acarretar uma baixa taxa de aprendizado e uma generalização limitada (HAYKIN, 2001).

Para superar estas dificuldades, a aplicação da arquitetura modular de uma rede neural surge como uma possibilidade (JORDAN e JACOBS, 1995). A combinação de redes neurais constituindo uma arquitetura modular aprimora o desempenho da técnica neurocomputacional, em termos de eficiência computacional e capacidade de generalização (HAYKIN, 2001).

Como visto na seção anterior, estes modelos visam resolver os problemas propostos usando o princípio de dividir e conquistar. Neste contexto, a tarefa de modelagem complexa não-linear é distribuída entre as várias redes especialistas.

Uma nova arquitetura modular é proposta nesta Tese e está representada na Fig. 3.15. Esta estrutura baseia-se na rede modular ME, sendo composta por uma rede de passagem (rede neural de saída) e duas redes especialistas. As redes especialistas são do tipo SF-ANN, descritas anteriormente.

A metodologia de aprendizagem consiste na apresentação de um conjunto de treinamento para o valor inicial do parâmetro à primeira rede especialista e na apresentação de um conjunto de treinamento para o valor final do parâmetro à segunda rede especialista. O conjunto total de treinamento é usado no processo de aprendizagem para a rede de passagem.

Fig. 3.15: Rede Neural Modular Função *Sample*.

A fusão dos resultados das duas especialistas ocorre na rede de passagem. A rede de passagem utiliza como entradas os valores obtidos nas saídas das redes especialistas, conseqüentemente, calcula a saída final da estrutura modular mediante ponderações (multiplicações por pesos) sobre os resultados das redes especialistas.

Para três ou mais redes especialistas, o conjunto de treinamento obtido para valores intermediários do parâmetro pode ser usado no processo de aprendizagem das redes especialistas adicionais.

Na definição para paradigma neural modular, todas as redes neurais individualmente possuem a mesma estrutura SF-ANN, mostrada na Fig. 3.8 e discutida na seção 3.7.

3.10 CONCLUSÃO

Foi apresentada uma breve descrição das características e aplicações gerais das redes neurais. Os dois tipos de redes neurais mais populares, a MLP e a RBF, foram descritos neste capítulo. Além disso, foi mostrada uma nova metodologia neurocomputacional, a Rede Neural Modular Função *Sample*, SF-ANN, baseada na função *sample* e na configuração das redes de funções de base radial (RBF-ANN).

Com processo de treinamento fundamentado no método do gradiente, a SF-ANN Modular é voltada para a modelagem dos dispositivos e circuitos EBG de modo a analisar os seus comportamentos eletromagnéticos.

Nos processos de modelagens de dispositivos e circuitos de microondas a serem apresentados nos capítulos seguintes, observa-se a comprovação da melhor eficiência da técnica modular SF-ANN em relação a técnica SF-ANN em vários aspectos como menor número de neurônios necessários, menor tempo de convergência, melhor generalização e maior precisão.

CAPÍTULO 4

APLICAÇÕES DAS ESTRUTURAS EBG EM GUIA DE ONDAS

4.1 INTRODUÇÃO

Uma extensa variedade de estruturas de transmissão é empregada na região de microondas. Estas incluem cabo coaxial, guias de ondas, linhas de fita, linhas de microfita, guias de onda coplanares, linhas de fita coplanares, linhas de fenda, além das linhas acopladas (WADELL, 1991). Seções de um meio, um quarto e um oitavo do comprimento de onda guiada destas estruturas formam alguns dos blocos básicos constituintes dos circuitos de microondas (POZAR, 1990).

Dentre estas estruturas de transmissão, o guia de ondas possui a característica de não propagar modos TEM. Além disso, há muitos modos ou soluções das equações de onda no guia e, cada uma possui uma frequência de corte associada. Desta forma, pode-se afirmar que ele se comporta como um filtro passa-altas. Estas e outras características contribuem para que o guia de ondas seja intensamente investigado e aplicado em sistemas de comunicações (FUSCO, 1987).

Recentemente, a introdução das estruturas periódicas com banda proibida, as estruturas EBG, em guias de ondas têm possibilitado o desenvolvimento de dispositivos de microondas mais eficientes e com características vantajosas.

Uma destas aplicações consiste no uso de estrutura EBG-UC-TP como paredes internas de um guia de ondas retangular, de modo a obter uma melhor distribuição da intensidade do campo elétrico, o que favorece sua utilização como alimentador de arranjos amplificadores de potência espacialmente acoplados (YANG F. 1999b).

Outra aplicação é a utilização de estrutura EBG-TP constituída por orifícios numa chapa metálica localizada no topo de um guia de placas paralelas, objetivando a eliminação dos modos espúrios indesejáveis presentes em dispositivos blindados (DAWN *et al.*, 2002).

Neste capítulo, os comportamentos eletromagnéticos dos guias de ondas com estrutura EBG citados anteriormente são investigados. Para isto, emprega-se a metodologia SF-ANN, Rede Neural Artificial Modular Função *Sample*, detalhada no Capítulo 3, para a geração de modelos neurais eficientes e precisos. São apresentados resultados para a velocidade de fase em função da frequência e para distribuição da intensidade de campo elétrico no interior de guias de ondas retangular com estruturas EBG. São também apresentados resultados para os parâmetros de espalhamento em guias de placas paralelas com estruturas EBG em função da frequência.

4.2 DISPOSITIVOS DE MICROONDAS USANDO GUIAS DE ONDAS

Essencialmente, pode-se dizer que o guia retangular é um tubo metálico com pequenas dimensões limitadas em meio comprimento de onda, λ , medido no espaço livre na frequência de operação de interesse, como mostrado na Fig. 4.1.




Fig.4.1: Guia de ondas retangular. (a) Vista frontal. (b) Vista longitudinal.

Idealmente, as paredes metálicas do guia são constituídas de um material condutor perfeito e funcionam como circuitos curto-circuitados gerando um percurso de baixa impedância para a corrente elétrica.

No centro do guia ao longo do eixo transversal, as paredes curto-circuitadas funcionam eletricamente como um circuito aberto para os modos de propagação TE_{2n+1} ($n=0,1,2\dots$). Isto significa que o centro do guia de ondas é uma região de alta impedância, conseqüentemente, os sinais podem atravessar ao longo do eixo central com o mínimo de atenuação (FUSCO, 1987).

O sinal com frequência mais baixa que o guia de ondas padrão pode propagar, f_0 (frequência de corte), está relacionado a sua largura, a . Ou seja, uma onda eletromagnética pode ser transmitida ao longo do guia de ondas, somente quando a frequência é maior que a frequência de corte, f_0 .

Outros tipos de estruturas de ondas guiadas são o guia circular, o guia de placas paralelas que pode ser considerado com uma linha de fenda blindada ou linha de microfita blindada.

4.2.1 Arranjos Amplificadores Espacialmente Acoplados

Os arranjos de amplificadores espacialmente acoplados ou quase-ópticos têm por objetivo integrar um grande número de dispositivos em uma estrutura irradiante planar. Estes possuem a capacidade de combinar eficientemente a potência de vários elementos ativos (PERKONS *et al.*, 1998).

Um circuito integrado amplificador quase-óptico é um arranjo monolítico de pequenos amplificadores, que intensifica um feixe de energia. A denominação quase-óptico é devido ao tamanho do arranjo tornar-se maior que dois comprimentos de onda no domínio óptico (HIGGINS *et al.*, 1999).

Arranjos de amplificadores têm sido obtidos em configurações do tipo grade (*grid*), ou usando antenas planares convencionais, como *patches* e *slots*. Em ambos os casos, os dispositivos são distribuídos em uma única camada transversal ao feixe de propagação. Isto requer antenas ressonantes de dimensões reduzidas, o que limita a largura de banda de operação do dispositivo (ALEXANIAN E YORK, 1997).

Além disso, a isolamento entrada/saída é um fator complicador do projeto de amplificadores quase-ópticos, pois requer o uso de geometrias com multicamadas, ou

polarização ortogonal para os sinais de entrada e saída ao longo da polarização externa dos componentes de controle. O uso de antenas transmissoras e receptoras separadas limitará a banda de passagem do circuito (ALEXANIAN E YORK, 1997).

Outro grande fator que dificulta o projeto de amplificadores quase-ópticos é o controle térmico. Na maioria das configurações projetadas, a dissipação de calor ocorre apenas na periferia do arranjo. Isto ocasiona uma limitação do tamanho do arranjo, de modo a manter os elementos centrais do arranjo na temperatura de operação especificada (ALEXANIAN E YORK, 1997).

Guias de ondas retangulares têm sido intensamente estudados para aplicações que envolvem o acoplamento de potência quase-óptica. Este fato deve-se à capacidade de eliminação das perdas de difração e à obtenção de respostas em banda larga destes dispositivos (ALEXANIAN E YORK, 1997; KOWN *et al.*, 1998).

Quando montado no interior de um guia de ondas convencional, o arranjo amplificador recebe uma densidade de potência que varia do quadrado do cosseno do valor máximo no meio do guia a zero nas paredes laterais. Isto compromete o funcionamento do arranjo amplificador com uma redução da potência de saída em torno de 6dB (HIGGINS *et al.*, 1999). Portanto, é essencial uma distribuição uniforme da intensidade do campo elétrico ao longo da abertura de um guia de ondas retangular.

Para obter esta propriedade, guias de ondas com preenchimento dielétrico são freqüentemente empregados em arranjos amplificadores espacialmente acoplados (ALEXANIAN E YORK, 1997). Entretanto, estes possuem algumas restrições: substratos com constantes dielétricas elevadas devem ser usados ou guias de ondas excessivamente grandes devem ser projetados (ZIENIUTYCZ e KILDAL, 1992). Podem-se usar ainda corrugações longitudinais para melhorar a distribuição do campo elétrico, contudo estas configurações provocam o estreitamento da banda de passagem e o aumento da complexidade do processo de fabricação (ZIENIUTYCZ e KILDAL, 1992).

Uma alternativa é o emprego de novas configurações de estruturas EBG, a EBG-UC (YANG F., 1999b) e a EBG-HIP (HIGGINS *et al.*, 1999) nas paredes internas dos guias de onda.

A estrutura EBG-UC comporta-se como uma superfície magnética perfeita na freqüência central da faixa de rejeição, onde o carregamento periódico muda a impedância de superfície para a condição de circuito aberto (MA *et al.*, 1998). Aplicando-se os refletores EBG-UC nas duas paredes laterais internas, o modo de propagação paralelo é

estabelecido pelas condições de borda magnética. Esta característica é vantajosa para a obtenção de um guia de ondas TEM com distribuição mais uniforme da intensidade do campo elétrico ao longo de sua seção transversal (YANG F., 1999b).

Estes refletores EBG-UC podem ser fabricados sobre uma camada fina de substrato e utilizar técnicas padrões de impressão que são mais simples que os processos de confecção dos guias convencionais com materiais de elevada constante dielétrica ou com corrugações.

4.2.2 Linhas de Transmissão Blindadas

A blindagem eletromagnética é comumente requerida em diversos circuitos de radiofrequência e de microondas, de modo a evitar as interferências mútuas entre dispositivos constituintes, e para protegê-los do contato atmosférico direto (HOFFMANN, 1987).

Um exemplo de uma estrutura de transmissão blindada é apresentado na Fig. 4.2. Consiste de uma fita condutora sobreposta a um material dielétrico delimitado por um guia de ondas metálico.




Fig.4.2: Linha de transmissão blindada.

As dimensões do guia de ondas, a e b , são escolhidas de maneira que a frequência de corte dos modos em um guia de ondas convencional seja suficientemente menor que os valores da faixa de operação a que se destina a estrutura de transmissão. Uma vez que, somente interessa o modo dominante, os modos de ordem superiores devem ser eliminados (HOFFMANN, 1987).

4.3 GUIA DE ONDAS RETANGULAR EBG-UC-TP

A Fig. 4.3 apresenta o dispositivo analisado neste trabalho. Consiste de um guia de ondas retangular carregado com estruturas EBG-UC nas suas laterais internas (YANG F. *et al.*, 1999b). A sua largura externa é igual a 22,86 mm, enquanto que a interna é igual a 21,59 mm.




Fig. 4.3: Guia de ondas com estrutura EBG-UC-TP.

As superfícies EBG-UC são impressas sobre um substrato Duroid 6010 com constante dielétrica igual a 10,2 e espessura de 0,635 mm (YANG F. *et al.*, 1999b). O período do arranjo é igual a 4,572 mm correspondendo a uma frequência de ressonância igual a 10 GHz.

A Fig. 4.4 mostra uma vista frontal do guia EBG-UC e o seu modelo equivalente que pode ser representada por dois circuitos LC em paralelo para obter uma primeira aproximação da relação de dispersão do dispositivo.

De modo a analisar o guia de ondas retangular com estrutura EBG-UC gravada nas suas paredes laterais internas, modelos SF-ANN modulares com três camadas foram desenvolvidos.




Fig. 4.4: Seção transversal do guia EBG-UC-TP e seu modelo de circuito equivalente.

A. Neuromodelagem SF-ANN para Análise da Velocidade de Fase no Guia de Ondas EBG-UC

No primeiro caso, modela-se o guia de ondas EBG-UC de modo a representar a sua velocidade de fase versus a frequência de operação. Para isto, utiliza-se a rede SF-ANN com uma unidade de entrada, a frequência de operação, dada em GHz. A camada oculta é formada por 15 neurônios. Já o nodo da camada de saída, a resposta do modelo neural, corresponde à velocidade de fase normalizada (v_p/c).

De modo a verificar a influência do número de dados de treinamento, foram projetados dois modelos neurais do guia de ondas EBG-UC. No primeiro modelo foram empregados 10 exemplos na fase de treinamento, mostrados na Fig. 4.5. Já no desenvolvimento do segundo modelo, foram usados 19 exemplos, mostrados na Fig. 4.6. Todos os exemplos foram obtidos a partir de medições disponíveis em Yang F. *et al.*, 1999b. Em ambos os casos, a taxa de aprendizagem foi 0,1 e após 200 épocas de treinamento, alcançou-se um erro quadrático médio final, (*MSE*, *mean-square error*), inferior a $1,0 \times 10^{-4}$.

Os resultados para a velocidade de fase, v_p/c , em função da frequência de operação do modelo SF-ANN para o guia de ondas EBG-UC são apresentados na Fig. 4.7, juntamente com valores correspondentes ao guia de ondas convencional (YANG F. *et al.*, 1999b) e com valores medidos e calculados pelo FDTD para o guia de onda EBG-UC.

Observa-se que a introdução de superfícies EBG-UC nas paredes laterais de um guia de ondas retangular proporciona uma redução média de 20% da velocidade de fase que alcança seu valor mínimo, $3,14 \times 10^8$ m/s, em 9,8 GHz (YANG F. *et al.*, 1999b). A curva da velocidade é relativamente plana e próxima da velocidade da luz entre 9,0 e 10,2 GHz, o que indica a formação do modo TEM. Além disso, a transição entre a parte indutiva para a capacitiva, em torno de 10 GHz, é suave, como mostrado na Fig. 4.7. Estas características favorecem o acoplamento eletromagnético necessário em válvulas de ondas caminantes.

Para efeito de validação da técnica neurocomputacional empregada, um conjunto teste de 4 valores medidos (dados de teste) e não utilizados na fase de treinamento da rede é apresentado na Fig. 4.7. Constata-se uma boa concordância entre este conjunto teste de 4 valores medidos e a resposta do modelo SF-ANN para o guia de ondas EBG-UC para a faixa de frequência de operação. O modelo SF-ANN também apresentou boa precisão em comparação como outros 17 resultados medidos disponíveis em (YANG F. *et al.*, 1999b).

