



UNIVERSIDADE FEDERAL DA
BAHIA
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA



ANÁLISE E SÍNTESE DE DISPOSITIVOS FOTÔNICOS UTILIZANDO REDES NEURAIS ARTIFICIAIS

ANDERSON DOURADO SISNANDO

2011

UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA

ANDERSON DOURADO SISNANDO

**ANÁLISE E SÍNTESE DE
DISPOSITIVOS FOTÔNICOS
UTILIZANDO REDES
NEURAIS ARTIFICIAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal da Bahia como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Vitaly Félix Rodríguez Esquerre.

SALVADOR

2011

D739 Dourado Sisnando, Anderson,
Análise e síntese de dispositivos fotônicos utilizando redes
neurais artificiais / Anderson Dourado Sisnando. - Salvador 2011.
93 f. : il. color.

Orientador: Prof. Doutor Vitaly Félix Rodríguez Esquerre

Dissertação (mestrado) – Universidade Federal da Bahia.
Escola Politécnica, 2011

1. Sistemas de comunicação óptica. 2. Redes neurais artificiais.
3. Guias de onda ópticos. I. Rodríguez Esquerre, Vitaly Félix.
II. Universidade Federal da Bahia. III. Título.

CDD 621.382



**UNIVERSIDADE FEDERAL DA
BAHIA
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA**



**ANÁLISE E SÍNTESE DE DISPOSITIVOS
FOTÔNICOS UTILIZANDO REDES NEURAIAS
ARTIFICIAIS**

DISSERTAÇÃO DE MESTRADO

Autor: Anderson Dourado Sisnando

Orientador: Vitaly Félix Rodriguez Esquerre

Banca Examinadora

Prof. Dr. Vitaly Felix Rodriguez Esquerre

Prof. Dr. Hugo Enrique Hernández Figueroa

Prof. Dr. Robson Nunes de Lima

Prof. Dr. Jês de Jesus Fiais Cerqueira

A Deus, minha família, amigos e noiva pelo apoio antes e durante, muito obrigado!

Agradecimentos

Ao professor Dr. Vitaly Félix Rodríguez Esquerre pela paciência, pelas aulas e orientações, pelas oportunidades em seus projetos de pesquisa, e pela importante amizade.

Aos amigos que fiz durante o mestrado, Lucas D'êça, Fabrício Simões, Edson Pinto, Joaquim Lima, Paulo Eduardo, Thiago, Joalbo Santos e Bruno Simões por dividirem as alegrias e angústias durante esses anos.

Aos amigos Márcio Costa, Rheurison Lima, Marcus Leone, Aquiles Santana, Michel Lima, Júlia Dourado, Bob Bastos pelo incomensurável apoio durante a realização desse projeto.

Aos meus pais Francisco Demontier e Eva Chirlen, aos meus irmãos Rômulo, Natali e Priscila, meus sobrinhos Sabrina e Felipe, minhas primas Kelly, Kátia e Karine, cunhada Kelly, minhas tias Vera Lúcia, Maria Sônia e Expedita Berenice, por serem a razão de tudo isso, amo vocês.

A Manuela, minha noiva, que sempre estava lá para me apoiar nos momentos de revés, onde eu pensava em desistir, e ela me dava forças pra prosseguir.

Aos professores Carloman Carlos Borges (*in memoriam*) e Trazíbulo Henrique pelo apoio e recomendações, e a todos os outros amigos e colegas, um muito obrigado de coração.

“Bazinga!!”
Sheldon “The Big Bang Theory”.

RESUMO

Esta dissertação aborda a modelagem, análise e projeto de Dispositivos Fotônicos: acopladores direcionais e fibras de cristais fotônicos (PCF- *Photonic Crystal Fiber*), através de redes neurais artificiais (RNA). Inicialmente é feita uma breve revisão sobre redes neurais artificiais e suas configurações, um estudo da teoria dos modos acoplados para auxiliar no entendimento do funcionamento dos acopladores direcionais analisados e um estudo da teoria de PCFs no intuito de descrever as suas características de dispersão.

Quanto aos problemas fotônicos nossos estudos se restringiram a dois casos gerais: proposta de modelagem e projeto de acopladores direcionais através de RNA e modelagem de fibras de cristais fotônicos, comparando os resultados obtidos de dispersão com os encontrados através de técnicas clássicas.

Como figura de mérito, avalia-se a simplicidade, o tempo, o custo computacional e a precisão dos modelos desenvolvidos.

Palavras-chave: Redes Neurais Artificiais, Acopladores Direcionais Ópticos, Fibras de Cristais Fotônicos, Dispersão.

ABSTRACT

The aim of this work is the modeling and the analysis of photonic devices such as directional couplers and photonic crystal fibers (PCF Photonic Crystal Fiber) by using artificial neural networks (ANN). First, a review of neural networks and their settings are given, then, the coupled mode theory is presented to help understanding the operation of directional couplers and finally, the theory of PCFs is presented in order to describe their chromatic dispersion characteristics.

Our studies were focused to two general problems: Modeling and synthesis of directional couplers based in planar waveguides and optical fibers by using RNA and the prediction of the chromatic dispersion of photonic crystal fibers by using RNA. The results were compared with classical techniques.

We take into account the simplicity, processing time, computational effort and the accuracy of the computational models here developed.

Keywords: Artificial Neural Networks, Optical Directional Couplers, Photonic Crystal Fibers, Dispersion.

SUMÁRIO

Lista de Figuras.....	v
Lista de Tabelas	vii
Lista de Símbolos.....	ix
Trabalhos Afins Publicados Pelo Autor.....	x
Capítulo 1 - Introdução	11
1.1. Motivações.....	11
1.2. Objetivos.....	14
1.3. Organização da Dissertação	17
Capítulo 2 - Redes Neurais Artificiais (RNA).....	18
2.1. Rede Neural	18
2.2. Mult Layer Perceptron (MLP)	19
2.3. Treinamento Supervisionado.....	20
2.4. Rede Feedforward.....	22
2.5. Algoritmo Backpropagation	22
2.6. Passos para o desenvolvimento das aplicações utilizando RNAs.....	23
2.7. Levenberg-Maquardt (LM)	24
2.7.1. Comparação de Velocidade e Memória.....	26
Conclusão do Capítulo	29
Capítulo 3 – Acopladores Direcionais	30
3.1. Teoria dos Modos Acoplados	32
3.1.1. Métodos Analíticos.....	39
3.1.1.1. Guia de Onda Dielétrico.....	39
3.1.1.2. Fibra Óptica.....	40
3.2. Acopladores Direcionais Planares (2D)	41
3.2.1. Acopladores Direcionais Planares com Guias de Sílica e Silício.....	41
3.2.2. Acopladores Direcionais Planares com Guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$	43
3.3. Acopladores Direcionais baseados em Fibras Ópticas	44
Conclusão do Capítulo.....	48
Capítulo 4 - Análise e Síntese de Acopladores Utilizando RNA	49
4.1. Configuração das Redes Neurais	49
4.2. Resultados Numéricos	54
4.2.1. Acoplador Direcional Planar com Guias de Sílica e Silício.....	54
4.2.2. Acoplador Direcional Planar com Guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$	58
4.2.3. Acoplador Direcional Baseado em Fibras Ópticas.....	60
Conclusão do Capítulo.....	64
Capítulo - 5 Dispersão Cromática em Fibras Ópticas Microestruturadas (MOFs)	65
5.1. Fibras Ópticas Microestruturadas.....	65
5.2. Dispersão Cromática: conceitos fundamentais.....	69
5.3. Resultados Numéricos PCF	72
Conclusão do Capítulo.....	78

Conclusões	79
Sugestões e Trabalhos futuros	80
Referências.....	81
ANEXOS.....	86

LISTA DE FIGURAS

Figura 1.1 Acoplador direcional: (a) distribuição de campo dos modos isolados e (b) transferência de potência do guia 1 para o guia 2 após uma distância Lc	12
Figura 1.2 Geometria de uma (a) <i>holey fiber</i> e (b) fibra PBG. d e Λ representam o diâmetro dos capilares e a constante periódica, respectivamente.....	13
Figura 1.3. Efeito da dispersão: alargamento do pulso após uma determinada distancia, limitando a distância do enlace óptico nas fibras.....	13
Figura 1.4. Esquema de modelagem de Acoplador Direcional utilizando o Método dos Elementos Finitos.....	15
Figura 1.5. Esquema de modelagem de Fibra de Cristais Fotônicos, utilizando o Método dos Elementos Finitos.....	16
Figura 2.1. Neurônio Artificial.....	19
Figura 2.2. Estrutura de uma rede neural artificial	20
Figura 2.3. Propagação das entradas.....	21
Figura 2.4. Retropropagação do erro	22
Figura 2.5. Tempo de convergência vs. Erro médio quadrático pretendido	28
Figura 2.6. Tempo de convergência vs. Convergência do erro	29
Figura 3.1. (a) e (b) Acoplador Planar (2D) com guias de sílica/silício e $\text{Al}_x\text{Ga}_{1-x}\text{As}$, respectivamente; (b) Acoplador baseado em Fibras Ópticas	30
Figura 3.2. Sistema de dois guias de onda dielétricos paralelos muito próximos, com mesmas constantes de propagação	31
Figura 3.3. Variação da potência nos guias em função da distância propagada.....	32
Figura 3.4. Acoplador com Guias de Onda Retangulares	33
Figura 3.5. Explicação do coeficiente de acoplamento C_{12} nas extremidades dos guias I e II.....	37
Figura 3.6. Distribuição do índice de refração $N^2(x, y)$ dos guias de onda acoplados, a diferença da distribuição do índice de refração $N^2 - N_p^2$ e o campo elétrico E_p que aparecem nas Equações (3.18) e (3.20).....	38
Figura 3.7. Perfil dos índices de refração no acoplador baseado em guias de onda planares	39
Figura 3.8. Perfil dos índices de refração no acoplador baseado em fibras ópticas ...	41
Figura 3.9. Variação do índice de refração do $\text{Al}_x\text{Ga}_{1-x}\text{As}$ em função do comprimento de onda e da fração de alumínio na liga metálica	44
Figura 3.10. Representação esquemática dos modos de um acoplador de dois guias uniformes.....	45
Figura 3.11. Supermodo simétrico	47
Figura 3.12. Supermodo assimétrico	47
Figura 4.1. Configuração das variáveis de entrada e saída na Análise	49
Figura 4.2. Configuração da rede neural e as variáveis de entrada e saída para análise do acoplador planar com guias de sílica e silício	50