Além disso na Fig. 4.7, pode-se concluir que a diferença entre a resposta do modelo SF-ANN e o conjunto teste de valores medidos é menor que a apresentada pela técnica de onda-completa FDTD. Este fato é justificado pela não consideração por parte da técnica FDTD do mecanismo alimentador do guia, que é constituído por uma antena quase-Yagi.




Fig. 4.5: Valores medidos (ooo) (10 dados de treinamento) usados no processo de aprendizagem do primeiro modelo neural SF-ANN do guia de ondas retangular EBG-UC-T para análise da velocidade de fase normalizada versus a frequência de operação (YANG F. *et al.*, 1999b).




Fig. 4.6: Valores medidos (ooo) (19 dados de treinamento) usados no processo de aprendizagem do segundo modelo neural SF-ANN do guia de ondas retangular EBG-UC-T para análise da velocidade de fase normalizada versus a frequência de operação (YANG F. *et al.*, 1999b).




Fig. 4.7: Resposta do modelo SF-ANN (—) para a análise da velocidade de fase normalizada versus a freqüência de operação em um guia de ondas retangular EBG-UC-TP: (a) Modelo 1 usando apenas 10 dados de treinamento, indicados na Fig.4.5, (b) Modelo 2 usando 19 dados de treinamento, indicados na Fig.4.6. Resultados experimentais (ooo) para o guia EBG-UC-TP não usados na fase de treinamento da rede (YANG F. *et al.*, 1999b). Resultados (***) obtidos através da técnica FDTD para o guia EBG-UC-TP (YANG F. *et al.*, 1999b). Resultados (+++) medidos para o guia retangular convencional (YANG F. *et al.*, 1999b).

B. Neuromodelagem SF-ANN para Análise da Distribuição da Intensidade do Campo Elétrico ao longo da Seção Transversal do Guia de Ondas EBG-UC-TP

A configuração da SF-ANN usada para estimar o comportamento da intensidade de campo elétrico ao longo da seção transversal do guia de ondas EBG-UC-TP é constituída por dois nodos de entrada, a frequência de operação, f , e a posição de medição do campo elétrico, x . A camada oculta foi projetada com 60 neurônios e a unidade de saída é a intensidade do campo elétrico em dBmV/m.

No processo de aprendizado da rede neural foi utilizado um conjunto de 40 exemplos, mostrado na Fig. 4.8, obtidos a partir de resultados experimentais disponíveis em Yang F. *et al.*, 1999b. Após 1000 épocas de treinamento, a uma taxa de aprendizado de 0,01, a rede apresentou um erro médio final, MSE , igual a $0,8 \times 10^{-4}$.

A resposta do modelo SF-ANN para o guia EBG-UC está mostrada na Fig 4.9. A posição central do guia está em $x = 0$ e a parede magnética encontra-se na posição $x = 1$.

Em um guia de ondas convencional a intensidade do campo elétrico decresce sensivelmente ao longo de sua seção transversal. Constata-se, por meio de observação da Fig 4.9, que a introdução de uma superfície EBG-UC nas faces laterais de um guia de ondas convencional gera uma distribuição uniforme da intensidade de campo elétrico ao longo de sua seção transversal.

Especialmente na faixa de frequência de 9,5 a 10,6 GHz, que corresponde à região onde as superfícies EBG-UC comportam-se como paredes magnéticas, a equalização da intensidade do campo elétrico é acentuada, sendo o ponto ótimo estabelecido em 9,8 GHz, onde a diferença entre a intensidade de campo na posição central e tangencial do guia não ultrapassa 4 dB.

Em relação à validação da técnica SF-ANN, mostrada na Fig 4.9, observa-se que as saídas do modelo SF-ANN referentes às intensidades de campo para quatro diferentes posições ao longo do guia de ondas EBG-UC apresentam uma excelente concordância com o conjunto de teste que é composto por 16 valores medidos (dados de teste) não usados na fase de treinamento, apresentados em Yang F. *et al.*, 1999b. A precisão das saídas do modelo SF-ANN para o guia EBG-UC também é elevada para um outro conjunto de teste composto por 16 novos valores medidos e apresentados na Fig 4.9.

De modo a avaliar a capacidade de generalização do modelo SF-ANN para o guia EBG-UC foi simulada a distribuição da intensidade do campo elétrico versus a frequência para uma nova posição ao longo da seção transversal. Esta generalização, para a posição

de medição $x = 1/2$, correspondendo a metade da largura do guia, é apresentada na Fig 4.10.

Baseado nos resultados experimentais (16 dados de teste), adicionados na Fig 4.10, constata-se que as respostas do modelo SF-ANN são satisfatórias e coerentes com valores estimativamente esperados.




Fig 4.8: Valores medidos (dados de treinamento) usados no processo de aprendizagem do modelo neural SF-ANN do guia de ondas retangular EBG-UC-T para análise da distribuição da intensidade do campo elétrico ao longo da seção transversal em função da frequência de operação : $x=0$ (ooo); $x=1/3$ (+++); $x=2/3$ (xxx) e $x=1$ (***) (YANG F. *et al.*, 1999b).




Fig 4.9: Resposta do modelo SF-ANN (—) para distribuição da intensidade do campo elétrico no guia de ondas EBG-UC-TP $x=0$; $x=1/3$; $x=2/3$ e $x=1$. Resultados experimentais (dados de teste) não usados na fase de treinamento da rede SF-ANN : $x=0$ (ooo); $x=1/3$ (+++); $x=2/3$ (xxx) e $x=1$ (***) (YANG F. *et al.*, 1999b).




Fig 4.10: Resposta do modelo SF-ANN (—) para a distribuição da intensidade do campo elétrico no guia de ondas EBG-UC em $x=0$; $x=1/3$; $x=2/3$ e $x=1$ e Generalização do modelo SF-ANN (—) em uma nova posição $x=1/2$. Resultados experimentais (16 dados de teste) não usados na fase de treinamento da rede SF-ANN : $x=0$ (ooo); $x=1/3$ (+++); $x=2/3$ (xxx) e $x=1$ (***) (YANG F. *et al.*, 1999b).

C. Neuromodelagem SF-ANN modular para Análise da Distribuição da Intensidade do Campo Elétrico ao longo da Seção Transversal do Guia de Ondas EBG-UC-TP

Com o objetivo de comprovar a eficiência superior da rede modular SF-ANN foi também realizada a modelagem do guia de ondas EBG-UC-TP mostrado na Fig. 4.3, com o uso da máquina de comitê empregando o paradigma SF-ANN discutido na seção 3.9.

A arquitetura do modelo SF-ANN modular é formada por duas redes especialistas e uma rede de passagem. As redes neurais possuem dois nodos de entradas correspondendo a frequência de operação do guia, f , e a posição de medição da intensidade do campo elétrico, x . Estabelece-se que a posição central do guia EBG-UC-TP está em $x = 0$, e a posição final está em $x = 1$. O nodo de saída das redes neurais é a magnitude do campo elétrico. A quantidade de neurônios nas camadas ocultas das especialistas e da rede de passagem é 15 e 25, respectivamente.

No treinamento das redes especialistas e de passagem foram empregados 30 valores medidos obtidos por (YANG F. *et al.*, 1999b) e mostrados na Fig. 4.11. A primeira rede especialista foi treinada com o conjunto de 10 exemplos referentes ao valor inicial do parâmetro posição de medição da intensidade do campo elétrico, $x = 0$, enquanto no processo de treinamento da segunda rede especialista foi empregado o conjunto de 10 exemplos referentes ao valor final do parâmetro, $x = 1$. No caso do processo de aprendizagem da rede de passagem emprega-se o conjunto total de 30 exemplos obtidos para três diferentes valores do parâmetro, $x = 0$, $x = 1/3$ e $x = 1$.

A Fig 4.12 mostra as curvas de resposta do modelo SF-ANN modular para o guia EBG-UC-TP para a intensidade do campo elétrico para três diferentes posições de medição ao longo de sua seção transversal em função da frequência.

Observa-se na Fig 4.12 que o modelo desenvolvido usando a rede modular SF-ANN simular com boa precisão o guia de ondas EBG-UC-TP, o que é indicado pela concordância entre as respostas do modelo neural e o conjunto teste constituídos por 12 novos resultados experimentais, obtidos por medição e diferentes do conjunto de exemplos usados no processo de treinamento. A precisão do modelo SF-ANN modular também é avaliada para outros 15 resultados experimentais não usados na fase de treinamento e é mostrada na Fig 4.13.

A capacidade de generalização do modelo modular da rede SF-ANN também é testada. Para isto, são geradas curvas de resposta do modelo SF-ANN para duas novas posições de medição, $x = 1/6$ e $x = 2/3$ que são mostradas na Fig 4.13.

Observa-se na Fig 4.13 que a curva de resposta do modelo SF-ANN modular para $x = 2/3$ apresenta valores satisfatórios com o conjunto teste constituído por 10 resultados experimentais disponíveis em (YANG F. *et al.*, 1999b). Já a curva de resposta para a posição $x = 1/6$ é considerada boa quando comparada aos valores estimativamente esperados baseados nos resultados experimentais apresentados na Fig 4.13. Estes fatos comprovam a excelente capacidade de generalização do modelo SF-ANN modular.

Quando comparado ao modelo SF-ANN apresentado na seção B, destacam-se algumas vantagens do modelo modular. Em relação ao número de exemplos, o modelo modular necessitou de um menor número, apenas valores para três parâmetros, o modelo SF-ANN para quatro parâmetros. Em relação ao processo de treinamento, o modelo modular reduziu em torno de 20% o tempo de treinamento, além de simplificar na escolha dos parâmetros iniciais da rede neural. Estes fatores favorecem a aplicação do modelo modular SF-ANN para a simulação de dispositivos e circuitos de microondas.




Fig 4.11: Valores medidos (30 dados de treinamento) usados no processo de aprendizagem do modelo neural SF-ANN modular do guia de ondas retangular EBG-UC-T para análise da distribuição da intensidade do campo elétrico ao longo da seção transversal em função da frequência de operação $x=0$ (+++); $x=1/3$ (ooo) e $x=1$ (***) (YANG F. *et al.*, 1999b).




Fig 4.12: Resposta do modelo SF-ANN modular (—) para a distribuição da intensidade do campo elétrico ao longo da seção transversal de um guia de ondas retangular EBG-UC-TP em função da frequência de operação $x=0$; $x=1/3$ e $x=1$. Resultados experimentais (12 dados de teste) não usados na fase de treinamento da rede SF-ANN para : $x=0$ (ooo); $x=1/3$ (+++) e $x=1$ (***) (YANG F. *et al.*, 1999b).

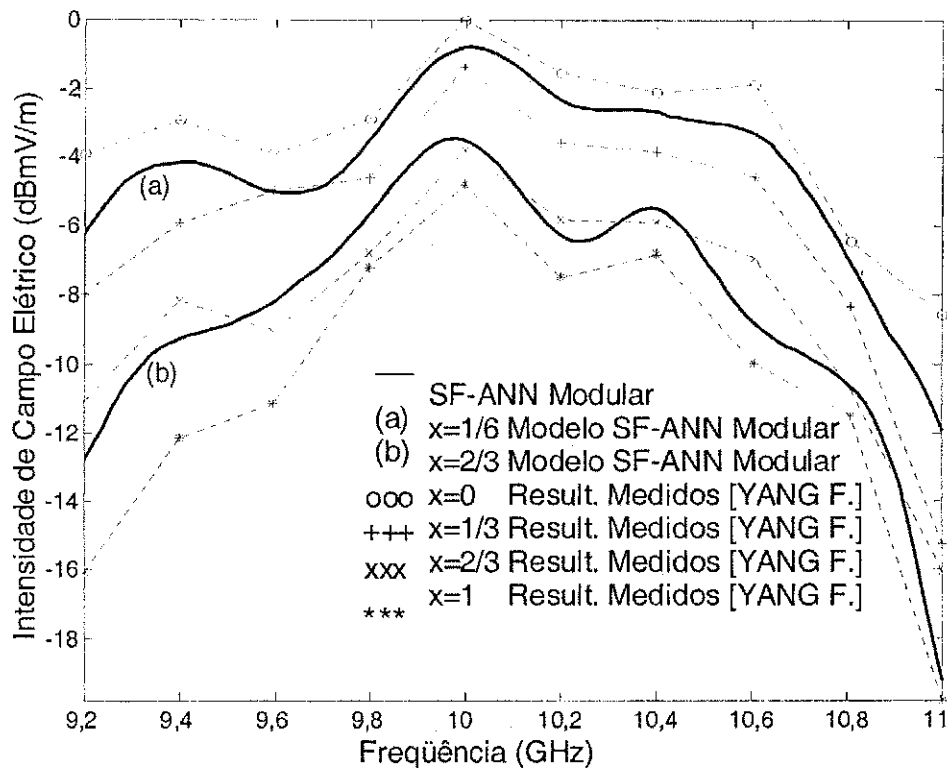


Fig 4.13: Resposta e generalização do modelo SF-ANN modular (—) para a distribuição da intensidade do campo elétrico ao longo da seção transversal de um guia de ondas retangular EBG-UC-TP em função da frequência de operação para $x= 1/6$ e $x= 2/3$. Resultados experimentais para : $x= 0$ (ooo); $x= 1/3$ (+++); $x= 2/3$ (xxx) e $x= 1$ (***) (YANG F. *et al.*, 1999b). Nota-se a concordância da generalização para $x = 2/3$ entre a resposta do modelo SF-ANN modular e o conjunto teste de resultados medidos (não usados no processo de treinamento) obtidos na literatura (YANG F., 1999b).

4.4 GUIA DE PLACAS PARALELAS EBG-TP

Como já comentado, as estruturas EBG geram o efeito de banda de rejeição (*stopband*), onde a propagação eletromagnética é proibida se o período dos elementos é igual à metade do comprimento de onda guiada do modo de propagação na frequência central da faixa de rejeição (COCCIOLI e ITOH, 1999).

Baseado neste princípio, a Fig 4.14 mostra um guia de placas paralelas EBG-TP proposto para reduzir os problemas de interferências entre dispositivos, e suprimir os modos espúrios em linhas planares blindadas (DAWN *et al.*, 2002).

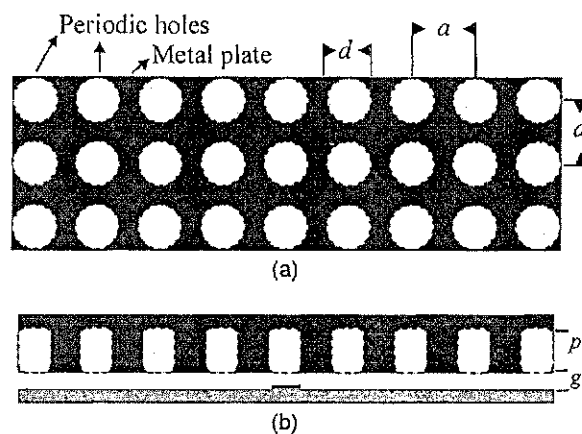


Fig 4.14: Guia de ondas com placas paralelas usando estrutura EBG: (a) Vista superior. (b) Vista da seção transversal.

Este dispositivo é formado por uma linha de microfita com uma blindagem metálica no topo separada por um gap g . Nesta chapa metálica é implantada a estrutura EBG-TP que é constituída por uma matriz de orifícios circulares de diâmetro d , profundidade p e espaçados por um período a .

É claro que a conexão deste dispositivo a qualquer circuito descontínuo ou desbalanceado pode gerar a propagação indesejada do modo de placas paralelas, além da transmissão do modo desejado na microfita. Isto causa problemas de interferências (*crosstalks*) entre os dispositivos circunvizinhos, e perda de potência devido ao vazamento (*leakage*).