Figura 4.3. Configuração das variáveis entrada e saída na análise do acoplador planar com guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$	50
Figura 4.4. Configuração da rede neural e as variáveis de entrada e saída para análise do acoplador baseado em fibras ópticas	51
Figura 4.5. Configuração das variáveis de entrada e saída na Síntese	51
Figura 4.6. Configuração da rede neural e as variáveis de entrada e saída para a 1ª síntese do acoplador planar com guias de sílica e silício	52
Figura 4.7. Configuração da rede neural e as variáveis de entrada e saída para a 2ª síntese do acoplador planar com guias de sílica e silício	52
Figura 4.8. Configuração das variáveis de entrada e saída para a 1ª síntese do acoplador planar com guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$	53
Figura 4.9. Configuração das variáveis de entrada e saída para a 2ª síntese do acoplador planar com guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$	53
Figura 4.10. Configuração da rede neural e as variáveis de entrada e saída para a 1ª síntese do acoplador baseado em fibras ópticas	54
Figura 4.11. Configuração da rede neural e as variáveis de entrada e saída para a 2ª síntese do acoplador baseado em fibras ópticas	54
Figura 4.12. Parâmetros utilizados para a análise e síntese do acoplador planar com guias de sílica e silício, com seus respectivos intervalos	55
Figura 4.13. Comparação dos resultados obtidos de soluções analíticas e obtidos na saída da rede neural para a análise da distância de acoplamento (acoplador 2D com guias de sílica e silício)	56
Figura 4.14. Comparação dos resultados obtidos de soluções analíticas e obtidos na saída da rede neural para a síntese do afastamento entre os guias (acoplador 2D com guias de sílica e silício)	57
Figura 4.15. Comparação dos resultados obtidos de soluções analíticas e obtidos na saída da rede neural para a síntese da largura dos guias (acoplador 2D com guias de sílica e silício)	57
Figura 4.16. Parâmetros utilizados para a análise e síntese do acoplador planar com guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$, com seus respectivos intervalos	58
Figura 4.17. Resultado do treinamento da Rede Neural relativa à análise da distância de acoplamento	59
Figura 4.18. Resultado do treinamento da Rede Neural relativa à síntese do afastamento entre os guias	60
Figura 4.19. Resultado do treinamento da Rede Neural relativa à síntese da largura dos guias	60
Figura 4.20. Parâmetros utilizados para a análise e síntese do acoplador planar com seus respectivos intervalos	61
Figura 4.21. Comparação dos resultados obtidos de soluções analíticas e obtidos na saída da rede neural para a análise da distância de acoplamento (acoplador à fibra)	62

Figura 4.22. Comparação dos resultados obtidos de soluções analíticas e obtidos na saída da rede neural para a síntese do afastamento entre os guias (acoplador à fibra)	63
Figura 4.23. Comparação dos resultados obtidos de soluções analíticas e obtidos na saída da rede neural para a síntese do raio das fibras (acoplador à fibra)	63
Figura 5.1. Seção transversal de uma fibra óptica microestruturada com núcleo sólido	66
Figura 5.2. Fibra óptica com banda fotônica proibida e núcleo de ar (PBG)	66
Figura 5.3. Esquemático de uma fibra óptica microestruturada e seus parâmetros ..	67
Figura 5.4. Frequência normalizada em função do afastamento entre o centro dos capilares normalizado	69
Figura 5.5. Ilustração das faixas espectrais em comunicações ópticas e da separação de canais em sistema WDM	70
Figura 5.6. Variáveis de entrada e saída da RNA para análise da dispersão cromática de PCFs	73
Figura 5.7. Dispersão cromática obtida pelo treinamento e validação dos dados através da RNA para o afastamento entre os capilares de $2\mu\text{m}$, (a) Superfície 3D e (b) Projeção 2D	74
Figura 5.8. Dispersão cromática obtida pelo treinamento e validação dos dados através da RNA para o afastamento entre os capilares de $2,5\mu\text{m}$, (a) Superfície 3D e (b) Projeção 2D	75
Figura 5.9. Dispersão cromática obtida pelo treinamento e validação dos dados através da RNA para o afastamento entre os capilares de $3\mu\text{m}$, (a) Superfície 3D e (b) Projeção 2D	76
Figura 5.10. Mapa de dispersão cromática para espaçamento entre os capilares de $2\mu\text{m}$	77
Figura 5.11. Mapa da dispersão cromática para espaçamento entre os capilares de $2,5\mu\text{m}$	77
Figura 5.12. Mapa de dispersão cromática para espaçamento entre os capilares de $3\mu\text{m}$	78

LISTA DE TABELAS

Tabela 2.1. Algoritmos de treinamento	27
Tabela 2.2. Resultados de formação da rede	28

LISTA DE SÍMBOLOS

CD	<i>Chromatic Dispersion</i>
FEM	Método dos Elementos Finitos
GVD	<i>Grup Velocity Dispersion</i>
HF	<i>Holey Fiber</i>
LM	Levenberg-Maquardt
MLP	<i>Multilayer Perceptron</i>
MOFs	<i>Microstructured Optical Fibers</i>
MSE	Erro Médio Quadrático
PBG	<i>Photonic Band Gap</i>
PCF	<i>Photonic Crystal Fibers</i>
RDS	<i>Relative Dispersion Slope</i>
RNA	Rede Neural Artificial
TE	Transversal Elétrico
V	Frequência Normalizada
WDM	<i>Wavelength Division Multiplexing</i>

TRABALHOS AFINS PUBLICADOS PELO AUTOR

1. V. Rodríguez-Esquerre, A. Dourado-Sisnando, and F. S. Silva, "Neural Network Analysis and Design of Directional Couplers," in Integrated Photonics Research, Silicon and Nanophotonics, OSA Technical Digest (CD) (Optical Society of America, 2010), paper JTUB25.
2. V. Rodríguez-Esquerre, J.J. Isídio-Lima, and A. Dourado-Sisnando, "Efficient Neural Network Modeling of Photonic CrystalFiber Chromatic Dispersion," in Latin America Optics and Photonics Conference, OSA Technical Digest (CD) (Optical Society of America, 2010), paper PDPTuK1.
3. V. F. Rodríguez-Esquerre ; A. Dourado-Sisnando ; Fabricio G. S. Silva . Análise e Projeto de Acopladores Direcionais através de Redes Neurais Artificiais. Anais do MOMAG 2010 - 14º SBMO Simpósio Brasileiro de Microondas e Optoeletrônica e o 9º CBMag Congresso Brasileiro de Eletromagnetismo, 2010. pp. 430-433.

Capítulo 1

1. Introdução

1.1. Motivações

O interesse nas comunicações ópticas surgiu nos anos 60 com a invenção do laser, uma fonte óptica coerente que possibilitou o uso de uma nova faixa de frequências do espectro eletromagnético. O laser permitiu também o incremento de ordens de magnitude nas aplicações existentes numa área recentemente desenvolvida e abriu novos campos e novas aplicações [1,2].

A óptica integrada surgiu devido à necessidade de se miniaturizar os dispositivos utilizados. Ela engloba assuntos tais como guiamento de ondas, acoplamento modal, chaveamento, modulação e outros. Para desempenhar estas funções, a óptica integrada envolve outras tecnologias, possibilitando a combinação de componentes ópticos, eletro-ópticos e elétricos num mesmo substrato, aumentando a flexibilidade e o escopo do circuito óptico integrado [2].

Na modelagem e simulação desses componentes ópticos integrados, podem ser utilizados métodos numéricos ou analíticos, permitindo explorar idéias para novos dispositivos sem a necessidade de custos com fabricação e testes [3].

Neste trabalho, aborda-se a modelagem e análise de dispositivos fotônicos (acopladores direcionais 2D e à Fibra, e fibras de cristais fotônicos) através das redes neurais artificiais (RNA).

O acoplador direcional é um dispositivo que constitui a base de várias redes de distribuição. Ele consiste de dois guias suficientemente próximos de tal forma que a distribuição espacial dos seus campos se sobrepõe, Figura 1.1(a), podendo assim a luz ser acoplada de um guia para o outro, Figura 1.1(b). A transferência de energia entre os dois guias é periódica.

Este dispositivo será estudado detalhadamente no Capítulo 3.

Um outro dispositivo que será modelado são as fibras de cristal fotônico (PCF's), Figura 1.2, também chamadas de fibras microestruturadas (MOF's), são constituídas de um núcleo, que pode ser oco ou sólido, por onde a luz viaja circundada por uma região externa microestruturada em geral de vidro e ar, podem ser classificadas em duas classes de fibras fotônicas, as fibras de núcleo sólido que são chamadas de fibras fotônicas (*holey fiber*), e as fibras de núcleo oco, chamadas de fibras de *bandgap* (PBG).




Figura.1.1. Acoplador direcional: (a) distribuição de campo dos modos isolados e (b) transferência de potência do guia1 para o guia 2 após uma distância L_c .

Esta classificação decorre do fato de o mecanismo de guiamento ser diferente para cada tipo de fibra. As fibras de núcleo sólido guiam a luz por reflexão interna total modificada. De maneira simples, a região microestruturada da casca tem um índice de refração médio menor que o índice de núcleo de vidro, de modo que a reflexão interna total funciona. No caso das fibras de *bandgap*, o índice do núcleo é menor que o da casca e reflexão interna total não funciona. O guiamento ocorre através de efeitos de *bandgap* fotônico. Basicamente, múltiplas reflexões na microestrutura da casca criam interferência construtiva no núcleo para alguns comprimentos de onda. Dentro desta faixa de comprimentos de onda, a luz é guiada no núcleo de ar.




Figura 1.2. Geometria de uma (a) *holey fiber* e (b) fibra PBG. d e Λ representam o diâmetro dos capilares e a constante periódica, respectivamente.