A. Neuromodelagem SF-ANN Modular para o Guia de Placas Paralelas com Estrutura EBG

A arquitetura neural modular SF-ANN foi constituída por duas redes especialistas e uma rede de passagem. Cada rede é formada por dois nodos de entrada que representam o diâmetro, d , e a frequência de operação, f ; e nodo de saída que representa o parâmetro de transmissão, S_{21} . Foram empregados 10 neurônios na camada oculta de cada rede especialista e 30 neurônios na camada oculta da rede de passagem.

No processo de treinamento, foi empregado um conjunto de 60 exemplos de valores de entrada e saída com dois valores de diâmetro, $d = 1,2$ mm e $d = 1,4$ mm, e uma faixa de frequência de 50 a 85 GHz. Este conjunto de exemplos foi obtido por simulação eletromagnética, HFSS, em 76 GHz para uma estrutura EBG-TP, mostrada na Fig 4.14, com $a = 1,62$ mm, $p = 1,2$ mm, $g = 0,5$ mm e com 9 elementos periódicos (DAWN *et al.*, 2002).

A primeira rede especialista foi treinada com um conjunto de 15 exemplos cujo valor do diâmetro é igual a 1,2 mm, enquanto, a segunda rede especialista utilizou no processo de treinamento 15 exemplos cujo valor do diâmetro era igual 1,4 mm. Já na rede de passagem emprega-se o conjunto completo de treinamento no processo de aprendizagem.

Após o processo de treinamento usando o algoritmo Rprop, a abreviação de *Resilient backpropagation* (RIEDMILLER e BRAUN, 1993), o erro quadrático médio final obtido ficou abaixo de $1,0 \times 10^{-5}$.

A Fig 4.15 apresenta a resposta do modelo SF-ANN modular para o guia de ondas de placas paralelas EBG-TP. Para avaliar a precisão da resposta do modelo SF-ANN modular é adicionado a Fig 4.15 um conjunto de teste constituído por 10 resultados simulados não usados na fase de treinamento da rede disponíveis em (DAWN *et al.*, 2002).

Como esperado, a introdução da estrutura EBG-TP reduz o modo de placas paralelas (76 GHz) em torno de -10dB para $d = 1,2$ mm e de -14dB para $d = 1,4$ mm, sem afetar a propagação do modo da linha de microfita.

Constata-se também, na Fig 4.15 que o nível de supressão do modo de placas paralelas pode ser acrescido com o aumento do diâmetro dos orifícios periódicos. A largura e a intensidade da supressão é consideravelmente aumentada com uma pequena variação de 1,2 mm para 1,4 mm de diâmetro. Isto pode também ser obtido pelo aumento do número de elementos ou da profundidade do elemento circular (DAWN *et al.*, 2002).

Em relação à resposta do modelo SF-ANN modular, consta-se uma excelente concordância com os 15 valores de testes apresentados, atestando a precisão dos seus valores de saída, como mostrado na Fig 4.15.

A capacidade de generalização do modelo desenvolvido para o guia de placas paralelas EBG-TP usando a metodologia SF-ANN modular é também avaliada. A Fig 4.16 apresenta a resposta do modelo neural para novos valores de diâmetro dos orifícios circulares: para $d = 1,25$ mm e para $d = 1,35$ mm.

Uma maneira de avaliar a generalização do modelo neural para novos valores do diâmetro dos elementos periódicos do guia de placas paralelas é a comparação com resultados obtidos por meio da técnica de escalonamento, discutida na seção 2.5.

A equação geral da técnica do escalonamento é rerepresentada com modificações nas variáveis de modo a englobar os parâmetros analisados.

$$\begin{bmatrix} a_2 \\ d_2 \end{bmatrix} = \frac{S_{21_1}}{S_{21_2}} \cdot \begin{bmatrix} a_1 \\ d_1 \end{bmatrix} \quad (4.1)$$

Para o primeiro caso da generalização, a curva (a) da Fig 4.16, têm-se como valores básicos $d_1 = 1,2$ mm, $a_1 = 1,62$ mm e $S2I_1 = -9,57$ dB na frequência, $f = 76$ GHz. O parâmetro a ser escalonado é $S2I_2$ com $d_2 = 1,25$ mm e $a_2 = 1,62$ mm.

Empregando-se (4.1) obtém-se $S2I_2 = 9,97$ dB. Este valor está condizente com o valor obtido pelo modelo neural SF-ANN que foi de 10,20 dB.

No segundo caso da generalização, a curva (b) da Fig 4.16, foram considerados como valores básicos $d_1 = 1,4$ mm, $a_1 = 1,62$ mm e $S2I_1 = -13,67$ dB na frequência, $f = 76$ GHz. Também o parâmetro escalonado é $S2I_2$ com $d_2 = 1,35$ mm e $a_2 = 1,62$ mm.

Mais uma vez, empregando-se (4.1) obtém-se o valor escalonado para é $S2I_2$ que foi de -13,19. O valor generalizado pelo modelo neural SF-ANN na frequência de 76 GHz, foi de 12,55 GHz, o que pode ser considerado condizente com o valor escalonado.

Observa-se de uma maneira geral, que a resposta do modelo SF-ANN modular está em conformidade com valores estimados baseados nos resultados para $d = 1,2$ mm e $d = 1,4$ mm. Isto comprova a boa capacidade de generalização da técnica neurocomputacional SF-ANN modular.




Fig 4.15: Resposta do modelo SF-ANN modular (—) para o guia de ondas de placas paralelas EBG-TP para valores de diâmetro $d=1,2$ mm e $d=1,4$ mm. Resultados simulados HFSS (dados de teste) não usados na fase de treinamento da rede SF-ANN para $d=1,2$ (ooo) e $d=1,4$ (***) (DAWN *et al.*, 2002).




Fig 4.16: Generalização do modelo SF-ANN modular (—) para o guia de ondas de placas paralelas EBG-TP para novos valores de diâmetro dos elementos circulares, não usados na fase de treinamento: (a) $d=1,25$ mm e (b) $d=1,35$ mm. Valores calculados (X) e (+) para frequência $f=76$ GHz para $d=1,25$ mm e $d=1,35$ mm, através da técnica de escalonamento. Resultados simulados HFSS para $d=1,2$ (ooo) e $d=1,4$ (***) (DAWN *et al.*, 2002).

4.5 CONCLUSÃO

O emprego de estruturas EBG em guias de onda, foi abordado neste capítulo. Para isto empregou-se a metodologia SF-ANN.

A introdução de refletores EBG-UC-TP nas paredes laterais de um guia de ondas retangular objetivando uma distribuição mais uniforme da intensidade do campo elétrico na abertura foi constatada, também na análise através do modelo neural SF-ANN. Isto propicia ao novo guia de ondas a capacidade de funcionar como um excelente alimentador para arranjos de amplificadores quase-ópticos.

Já a presença de uma estrutura EBG-TP no topo de um guia de ondas de placa paralelas propicia a redução do nível de intensidade dos modos espúrios presentes em estruturas blindadas de transmissão, fato também observado na análise através de redes neurais.

Os modelos desenvolvidos por meio da metodologia SF-ANN para os dois tipos de guias de onda discutidos mostraram-se precisos quando comparados aos resultados obtidos na literatura científica e não incluídos nas fases de treinamento da rede. Além disso, eles foram aptos e eficientes na generalização do comportamento eletromagnético dos guias de ondas para novos valores dos seus parâmetros estruturais.

Também foram desenvolvidos modelos modulares da SF-ANN para as simulações dos guias de ondas discutidos neste capítulo. Os modelos modulares projetados funcionam pois o algoritmo proposto permitiu a obtenção de uma alta taxa de aprendizagem e uma boa capacidade de generalização que foi verificada com a aplicação da técnica do escalonamento. A utilização da arquitetura modular gera algumas vantagens, como melhor eficiência no processo de treinamento, mais rápida convergência, além de melhores generalizações.

CAPÍTULO 5

APLICAÇÕES DE ESTRUTURAS EBG EM LINHAS DE MICROFITA

5.1 INTRODUÇÃO

As linhas de transmissão planares desempenham as mesmas tarefas em circuitos integrados de microondas (MIC, *microwave integrated circuits*) que os cabos coaxiais e os guias de ondas nos circuitos de microondas convencionais. Nos MICs, da mesma maneira que em circuitos integrados digitais, todos os componentes devem ser interconectados e confeccionados por meio da mesma tecnologia planar (HOFFMANN, 1987).

A primeira geração de linhas de transmissão planares é a linha de fita, também denominada linha *stripline*. Entretanto, apenas com o advento da linha de microfita que a tecnologia de circuitos integrados de microondas deu um salto em número de aplicações. Dentre as linhas planares, a linha de microfita, ainda é a mais comumente usada, devido a sua simples fabricação e adaptabilidade (WADELL, 1991).

A introdução de estruturas com banda proibida eletromagnética, estruturas EBG, em linhas de microfita propiciou inúmeras características com a exibição de faixa de rejeição de frequência e aumento do valor da constante de propagação. Estas particularidades são empregadas, por exemplo, na confecção de filtros para rejeitar modos de propagação indesejáveis e de dispositivos de ondas lentas com dimensões reduzidas.

Algumas aplicações de estrutura EBG em linhas de microfita são analisadas neste capítulo. Para isto, é empregada a Rede Neural Modular Função *Sample* – SF-ANN, no desenvolvimento de modelos que possam simular o comportamento eletromagnético dos dispositivos de microondas constituídos por linhas de microfita usando estruturas EBG.

5.2 DISPOSITIVOS DE LINHAS DE MICROFITA

A linha de microfita é provavelmente a mais empregada e mais investigada linha de transmissão planar. A sua geometria, como mostra a Fig. 5.1, consiste de uma fita condutora de largura, w , e espessura, t , sobreposta a um material dielétrico de espessura, h , com permissividade relativa, ϵ_r .




Fig. 5.1: Linha de microfita convencional. Vista frontal.

A fácil fabricação por meio de técnicas de fotolitografia, a extensa faixa de impedância e os diversos acoplamentos permitem que a linha de microfita seja empregada em uma grande variedade de componentes em circuitos integrados de microondas - MIC (FOOKS e ZAKAREVICIUS, 1990).

Embora com sua geometria simples, os diagramas de campos ao redor dos condutores são complexos, devido à característica não-homogênea da linha de microfita. Há uma concentração do campo elétrico na região do substrato dielétrico em relação ao ar, isto provoca que o modo de propagação não é o TEM e sim o quase - TEM, devido à tênue distorção gerada pela mistura de dielétricos.

Diversas técnicas de análise e síntese de linhas de microfita têm sido reportadas, análises quase-estáticas, modelos semi-empíricos e análises de onda completa (GUPTA *et al.*, 1979). Em baixas frequências, as equações simplificadas tornam-se razoavelmente precisas, no entanto, na faixa de microondas, a componente de campo ao longo da linha torna-se mais expressiva e deve ser levada em consideração. Isto ocasiona a dependência de frequência da impedância e constante dielétrica efetiva, conseqüentemente, para uma análise precisa, técnicas de onda completa são requeridas.

As análises de onda completa empregam métodos numéricos para caracterização de linhas de microfita que, geralmente, exigem computação intensa. Conseqüentemente, as

expressões em forma fechada são ainda muito usadas em projeto auxiliado por computador - CAD e otimização (GUPTA *et al.*, 1981).

5.2.1 Filtros Planares

A filtragem é uma das partes mais importantes dos vários circuitos e sistemas de microondas. A eliminação de frequências indesejáveis pode ser alcançada através de tocos curto-circuitados ou linhas de impedância crescente em circuitos de microfita (FOOKS e ZAKAREVICIUS, 1990). Tipicamente para aplicações em faixa estreita, estas configurações ocupam grande parte do circuito e produzem espúrios do sinal dentro da faixa de rejeição (KIM e SEO, 2000).

As estruturas *bandgap* eletromagnético, EBG, têm sido consideradas como uma alternativa para minimizar estas desvantagens em aplicações de filtros de microondas usando linhas de microfita (KIM e SEO, 2000; RADISIC *et al.*, 1998; RUMSEY *et al.*, 1998; YANG F. *et al.*, 1999a; YANG F. *et al.*, 1999; XUE *et al.*, 2000). Compatível com a tecnologia de sistemas monolíticos, o uso de estrutura EBG em circuitos de microfita realiza a filtragem de faixas de frequências específicas.

Um filtro de microondas padrão pode ser constituído por uma estrutura EBG no plano de terra de uma linha de microfita onde a intensidade e a largura da faixa de rejeição de frequência depende das dimensões dos seus elementos periódicos (RADISIC *et al.*, 1998). Já um filtro de microfita banda larga pode ser facilmente construído através de uma conexão em série de diferentes estruturas EBG dimensionadas de modo a alcançar o alargamento da faixa de rejeição (RUMSEY *et al.*, 1998).

Em geral, a frequência central de rejeição do filtro EBG, f_0 , é função do espaçamento dos elementos periódicos, a . Basicamente, o comprimento de onda guiada, λ_g , em f_0 é aproximadamente duas vezes o espaçamento a (COCCIOLI e ITOH, 1999). Entretanto, uma caracterização apurada do filtro de microondas com estrutura EBG com a determinação da sua matriz de espalhamento não é facilmente realizada, necessitando de uma análise de onda completa.

5.2.2 Dispositivos de Ondas Lentas

O modo de propagação em ondas lentas é de grande interesse para o casamento entre a velocidade da onda e a velocidade dos elétrons em sistemas de válvulas de ondas caminantes (TWT, *traveling wave tubes*), e para a redução das dimensões dos componentes distribuídos em circuitos integrados (FOOKS e ZAKAREVICIUS, 1990).

É fator crucial a diminuição da disparidade das dimensões entre dispositivos ativos e passivos em circuitos monolíticos ou híbridos. Para alcançar este objetivo, linhas de transmissão de ondas lentas, como as estruturas metal-isolante-semicondutor (MIS, *metal-insulator-semiconductor*), têm sido investigadas (HASEGAWA *et al.*, 1971; HASEGAWA *et al.*, 1984; MU *et al.*, 1986).

Entretanto, para aplicações em alta frequência, as estruturas MIS são inadequadas, devido a algumas desvantagens. A primeira delas é a elevada perda ôhmica provocada pela grande concentração de corrente na superfície do condutor (KWON *et al.*, 1998). A segunda desvantagem é a proporcionalidade inversa entre a frequência de operação e a parte imaginária da permissividade elétrica do material, fazendo com que o fator de ondas lentas decresça com o aumento da frequência (OGAWA e ITOH, 1986). Além disso, a impedância característica das linhas MIS é excessivamente baixa exigindo uma fotolitografia mais precisa para a maioria dos ajustes finos.

Modificações das estruturas MIS como as estruturas de ondas-lentas *cross-tie* têm sido propostas para minimizar estas desvantagens (WANG e ITOH, 1988). Entretanto, as perdas de inserção, ainda são, consideravelmente, maiores do que da linha de microfita convencional, e um aumento da complexidade do processo de fabricação é requerido (YANG, F. *et al.*, 1998).

O desenvolvimento de um dispositivo ideal de ondas lentas com impedância moderada, baixas perdas e um processo de fabricação simples tem sido o alvo principal de muitas pesquisas. Uma alternativa viável é o dispositivo de ondas lentas usando estrutura EBG-UC. Um exemplo desta aplicação é a linha de ondas lentas EBG-UC-GP, que consiste de uma linha de microfita convencional com estrutura EBG uniplanar compacta gravada no seu plano de terra. Esta apresenta baixas perdas, impedância moderada e características uniplanares que pode ser integrada facilmente com outros componentes em um circuito de microondas (YANG F. *et al.*, 1998; YANG F. *et al.*, 1999a).

5.3 LINHAS DE MICROFITA COM ESTRUTURAS EBG-GP

5.3.1 Filtro EBG-GP

O primeiro dispositivo EBG modelado pela rede SF-ANN é apresentado na Fig. 5.1. Constituído por uma linha de microfita usando uma estrutura EBG-GP, foi proposto para funcionar como filtro de microondas (RADISIC, *et al.*, 1998). A estrutura EBG empregada consiste de uma rede periódica quadrada bi-dimensional, com três filas de nove círculos encravados no plano de terra da uma linha de microfita.




Fig. 5.2: Linha de microfita com estrutura EBG-GP.

O substrato considerado é o RT/Duroid 6010, com constante dielétrica igual a 10,5 e espessura igual a 0,635 mm. A impedância característica da linha de microfita é igual a 50Ω , correspondendo a uma largura de fita igual a 0,686 mm (RADISIC, *et al.*, 1998).

Os parâmetros da matriz EBG, o espaçamento e o raio dos elementos periódicos, a e r , respectivamente, são os fatores que definem o diagrama de dispersão da estrutura, ou mais especificamente a caracterização de filtragem da linha de microfita.

A. Neuromodelagem do Filtro EBG-GP

Uma vez definido o dispositivo com estrutura EBG, Fig. 5.1, a metodologia SF-ANN é implementada para desenvolver modelos que permitam simular o seu comportamento eletromagnético, através da apresentação de sua matriz de espalhamento em função de diversos parâmetros.

De modo a investigar o efeito sobre a faixa de rejeição apresentada pelo dispositivo EBG-GP, o raio dos elementos periódicos da estrutura EBG é variado para três valores diferentes: a) 0,635 mm; b) 1,27 mm e c) 2,286 mm. O espaçamento entre os círculos, a , ficou constante e igual a 5,08 mm, de modo a projetar f_0 em torno de 10,8 GHz, de acordo com as fórmulas aproximadas de projeto apresentadas no Capítulo 2.

No processo de modelagem foi empregada a Rede Neural Função *Sample*, SF-ANN. A camada de entrada possui dois nodos que representam as variáveis de entrada: o raio das perfurações periódicas, r , e a frequência de operação, f . A camada oculta é formada por 90 neurônios, e a camada de saída possui um nodo de saída que representa o parâmetro de espalhamento, S_{21} , em dB.

A SF-ANN foi treinada com um conjunto de 75 dados para três diferentes valores de raio: 0,635 mm, 1,270 mm e 2,286 mm, e a faixa de frequência de 2,0 GHz a 15,5 GHz, de acordo com os resultados medidos (RADISIC *et al.*, 1998). A taxa de aprendizado foi de 0,02 e o erro quadrático médio depois de 1500 épocas foi de $1,0 \times 10^{-4}$.

Depois do processo de treinamento, a validação do modelo SF-ANN para o filtro de microondas EBG-GP foi verificada. A Fig. 5.3 mostra as respostas obtidas pelo modelo SF-ANN para o coeficiente de transmissão, S_{21} , em função da frequência de três diferentes filtros planares EBG-GP juntamente com os correspondentes conjuntos de teste constituídos por 30 pares de resultados experimentais e que não foram usados durante o processo de treinamento.

Na Fig. 5.3, constata-se que o aumento do raio dos elementos periódicos do filtro planar EBG-GP produz uma faixa de rejeição mais larga e acentuada. No caso limite, $r \rightarrow 0$, não há faixa de rejeição e o filtro comporta-se como uma linha de microfita convencional.

Também na Fig. 5.3, em relação à técnica SF-ANN, verifica-se uma boa concordância entre as respostas do modelo SF-ANN e o conjunto de resultados medidos amostrados; comprovando sua precisão.

De modo a verificar a capacidade de generalização do modelo SF-ANN, foram obtidas novas curvas de S_{21} versus a frequência de operação, f , para filtros EBG com raio dos elementos periódicos diferentes.

A Fig. 5.4 mostra a generalização da resposta do modelo SF-ANN para um Filtro EBG com perfurações periódicas de raio igual a 1,22 mm.

Similarmente, a Fig. 5.5 mostra uma generalização obtida pelo modelo SF-ANN que representa a resposta do filtro EBG com raio igual a 1,32 mm.

De modo a avaliar as generalizações apresentadas nas Figs. 5.4 e 5.5, fez-se uso da técnica do escalonamento discutida na seção 2.5, empregando a expressão aqui novamente apresentada e modificada.

$$\begin{bmatrix} a_2 \\ r_2 \end{bmatrix} = \frac{Ganho_1}{Ganho_2} \cdot \begin{bmatrix} a_1 \\ r_1 \end{bmatrix} \quad (5.1)$$

Como parâmetros iniciais foram escolhidas as medidas e os valores referentes a um resultado experimental mostrado na curva *b* da Fig. 5.3, que corresponde a $r_1 = 1,27\text{mm}$; $a_1 = 5,08\text{mm}$ e $Ganho_1 = -38,58\text{ dB}$ para $f_1 = 11,20\text{ GHz}$.

Para o primeiro caso, mostrado na Fig. 5.4, tem-se $r_2 = 1,22$ e $a_2 = 5,08$. Empregando-se (5.1) obtém-se $Ganho_2 = -37,06\text{ dB}$. A generalização obtida pelo modelo neural para $f_1 = f_2 = 11,20\text{ GHz}$ foi de $-36,60\text{ dB}$, o que condiz com o valor definido pela técnica do escalonamento.

No segundo caso, mostrado na Fig. 5.5, os valores dos parâmetros são $r_2 = 1,32$ e $a_2 = 5,08$. Similarmente, utilizando (5.1) calcula-se o valor estimado pela técnica do escalonamento, $Ganho_2 = -40,10\text{ dB}$. A resposta do modelo neural, $-40,80\text{ dB}$, está muito próxima do valor calculado pela técnica do escalonamento.

Observa-se nos casos descritos anteriormente que a capacidade de generalização do modelo SF-ANN pode ser considerada satisfatória. Suas saídas estão em excelente concordância com resultados estimados baseados nos valores medidos disponíveis, bem como, os valores calculados pela técnica do escalonamento.




Fig. 5.3: Resposta do modelo SF-ANN para o filtro EBG-GP (—) para análise do ganho versus a frequência de operação apresentado por três diferentes estruturas com raios, (a) $r = 0,635$ mm, (b) $r = 1,27$ mm e (c) $r = 2,286$ mm. Resultados experimentais não usados na fase de treinamento da rede SF-ANN para : $r = 0,635$ mm (***) ; $r = 1,27$ mm (ooo) e $r = 2,286$ mm (+++) (RADISIC *et al.*, 1998).




Fig. 5.4: Resposta e generalização do modelo SF-ANN modular para o filtro EBG-GP (—) para análise do ganho versus a frequência de operação apresentado por quatro diferentes estruturas com raios, (a) $r = 0,635$ mm, (b) $r = 1,27$ mm, (c) $r = 2,286$ mm e (d) $r = 1,22$ mm. Valor calculado (X) para frequência $f = 11,20$ GHz para $r = 1,22$ mm, através da técnica de escalonamento. Resultados experimentais não usados na fase de treinamento da rede SF-ANN para : $r = 0,635$ mm (***) ; $r = 1,27$ mm (ooo) e $r = 2,286$ mm (+++) (RADISIC *et al.*, 1998).




Fig. 5.5: Resposta e generalização do modelo SF-ANN modular para o filtro EBG-GP (—) para análise do ganho versus a frequência de operação apresentado por quatro diferentes estruturas com raios: (a) $r = 0,635$ mm, (b) $r = 1,27$ mm, (c) $r = 2,286$ mm e (d) $r = 1,32$ mm. Valor calculado (X) para frequência $f = 11,20$ GHz para $r = 1,32$ mm, através da técnica de escalonamento. Resultados experimentais não usados na fase de treinamento da rede SF-ANN para : $r = 0,635$ mm (***) , $r = 1,27$ mm (ooo) e $r = 2,286$ mm (+++) (RADISIC *et al.*, 1998).

5.3.2 Filtro EBG-UC-GP

A propagação em linhas de microfita com estrutura EBG-UC gravada no seu plano de terra é analisada nesta seção. O uso desta estrutura produz uma redução do comprimento de onda guiada e conseqüentemente redução no espaçamento dos elementos periódicos da estrutura resultando em um circuito mais compacto.

A Fig. 5.6 mostra a linha de microfita com plano de terra constituído por uma estrutura EBG-UC (YANG F. *et al.*, 1999).




Fig. 5.6: Linha de microfita com estrutura EBG-UC-GP: (a) Vista superior (b) Vista inferior.

A seção da estrutura EBG-UC possui 18,29 mm correspondendo a sete células unitárias EBG-UC. O substrato empregado é RT/Duroid 6010 com constante dielétrica igual a 10,2 e espessura igual a 0,635 mm.

A largura da microfita é de 0,61 mm, correspondendo à linha de microfita de 50- Ω . Um pequeno comprimento do plano de terra foi incluído em cada extremidade da linha de microfita para facilitar a conexão com os conectores SMA.

A. Neuromodelagem do Filtro EBG-UC-GP

A arquitetura da SF-ANN para a modelagem do filtro EBG-UC-GP é constituída por um nodo de entrada que corresponde à frequência operacional, f , de 1 GHz a 20 GHz; dois nodos de saída que representam os parâmetros de espalhamento, S_{11} e S_{21} . Foram empregados 23 neurônios na camada oculta.

O processo de treinamento do modelo SF-ANN empregou um conjunto de 100 valores medidos e disponíveis na literatura (YANG F. *et al.*, 1999). Após 2000 épocas de treinamento, obteve-se um erro médio quadrático inferior a $1,0 \times 10^{-5}$.

A Fig. 5.7 e a Fig. 5.8 apresentam a validação do modelo SF-ANN para o filtro EBG-UC-GP, juntamente com um conjunto teste constituído por 37 resultados experimentais não usados na fase de treinamento, e com um conjunto de resultados obtidos pela técnica FDTD (YANG F. *et al.*, 1999).

Na Fig. 5.7 estão apresentadas as perdas de retorno, S_{11} , para o filtro EBG-UC-GP, enquanto na Fig. 5.8 estão apresentadas as perdas de inserção, S_{21} .

Observa-se que os modos espúrios são suprimidos e na banda de passagem a perda de inserção do filtro EBG-UC-GP é equiparável ao de um filtro convencional, ou seja, a aplicação da estrutura EBG não altera a impedância de linha, conseqüentemente as condições de casamento entre circuitos; e não aumenta as perdas do condutor (YANG F. *et al.*, 1999).

Em relação a técnica neurocomputacional, observa-se uma excelente concordância entre a resposta do modelo SF-ANN e o conjunto teste de valores medidos para o filtro EBG-UC-GP não usados na fase de treinamento, ou seja a diferença média entre as saídas calculadas pelo modelo SF-ANN e os valores medidos disponíveis na literatura é pequena.

Além disso, quando comparado aos resultados obtidos pela técnica FDTD, as respostas do modelo SF-ANN aproximam mais precisamente o conjunto teste de valores medidos apresentados. Este fato, deve-se a natureza mais abrangente da técnica neurocomputacional que considera o circuito em sua totalidade, o mesmo não ocorrendo com a técnica FDTD, que neste caso não considerou a “sobregravação” (*overetching*) e o efeito dos conectores empregados na realização das medidas eletromagnéticas.




Fig. 5.7: Resposta do modelo SF-ANN (—) para filtro EBG-UC-GP para análise das perdas de retorno versus frequência de operação. Resultados experimentais (ooo) para o filtro EBG-UC-GP não usados na fase de treinamento da rede (YANG F. *et al.*, 1999). Resultados obtidos através da técnica FDTD (***) para o filtro EBG-UC-GP (YANG F. *et al.*, 1999).




Fig. 5.8: Resposta do modelo SF-ANN (—) para filtro EBG-UC-GP para análise das perdas de inserção versus frequência de operação. Resultados experimentais (ooo) para o filtro EBG-UC-GP não usados na fase de treinamento da rede (YANG F. *et al.*, 1999). Resultados obtidos através da técnica FDTD (***) para o filtro EBG-UC-GP (YANG F. *et al.*, 1999).

5.4 LINHAS DE MICROFITA COM ESTRUTURA EBG-D

5.4.1 Filtro EBG-D Banda Larga

A Fig. 5.9 apresenta o filtro EBG-D banda larga (RUMSEY *et al.*, 1998). Este circuito é constituído por uma fita condutora sobreposta a um material EBG em cascata. A estrutura EBG-D consiste de uma rede periódica de orifícios cilíndricos cravados no substrato dielétrico.




Fig. 5.9: Linha de microfita com estrutura EBG-D em cascata.

O substrato EBG é constituído por material dielétrico Duroid com constante dielétrica igual a 10; possui 50 mm de largura e 1,6 mm de espessura. Já a linha condutora possui 190 mm de comprimento e 1,2 mm de largura (RUMSEY *et al.*, 1998).

A fita condutora está implantada em uma sobrecamada bastante fina, 0,127mm de espessura, de material dielétrico G10, que, por sua vez, está sobreposto ao substrato EBG. Com isso, a dificuldade de posicionamento da fita condutora sobre as perfurações periódicas é superada. A introdução deste substrato secundário não acarreta mudanças significativas no comportamento eletromagnético do dispositivo, uma vez que, sua espessura é muito inferior a do substrato EBG, além de possuir uma constante dielétrica menor (RUMSEY, *et al.*, 1998).

Cada estágio do dispositivo mostrado na Fig. 5.9 pode funcionar separadamente como um filtro padrão EBG-D atuando com uma faixa de rejeição específica, de modo que, a conexão em cascata produz um filtro de banda larga. O projeto da estrutura EBG-D foi baseado nos dados de antenas sobre substrato EBG-D (YANG H., *et al.*, 1997), com a substituição das perfurações quadradas por orifícios circulares de igual volume e

escalonadas para a frequência desejada. O primeiro estágio foi projetado para possuir faixa de rejeição centrada em 5 GHz,

Os dimensionamentos dos dois outros estágios foram realizados separadamente de modo a apresentar frequências centrais da faixa de rejeição, f_0 , próximas de 7,5 GHz e de 12,2 GHz, respectivamente. Os parâmetros estruturais do segundo e do terceiro estágio da conexão em cascata foram projetados com base no escalonamento linear, visto no Capítulo 2, do projeto do filtro em 5 GHz, de acordo com a seguinte relação:

$$\begin{bmatrix} a_{novo} \\ d_{novo} \end{bmatrix} = \frac{f_{anterior}}{f_{novo}} \begin{bmatrix} a_{anterior} \\ d_{anterior} \end{bmatrix} \quad (5.1)$$

em que, a é a distância entre os centros dos elementos circulares, e d é o diâmetro dos orifícios cilíndricos da estrutura EBG-D.

As dimensões projetadas para cada um dos três conjuntos de cinco orifícios cilíndricos periódicos da conexão em cascata de estruturas EBG são: a) $a = 18$ mm e $d = 12$ mm, para f_0 em 5 GHz, b) $a = 12$ mm e $d = 8$ mm; para f_0 em 7,5 GHz, e c) $a = 7,4$ mm e $d = 5$ mm, para f_0 em 12,2 GHz.