A dispersão cromática é um dos principais fatores limitantes nos atuais sistemas de transmissão de dados em fibras ópticas. A qual será o fenômeno analisado neste trabalho nas fibras PCF's. Este fenômeno é a medida do alargamento temporal do pulso, em uma faixa espectral, após sua propagação por um determinado comprimento de fibra [4,5]. Sua origem está relacionada com as características materiais e estruturais das fibras ópticas.

Este fenômeno dispersivo e as fibras de cristais fotônicos serão estudados no Capítulo 5.



Figura 1.3. Efeito da dispersão: alargamento do pulso após uma determinada distância, limitando a distância do enlace óptico nas fibras.

Para todos os casos, foram implementados códigos específicos para a obtenção de dados (com a exceção da dispersão cromática da PCF, cujos dados foram obtidos da literatura [6]) a serem utilizados nas redes neurais artificiais.

1.2. Objetivos

O objetivo deste trabalho é realizar a análise e projeto de estruturas muito utilizadas na óptica integrada: o acoplador direcional e fibras de cristais fotônicos, utilizando a ferramenta RNA, para que profissionais atuando na área de telecomunicações, possam modelar estas estruturas sem a necessidade de grande conhecimento da teoria eletromagnética avançada e de métodos numéricos, com pouco esforço computacional e simplicidade no processo de sintetização dos dispositivos analisados.

As equações de *Maxwell* descrevem completamente os fenômenos eletromagnéticos. Porém, sua resolução analítica é impraticável em dispositivos com geometria complexa. Uma alternativa para contornar esse problema é a utilização de métodos do cálculo numérico para obter-se uma solução aproximada.

O Método dos Elementos Finitos (FEM) é um entre os vários métodos clássicos conhecidos para fenômenos eletromagnéticos, projeto e análise de acopladores direcionais e de fibras de cristais fotônicos. Mas, para utilização deste método o objeto de estudo (acoplador e fibras de cristal fotônico) deve ter sua geometria subdividida (discretização) em várias partes, os chamados elementos finitos. Essas subdivisões recebem o nome de malhas, sendo constituídas, normalmente, por triângulos ou quadriláteros (bidimensional) ou pirâmides e tetraedros (tridimensional). Os vértices dessas malhas são denominados nós e são utilizados para montar um sistema de equações cuja solução permite determinar as grandezas de interesse no fenômeno analisado. No caso eletromagnético, essa solução é o vetor campo magnético ou campo elétrico em cada nó da malha, a partir dos quais é possível determinar os campos magnéticos e elétricos no interior dos elementos finitos [7].

A utilização do FEM em uma ferramenta computacional pode ser dividida em três etapas [7]:

- pré-processamento: engloba o desenho da geometria do objeto estudado, a geração da malha, a imposição das propriedades físicas dos meios envolvidos, a imposição dos valores das fontes de campo no objeto (densidade de corrente elétrica ou densidade de carga elétrica nos materiais) e a imposição das condições de contorno pertinentes ao fenômeno e ao objeto estudado;
- processamento: inclui a montagem do sistema de equações, através dos dados de pré-processamento, e a sua resolução através de métodos diretos ou iterativos;
- pós-processamento: os dados das etapas anteriores permitem criar procedimentos para cálculo e apresentação da grandeza do fenômeno estudado. Os algoritmos que traçam linha de campo ou equipotenciais sobre a geometria fornecida, os que

calculam energia, força, torque e parâmetros, os que traçam gráficos de campos e potenciais sobre segmentos definidos no objeto ou outros mais específicos para alguns fenômenos ou outras grandezas, são os constituintes do pós-processamento. Logo, necessita-se de conhecimentos avançados de eletromagnetismo e de métodos numéricos, os quais precisam de grandes recursos computacionais e longos tempos de processamento.

Na Figura 1.4 e 1.5 são apresentadas as etapas necessárias para analisar um acoplador direcional e uma fibra de cristal fotônico através do método dos elementos finitos.

Acoplador Direcional




Figura 1.4. Esquema de modelagem de Acoplador Direcional utilizando o Método dos Elementos Finitos.

Dispersão Cromática da Fibra PCF




Figura 1.5. Esquema de modelagem de Fibra de Cristais Fotônicos, utilizando o Método dos Elementos Finitos.

A partir da aplicação do método dos elementos finitos na equação de *Hemlhotz* que governa o sistema a ser analisado obtém-se um problema matricial de autovalores e autovetores, onde γ é o autovalor que representa as constantes de propagação e atenuação, e a partir dele se obtém os índices efetivos n_{eff} 's dos supermodos simétrico e antissimétrico, que serão utilizados para encontrar a distância de acoplamento no caso do acoplador, Figura 1.4, O campo elétrico está no autovetor e relaciona a distribuição espacial dos campos dos supermodos 1 e 2, Figura 1.4.

No caso da dispersão cromática da PCF, Figura 1.5, o processo é similar, sendo necessário o cálculo do índice efetivo em diversos comprimentos de onda, e a dispersão é calculada através da derivada de segunda ordem do índice efetivo. Assim, a precisão do cálculo do índice efetivo é de suma importância e requer de uma malha bem discretizada o que implica um maior esforço computacional.

Então visando a simplificação e a redução do custo computacional deste processo de análise e síntese do acoplador direcional e da fibra de cristal fotônico, utiliza-se neste trabalho as redes neurais artificiais. Os modelos a serem obtidos podem ser utilizados juntamente com técnicas de computação evolutiva para projetar acopladores ou fibras com um determinado comportamento, nesses casos fica mais evidente o ganho do tempo de processamento, pois lida-se com muitos indivíduos a serem avaliados em cada geração.

1.3. Organização da Dissertação

O segundo capítulo dedica-se ao estudo de alguns tipos de redes neurais artificiais e os seus algoritmos de treinamento, mostrando o modelo de neurônio artificial, conceitos e justificativas para a utilização das mesmas. Inicia-se contextualizando as redes neurais artificiais e suas potencialidades para a implementação em problemas de diversas áreas inclusive na modelagem de dispositivos ópticos. Em seguida, são explorados os passos necessários para a sua utilização, além disso, é feita uma justificativa pela escolha e utilização do algoritmo de *Levenberg-Maquardt* comparando-o com outros.

O terceiro capítulo trata-se dos acopladores direcionais ópticos, aborda a teoria de modos acoplados e as deduções necessárias para o entendimento do acoplamento dos modos nos guias utilizados no trabalho e dos métodos analíticos para os guias dielétricos e de fibras. Também são apontadas algumas configurações existentes de acopladores direcionais e seus parâmetros ópticos e geométricos. Descreve analiticamente e com ilustração, a iteração do campo evanescente dos modos dos guias adjacentes. Trata-se especificamente de acopladores planares e à fibra.

No quarto capítulo apresenta-se como é realizada a análise e síntese ou projeto dos dispositivos através da predição de seus comportamentos e são apresentados os resultados numéricos para os acopladores analisados, utilizando redes neurais. Apresentam-se as configurações das entradas e saídas das redes neurais na análise e na síntese dos acopladores planares (com guias de Sílica-Silício e com guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$) e dos baseados em fibras ópticas. Também são mostradas as configurações utilizadas juntamente com os intervalos de cada parâmetro obtido e a comparação dos resultados obtidos pela RNA com os obtidos analiticamente.

No quinto capítulo apresenta-se a teoria de fibras microestruturadas (de cristais fotônicos) e as características da dispersão cromática. São apresentados os resultados do cálculo da predição da dispersão cromática, utilizando redes neurais e a comparação com os encontrados na literatura.

Na conclusão destacam-se as principais contribuições deste trabalho e sugestões para trabalhos futuros.

Capítulo 2

2. Redes Neurais Artificiais (RNA)

Neste capítulo, apresenta-se a teoria de redes neurais artificiais, visando o entendimento desta ferramenta e as justificativas de sua utilização neste trabalho.

As Redes Neurais Artificiais representam uma ferramenta computacional de aplicação nas mais diversas áreas da ciência e da vida humana [8,9]. Dentre as aplicações mais comuns encontradas, podem ser destacadas a simulação de sistemas não-lineares, o controle de plantas industriais, o reconhecimento de padrões, a modelagem de problemas eletromagnéticos [9], análise e processamento de sinais, controle de processos, robótica, classificação de dados, análise de imagens, análise de voz e avaliação de crédito.

Atributos importantes e únicos desta poderosa ferramenta são a aproximação universal (mapeamento entrada-saída não-linear), capacidade de aprender e se adaptar ao ambiente em que está operando e a capacidade de generalização [9-11]. As redes neurais utilizam um modelo matemático que se baseia originalmente na estrutura neural dos organismos inteligentes. Estas estruturas são formadas por milhões de neurônios interconectados por ligações chamadas sinapses. Estas ligações, além de conduzirem a informação de um neurônio para o outro, também possuem pesos que multiplicam a informação aplicada à sua entrada. Com isso, uma informação pode ser atenuada, amplificada ou simplesmente permanecer inalterada quando passada de um neurônio a outro. Estudos científicos já demonstraram que a memória da estrutura neural não está nos neurônios, mas sim nos pesos das sinapses. Estes pesos é que são alterados ou não quando recebem mais informação ou quando estão em processo de aprendizagem, por exemplo.

2.1. Rede neural

O modelo atual para representar um neurônio artificial tem origem nos neurônios formais propostos pelo neurofisiologista *Warren McCulloch* e o matemático *Walter Pitts* (1943) [9]. O k -ésimo neurônio artificial pode ser modelado com os seguintes elementos: *entradas* (x_j representa a saída do neurônio j); *sinapse* (ligação saída-entrada entre o neurônio j e o neurônio k , caracterizada pelo peso sináptico $w_{k,j}$), *somador* (soma ponderada, u_k , das entradas do neurônio k pelos respectivos pesos sinápticos); *função de ativação* (F), *bias* (b_k , constante adicionada à soma ponderada u_k) e *saída* (y_k). Para simplificar a notação, o *bias* b_k pode ser considerado como o peso sináptico $w_{k,0}$ associado a uma entrada constante $x_{f=0}=1$, conforme Equações (2.1) e (2.2):

$$u_k = \sum_{f=0}^m w_{kj} x_f \quad (2.1)$$

$$y_k = F(u_k) \quad (2.2)$$




Figura 2.1. Neurônio Artificial

Um neurônio com um único vetor de entrada com R elementos, Figura 2.1 [12]. Aqui os elementos de entrada são multiplicados individualmente por pesos e os valores ponderados são alimentados à junção de soma. A soma é simplesmente Wp , produto escalar da matriz W (linha única) e o vetor p.

2.2. Multilayer Perceptron (MLP)

O *perceptron* é a forma mais simples de uma rede neural usada para a classificação de padrões ditos linearmente separáveis (i.e., padrões que se encontram em lados opostos de um hiperplano) [8,9]. Basicamente, ele consiste de um único neurônio com pesos sinápticos ajustáveis e *bias* [8].

É denominada *Multilayer Perceptron*, Figura 2.2, a forma de arranjar *perceptrons* em camadas. O *multilayer perceptron* foi concebido para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico. Um único *perceptron* ou uma combinação das saídas de alguns *perceptrons* poderia realizar uma operação XOR, porém, seria incapaz de aprendê-la. Logo são necessárias mais conexões, as quais só existem em uma rede de *perceptrons* dispostos em camadas. Os neurônios internos são de suma importância na rede neural, pois se provou que sem estes se torna impossível a resolução de problemas linearmente não separáveis [8,9]. Ou seja, pode-se dizer que uma rede é composta por várias unidades

de processamento, essas unidades geralmente são conectadas por canais de comunicação (sinapses) que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões (sinapses).

O comportamento inteligente de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede. A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos.

Arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior [8-12]. A rede neural passa por um processo de treinamento a partir dos casos reais conhecidos, adquirindo, a partir daí, a sistemática necessária para executar adequadamente o processo desejado com os dados fornecidos. Sendo assim, a rede neural é capaz de extrair regras básicas a partir de dados reais, diferindo da computação programada, na qual é necessário um conjunto de regras rígidas pré-fixadas e algoritmos.

Usualmente as camadas são classificadas em três grupos [9,13]:

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




Figura 2.2. Estrutura de uma rede neural artificial MLP

2.3. Treinamento Supervisionado

O processo de treinamento supervisionado de uma rede neural consiste basicamente em apresentar pares entrada-saída à rede, calcular as saídas da rede em função das entradas, calcular o erro entre a saída desejada e a saída calculada e

alterar os valores sinápticos por algum tipo de algoritmo. À medida que os pares entrada-saída vão sendo apresentados e os pesos das sinapses atualizados, o erro médio quadrático (MSE) da saída da rede tende a diminuir. Existem alguns tipos mais importantes de algoritmos, dentre os quais o mais utilizado e eficiente é o chamado de *Backpropagation*, Figuras 2.3 e 2.4. O processo de treinamento da rede neural pelo método de *Backpropagation* realiza, como o próprio nome diz, a retropropagação dos erros calculados das saídas em direção às entradas. O erro calculado na saída de um neurônio é multiplicado pela derivada da função de ativação daquele neurônio e propagado para a sua entrada. Este valor então é enviado para todos os neurônios da camada anterior ponderado pelo peso da camada. O treinamento pode ser por época, onde todo o conjunto de treinamento utilizado é apresentado à rede e só após isso, as sinapses são atualizadas, isto é realizado somando-se os gradientes calculados para cada par entrada-saída até o último par do conjunto de treinamento. Quando passamos todos os pares dizemos que ocorreu uma época. Este tipo de treinamento é mais rápido que por Regra Delta e muitas vezes, chamado de Regra Delta Generalizada.




Figura 2.3. Propagação das entradas




Figura 2.4. Retropropagação do erro

2.4. Rede *Feedforward*

Redes *feedforward* têm uma ou mais camadas ocultas de neurônios com função *sigmóide*, seguido por uma camada de saída de neurônios com função linear.

Múltiplas camadas de neurônios com funções de transferência não-lineares fazem com que a rede não aprenda as relações lineares entre os vetores de entrada e saída. A camada de saída linear permite que a rede produza valores fora do intervalo -1 a 1. Por outro lado, se quisermos restringir os resultados de uma rede (entre 0 e 1), então a camada de saída deve usar uma função de transferência *sigmóide*. Em redes com múltiplas camadas o número de camadas determina o sobrescrito nas matrizes de peso [12].

Esta rede pode ser usada como um aproximador da função geral, aproximando qualquer função com um número finito de descontinuidades arbitrárias se houver neurônios suficientes na camada escondida.

2.5. Algoritmo *Backpropagation*

Há muitas variações do algoritmo *backpropagation*, a implementação mais simples de aprendizagem por retropropagação atualiza os pesos da rede na direção em que a função de desempenho diminui mais rapidamente o negativo do gradiente. Uma iteração deste algoritmo pode indicar um vetor de peso atual, tendências do gradiente e da taxa de aprendizagem. Há duas maneiras diferentes em que este algoritmo com gradiente descendente pode ser implementado: o modo incremental e o modo em lote. No modo incremental, o gradiente é calculado e os pesos são atualizados após cada

entrada ser aplicada à rede. No modo de lote, todos os insumos (todas as entradas) são aplicados à rede antes dos pesos serem atualizados [9-12].

2.6. Passos para o desenvolvimento das aplicações utilizando RNA's.

1 e 2. Coleta de dados e separação em conjuntos:

Os dois primeiros passos do processo de desenvolvimento de redes neurais artificiais são a coleta de dados relativos ao problema e a sua separação em um conjunto de treinamento, um conjunto de validação e outro de testes. Os quais serão utilizados para verificar o desempenho da rede sob condições reais de utilização.

Esta tarefa exige uma análise cuidadosa sobre o problema para minimizar ambiguidades e erros nos dados. Além disso, os dados coletados devem ser significativos e cobrir amplamente o domínio do problema, no entanto, não devem cobrir apenas as operações normais ou rotineiras, mas também as exceções e as condições nos limites do domínio do problema.

Uma subdivisão do conjunto de treinamento será utilizada como conjunto de validação, para verificar a eficiência da rede quanto à sua capacidade de generalização durante o treinamento e podendo ser empregada como critério de parada do treinamento. Estes conjuntos são geralmente colocados em ordem aleatória para prevenção de tendências associadas à ordem de apresentação dos dados.

Pode-se pré-processar estes dados através de normalizações, escalonamentos e conversões de formato para torná-los mais apropriados à sua utilização na rede.

3. Configuração da rede

A definição da configuração da rede pode ser dividida em três etapas [6]:

- I. Escolha do paradigma neural apropriado à aplicação.
- II. Topologia da rede a ser utilizada - o número de camadas, o número de unidades em cada camada, etc.
- III. Determinação de parâmetros do algoritmo de treinamento e funções de ativação. Este passo tem um grande impacto no desempenho do sistema resultante.

Existem metodologias, "dicas" e "truques" na condução destas tarefas. Normalmente estas escolhas são feitas de forma empírica. A definição da configuração de redes neurais é ainda considerada uma arte, que requer grande experiência dos projetistas [9,13].

4. Treinamento

Nesta etapa, após a escolha do algoritmo de treinamento, serão ajustados os pesos das conexões. Dando importância a aspectos como a inicialização da rede, o modo de treinamento e o tempo de treinamento. Fazer uma boa escolha dos valores iniciais dos pesos da rede pode diminuir o tempo necessário para o treinamento. Geralmente, os valores iniciais dos pesos da rede são números aleatórios uniformemente distribuídos em um intervalo definido. A escolha errada destes pesos pode levar a uma saturação prematura.

Uma eficiência dos modos de treinamento depende do problema que está sendo tratado. Quanto ao tempo de treinamento, vários fatores podem influenciar a sua duração, porém sempre será necessário utilizar algum critério de parada. O critério de parada do algoritmo *Backpropagation* não é bem definido, e geralmente é utilizado um número máximo de ciclos (épocas). Mas, pode-se considerar a taxa de erro médio por ciclo e a capacidade de generalização da rede.

Pode ocorrer o problema de *over-training*, ou seja, a rede se especializa no conjunto de dados do treinamento e perde a capacidade de generalização, então o treinamento deve ser interrompido quando a rede apresentar uma boa capacidade de generalização e quando a taxa de erro for suficientemente pequena, ou seja, menor que um erro admissível. Assim, deve-se encontrar um ponto ótimo de parada com erro mínimo e capacidade de generalização máxima.

5. Teste

O conjunto de teste é utilizado para determinar o desempenho da rede com dados que não foram previamente utilizados, mas que fazem parte do domínio de treinamento. O desempenho da rede, medido nesta etapa, é uma boa indicação de seu desempenho real. São considerados ainda outros testes como análise do comportamento da rede, utilizando entradas especiais e análise dos pesos atuais da rede, pois se existirem valores muito pequenos as conexões associadas podem ser consideradas insignificantes e assim serem eliminadas (*prunning*). De modo inverso, valores substantivamente maiores que os outros poderiam indicar que houve *over-training* da rede.

6. Integração

Nesta fase, a rede treinada e avaliada pode ser integrada em um sistema do ambiente operacional da aplicação. Para maior facilidade de utilização e eficiência da solução, devem conter neste sistema interfaces convenientes e de aquisição de dados através de planilhas eletrônicas, interfaces com unidades de processamento de sinais e arquivos padronizados. Melhorias poderão ainda ser sugeridas quando os usuários forem se tornando mais familiares com o sistema, estas sugestões poderão ser muito úteis em novas versões.

2.7. *Levenberg-Marquardt* (LM):

O método *Levenberg-Marquardt* utiliza treinamento em lote e consiste em um aperfeiçoamento do método *Gauss-Newton*, que é uma variante do método de *Newton*. O método de *Newton* usa a informação da derivada parcial de segunda ordem do índice de desempenho utilizado para corrigir os pesos w . Isso permite que além da informação do gradiente ∇ seja usada informação sobre a curvatura da superfície do erro [14].