A. Neuromodelagem do Filtro EBG-D Padrão

Nesta seção, a SF-ANN modela o primeiro estágio do circuito integrado mostrado na Fig. 5.9. Este consiste de um filtro EBG-D padrão que é formado por três linhas de cinco orifícios circulares idênticos cravados no substrato dielétrico da linha de microfita. O raio dos círculos periódicos, r , é igual a 6 mm e o espaçamento entre os seus centros, a , é igual a 18 mm. Estas dimensões predizem uma frequência central de rejeição igual a 5 GHz.

É também investigado, o efeito da variação do posicionamento da fita condutora sobreposta aos orifícios periódicos em relação ao comportamento eletromagnético da linha de microfita EBG-D. Três diferentes posições da fita condutora em relação às perfurações, pos , são consideradas: $pos1$ corresponde a posição centralizada; $pos2$ corresponde a posição intermediária entre a posição central e a borda dos orifícios periódicos; e $pos3$ corresponde a posição tangencial a borda dos orifícios periódicos.

A arquitetura da rede neural Função *Sample* - SF-ANN é formada por dois nodos na camada de entrada representando a frequência de operação, f , e o posicionamento da fita

condutora em relação aos orifícios periódicos, *pos*; enquanto na camada de saída tem-se apenas um nó representando o ganho, S_{21} , em dB. A camada oculta possui 50 neurônios.

Na fase de treinamento, foi empregado um conjunto de 30 resultados experimentais (RUMSEY, *et al.*, 1998), mostrado na Fig. 5.10. Após 1500 épocas de treinamento, o modelo SF-ANN para o filtro padrão EBG-D apresentou um erro médio final inferior a $1,0 \times 10^{-5}$.

Após o processo de treinamento, realiza-se a validação do modelo SF-ANN desenvolvido. Inicialmente é a apresentada na Fig. 5.11, a resposta do modelo SF-ANN apenas para a posição central da fita condutora, *pos1*, juntamente com o conjunto teste composto por 16 novos valores medidos, ou seja, não usados na fase de treinamento, e com um conjunto de resultados obtidos por simulação eletromagnética usando a técnica FDTD (RUMSEY, *et al.*, 1998).

Como esperado, a aplicação da estrutura EBG-D em uma linha de microfita propicia a formação de filtro de microondas com frequência central da faixa de rejeição em torno de 5,0 GHz, mais precisamente em torno de 5,5 GHz.

Para investigar o efeito do posicionamento da fita condutora, é apresentado na Fig. 5.12 a resposta do modelo SF-ANN para três diferentes posições da fita condutora, *pos1*, *pos2* e *pos3*, juntamente com um conjunto teste de 45 novos valores medidos, ou seja, resultados experimentais que não foram usados na fase de treinamento.

Na Fig. 5.12, constatam-se diferenças significativas nos três tipos de circuitos simulados. Este fato possibilita a obtenção de comportamentos eletromagnéticos diferentes do filtro EBG-D apenas com a variação do posicionamento da fita condutora.

Também na Fig. 5.12, em relação ao modelo neural para o filtro EBG-D desenvolvido pela metodologia da SF-ANN, constata-se que a diferença entre os valores das saídas do modelo SF-ANN e os resultados experimentais é pequena. Além disso, quando comparado ao simulador FDTD, observa-se uma melhor precisão por parte do modelo SF-ANN. Este fato pode ser justificado pela consideração por parte da metodologia SF-ANN das transições entre a linha de microfita e os conectores, além das tolerâncias dos materiais envolvidos na confecção do dispositivo.




Fig. 5.10: Valores medidos (ooo) usados no processo de treinamento do modelo neural SF-ANN para filtro EBG-D (RUMSEY, *et al.*, 1998).




Fig. 5.11: Resposta do modelo SF-ANN (—) para filtro EBG-D para análise do ganho versus frequência de operação. Resultados experimentais (ooo) para o filtro EBG-D não usados na fase de treinamento da rede (RUMSEY, *et al.*, 1998). Resultados obtidos através da técnica FDTD (***) para o filtro EBG-D (RUMSEY, *et al.*, 1998).




Fig. 5.12: Resposta do modelo SF-ANN (—) para filtro EBG-D para análise do ganho versus frequência de operação com três posições diferentes da fita condutora em relação aos elementos periódicos: (a) Tangencial, (b) Metade do raio e (c) Centralizada. Resultados experimentais para o filtro EBG-D não usados na fase de treinamento da rede para posição tangencial (+++), posição metade do raio (ooo) e posição centralizada (***) (RUMSEY, *et al.*, 1998).

B. Neuromodelagem do Filtro EBG-D Banda Larga

A configuração da SF-ANN usada para modelar o filtro EBG-D banda larga foi similar à empregada no estudo do filtro EBG-D padrão. Esta é formada por uma unidade de entrada, a frequência, por uma camada oculta com 50 neurônios, e uma unidade de saída, o ganho, S_{21} .

No processo de treinamento da rede foi utilizado um conjunto de 50 exemplos obtidos a partir de resultados experimentais (RUMSEY, *et al.*, 1998). Esta etapa não exige esforço computacional elevado, por exemplo, o tempo de processamento necessário em um microcomputador *Pentium 4*, foi de 10 minutos, a uma taxa de aprendizado de 0,01. Após 2000 épocas de treinamento, o modelo SF-ANN apresentou um erro final, SSE, inferior a $0,8 \times 10^{-5}$.

A Fig. 5.13 mostra a resposta do modelo SF-ANN para o filtro EBG-D de banda larga juntamente com o conjunto teste de novos valores medidos, ou seja, resultados experimentais não empregados no processo de treinamento, e com resultados obtidos pela aplicação da técnica de onda completa FDTD (RUMSEY, *et al.*, 1998).

Constata-se que a aplicação em cascata de estruturas EBG-D com diferentes dimensões, de modo a atuar em frequências centrais de rejeição diferentes, geram um alargamento da faixa de rejeição de frequência total imposta pelo um filtro planar EBG-D padrão.

Observa-se também que a resposta calculada pelo modelo SF-ANN referente aos valores de ganho entre 1 GHz e 15 GHz apresenta uma excelente concordância com o conjunto de teste composto por 20 valores medidos, o que comprova a precisão da técnica neurocomputacional empregada.

Além disso, quando se compara os resultados obtidos pelo modelo neural SF-ANN e os obtidos pelo simulador FDTD, constata-se uma melhor precisão em relação aos valores do conjunto de resultados experimentais parte do modelo SF-ANN. Este fato deve-se à característica de abrangência geral da análise neurocomputacional, onde estão inclusos os efeitos dos conectores, das linhas alimentadoras e da tolerância do material do substrato; diferentemente da análise desenvolvidas pela técnica FDTD.




Fig. 5.13: Resposta do modelo SF-ANN (—) para filtro EBG-D banda larga para análise do ganho versus frequência de operação. Resultados experimentais (ooo) para o filtro EBG-D banda larga não usados na fase de treinamento da rede (RUMSEY, *et al.*, 1998). Resultados obtidos através da técnica FDTD (***) para o filtro EBG-D (RUMSEY, *et al.*, 1998).

5.5 CONCLUSÃO

Estruturas com *bandgap* eletromagnético, estruturas EBG, são apropriadas para diversas aplicações na faixa de microondas e ondas milimétricas. Especificamente, este capítulo realizou um estudo de filtros planares padrão e banda larga constituídos por linhas de microfita com estruturas com *bandgap* eletromagnético no substrato dielétrico, EBG-D e linhas de microfita com estruturas com *bandgap* eletromagnético no plano de terra, EBG-GP.

Além disso, foram também abordadas as características de estruturas EBG-UC. A utilização da estrutura EBG-UC-GP em linha de microfita eleva o fator de ondas lentas e reduz as perdas de inserção em comparação com linhas de microfita convencionais. Além disso, facilita a integração com outros dispositivos, de modo a compactar circuitos de microondas, como os defasadores e as linhas de atraso.

Alguns parâmetros estruturais como o raio e o espaçamento dos elementos periódicos das estruturas EBG foram variados de modo a se investigar a consequência sobre o desempenho dos filtros de microondas. Além disso, foi determinado através dos modelos neurais, o efeito sobre as características dos filtros de microondas em função da localização da fita condutora em relação às perfurações periódicas das estruturas EBG.

Para esta análise, a técnica neurocomputacional, denominada Rede Neural Função *Sample*, SF-ANN, foi empregada. Os modelos SF-ANN desenvolvidos alcançaram aproximações globais para os complexos mapeamentos das relações de entrada e saída dos filtros de microondas com estruturas EBG. Além disso, os modelos SF-ANN forneceram generalizações coerentes com valores teoricamente esperados e estimados através de resultados experimentais.

CAPÍTULO 6

APLICAÇÕES DAS ESTRUTURAS EBG EM LINHAS ACOPLADAS

6.1 INTRODUÇÃO

As principais dificuldades em projetos de circuitos integrados monolíticos de microondas ou de ondas milimétricas em alta densidade são o efeito do acoplamento parasita e as interferências (*crosstalk*) entre os sinais das linhas de transmissão circunvizinhas.

Há vários estudos que visam superar estas limitações na engenharia de telecomunicações. Um deles consiste no estreitamento do substrato sob as linhas de transmissão para facilitar a propagação do modo quase-TEM. Entretanto, de um modo geral, estas técnicas requerem um processo de fabricação complexo (DRAYTON *et al.*, 1998)

A utilização de estruturas EBG-GP reduz o efeito de acoplamento e de interferências indesejáveis em circuitos integrados de alta densidade, permitindo que linhas acopladas situem-se próximas ou até mesmo linhas interceptadas. Além disso, a tecnologia EBG possibilita opções de modificação no projeto de circuitos integrados, tornando-se mais compactos e simplificados.

Neste capítulo, a metodologia neurocomputacional da Rede Neural Modular Função *Sample* (SF-ANN) é empregada na modelagem de duas topologias de linhas de transmissão acopladas que usam estruturas EBG-GP. Este tipo de estrutura EBG consiste-se de orifícios periódicos no plano de terra do circuito, de modo a obter uma redução do efeito de acoplamento e das interferências entre as fitas condutoras.

A primeira consiste em um par de linhas de microfita adjacentes proximamente espaçadas, uma propagando sinais da banda-Ku e a outra propagando sinais da banda-X, que pode constituir num módulo de um direcionador transmissor-receptor de frequências superiores e inferiores.

No segundo dispositivo, o circuito é formado por linhas interceptadas que são projetadas para propagar bandas de frequência específicas, sem interferir no grau de liberdade entre os sinais.

6.2 CARACTERÍSTICAS DAS LINHAS ACOPLADAS

As linhas planares acopladas são usadas extensivamente como elementos básicos em uma variedade de circuitos, como por exemplo, acopladores direcionais, filtros, redes casadoras de impedância e linhas de atraso (GUPTA *et al.*, 1981). Um das linhas acopladas planares mais empregada é a linha de microfita acoplada que consiste de duas fitas condutoras situadas proximamente juntas com um plano de terra comum, como mostrado na Fig. 6.1.




Fig. 6.1: Linhas de microfita acopladas e simétricas.

Devido ao acoplamento entre os campos eletromagnéticos, o par de fitas condutoras permitem a propagação de dois diferentes modos com diferenças entre suas impedâncias características. A velocidade de propagação destes dois modos é igual quando as linhas acopladas estão inseridas em um meio homogêneo, como em linhas de fita acopladas.

Entretanto em meios não homogêneos, como mostrado na Fig. 6.1, uma parte do campo estende-se pelo ar acima do substrato. Como esta fração do campo é diferente para os dois modos, a constante dielétrica efetiva e velocidade de fase não são iguais para os dois modos das linhas acopladas. Esta falta de sincronismo deteriora o desempenho dos circuitos.

Quando as duas fitas condutoras estão suficientemente próximas, de modo que, seus diagramas de campo são afetados em relação ao diagrama quando isolada, tem-se que uma parte do sinal de uma linha está presente na segunda linha.

Esta propriedade pode ser vantajosa, quando se deseja um acoplador direcional, ou prejudicial, quando se requer de um circuito multicondutor de sinais com diferentes faixas de frequência operacionais. No primeiro caso, denomina-se o sinal secundário de acoplamento, enquanto no último caso, tem-se uma interferência.

Quando as duas fitas do par de linhas acopladas são idênticas, tem-se uma configuração simétrica, o que simplifica a análise e projeto destes dispositivos. Se as duas linhas não possuem a mesma impedância, a configuração é chamada assimétrica.

As propriedades das linhas acopladas podem ser determinadas por meio das capacitâncias e indutâncias próprias e mútuas associadas a cada fita condutora. Há numerosas técnicas de análise e síntese das linhas acopladas, ambas quase-estáticas e de onda completa têm sido reportadas (GUPTA *et al.*, 1979).

Um das aplicações primordiais das linhas acopladas são os dispositivos de portas direcionais. Estes circuitos são intensamente usados nas comunicações de uma maneira geral. Claramente, estes circuitos requerem uma perfeita isolação entre os sinais propagantes entre suas portas, ou seja, não deverá ocorrer efeito de acoplamento mútuo entre as linhas próximas e interferências entre os sinais.

O emprego de estruturas EBG em dispositivos de microondas tem sido demonstrado vantajoso em diversas aplicações, como por exemplos, no aprimoramento da eficiência e diagrama de radiação de antenas, no controle harmônico de amplificadores de potência, e na supressão de modos indesejáveis em linhas de transmissão planares (YANG F. *et al.*, 2000).

Outro campo de aplicação, bastante recente, das estruturas EBG é a área dos acopladores direcionais: linhas de microfita adjacentes e interceptadas (LEONG *et al.*, 2002) e divisores circulares de potência (SHUM *et al.*, 2001). Nestes casos, a introdução

das estruturas EBG possibilita a redução das interferências entre os sinais propagantes e das dimensões dos circuitos.

6.3 LINHAS DE TRANSMISSÃO ADJACENTES EBG-GP

Um circuito que pode ser considerado como um módulo de um transmissor-receptor integrado direcional é apresentado na Fig. 6.2 (LEONG *et al.*, 2002). Este é constituído por duas fitas condutoras paralelas sobrepostas a um material dielétrico que, por sua vez, está sobreposto a um plano de terra com uma matriz EBG.




Fig. 6.2: Linhas de microfita adjacentes com estrutura EBG-GP.

As linhas de microfita paralelas possuem uma impedância de 50Ω e estão separadas por 1 mm. O substrato é do tipo RT/Duroid, com constante dielétrica, $\epsilon_r = 2,2$ e espessura de 0.71 mm. No seu plano de terra é gravada uma estrutura EBG, que é formada por uma rede quadrada de perfurações (orifícios) periodicamente espaçadas.

O acoplador direcional constituído por um circuito EBG-GP de linhas adjacentes, objetiva permitir a propagação de sinais da banda-Ku na linha A (Portas 1 e 2) e a propagação de sinais da banda-X na linha B (Portas 3 e 4). Conseqüentemente, faz-se necessário a supressão de sinais da banda-X na linha A e a supressão de sinais da banda-Ku na linha B.

Para obter estas especificações é empregada a estrutura EBG-GP. Esta estrutura foi dimensionada baseada nas expressões aproximadas que foram vistas no Capítulo 2, onde o período da rede, tamanho do espaçamento entre os orifícios periódicos, deve ser metade do

comprimento de onda guiada na frequência central da faixa de rejeição desejada (COCCIOLI e ITOH, 1998).

Portanto, os orifícios 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 orifícios periódicos possuem período, *b*, igual a 6,1 mm, correspondendo a uma frequência central da faixa de rejeição em torno de 9 GHz.

O raio dos elementos periódicos influencia basicamente a largura e intensidade do faixa de rejeição (RADISIC *et al.*, 1998). Neste caso, o raio dos orifícios no plano de terra foi fixado em 2 mm. Este pode ser otimizado para alcançar o nível de atenuação desejada e a distância ideal de separação em frequência dos dois sinais.

A. Neuromodelagem SF-ANN para circuito EBG-GP de linhas adjacentes

A arquitetura da SF-ANN com um nodo 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. 6.2.

Para isto, foi empregado um conjunto de treinamento, mostrado na Fig. 6.3, composto por 25 pares de exemplos de entrada e saída de valores medidos (LEONG *et al.*, 2002). Após 1000 épocas de treinamento, o erro quadrático médio, *SSE*, foi inferior a $1,0 \times 10^{-5}$.

A Fig. 6.4 apresenta a resposta do modelo SF-ANN para o circuito EBG-GP de linhas adjacentes, correspondendo ao coeficiente de transmissão da linha *B*, S_{34} , ao longo da faixa de frequência de microondas.

Como esperado, o dispositivo EBG-GP de linhas adjacentes apresenta uma larga faixa de rejeição na banda-Ku de 13 a 18 GHz para transmissões na linha *B*. Já na banda-X, as perdas de inserção são equiparáveis a de um circuito semelhante de linhas adjacentes em um plano de terra regularmente sólido, ou seja, a introdução não prejudicou o desempenho do dispositivo.

Para efeito de validação do modelo SF-ANN proposto, são também apresentados na Fig. 6.4, um conjunto teste de 11 valores medidos que não foram usados no processo de treinamento, e resultados obtidos utilizando o popular simulador *Sonnet* (LEONG *et al.*, 2002).

Como pode ser observado na Fig. 6.4, a validação do modelo SF-ANN para o circuito EBG-GP de linhas adjacentes pode ser considerada satisfatória, uma vez que, os

valores de suas saídas são bastante próximos dos resultados experimentais apresentados e pertencentes ao conjunto teste de valores medidos que não foram empregados na etapa de treinamento (LEONG *et al.*, 2002).. Além disso, constata-se uma melhor precisão da resposta do modelo neural SF-ANN para linhas adjacentes EBG em relação aos resultados obtidos pelo simulador *Sonnet* (LEONG *et al.*, 2002).




Fig. 6.3: Valores medidos (ooo) que compõem o conjunto de treinamento (25 exemplos) usado na modelagem neurocomputacional SF-ANN para o circuito EBG-GP de linhas adjacentes (LEONG *et al.*, 2002).




Fig. 6.4: Resposta do modelo SF-ANN (—) para o circuito EBG-GP de linhas adjacentes para análise do coeficiente de transmissão, S_{34} versus frequência de operação.

Resultados experimentais (ooo) para o circuito EBG-GP de linhas adjacentes não usados na fase de treinamento da rede (LEONG *et al.*, 2002). Resultados simulados (***) obtidos através do uso do simulador *Sonnet* para o circuito EBG-GP de linhas adjacentes (LEONG *et al.*, 2002).

6.4 LINHAS DE TRANSMISSÃO INTERCEPTADAS EBG-GP

Em circuitos integrados de alta densidade são comumente usadas arquiteturas multicamadas quando se requer o cruzamento entre linhas de transmissão. Neste caso, uma linha de transmissão em uma camada é confeccionada cruzando a outra linha de transmissão presente na segunda camada.

A Fig. 6.5 apresenta uma alternativa a estrutura multicamadas. Consiste em uma arquitetura de camada simples formada por circuito de linhas interceptadas usando estrutura EBG-GP (LEONG *et al.*, 2002).




Fig. 6.5: Linhas de microfita interceptadas com estrutura EBG-GP.

Neste circuito, a linha *A*, que conecta as portas 1 e 2, é projetada para permitir a propagação de sinais da banda-X e possui uma estrutura EBG gravada no seu plano de terra para eliminar o acoplamento dos sinais da banda-Ku propagando-se ao longo da Linha *B*, que conecta as portas 3 e 4. Já na linha *B* ocorre o inverso, pretende-se permitir a propagação de sinais da banda-Ku e limitar o acoplamento dos sinais da banda-X proveniente da linha *A*.

O projeto das duas matrizes de orifícios periódicos cravados no plano de terra do circuito segue a mesma metodologia do caso de linhas de microfita adjacentes. O raio é igual a 2 mm e os períodos, *a*, igual a 9,8 mm e *b*, igual 6,1 mm, de modo a suprimir faixas de frequência da banda-Ku e banda-X, respectivamente.

Claramente, esta alternativa, circuito de linhas de microfita interceptadas com estrutura EBG-GP, permite novas opções no projeto de circuitos integrados de microondas e ondas milimétricas. A redução da dimensão e simplificação do circuito são algumas das vantagens oferecidas. Além disso, a possibilidade de utilização de estrutura EBG-GP curvada aumenta a flexibilidade do projeto de circuitos acopladores (RADISIC *et al.*, 1998; LEONG *et al.*, 2002).

A. Neuromodelagem SF-ANN para o circuito EBG-GP de linhas interceptadas

A rede SF-ANN projetada para modelar o circuito EBG-GP de linhas de microfita interceptadas, mostrado na Fig. 6.4, é formada por uma unidade de entrada, a frequência de operação, por 50 neurônios na camada oculta, e por uma unidade de saída, o parâmetro de acoplamento entre as portas 2 e 3, S_{23} .

Dois processos de treinamento foram realizados. No primeiro treinamento foi utilizado um conjunto de 25 pares de entrada e saída de resultados medidos (LEONG *et al.*, 2002) mostrados na Fig. 6.6. Após 500 épocas de treinamento, o erro quadrático médio, SSE, foi inferior a $1,0 \times 10^{-5}$.

De modo a verificar a influência do número de exemplos de treinamento na precisão da resposta do modelo SF-ANN, também foi realizado um segundo processo de treinamento, desta vez com um conjunto menor composto por 20 pares de entrada e saída de resultados medidos (LEONG *et al.*, 2002) mostrados na Fig. 6.7.

A Fig. 6.8 mostra a resposta do modelo SF-ANN para o circuito EBG-GP de linhas interceptadas, correspondendo ao coeficiente de acoplamento entre as portas 2 e 3, S_{23} , pertencentes as linhas A e B, respectivamente, para os dois processos de treinamento.

Observa-se que a introdução de estrutura EBG-GP aumentou a atenuação do acoplamento entre as linhas de microfita interceptadas. Para um circuito convencional, o acoplamento está entre 6 a 8 dB, já para um circuito com estrutura EBG-GP, a redução do acoplamento alcança 20dB em 11 GHz e 28 dB em 17 GHz.

Para verificar a precisão da técnica neurocomputacional empregada na produção do modelo para o circuito EBG-GP de linhas de microfita interceptadas, foi acrescentado à Fig. 6.8, um conjunto teste composto por 5 resultados experimentais não usados na fase de treinamento da rede, além de resultados obtidos pelo simulador *Sonnet* (LEONG *et al.*, 2002).

Observa-se uma excelente concordância entre a resposta do modelo SF-ANN e o conjunto teste de valores medidos. Sendo que a resposta do modelo que utilizou um conjunto de treinamento de 25 exemplos aproximou-se mais do conjunto de teste.

Em relação aos resultados obtidos pelo simulador eletromagnético *Sonnet1*, constata-se uma melhor precisão obtida pela técnica neurocomputacional proposta.




Fig. 6.6: Valores medidos (ooo) que compõem o primeiro conjunto de treinamento (25 exemplos) usado na modelagem neurocomputacional SF-ANN do circuito EBG-GP de linhas interceptadas (LEONG *et al.*, 2002).

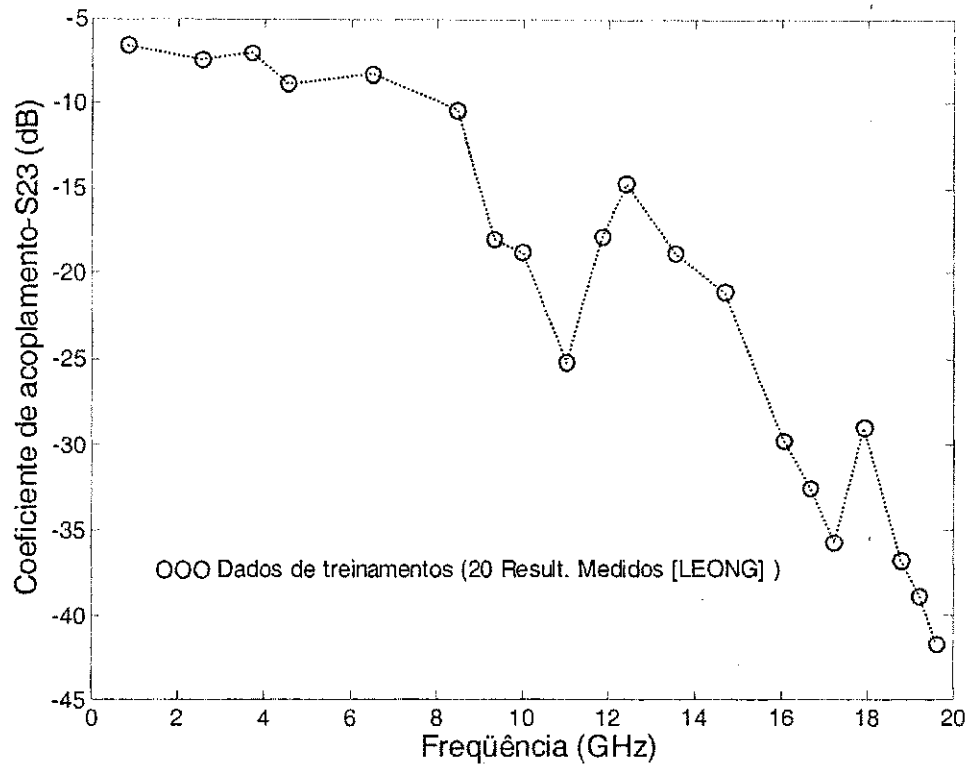


Fig. 6.7: Valores medidos (ooo) que compõem o segundo conjunto de treinamento (20 exemplos) usado na modelagem neurocomputacional SF-ANN do circuito EBG-GP de linhas interceptadas (LEONG *et al.*, 2002).




Fig. 6.8: Resposta do modelo SF-ANN (—) e (---) usando 25 e 20 exemplos de treinamento, respectivamente, para o circuito EBG-GP de linhas interceptadas para análise do coeficiente de acoplamento, S_{23} versus frequência de operação. Resultados experimentais (ooo) para o circuito EBG-GP de linhas interceptadas não usados na fase de treinamento da rede (LEONG *et al.*, 2002). Resultados simulados (***) obtidos através do uso do simulador *Sonnet* para o circuito EBG-GP de linhas interceptadas (LEONG *et al.*, 2002).

6.5 CONCLUSÃO

Neste capítulo, a análise de dois tipos de linhas de transmissão acopladas com estruturas EBG-GP foi efetuada. Para isto, foi empregada a modelagem SF-ANN que se mostrou eficiente e precisa.

O primeiro tipo consiste de um circuito EBG-GP de linhas adjacentes que pode ser empregado como módulo de acoplador direcional seletor de frequências. Já o segundo é formado por circuito EBG-GP de linhas interceptadas que pode funcionar como uma alternativa à estrutura multicamadas requerida na confecção de circuitos integrados monolíticos de alta densidade.

Em ambos os casos, as perfurações no plano de terra de circuitos de linhas de microfita acopladas, a matriz EBG-GP, proporciona a redução do acoplamento mútuo entre as fitas condutoras, fato também observado na análise através dos modelos neurais. Além disso, uma redução do tamanho e simplificação do projeto de acopladores direcionais pode ser obtida usando a tecnologia EBG.

Os modelos neurais desenvolvidos por meio da metodologia SF-ANN apresentam curvas de resposta para o comportamento dos parâmetros de espalhamento de ambos os circuitos. As saídas do modelo SF-ANN foram consideradas precisas pois apresentaram apenas diferenças reduzidas em relação a resultados experimentais disponíveis na literatura.

Além disso, as respostas obtidas pelos modelos SF-ANN para os circuitos EBG-GP de linhas adjacentes e de linhas interceptadas superam em precisão e em eficiência computacional os resultados obtidos pelo simulador *Sonnet* (LEONG *et al.*, 2002).

CAPÍTULO 7

CONCLUSÕES FINAIS

A análise de cristais fotônicos/eletromagnéticos, um dos campos de pesquisa mais recente e mais fascinante da física e engenharia, foi realizada neste trabalho. Foi abordado o uso das estruturas EBG que se caracterizam pelo controle da propagação eletromagnética em diversos dispositivos de telecomunicações. Seus principais aspectos, parâmetros e diversidades de configurações foram apresentados, bem como, suas principais vantagens e aplicações. Para esta análise, foi empregada uma nova metodologia neurocomputacional, a SF-ANN, que se mostrou eficiente e precisa, proporcionando inúmeras vantagens na confecção de modelos voltados para projetos auxiliados por computador (CAD).

O estudo dos cristais fotônicos está estreitamente relacionado ao campo da física do estado sólido e do eletromagnetismo. Neste trabalho, partiu-se das equações de Maxwell para o caso de propagação eletromagnética em dielétricos mistos. Em seguida, estas equações foram computadas como um problema de autovalor hermitiniano que propiciou clareza em aspectos proveitosos como a ortogonalização dos modos e o teorema do variacional eletromagnético.

Estruturas com bandgap eletromagnético, estruturas EBG, são apropriadas para diversas aplicações na faixa de microondas e ondas milimétricas. Inicialmente, considerou-se a utilização de estruturas EBG em guias de ondas. A possibilidade de funcionar como um refletor magnético é uma característica valiosa da estrutura EBG-UC. Sua introdução nas paredes de um guia retangular melhora a distribuição da intensidade de campo elétrico ao longo da seção transversal desse dispositivo, favorecendo sua aplicação no desenvolvimento de arranjos de amplificadores espacialmente acoplados.

Outra aplicação das estruturas EBG está em estruturas blindadas, mas propriamente em guias de ondas de placas paralelas. Neste caso, a estrutura EBG constituída de orifícios na chapa metálica do guia, proporcionou a redução da propagação dos modos espúrios que prejudicam as transmissões em circuitos integrados monolíticos.

Numa segunda etapa, foi analisado o efeito da introdução de estruturas EBG em linhas de microfita. Foi focalizado o desenvolvimento de filtros planares padrão e banda larga constituídos por linhas de microfita com estruturas com bandgap eletromagnético no substrato dielétrico, EBG-D e linhas de microfita com estruturas com bandgap eletromagnético no plano de terra, EBG-GP.

Alguns parâmetros estruturais como o raio e o espaçamento dos elementos periódicos das estruturas EBG foram variados de modo a se investigar a consequência sobre o desempenho dos filtros de microondas. Além disso, foi determinado o efeito sobre as características dos filtros de microondas em função da localização da fita condutora em relação os orifícios periódicos das estruturas EBG.

A adição de elementos indutivos e capacitivos presentes na estrutura EBG-UC resulta em um aumento no valor da constante de propagação, em linhas de microfita, o que favorece a confecção de dispositivos de ondas lentas com impedância moderada e baixas perdas, além de simplicidade no processo de fabricação.

Estas características são vantajosas no projeto de circuitos integrados monolíticos e híbridos de microondas, em especial, filtros passa-faixa com supressão de espúrios intrínsecos. Uma vez que um dispositivo EBG-UC, além de possuir um alto fator de ondas lentas, possui uma faixa de rejeição de frequência intrínseca, que pode ser projetada para eliminar os espúrios do sinal, reduzindo as dimensões do circuito como um todo.