Esse algoritmo é mais eficiente do que o algoritmo de retropropagação padrão e suas variantes. Enquanto o algoritmo de retropropagação do erro padrão utiliza a descida de gradiente como método de aproximação do mínimo da função de erro, o

algoritmo de *Levenberg-Maquardt* utiliza uma aproximação pelo método de *Newton*. Quando está longe da convergência, o método LM comporta-se como um método de descida mais íngreme, ou seja, retarda, mas é garantida a convergência. Caso contrário, comporta-se como método do *Gauss-Newton* [8,12,15].

O método LM na prática tem características de convergência global (converge para o mínimo local a partir de qualquer valor aproximado).

O treinamento da rede por este método ocorre por iterações. Essas iterações consistem em aplicar todos os dados de entrada de treinamento na rede, verificar o erro entre a saída obtida e a saída desejada para cada um destes conjuntos e ajustar os pesos das conexões para diminuir o erro médio (MSE) encontrado. Isso evita que, ao ajustar a rede para uma entrada, aumentem os erros das outras.

Assim como os métodos *Quasi-Newton*, o algoritmo *Levenberg-Marquardt* foi projetado para uma abordagem de segunda ordem da velocidade de formação, sem ter que calcular a matriz Hessiana. Quando a função de desempenho tem a forma de uma soma de quadrados (como é típico na formação de redes *feedforward*) [12], então a Hessiana pode ser aproximada:

$$H = J^T J \quad (2.3)$$

e o gradiente pode ser calculado como:

$$g = eJ^T \quad (2.4)$$

onde J é a matriz Jacobiana, que contém a primeira derivada de erros da rede com relação aos pesos e e é um vetor de erros da rede. A matriz Jacobiana pode ser calculada através de uma norma técnica de retropropagação [12], que é muito menos complexa do que computar matriz Hessiana. O algoritmo de *Levenberg-Marquardt* utiliza essa aproximação com a Hessiana como a atualização de *Newton*:

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (2.5)$$

Quando o escalar μ é zero, ele é apenas o método de *Newton*, usando a aproximação da matriz Hessiana. Quando μ é grande, torna-se gradiente descendente com um pequeno passo. O método de *Newton* é mais rápido e preciso nas imediações de um erro mínimo, de modo que o objetivo é mudar para o método de *Newton* o mais rápido possível. Assim, μ é reduzido após cada etapa bem sucedida (redução no desempenho função) e é aumentado somente quando um passo aumentaria o desempenho da função. Desta forma, a função de desempenho é sempre reduzida a cada iteração do algoritmo. Este algoritmo parece ser o método mais rápido para a formação de redes neurais com tamanho moderado (até algumas centenas de pesos). Tem também uma eficiente implementação no *software* MATLAB®, porque a solução da equação matricial é uma função interna, portanto seus atributos tornam-se ainda melhores neste ambiente computacional.

A principal desvantagem do algoritmo *Levenberg-Marquardt* é que ele requer o armazenamento de algumas matrizes que podem ser muito grandes para determinados problemas [14,15]. Logo pode ser utilizada uma redução de memória, subdividindo a

matriz jacobiana em duas submatrizes de mesma dimensão, podendo ser calculada a matriz Hessiana aproximada da seguinte forma:

$$H_{n \times n} = J_{n \times m}^T J_{m \times n} = \begin{bmatrix} J_1^T & J_2^T \end{bmatrix}_{n \times m} \begin{bmatrix} J_1 \\ \cdots \\ J_2 \end{bmatrix}_{m \times n} = \begin{bmatrix} J_1^T J_1 + J_2^T J_2 \end{bmatrix}_{n \times n} \quad (2.6)$$

Onde, $J_1^T = J_{n \times k}^T$

$$J_2^T = J_{n \times (m-k)}^T$$

$$J_1 = J_{k \times n}$$

$$J_2 = J_{(m-k) \times n}$$

Portanto, o Jacobiano completo não tem que existir de uma vez. Pode-se calcular a Hessiana aproximada pela soma de uma série de subtermos. Uma vez que um subtermo foi calculado, a submatriz correspondente do Jacobiano pode ser apagada.

Quando se utiliza LM como função de treinamento de redes neurais no MATLAB®, o parâmetro *mem_reduc* determina quantas linhas do Jacobiano são calculadas em cada submatriz. Se *mem_reduc* é definido como 1, então o Jacobiano completo é calculado, não acontecendo a redução de memória. Se *mem_reduc* está definido como 2, então apenas metade do Jacobiano é calculado. Isto economiza metade da memória usada pelo cálculo do Jacobiano completo.

Existe uma desvantagem em utilizar a redução de memória. Pode acontecer uma sobrecarga computacional significativa associada com o cálculo do Jacobiano em submatrizes. Se houver memória suficiente disponível, então é melhor definir *mem_reduc* como 1 e calcular o Jacobiano completo. Se o conjunto de treinamento for muito grande, e estiver com memória insuficiente, então deve-se definir *mem_reduc* como 2 e tentar novamente. Continuando ainda sem memória, aumenta-se o *mem_reduc*.

Porém, mesmo se for utilizada a redução da memória, o algoritmo *Levenberg-Marquardt* sempre irá calcular a matriz Hessiana aproximada que tem dimensões $\mathbf{n} \times \mathbf{n}$. Se a rede é muito grande, então pode-se executar fora de memória. Se este for o caso, utiliza-se um dos algoritmos de gradiente conjugado.

2.7.1. Comparação de velocidade e memória

É muito difícil saber qual algoritmo de treinamento será mais rápido para um determinado problema. Depende de muitos fatores, incluindo a complexidade do problema, o número de pontos obtidos no conjunto de treinamento, o número de pesos e *bias* na rede, a meta de erro, e se a rede está sendo utilizada para reconhecimento de padrões (análise discriminante) ou aproximação de funções (regressão). Será mostrada a comparação dos vários algoritmos de treinamento de

redes neurais disponíveis na ferramenta de simulação do *software* MATLAB® num problema envolvendo um conjunto de dados de uma função seno.

O conjunto de dados é um problema simples de aproximação da função. A rede foi configurada com um neurônio na primeira camada intermediária, cinco na segunda e um neurônio na camada de saída, com funções de transferência tangente hiperbólica nas camadas escondidas (ou intermediárias) e função de transferência linear na camada de saída. O objetivo é aproximar um único período de uma onda senoidal. A Tabela 2.1, lista os algoritmos que são testados e as siglas utilizadas para identificá-los.

Tabela 2.1. Algoritmos de treinamento

SIGLA	ALGORITMO
LM	<i>Levenberg-Marquardt</i>
BFG	<i>BFGS Quasi-Newton</i>
RP	<i>Resilient Backpropagation</i>
SCG	<i>Scaled Conjugate Gradient</i>
CGB	<i>Conjugate Gradient with Powell/Beale Restarts</i>
CGF	<i>Fletcher-Powell Conjugate Gradient</i>
CGP	<i>Polak-Ribière Conjugate Gradient</i>
OSS	<i>One Step Secant</i>
GDX	Variable Learning Rate Backpropagation

A Tabela 2.2, resume os resultados da formação da rede por meio de nove algoritmos de treinamento diferentes. Cada entrada na tabela representa 30 ensaios diferentes, onde diferentes pesos iniciais aleatórios são usados em cada ensaio. Em cada caso, a rede é treinada até que o erro quadrático seja menor que 0,002. O algoritmo mais rápido para este problema é o algoritmo de *Levenberg-Marquardt*. Mais rápido em média e quatro vezes mais rápido que o próximo algoritmo. Este é o tipo de problema para o qual o algoritmo LM é o mais adequado, um problema de aproximação de funções onde a rede tem menos de cem pesos e a aproximação deve ser muito precisa.

O desempenho dos algoritmos pode ser afetado pela precisão necessária à aproximação. Isso pode ser observado na Figura 2.5, que representa o erro médio quadrático em função do tempo de execução (em média 30 ensaios) para vários algoritmos. Pode-se notar que o erro no algoritmo LM diminui muito mais rapidamente com o tempo que os outros algoritmos apresentados.

A Figura 2.5 apresenta o comportamento dos algoritmos em relação ao tempo necessário para convergir em função da meta de convergência do erro médio quadrático. Aqui é possível ver como o objetivo de erro é reduzido, o ganho proporcionado pelo algoritmo LM torna-se mais pronunciado. Os algoritmos de melhor desempenho em que a meta de erro é reduzida são LM e BFG, outros algoritmos em que o objetivo de erro é reduzido são OSS e GDX.

Tabela 2.2. Resultados de formação da rede

ALGORITMO	TEMPO MÉDIO (s)	RAZÃO	TEMPO Min.(s)	TEMPO Máx.(s)
LM	1,14	1,0	0,65	1,83
BFG	5,22	4,58	3,17	14,38
RP	5,67	4,97	2,66	17,24
SCG	6,09	5,34	3,18	23,64
CGB	6,61	5,80	2,99	23,65
CGF	7,86	6,89	3,57	31,23
CGP	8,24	7,23	4,07	32,32
OSS	9,64	8,46	3,97	59,63
GDX	27,69	24,29	17,21	258,15

A relação entre os algoritmos é ilustrada na Figura 2.6, que relaciona o tempo necessário para convergir em relação ao objetivo de convergência do erro médio quadrático. Pode ser observado que quando o erro desejado é reduzido, o ganho proporcionado pelo algoritmo LM é mais evidente. Dessa forma, os algoritmos de melhor desempenho quando o erro é reduzido são o LM e BFG, e os que degradam são o OSS e GDX.




Figura 2.5. Tempo de convergência versus erro médio quadrático pretendido




Figura 2.6. Tempo de convergência versus Convergência do erro

Conclusão do Capítulo

Aqui, foi apresentada a teoria de redes neurais artificiais bem como a sua utilização em outras áreas de conhecimento e suas arquiteturas. Foi realizada uma comparação entre os algoritmos de treinamentos existentes na ferramenta computacional a ser utilizada visando a escolha do algoritmo mais eficiente para o nosso problema.

Capítulo 3

3. Acopladores Direcionais

Neste capítulo apresenta-se a teoria dos acopladores direcionais planares e à fibra e suas expressões aproximadas que permitem calcular a distância de acoplamento dos mesmos.

Acoplamento direcional é um fenômeno de troca de energia entre ondas eletromagnéticas que se propagam em diferentes estruturas de guiamento [7]. O dispositivo que resulta da disposição destas estruturas de guiamento com o objetivo de controlar a troca de energia denomina-se acoplador direcional. Seja para a aquisição de amostras ou para a divisão de sinais, o acoplador é um dispositivo fundamental em qualquer circuito óptico.

Acopladores direcionais são estruturas básicas importantes no projeto de dispositivos fotônicos e circuitos como filtros, dispositivos multiplexadores e demultiplexadores. É um dispositivo óptico que consiste em dois guias de onda dielétricos paralelos muito próximos, Figura 3.1.




Figura 3.1. (a) e (b) Acoplador Planar (2D) com guias de sílica/silício e $\text{Al}_x\text{Ga}_{1-x}\text{As}$, respectivamente; (c) Acoplador baseado em Fibras Ópticas.

O comportamento do acoplador pode ser interpretado (e, em muitos casos, essa é a análise possível) como o resultado da interação dos campos evanescentes dos “modos” próprios dos guias, isto é, como o resultado do acoplamento entre os modos dos guias isolados. De uma forma simples, pode-se considerar que a propagação no guia 1 é perturbada pela presença do guia 2, e vice-versa. Uma consequência da perturbação é a troca periódica de energia entre os guias ao longo da propagação.

A potência de entrada aparecerá nas saídas do acoplador e a fração de potência em cada porta dependerá dos parâmetros ópticos e geométricos de cada acoplador.

Para isso, dois ou mais guias de ondas devem estar suficientemente próximos de forma a permitir que o campo evanescente do modo em um dos guias “enxergue” o núcleo do guia de onda adjacente. Quando os modos dos guias acoplados exibem a mesma velocidade de fase, a interação ressonante acontece e a transferência total de energia ocorre Figura 3.2 [16].




Figura 3.2. Sistema de dois guias de onda dielétricos paralelos muito próximos, com mesmas constantes de propagação [17]

A fabricação de acopladores ópticos se dá por meio do crescimento, ou deposição de materiais com índices de refração diferentes de forma a construir uma estrutura multicamada. Em alguns casos, e com o uso de algumas aproximações, existem soluções analíticas aproximadas [17,18].

O acoplador pode ser aproximado por uma estrutura em duas dimensões, formada por dois guias planares paralelos com largura w e afastamento d , onde a potência nas duas portas de saída obedece a seguinte relação:

$$P_1 = P_{in} \cos^2(C \cdot z) \quad (3.1)$$

$$P_2 = P_{in} \sin^2(C \cdot z) \quad (3.2)$$

Onde P_1 e P_2 são as potências nas portas de saída, P_{in} é a potência na porta de entrada, C é o fator de acoplamento e z a distância medida desde a porta de entrada.




Figura 3.3. Variação da potência nos guias em função da distância propagada

Assim, à distância em que a potência é transferida totalmente para o outro guia é quando $C.z = \pi/2$, Figura 3.3. Consequentemente, à distância de acoplamento será:

$$L_c = \frac{\pi}{2C} \quad (3.3)$$

Onde o fator de acoplamento C varia de acordo com o modelo do acoplador a ser utilizado.

A abordagem formal para estudar a propagação da luz neste tipo de estrutura é feita escrevendo as equações de *Maxwell* para as diferentes regiões e usar as condições de contorno para determinar os modos do sistema em geral. Estes modos são diferentes em cada um dos guias isoladamente.

3.1. Teoria dos Modos Acoplados

A teoria dos modos acoplados baseia-se na interação mútua entre duas ondas copropagantes em guias de onda adjacentes [18,19]. O acoplamento também pode acontecer entre duas ondas contrapropagantes presentes em dois guias corrugados, mas essa aplicação não será abordada nesse trabalho.

Ao aproximar dois guias de onda, Figura 3.4, os modos propagantes de cada guia vão interferir entre si. Quando as distribuições de campo, após o acoplamento, não diferem das distribuições anteriores as características da propagação do modo acoplado pode-se analisá-las através do método da perturbação [18].




Figura 3.4. Acoplador com Guias de Onda Retangulares

Quando se considera os modos próprios em cada guia de onda óptico, o modo de acoplamento de $\tilde{E}_p$, $\tilde{H}_p$ ($p=1,2$), devem satisfazer as seguintes equações de Maxwell [9]:

$$\nabla \times \tilde{E}_p = -j\omega\mu_0\tilde{H}_p \quad (3.4a)$$

$$\nabla \times \tilde{H}_p = j\omega\epsilon_0 N^2 \tilde{E}_p \quad (3.4b)$$

onde $N_p^2(x,y)$ representa a distribuição do índice de refração de cada guia de onda.

Assume-se que os campos eletromagnéticos dos guias de onda acoplados podem ser expressos como a soma dos modos próprios em cada guia de onda:

$$\tilde{E} = A(z)\tilde{E}_1 + B(z)\tilde{E}_2 \quad (3.5a)$$

$$\tilde{H} = A(z)\tilde{H}_1 + B(z)\tilde{H}_2 \quad (3.5b)$$

Os campos eletromagnéticos nos guias de onda acoplados $\tilde{E}$ e $\tilde{H}$ também devem satisfazer as equações de Maxwell. Então, substituindo as Equações (3.5a) e (3.5b) em

$$\nabla \times \tilde{E} = -j\omega\mu_0\tilde{H} \quad (3.6a)$$

$$\nabla \times \tilde{H} = j\omega\epsilon_0 N^2 \tilde{E} \quad (3.6b)$$

e usando as Eq. (3.4a) e (3.4b), e a fórmula de vetores [18]

$$\nabla \times (A\tilde{E}) = A\nabla \times \tilde{E} + \nabla A \times \tilde{E} = A\nabla \times \tilde{E} + \frac{dA}{dz} \mathbf{u}_z \times \tilde{E}$$

obtém-se as seguintes relações:

$$\left(u_z \times \tilde{E}_1\right) \frac{dA}{dz} + \left(u_z \times \tilde{E}_2\right) \frac{dB}{dz} = 0 \quad (3.7)$$

$$\begin{aligned} & \left(u_z \times \tilde{H}_1\right) \frac{dA}{dz} - j\omega\epsilon_0 \left(N^2 - N_1^2\right) A \tilde{E}_1 \\ & + \left(u_z \times \tilde{H}_2\right) \frac{dB}{dz} - j\omega\epsilon_0 \left(N^2 - N_2^2\right) B \tilde{E}_2 = 0 \end{aligned} \quad (3.8)$$

Aqui, $N^2(x, y)$ denota a distribuição do índice de refração em todo o guia de onda acoplado. Substituindo as Equações (3.7) e (3.8) nas integrais:

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \left[\tilde{E}_1^* \cdot \left(\left(u_z \times \tilde{H}_1\right) \frac{dA}{dz} - j\omega\epsilon_0 \left(N^2 - N_1^2\right) A \tilde{E}_1 + \left(u_z \times \tilde{H}_2\right) \frac{dB}{dz} - j\omega\epsilon_0 \left(N^2 - N_2^2\right) B \tilde{E}_2 \right) \right. \\ \left. - \tilde{H}_1^* \cdot \left(\left(u_z \times \tilde{E}_1\right) \frac{dA}{dz} + \left(u_z \times \tilde{E}_2\right) \frac{dB}{dz} \right) \right] dx dy = 0 \quad (3.9)$$

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \left[\tilde{E}_2^* \cdot \left(\left(u_z \times \tilde{H}_1\right) \frac{dA}{dz} - j\omega\epsilon_0 \left(N^2 - N_1^2\right) A \tilde{E}_1 + \left(u_z \times \tilde{H}_2\right) \frac{dB}{dz} - j\omega\epsilon_0 \left(N^2 - N_2^2\right) B \tilde{E}_2 \right) \right. \\ \left. - \tilde{H}_2^* \cdot \left(\left(u_z \times \tilde{E}_1\right) \frac{dA}{dz} + \left(u_z \times \tilde{E}_2\right) \frac{dB}{dz} \right) \right] dx dy = 0 \quad (3.10)$$

O termo na Equação (3.9) a ser integrada pode ser expresso como

$$\begin{aligned} I_1 = & \tilde{E}_1^* \cdot (3.8) - \tilde{H}_1^* \cdot (3.7) = \frac{dA}{dz} \left[\tilde{E}_1^* \cdot \left(u_z \times \tilde{H}_1\right) - \tilde{H}_1^* \cdot \left(u_z \times \tilde{E}_1\right) \right] \\ & + \frac{dB}{dz} \left[\tilde{E}_1^* \cdot \left(u_z \times \tilde{H}_2\right) - \tilde{H}_1^* \cdot \left(u_z \times \tilde{E}_2\right) \right] - j\omega\epsilon_0 A \left(N^2 - N_1^2\right) \tilde{E}_1^* \cdot \tilde{E}_1 \\ & - j\omega\epsilon_0 B \left(N^2 - N_2^2\right) \tilde{E}_1^* \cdot \tilde{E}_2 \end{aligned} \quad (3.11)$$

e usa-se as seguintes fórmulas vetoriais:

$$\tilde{E}_1^* \cdot \left(u_z \times \tilde{H}_1\right) = -u_z \cdot \left(\tilde{E}_1^* \times \tilde{H}_1\right) \quad (3.12a)$$

$$\tilde{H}_1^* \cdot \left(u_z \times \tilde{E}_1\right) = u_z \cdot \left(\tilde{E}_1 \times \tilde{H}_1^*\right) \quad (3.12b)$$

Então a Equação (3.11) pode ser reescrita como

$$\begin{aligned} I_1 = & -\frac{dA}{dz} \left[\tilde{E}_1^* \times \tilde{H}_1 + \tilde{E}_1 \times \tilde{H}_1^* \right] - \frac{dB}{dz} u_z \cdot \left[\tilde{E}_1^* \times \tilde{H}_2 + \tilde{E}_2 \times \tilde{H}_1^* \right] \\ & - j\omega\epsilon_0 A \left(N^2 - N_1^2\right) \tilde{E}_1^* \cdot \tilde{E}_1 - j\omega\epsilon_0 B \left(N^2 - N_2^2\right) \tilde{E}_1^* \cdot \tilde{E}_2 \end{aligned} \quad (3.13)$$