Na última etapa, foram abordadas as linhas acopladas usando estruturas EBG. Circuito de linhas adjacentes funcionando como módulo de comunicação entre portas foram obtidos com o emprego de estruturas EBG-GP. Isto possibilitou a redução de interferências entre as linhas próximas.

Também foram obtidos parâmetros de espalhamento de circuitos de linhas interceptadas usando estruturas EBG-GP. A introdução deste tipo de estrutura EBG possibilitou a redução do acoplamento mútuo entre as linhas cruzadas.

De modo geral, como desvantagens do emprego das estruturas EBG estão o aumento da complexidade de fabricação e do análise devido a introdução dos elementos periódicos.

Para todas estas análises, uma nova técnica neurocomputacional, denominada Rede Neural Artificial Função *Sample*, SF-ANN, foi empregada. Modelos SF-ANN para os diversos dispositivos e circuitos de microondas usando estruturas EBG foram desenvolvidos de modo a simular os seus comportamentos eletromagnéticos. Estes modelos SF-ANN mostraram-se precisos e eficientes, alcançando aproximações globais para os complexos mapeamentos das relações de entrada e saída dos dispositivos EBG. Além disso, os modelos SF-ANN forneceram generalizações coerentes com valores teoricamente estimados.

São apresentados alguns dos conjuntos de pontos usados no processo de treinamento dos modelos neurais SF-ANN para os vários dispositivos com estruturas EBG analisados neste trabalho. A escolha dos dados que compõem o conjunto de treinamento e o conjunto de teste é um dos fatores cruciais para o bom desenvolvimento de modelos neurais. De um modo geral, o conjunto de treinamento deverá representar de maneira satisfatória o esboço básico do comportamento do dispositivo ou circuito a ser analisado. Isto deverá ser feito com o menor número possível de exemplos para não prejudicar a capacidade de generalização do modelo.

Em relação aos parâmetros no processo de modelagem, número de neurônios ocultos, taxas de aprendizagem e número de épocas são dependentes do grau de precisão requerido e da capacidade de generalização desejada. Além disso, a convergência do processo de aprendizagem requer habilidade e experiência do projetista.

Adicionalmente, comparações das respostas dos modelos SF-ANN para os guias de ondas, linhas de microfita e linhas acopladas com estruturas EBG foram realizadas com resultados calculados pelo método das diferenças finitas no domínio do tempo, FDTD. Como resultado, de modo geral, os modelos SF-ANN obtiveram melhores aproximações para conjuntos de valores medidos disponíveis. Este fato, se deve à característica generalista das técnicas neurocomputacionais, o que não acontece em algumas técnicas numéricas que não consideram dispositivos alimentados, desprezando determinadas dimensões como a espessura das fitas condutoras, entre outros aspectos.

Além disso, uma forte redução do esforço computacional é outra principal vantagem da metodologia SF-ANN. Isto se deve, à característica de computação maciçamente distribuída das técnicas neurocomputacionais.

A continuidade deste trabalho é recomendada em função do grande número de possibilidades. À partir do conhecimento e da experiência obtidos ao longo do

desenvolvimento deste projeto, pode-se sugerir os seguintes tópicos como trabalhos futuros: o projeto de dispositivos de microondas EBG com orifícios circulares, dipolos em cruz, orifícios desalinhados, além do uso de substratos dielétricos anisotrópicos ou quirais.

REFERÊNCIAS BIBLIOGRÁFICAS

AGI, K.; MOJAHEDI, M.; MINHAS, B.; SCHAMILOGLU, E., MALLOY, K. J. The Effects of an Electromagnetic Crystal Substrate on a Microstrip Patch Antenna. *IEEE Transactions on Antennas and Propagation*, v.50, n.04, p.451-456, abril, 2002.

ALEXANIAN, A. R.; YORK, A. Broadband Spatially Combined Amplifier Array Using Tapered Slot Transitions in Waveguide. *IEEE Microwave and Guided Wave Letters*, v.07, n.02, p.42-44, fevereiro, 1997.

ALVES, M. J. L.; SOBRINHO, C. L. S. S. Design of 2-D PBG Structures With High Refractive Index Contrast. In: INTERNATIONAL MICROWAVE OPTOELECTRONICS CONFERENCE, 9., 2001, Belém.

ANAYA, M.; MARCOTEGUI, J. A.; LOPETEGI, T.; LASO, M. A. G.; SOROLLA, M. Analysis Of New Periodic Structures In Microstrip By FDTD. In: EUROPEAN CONGRESS ON COMPUTACIONAL METHODS IN APPLIED SCIENCES AND ENGINNEERING, 2000, Barcelona.

BANDLER, J. W.; ISMAIL, M. A.; RAYAS-SANCHEZ, J. E.; ZHANG, Q. Neuromodeling of Microwave Circuits Exploiting Space-Mapping Technology. *IEEE Transactions on Microwave Theory and Techniques*, v.47, n.12, p.2417-2427, dezembro, 1999.

BRIDLE, J. S. Probabilistic Interpretation of Feedforward Classification Network Output, with Relationship to Statistical Pattern Recognition. *Neuro-Computing: Algorithms, Architectures and Applications*, F. Fougelman-Soulie and J. Héroult, New York: Springer-Verlag, 1990.

BROWN, E. R.; PARKER, C. D.; YABLONOVITCH, E. Radiation Properties of a Planar Antenna on a Photonic-Crystal Structure. *Journal of the Optical Society of America*, v.10, n.02, p.404-407, fevereiro, 1993.

BRILLOUIN, L. *Wave Propagation in Periodic Structures*. 2^aed. Nova York: Dover Publications, 1953.

CALOZ, C.; ITOH, T. Multilayer and Anisotropic Planar Compact PBG Structures for Microstrip Applications. *IEEE Transactions on Microwave Theory and Techniques*, v.50, n.09, p.2206-2208, setembro, 2002.

CHANG, C.; HSU, W. Photonic Bandgap Dielectric Waveguide Filter. *IEEE Microwave and Wireless Components Letters*, v.12, n.04, p.137-139, abril, 2002.

CHEW, S. T.; ITOH, T. PBG-Excited Split-Mode Resonator Bandpass Filter. *IEEE Microwave and Wireless Components Letters*, v.11, n.09, p.364-366, setembro, 2001.

CHRISTODOULOU, C.; GEORGIPOULOS, M. **Applications of Neural Networks in Electromagnetics**. 1.ed. Boston: Artech House, 2001. 512p.

COCCIOLI, R.; ITOH, T. Design of Photonic Band-Gap Substrates for Surface Waves Suppression. In: IEEE MTT-S INTERNATIONAL MICROWAVE SIMPOSIUM, 1998, Baltimore. *IEEE MTT-S Digest*, p. 1259-1262, 1998.

COCCIOLI, R.; YANG, F.; MA, K.; ITOH, T. Aperture-Coupled Patch Antenna on UC-PBG Substrate. *IEEE Transactions on Microwave Theory and Techniques*, v.47, n.11, p.2123-2130, novembro, 1999.

CREECH, G. L.; PAUL, B. J.; LESNIAK, C. D.; JENKINS, T. J.; CALCATERA, M. C. Artificial Neural Networks for Fast and Accurate EM-CAD of Microwave Circuits. *IEEE Transactions on Microwave Theory and Techniques*, v.45, n.05, p.794-802, maio, 1997.

DANGLLOT, J.; VANBÉSIEN, O.; LIPPENS, D. A 4-Port Resonant Switch Patterned in a Photonic Crystal. *IEEE Microwave and Guided Wave Letters*, v.09, n.07, p.274-276, julho, 1999.

DAWN, D.; OHASHI, Y.; SHIMURA, T. A Novel Electromagnetic Bandgap Metal Plate for Parallel Plate Mode Suppression in Shielded Structures. *IEEE Microwave and Wireless Components Letters*, v.12, n.05, p.166-168, maio, 2002.

DESLANDES, D.; WU, K. Integrated Microstrip and Rectangular Waveguide in Planar Form. *IEEE Transactions on Microwave Theory and Techniques*, v.11, n.02, p.68-70, fevereiro, 2001.

DEVABHAKTUNI, V. K.; YAGOUB, M. C.; ZHANG, Q. A Robust Algorithm for Automatic Development of Neural-Network Models for Microwave Applications. *IEEE Transactions on Microwave Theory and Techniques*, v.49, n.12, p.2282-2291, dezembro, 2001.

DRAYTON, R. F.; HENDERSON, R. M.; KATEHI, L. P. B. Monolithic Packaging Concepts for High Isolation in Circuits and Antennas. *IEEE Transaction on Microwave Theory Techniques*, v.46, p.900-906, julho, 1998.

FEDI, G.; MANETTI, S.; PELOSI, G.; SELLERI, S. Profiled Corrugated Circular Horns Analysis and Synthesis Via an Artificial Neural Network. *IEEE Transactions on Antennas and Propagation*, v.49, n.11, p.1597-1602, novembro, 2001.

FERNANDES, E. N. R. Q.; SILVA, P. H. F. Modelagem de Filtros de Telecomunicações sobre Estruturas EBG com o Uso de Redes Neurais. *Revista Expressão da Universidade do Estado do Rio Grande do Norte*, Mossoró, v.31, n.02, jul-dez, , 2000.

FERNANDES, E. N. R. Q.; SILVA, P. H. F.; MELO, M. A. B.; D'ASSUNÇÃO, A. G. Análise de Filtros de Microondas com Estruturas PBG através de Redes Neurais. In: X SIMPÓSIO BRASILEIRO DE MICROONDAS E OPTOELETRÔNICA, 10., 2002a, Recife.

_____. A New Neural Network Model for Accurate Analysis of Microstrip Filters on PBG Structure. In: EUROPEAN MICROWAVE CONFERENCE, 32., 2002b, Milão-Itália.

_____. Um Novo Modelo para Análise de Guias de Ondas PBG através de Redes Neurais. In: CONGRESSO BRASILEIRO DE ELETROMAGNETISMO, 10., 2002c, Gramado.

_____. A Neural Network Modeling of Microwave Circuits on PBG Structures. In: IEEE-MTT INTERNATIONAL MICROWAVE SYMPOSIUM, 2003, Filadélfia-E.U.A. **2003 IEEE MTT-S DIGEST**, Filadélfia-E.U.A, p.181-184, 2003a.

_____. Neuro Modeling of Microwave Waveguides with EBG Structures. In: INTERNATIONAL MICROWAVE AND OPTOELECTRONICS CONFERENCE-IMOC, 2003, Foz do Iguaçu. **Proceedings SBMO/IEEE MTT-S IMOC 2003**, Foz de Iguaçu, p.215-218, 2003b.

FOOKS, E. H.; ZAKAREVICIUS, R. A. **Microwave Engineering Using Microstrip Circuits**. 2ed. New Jersey: Prentice Hall, 1990. 301p.

FU, Y.; ZHANG, G.; YUAN, N. A Novel PBG Coplanar Waveguide. *IEEE Microwave and Wireless Components Letters*, v.11, n.11, p.447-449, novembro, 2001.

FUSCO, V. F. **Microwave Circuits: Analysis and Computer-Aided Design**. 1ed. Englewood Cliffs, NJ: Prentice Hall, 1987.

GONZALO R.; DE MAAGT P.; SOROLLA M. Enhanced Patch-Antenna Performance by Suppressing Surface Waves Using Photonic-Bandgap Substrates. *IEEE Transactions on Microwave Theory and Techniques*, v.47, n.11, p.2131-2138, novembro, 1999.

GUPTA, K. C.; GARG, R.; BAHL I. J. **Microstrip Lines and Slotlines**. 1.ed. Dedham, Massachusetts: Artech House, 1979. 377p.

GUPTA, K. C.; GARG, R.; CHADHA, R. **Computer-Aided Design of Microwave Circuits**. 1.ed. Dedham, Massachusetts: Artech House, 1981. 656p.

GUPTA, K. C. Emerging Trends in Millimeter-Wave CAD. *IEEE Transactions on Microwave Theory and Techniques*, v.46, n.06, p.747-755, junho, 1998.

HASEGAWA, H.; FURUKAWA M.; YANAI, H. Properties of Microstrip Line on Si-SiO₂ System. *IEEE Transactions on Microwave Theory and Techniques*, v.19, n.11, p.869-881, novembro, 1971.

HASEGAWA, H.; SEKI, S. Analysis of Interconnection Delay on Very High Speed LSI/VLSI Chips Using an MIS Microstrip Line Model. *IEEE Transactions on Microwave Theory and Techniques*, v.32, n.12, p.1721-1727, dezembro, 1984.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2.ed. Porto Alegre: Artmed Editora, 2001. 900p.

HIGGINS, J. A.; KIM, M.; HACKER, J. B.; SIEVENPIPER, D. The Application of Photonic Crystals to Quasi-Optic Amplifiers. *IEEE Transactions on Microwave Theory Techniques*, v.47, n.11, p.2139-2143, novembro, 1999.

HOFFMANN, R. K. **Handbook of Microwave Integrated Circuits**, 1ed. Artech House, 1987.

HORII, Y.; TSUTSUMI, M. Harmonic Control by Photonic Bandgap on Microstrip Patch Antenna. *IEEE Microwave and Guided Wave Letters*, v.09, n.01, p.13-15, janeiro, 1999.

JOANNOPOULUS, J. D.; MEADE R.; WINN, J. **Photonic Crystals. Molding the Flow of Light**. 1.ed. New Jersey: Princeton University Press, 1995. 137p

JORDAN, M. I.; JACOBS, R. A. Modular and Hierarchical Learning Systems. **The Handbook of Brain Theory and Neural Networks**. Cambridge, MA: MIT Press, p.579-583, 1995.

KIM, T.; SEO, C. A Novel Photonic Bandgap Structure for Low-Pass Filter of Wide Stopband. *IEEE Microwave and Guided Wave Letters*, v.10, n.1, p.13-15, janeiro, 2000.

KITTEL, C. **Introduction to Solid State Physics**. 7.ed. New York: John Wiley & Sons, 1996. 673p.

KRETLY, L. C.; TÁVORA, A.; MARANGONI, L. C. Antenas e Linhas de Microfita com Estrutura PBG-GP, Photonic Bandgap - Ground Plane, para Diferentes Substratos: Estratégia de Projeto e Resultados para Frequências em Torno de 1 GHz. In: SIMPÓSIO BRASILEIRO DE MICROONDAS E OPTOELETRÔNICA, 9., 2000, João Pessoa. **Anais...** João Pessoa: Sociedade Brasileira de Microondas e Optoeletrônica, 2000. 950p. p.324.

KUNZ, K. S.; LUEBBERS R. J. **The Finite Difference Time Domain Method for Electromagnetics**. 1.ed. Boca Raton: CRC Press, 1993. 448p.

KWON, Y. E.; SOVERO, A.; DEAKIN, D. S.; HIGGINS, J. A. A 44-GHz Monolithic Waveguide Plane-Wave Amplifier with Improved Unit Cell Design. *IEEE Transaction on Microwave Theory Techniques*, v.46, n.09, p.1237-1241, setembro, 1998.

KYRIAZIDOU C. A.; CONTOPANAGOS H. F.; ALEXÓPOULOS N. G., Monolithic Waveguide Filters Using Printed Photonic-Bandgap Materials. *IEEE Transactions on Microwave Theory Techniques*, v.49, n.2, p.297-304, fevereiro, 2001.

LASO, M. A. G.; LOPETEGI, T.; ERRO, M. J.; BENITO, D.; GARDE, M. J.; SOROLLA, M. Multiple-Frequency-Tuned Photonic Bandgap Microstrip Structures. *IEEE Microwave and Guided Wave Letters*, v.10, n.06, p.220-222, junho, 2000.