De maneira análoga, o termo da Equação (3.10) a ser integrada é expresso como:

$$\begin{aligned}
I_2 = \tilde{E}_2^* \cdot (4.5) - \tilde{H}_2^* \cdot (4.4) = -\frac{dA}{dz} u_z \left[\tilde{E}_2^* \times \tilde{H}_1 + \tilde{E}_1 \times \tilde{H}_2^* \right] \\
-\frac{dB}{dz} u_z \left[\tilde{E}_2^* \times \tilde{H}_2 + \tilde{E}_2 \times \tilde{H}_2^* \right] - j\omega\epsilon_0 A (N^2 - N_1^2) \tilde{E}_2^* \cdot \tilde{E}_1 - j\omega\epsilon_0 B (N^2 - N_2^2) \tilde{E}_2^* \cdot \tilde{E}_2
\end{aligned} \tag{3.14}$$

Obtêm-se então,

$$\begin{aligned}
\frac{dA}{dz} + \frac{dB}{dz} \frac{\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u_z \cdot (\tilde{E}_1^* \times \tilde{H}_2 + \tilde{E}_2 \times \tilde{H}_1^*) dx dy}{\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u_z \cdot (\tilde{E}_1^* \times \tilde{H}_1 + \tilde{E}_1 \times \tilde{H}_1^*) dx dy} + jA \frac{\omega\epsilon_0 \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u_z \cdot (N^2 - N_1^2) \tilde{E}_1^* \cdot \tilde{E}_1 dx dy}{\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u_z \cdot (\tilde{E}_1^* \times \tilde{H}_1 + \tilde{E}_1 \times \tilde{H}_1^*) dx dy} \\
+ jB \frac{\omega\epsilon_0 \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u_z \cdot (N^2 - N_2^2) \tilde{E}_1^* \cdot \tilde{E}_2 dx dy}{\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u_z \cdot (\tilde{E}_1^* \times \tilde{H}_1 + \tilde{E}_1 \times \tilde{H}_1^*) dx dy} = 0
\end{aligned} \tag{3.15a}$$

$$\begin{aligned}
\frac{dB}{dz} + \frac{dA}{dz} \frac{\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u_z \cdot (\tilde{E}_2^* \times \tilde{H}_1 + \tilde{E}_1 \times \tilde{H}_2^*) dx dy}{\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u_z \cdot (\tilde{E}_2^* \times \tilde{H}_2 + \tilde{E}_2 \times \tilde{H}_2^*) dx dy} + jA \frac{\omega\epsilon_0 \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u_z \cdot (N^2 - N_1^2) \tilde{E}_2^* \cdot \tilde{E}_1 dx dy}{\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u_z \cdot (\tilde{E}_2^* \times \tilde{H}_2 + \tilde{E}_2 \times \tilde{H}_2^*) dx dy} \\
+ jB \frac{\omega\epsilon_0 \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u_z \cdot (N^2 - N_2^2) \tilde{E}_2^* \cdot \tilde{E}_2 dx dy}{\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} u_z \cdot (\tilde{E}_2^* \times \tilde{H}_2 + \tilde{E}_2 \times \tilde{H}_2^*) dx dy} = 0
\end{aligned} \tag{3.15b}$$

Separaram-se as dependências transversais e longitudinais dos campos eletromagnéticos:

$$\begin{cases} \tilde{E}_p = E_p \exp(-j\beta_p z) \\ \tilde{H}_p = H_p \exp(-j\beta_p z) \end{cases} \tag{3.16}$$

Substituindo as Equações (3.16) nas Equações (3.15a) e (3.15b), obtém-se as seguintes relações:

$$\frac{dA}{dz} + c_{12} \frac{dB}{dz} \exp[-j(\beta_2 - \beta_1)z] \tag{3.17a}$$

$$+ jx_1 A + jk_{12} B \exp[-j(\beta_2 - \beta_1)z] = 0$$

$$\frac{dB}{dz} + c_{21} \frac{dA}{dz} \exp[+j(\beta_2 - \beta_1)z] \tag{3.17b}$$

$$+ jx_2 A + jk_{21} A \exp[+j(\beta_2 - \beta_1)z] = 0$$

onde

$$k_{pq} = \frac{\omega \varepsilon_0 \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (N^2 - N_q^2) E_p^* \cdot E_q dx dy}{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} u_z \cdot (E_p^* \times H_p + E_p \times H_p^*) dx dy} \quad (3.18)$$

$$c_{pq} = \frac{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} u_z \cdot (E_p^* \times H_q + E_q \times H_p^*) dx dy}{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} u_z \cdot (E_p^* \times H_p + E_p \times H_p^*) dx dy} \quad (3.19)$$

$$x_p = \frac{\omega \varepsilon_0 \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (N^2 - N_p^2) E_p^* \cdot E_p dx dy}{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} u_z \cdot (E_p^* \times H_p + E_p \times H_p^*) dx dy} \quad (3.20)$$

e o par p e q são $(p, q) = (1, 2)$ ou $(2, 1)$, respectivamente k_{pq} é um coeficiente de acoplamento do acoplador direcional. O significado do c_{pq} é descrito como segue. Vamos considerar as configurações de guia de ondas, Figura 3.5, onde o guia de ondas I existe apenas na região $z < 0$ e o guia de ondas II em $z \geq 0$. Quando os modos próprios (E_1, H_1) do guia de ondas I se propagam a partir da direção negativa z para $z = 0$, o campo eletromagnético no revestimento excita os modos próprios (E_2, H_2) no ponto $z = 0$. Esta eficiência de excitação é considerada como c_{12} . Portanto, c_{pq} representa o coeficiente de acoplamento da extremidade entre os dois guias de ondas [18]. Em seguida, compara-se a magnitude de k_{pq} e x_{pq} para o caso de $p = 1$ e $q = 2$. Como pode ser observado na Figura 3.6(c), o valor real de $(N^2 - N_2^2)$ no guia de ondas I é igual a $(n_1^2 - n_0^2)$ e zero em todas as outras regiões. Então, a integral de k_{12} é realizada apenas no interior da região central de guia de ondas I. O campo elétrico E_2 no interior de guia de ondas I (denota-se como $|E_2| = \eta |E_1|$) é muito pequeno quando comparado a E_1 .




Figura 3.5. Explicação do coeficiente de acoplamento C_{12} nas extremidades dos guias I e II.

Então, a magnitude do termo integral de k_{12} no numerador trata-se de $(n_1^2 - n_0^2)\eta$. A integral de X_1 na Equação (3.20) é realizada fora do guia de ondas II, onde $(N^2 - N_1^2)$ não é zero. A magnitude do termo integral de X_1 no numerador trata-se de $(n_1^2 - n_0^2)\eta^2$, uma vez que a intensidade do campo elétrico E_1 no guia II é sobre η . Com base nas comparações apresentadas, sabe-se que x_p é η vezes menor do que k_{pq} . Assim, x_p pode ser negligenciado quando dois guias de ondas são suficientemente separados e $\eta \ll 1$, uma vez que x_p é muito menor do que k_{pq} . Ao contrário, x_p não pode ser negligenciado quando dois guias estão próximos uns dos outros. Na maioria das análises convencionais de acopladores direcionais, C_{pq} e x_p são negligenciados e assumidos como $C_{pq} = x_p = 0$. No entanto, ambos C_{pq} e x_p são levados em conta para analisar o efeito de acoplamento de modo estrito.




Figura 3.6. Distribuição do índice de refração $N^2(x, y)$ dos guias de onda acoplados, a diferença da distribuição do índice de refração $N^2 - N_p^2$ e o campo elétrico E_p que aparecem nas Equações (3.18) e (3.20).

3.1.1. Métodos Analíticos

3.1.1.1. Guia de Onda Dielétrico

Para o acoplador direcional, formado por dois guias de onda dielétricos paralelos, usaremos como base a equação do coeficiente de acoplamento dado pela Equação (3.18), apenas para o modo TE [18]:

$$k_{12} = C = \frac{\omega \varepsilon_0 \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (N^2 - N_2^2) E_1^* \cdot E_2 dx}{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} u_z \cdot (E_1^* \times H_1 + E_1 \times H_1^*) dx} \quad (3.21)$$

As componentes do campo eletromagnético do modo TE são expressas como $E_x = H_y = 0$ e $H_x = -(\beta/\omega\mu_0)E_y$. Portanto, têm-se as seguintes igualdades:

$$u_z \cdot (E_1^* \times H_1 + E_1 \times H_1^*) = \frac{2\beta}{\omega\mu_0} |E_{1y}|^2 \quad (3.22a)$$

$$E_1^* \cdot E_2 = E_{1y}^* \cdot E_{2y} \quad (3.22b)$$




Figura 3.7. Perfil dos índices de refração no acoplador baseado em guias de onda planares.