LENOIR, B.; BAILLARGEAT, D.; VERDEYME, S.; GUILLON, P. Finite Element Method For Rigorous Design of Microwave Devices Using Photonic Band Gap Structures. In: IEEE INTERNATIONAL MICROWAVE SIMPOSIUM, 1998, Baltimore. *IEEE MTT-S Digest*, p. 1061-1064, 1998.

LENOIR, B.; BAILLARGEAT, D.; VERDEYME, S.; GUILLON, P. Finite Element Method For Rigorous Design of Microwave Bandpass Filter Device Using Periodic Metallic Lattice. In: EUROPEAN MICROWAVE CONFERENCE, 29., 1999, München.

LENOIR, B.; BAILLARGEAT, D.; VERDEYME, S.; GUILLON, P.; ZANCHI, C.; PUECH, J. Periodic Structures For Original Design of Voluminous And Planar Microwave Filters. In: IEEE INTERNATIONAL MICROWAVE SIMPOSIUM, 2001, Phoenix. *IEEE MTT-S Digest*, p. 1479-1482, 2001.

LEONG, K. M. K. H.; GUYETTE, A. C.; ELAMARAN, B.; SHIROMA, W. A.; ITOH, T. Coupling Suppression in Microstrip Lines Using a Bi-Periodically Perforated Ground Plane. *IEEE Microwave and Wireless Components Letters*, v.12, n.05, p.169-171, maio, 2002.

LOPETEGI, T.; LASO, M. A. G.; ERRO, M. J.; SOROLLA, M.; THUMM, M. Analysis and Design of Periodic Structures for Microstrip Lines by Using The Coupled Mode Theory. *IEEE Microwave and Wireless Components Letters*, v.12, n.11, p.441-443, novembro, 2002.

MA, K. -P.; HIROSE, K.; YANG, F. -R.; QIAN Y.; ITOH, T. Realisation of Magnetic Conducting Surface Using Novel Photonic Bandgap Structure. *Electronics Letters*, v.34, n.21, p.2041-2042, outubro, 1998.

MA, K. -P.; KIM, J.; YANG, F. -R.; QIAN Y.; ITOH, T. Leakage Suppression in Stripline Circuits Using a 2-D Photonic Bandgap Lattice. In: IEEE INTERNATIONAL MICROWAVE SIMPOSIUM, 1999, Anaheim. *IEEE MTT-S Digest*, p.73-76, 1999.

MARTÍN, F.; FALCONE, F.; BONACHE, J.; LOPETEGI, T.; LASO, M. A. G.; SOROLLA M. New Periodic-Loaded Electromagnetic Bandgap Coplanar Waveguide With Complete Spurious Passband Suppression. *IEEE Microwave and Wireless Components Letters*, v.12, n.11, p.435-437, novembro, 2002.

MAYSTRE, D. Electromagnetic Study of Photonic Band Gaps. *Pure Appl. Opt.*, v.03, n.06, p.975-993, novembro, 1994.

MEADE, R. D.; RAPPE, A. M.; BROMMER, K. D.; JOANNOPOULOS, J. D.; ALERHAND, E O. L. Accurate Theoretical Analysis of Photonic Band-gap Materials. *Physical Review B*, v.48, n.11, 1993.

MERRILL, W. M.; KYRIAZIDOU, C. A.; CONTOPANAGOS, H. F.; ALEXÓPOULOS, N. G. Electromagnetic Scattering from a PBG Material Excited by an Electric Line Source. *IEEE Transactions on Microwave Theory Techniques*, v.47, n.11, p.2105-2114, novembro, 1999.

MISHRA, R. K.; PATNAIK, A. Neural Network-Based CAD Model for The Design of Square-Patch Antennas. *IEEE Transactions on Antennas and Propagation*, v.46, n.12, p.1890-1891, dezembro, 1998.

- MU, T. C.; OGAWA, H.; ITOH, T. Characteristics of Multiconductor, Asymmetric, Slow-Wave Microstrip Transmission Line. *IEEE Transactions on Microwave Theory and Techniques*, v.34, n.12, p.1471-1477, dezembro, 1986.
- OGAWA, H.; ITOH, T. Slow-Wave Characteristics of Ferromagnetic Semiconductor Microstrip Line. *IEEE Transactions on Microwave Theory and Techniques*, v.34, n.12, p.1478-1482, dezembro, 1986.
- OLINER A. A. Periodic Structures and Photonic Band-Gap Terminology: Historical Perspectives. In: EUROPEAN MICROWAVE CONFERENCE, 29., 1999, Munich.
- OLIVEIRA, L. C. M. **Aplicação de Estruturas PBG em Dispositivos Planares de Microondas - Linhas e Antenas - em Substratos Dielétricos e Semicondutores: Desenvolvimento de Tecnologia e Caracterização.** 2001. 119f. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia Elétrica e Computação, UNICAMP, Campinas, 2001.
- OSHERSON, D. N., WEINSTEIN, S., STOLI, M. Modular Learning. *Computacional Neuroscience*, E. L. Schwartz, ed., Cambridge, MA: MIT Press, p.369-377, 1990.
- PATNAIK, A.; MISHRA, R. K.; PATRA, G. K.; DASH, S. K. An Artificial Neural Network Model for Effective Dielectric Constant of Microstrip Line. *IEEE Transactions on Antennas and Propagation*, v.45, n.11, p.1697-1698, novembro, 1997.
- PATNAIK, A.; MISHRA, R. K. ANN Techniques in Microwave Engineering. *IEEE Microwave Magazine*, v.01, n.01, p.55-60, março, 2000.
- PERKONS, A. R.; QIAN, Y.; ITOH, T. TM Surface-Wave Power Combining by a Planar Active-Lens Amplifier. *IEEE Transaction on Microwave Theory Techniques*, v.46, n.06, p.775-783, setembro, 1998.
- POZAR, D. M. **Microwave Engineering.** 1.ed. New Jersey: Addison-Wesley, 1990. 301p.

RADISIC, V.; QIAN, Y.; ITOH, T. Broad-Band Power Amplifier Using Dielectric Photonic Bandgap Structure. *IEEE Microwave and Guided Wave Letters*, v.08, n.01, p.13-14, janeiro, 1998.

RADISIC V.; QIAN Y.; COCCIOLI R.; ITOH T. Novel 2-D Photonic Band-Gap Structures for Microstrip Lines. *IEEE Microwave and Guided Wave Letters*, v.8, n.2, p.69-71, fevereiro, 1998.

RIEDMILLER, M.; BRAUN, H. A Direct Adaptive Method for Faster Backpropagation Learning: the Rprop Algorithm. *Proceedings of the IEEE International Conference on Neural Networks*, p.586-591, 1993.

RUMSEY, I.; PIKET-MAY, M.; KELLY, P. K. Photonic Band-Gap Structures Used as Filters in Microstrip Circuits. *IEEE Microwave and Guided Wave Letters*, v.08, n.10, p.336-338, outubro, 1998.

SHARMA, S. K.; SHAFAL, L. Enhanced Performance of an Aperture-Coupled Rectangular Microstrip Antenna on a Simplified Unipolar Compact Photonic Bandgap Structure. In: IEEE INTERNATIONAL MICROWAVE SIMPOSIUM, 2001, Phoenix. *IEEE MTT-S Digest*, p.498-502, 2001.

SHUM, K. M.; XUE, Q.; CHAN, C. H. A Novel Microstrip Ring Hybrid Incorporating a PBG Cell. *IEEE Microwave and Wireless Components Letters*, v.11, n.06, p.258-260, junho, 2001.

SILVA, P. H. F. **Modelos através de Redes Neurais sem Realimentação para Dispositivos e Circuitos de Microondas**. 2002. 166f. Tese (Doutorado em Engenharia Elétrica) - Centro de Ciências Exatas e da Terra, Universidade Federal de Campina Grande, Campina Grande, 2002.

SILVA, P. H. F.; FERNANDES, E. N. R. Q.; DÓRIA NETO, A. D. A Feed Forward Neural Network with Resolution Properties for Function Approximation and Modeling. In: BRAZILIAN SYMPOSIUM ON NEURAL NETWORKS, 7., 2002, Recife.

SMITH, W. T.; BASTIAN, R. J.; CHEAH, S. Y. An Efficient Neural Network Algorithm for Reflector Surface Error Compensation. *IEEE Transactions on Antennas and Propagation*, v.44, n.02, p.137-142, fevereiro, 1996.

SOUTHALL, H. L.; SIMMERS, J. A.; O'DONNELL, T. H. Direction Finding in Phased Arrays with a Neural Network Beamformer. *IEEE Transactions on Antennas and Propagation*, v.43, n.12, p.1369-1374, dezembro, 1995.

THÉVENOT, M.; CHEYPE, C.; REINEIX, A.; JECKO, B. Directive Photonic-Bandgap Antennas. *IEEE Transactions on Microwave Theory Techniques*, v.47, n.11, p.2115-2122, novembro, 1999.

VAI, M.; PRASAD, S. Microwave Circuit Analysis and Design by a Massively Distributed Computing Network. *IEEE Transactions on Microwave Theory and Techniques*, v.43, n.05, p.1087-1094, maio, 1995.

WADELL, B. C. **Transmission Line Design Handbook**. 1.ed. Boston, Massachusetts: Artech House, 1991. 451p.

WANG, T. H.; ITOH, T. Confirmation of Slow-Wave in a Crosstie Overlay Coplanar Waveguide and its Applications to Band-Reject Gratings and Reflectors. *IEEE Transactions on Microwave Theory and Techniques*, v.36, n.12, p.1811-1818, dezembro, 1988.

WANG, F.; ZHANG, Q. J. Knowledge-Based Neural Models for Microwave Design. *IEEE Transactions on Microwave Theory and Techniques*, v.45, n.12, p.2333-2343, dezembro, 1997.

WANG, F.; DEVABHAKTUNI, V. K.; ZHANG, Q. A Hierarchical Neural Approach to the Development of a Library of Neural Models for Microwave Design. *IEEE Transactions on Microwave Theory and Techniques*, v.46, n.12, p.2391-2402, dezembro, 1998.

WASHINGTON, G. Aperture Antenna Shape Prediction by Feedforward Neural Network. *IEEE Transactions on Antennas and Propagation*, v.45, n.04, p.683-688, abril, 1997.

WATSON, P. M.; GUPTA, K. C. EM-ANN Models for Microstrip Vias and Interconnects in Dataset Circuits. *IEEE Transactions on Microwave Theory and Techniques*, v.44, n.12, p.2495-2503, dezembro, 1996.

WATSON, P. M.; GUPTA, K. C. Design and Optimization of CPW Circuits Using EM-ANN Models for CPW Components. *IEEE Transactions on Microwave Theory and Techniques*, v.45, n.12, p.2515-2523, dezembro, 1997.

YABLONOVITCH, E.; GMITTER, T. J.; LEUNG, K. M. Photonic Band Structure: The face-centered-cubic case employing nonspherical atoms. *Physical Review Letters*, v.67, p.2295-2298, 1991.

YANG, F. -R.; QIAN, Y.; COCCIOLI, R.; ITOH, T. A Novel Low-Loss Slow-Wave Microstrip Structure. *IEEE Microwave and Guided Wave Letters*, v.08, n.11, p. 372-374, novembro, 1998.

YANG, F. -R.; MA, K.; QIAN, Y.; ITOH, T. A Uniplanar Compact Photonic Band-Gap (UC-PBG) Structure and its Applications for Microwave Circuits. *IEEE Transactions on Microwave Theory Techniques*, v.47, n.8, p.1509-1514, agosto, 1999a.

_____. A Novel TEM Waveguide Using Uniplanar Compact Photonic-BandGap (UC-PBG) Structure. *IEEE Transactions on Microwave Theory Techniques*, v.47, n.11, p.2092-2098, novembro, 1999b.

YANG, F. R.; QIAN, Y.; ITOH, T. A Novel Uniplanar Compact PBG Structure for Filter and Mixer Applications. In: IEEE INTERNATIONAL MICROWAVE SIMPOSIUM, 1999, Anaheim. *IEEE MTT-S Digest*, p.919-922, 1999.

YANG, F. R.; COCCIOLI, R.; QIAN, Y.; ITOH, T. Planar PBG Structures: Basic Properties and Applications. *IEICE Transactions on Electronics*, v.E83C, n.05, p.687-695, 2000.

YANG, H. D. Finite Difference Analysis of 2-D Photonic Crystals. *IEEE Transactions on Microwave Theory Techniques*, v. 44, n.12, p.2688-2695, dezembro, 1996.

YANG, H. D.; ALEXOPOULOS, N. G.; YABLONOVITCH, E. Photonic Band-gap Materials for High-Gain Printed Circuit Antennas. *IEEE Transactions on Antennas and Propagation*, v.45, n.01, p.185-187, janeiro, 1997.

YANG, H. D. Theory of Microstrip Lines on Artificial Periodic Substrate. *IEEE Transactions on Microwave Theory Techniques*, v. 47, n.05, p.629-635, maio, 1999.

YANG, H. D.; WANG, J. Surface Waves of Printed Antennas on Planar Artificial Periodic Dielectric Structures. *IEEE Transactions on Antennas and Propagation*, v.49, n.03, p.444-450, março, 2001.

YI, X.; YEH, P.; HONG, J. H. Photonic Bandgap Structure in Thin Film Waveguides. In: IEEE MTT-S INTERNATIONAL MICROWAVE OPTOELECTRONICS CONFERENCE, 8., 1999, Rio de Janeiro.

YOON, J.; SEO, C. Improvement of Broadband Feedforward Amplifier Using Photonic Bandgap. *IEEE Microwave and Wireless Components Letters*, v.11, n.11, p.450-452, novembro, 2001.

YOUNG, P.; HERSCHLEIN, A.; WIESBECK, W. A Photonic Bandgap (PBG) Structure for Guiding and Suppressing Surface Waves in Millimeter-Wave Antennas. *IEEE Transactions on Microwave Theory and Techniques*, v.49, n.10, p.1854-1859, outubro, 2001.

YUN, T.; CHANG, K. Uniplanar One-Dimensional Photonic-Bandgap Structures and Resonators. *IEEE Transactions on Microwave Theory and Technique*, v.49, n.03, p.549-553, março, 2001.

XU, J.; YAGOUB, M. C. E.; DING, R.; ZHANG, Q. -J. Neural-Based Dynamic Modeling of Nonlinear Microwave Circuits. *IEEE Transactions on Microwave Theory and Techniques*, v.50, n.12, p.2769-2780, dezembro, 2002.

XUE, Q.; SHUM, K. M.; CHAN, C. H. Novel 1-D Microstrip PBG Cells. *IEEE Microwave and Guided Wave Letters*, v.10, n.10, p.403-405, outubro de 2000.

ZAABAB, A. H.; ZHANG Q. J.; NAKHLA M. A Neural Network Modeling Approach to Circuit Optimization and Statistical Design. *IEEE Transactions on Microwave Theory and Techniques*, v.43, n.06, p.1349-1358, junho, 1995.

ZHANG, Q. J.; GUPTA, K. C. **Neural Networks for RF and Microwave Design**. 1.ed. Boston: Artech House, 2000. 369p.

ZHANG, Q. J.; GUPTA, K. C. Artificial Neural Network for RF and Microwave – From Theory to Practice. *IEEE Transactions on Microwave Theory and Techniques*, v.51, n.04, p.1339-1350, abril, 2003.

ZIENIUTYCZ, W.; KILDAL, P. Study of Wall Region and Dielectric Losses in a Square Hard Horn. *Proc. Inst. Elect. Eng.*, v.139, p.139-142, abril, 1992.