Como fora do guia, a diferença $(N^2 - N_2^2)$ é nula, a integração deve ser feita apenas dentro do guia. Substituindo as Equações (3.22a) e (3.22b) na equação do coeficiente de acoplamento, encontra-se:

$$C = \frac{\omega \varepsilon_0 (n_1^2 - n_0^2) \int_{-a}^a E_{1y}^* \cdot E_{2y} dx}{\frac{2\beta}{\omega \mu_0} \int_{-\infty}^{+\infty} |E_{1y}|^2 dx} \quad (3.23)$$

Nos guias dielétricos, os campos elétricos são dados por:

$$E_{1y} = \begin{cases} A \cdot \cos(k_{2x}x), |x| \leq a \\ A \cdot \cos(k_{2x}a) \cdot e^{[-\alpha_{2x}(|x|=a)]}, x > a \end{cases} \quad (3.24a)$$

$$E_{2y} = A \cdot \cos(k_{2x}a) \cdot e^{[\alpha_{2x}(x-D+a)]} \quad (3.24b)$$

Sabe-se das seguintes relações:

$$\beta = k_z \quad (3.25a)$$

$$\omega^2 \mu_0 \varepsilon_0 = k^2 = k_{2x}^2 + \alpha_{2x}^2 \quad (3.25b)$$

Usa-se a condição de guiamento do modo TE, dada por:

$$tg(k_{2x}) = \frac{\alpha_{2x}}{k_{2x}} \quad (3.26)$$

Aplicam-se essas relações e substituem-se as equações dos campos elétricos na equação do coeficiente de acoplamento, têm-se como resultado [18,19]:

$$C = \frac{\alpha_{2x} \cdot k_{2x}^2 \cdot e^{-\alpha_{2x}(D-2a)}}{k_z \cdot a \cdot \left(1 + \frac{1}{\alpha_{2x} \cdot a}\right) \cdot (k_{2x}^2 + \alpha_{2x}^2)} \quad (3.27)$$

3.1.1.2. Fibra Óptica

Para o acoplador baseado em fibra óptica, toma-se como base as Equações (3.28) (para $m = 0$ – modo fundamental) e (3.18):

$$\left[\frac{J'_m(k_x a)}{k_x J_m(k_x a)} + \frac{K'_m(\alpha_x a)}{\alpha_x K_m(\alpha_x a)} \right] + \left[\frac{J'_m(k_x a)}{k_x J_m(k_x a)} + \frac{n_2^2}{n_1^2} \frac{K'_m(\alpha_x a)}{\alpha_x K_m(\alpha_x a)} \right] = \frac{m^2}{a^2} \left(\frac{1}{k_x^2} + \frac{1}{\alpha_x^2} \right) \left(\frac{1}{k_x^2} + \frac{n_2^2}{n_1^2} \frac{1}{\alpha_x^2} \right) \quad (3.28)$$

além do desenvolvimento feito por [18]:

$$C = \frac{\sqrt{\Delta}}{a} \frac{u^2}{K_1^2(w)} \sqrt{\frac{\pi \cdot a}{w \cdot D}} \exp\left(-\frac{w}{a} D\right) \quad (3.29)$$




Figura 3.8. Perfil dos índices de refração no acoplador baseado em fibras ópticas.

Tendo em conta as seguintes relações:

$$\Delta = \frac{\sqrt{n_1^2 - n_0^2}}{n_0} \quad (3.30a)$$

$$u = k_x a \quad (3.30b)$$

$$v = a \sqrt{k_x^2 + \alpha_x^2} \quad (3.30c)$$

$$K_0(z) = \sqrt{\frac{\pi}{2z}} \exp(-z) \quad (3.30d)$$

Aplica-se as Equações (3.26) em (3.25) e têm-se:

$$C = \frac{k_x^2}{a^2(k_x^2 + \alpha_x^2)n_0k_0} \frac{K_0(\alpha_x D)}{K_1^2(\alpha_x a)} \quad (3.31)$$

3.2. Acopladores Direcionais Planares

3.2.1. Acopladores Direcionais Planares com Guias de Sílica e Silício

O acoplador direcional planar é constituído de duas placas paralelas, que são os guias de ondas, com uma pequena espessura w , separadas por um substrato através de um afastamento d , de forma que estejam suficientemente separadas, Figura 3.1 (a). Sua estrutura é formada por guias constituídos por silício (Si) e o substrato de sílica (SiO_2). É importante destacar que o coeficiente de acoplamento é determinado considerando o modo de propagação TE e que o acoplador analisado é relativamente

simétrico. Dessa forma, a expressão para o coeficiente de acoplamento é definida pela equação:

$$C = \frac{\omega \varepsilon_0 \int_{-\infty}^{+\infty} (N^2 - N_2^2) E_1^* \cdot E_2 dx}{\int_{-\infty}^{+\infty} u_z \cdot (E_1^* \times H_1 + E_1 \times H_1^*) dx} \quad (3.32)$$

Desenvolvendo a Equação (3.32), encontra-se a expressão analítica para o coeficiente de acoplamento:

$$C = \frac{\alpha_x \cdot k_x^2 \cdot e^{-\alpha_x \cdot d}}{k_z \cdot \left(\frac{w}{2}\right) \cdot \left(1 + \frac{2}{\alpha_x \cdot w}\right) \cdot (\alpha_x^2 + k_x^2)} \quad (3.33)$$

A expressão analítica, aproximada, usada para gerar os dados de treinamento, que fornece o valor da distância de acoplamento é dada por [2,18],

$$L_c = \frac{\pi \cdot k_z \cdot \left(\frac{w}{2}\right) \cdot \left(1 + \frac{2}{\alpha_x \cdot w}\right) \cdot (\alpha_x^2 + k_x^2)}{2 \cdot \alpha_x \cdot k_x^2 \cdot e^{-\alpha_x \cdot d}} \quad (3.34)$$

Onde, w é a largura do guia, d é o afastamento dos guias e α_x, k_x são parâmetros associados aos guias, os quais são obtidos resolvendo a equação transcendental:

$$\tan g(k_x d / 2) = \frac{\alpha_x}{k_x} \quad (3.35)$$

Onde $\alpha_x = k_0 \sqrt{n_{eff}^2 - n_1^2}$ e $k_x = k_0 \sqrt{n_2^2 - n_{eff}^2}$

Onde k_0 é o número de onda dado por $2\pi / \lambda$, n_1 é o índice de refração do substrato e n_2 é o índice de refração dos guias.

Os materiais considerados foram a sílica e o silício, cujos índices de refração são denominados de n_1 e n_2 , e os valores são determinados através das equações de *Sellmeier*,

para a Sílica (SiO_2) (n_1):

$$n(\lambda) = \sqrt{1 + \frac{0,6961663\lambda^2}{\lambda^2 - 0,0684043^2} + \frac{0,4079426\lambda^2}{\lambda^2 - 0,1162434^2} + \frac{0,8974794\lambda^2}{\lambda^2 - 9,896161^2}} \quad (3.36)$$

para o Silício (Si) (n_2):

$$n^2 = \varepsilon + \frac{A}{\lambda^2} + \frac{B\lambda^2}{(\lambda^2 - \lambda_1^2)} \quad (3.37)$$

onde $\lambda_1 = 1,1071\mu m$, $\varepsilon = 1,16858 \times 10^1$, $A = 9,39816 \times 10^1$ e $B = 8,10461 \times 10^{-3}$.

3.2.2. Acopladores Direcionais Planares com Guias de $Al_xGa_{1-x}As$

O $Al_xGa_{1-x}As$ é um material cujas perdas na propagação em guias simples possuem valores relativamente baixos, em torno de 0.2 dB/cm, o que atestando a aplicabilidade do uso desta liga metálica em guias acoplados.

Além disso, o índice de refração varia com a fração de alumínio presente na liga e com o comprimento de onda incidente no material.

Dessa forma, o guia é formado por uma liga com uma fração x de alumínio, resultando num índice de refração n_2 , enquanto que o substrato é formado pela mesma liga metálica, porém com outra fração y de alumínio, resultando num índice de refração n_1 .

Com isso, pode-se representar com a Figura 3.1(b), o acoplador em que os guias e o substrato são formados por essa liga metálica.

Assim, é preciso saber como ocorre a variação do índice de refração dessa liga metálica com o comprimento de onda e com fração de alumínio na liga.

A parte real do índice de refração n do $Al_xGa_{1-x}As$ pode ser expresso por um modelo simplificado, para uma temperatura de 300K, Equação (3.38) [20].

$$n(\lambda) = \sqrt{A_0 \left[f(\chi) + \frac{f(\chi_{so})}{2} \left(\frac{E_0}{E_0 + \Delta_0} \right)^{3/2} \right] + B_0} \quad (3.38)$$

Sendo que, $f(\chi) = \frac{2 - \sqrt{1+\chi} - \sqrt{1-\chi}}{\chi^2}$, $\chi = \frac{hc}{\lambda E_0}$ e $\chi_{so} = \frac{hc}{\lambda(E_0 + \Delta_0)}$ $A_0 = 6,3 + 19,0x$ e

$B_0 = 9,4 - 10,2x$ são constantes, x é a fração de alumínio presente na liga metálica de $Al_xGa_{1-x}As$, $E_0 = 1,425 + 1,155x + 0,37x^2$ representa a *Fundamental Energy Band Gap at -point* em eletrovolts (eV), $E_0 + \Delta_0 = 1,765 + 1,115x + 0,37x^2$ é a soma da *Fundamental Energy Band Gap* mais a *Spin-Orbit Splitting Energy* em eletrovolts (eV) representada por Δ_0 , $c = 2,998 \times 10^8 m/s$ é a velocidade da luz no vácuo e $h = 4,1356179 \times 10^{-15} eV.s$ é a constante de *Planck* [20].

Com isso, pode-se obter o gráfico de variação do índice de refração da liga em função do comprimento de onda incidente para diferentes valores da fração de alumínio na liga, apresentado na Figura 3.9




Figura. 3.9. Variação do índice de refração do $\text{Al}_x\text{Ga}_{1-x}\text{As}$ em função do comprimento de onda e da fração de alumínio na liga metálica.

Após obter-se os valores dos índices de refração do $\text{Al}_x\text{Ga}_{1-x}\text{As}$ para o guia e substrato, pode-se calcular a distância de acoplamento através da Equação (3.34).

3.3. Acopladores Direcionais baseados em Fibras Ópticas

O acoplador direcional baseado em duas fibras ópticas, Figura 3.1(c), possui os núcleos, das duas fibras ópticas, fundidos sob o substrato, os quais estão muito próximos um do outro. Tendo em vista a proximidade dos núcleos, os modos fundamentais se propagam em cada um dos núcleos e se sobrepõem parcialmente na região entre os dois núcleos. Como foi dito anteriormente, a onda evanescente acoplada entre os dois núcleos pode ocasionar a transferência de potência óptica de um núcleo para o outro sob condições apropriadas.

Neste trabalho, consideram-se os guias de ondas constituídos de uma mistura de dióxido de silício com dióxido de germânio numa proporção de 86,5% e 13,5%, respectivamente, bem como um substrato formado por dióxido de silício (SiO_2). Também utiliza-se as equações de *Sellmeier* para determinar os valores dos índices de refração dos guias.

Da mesma forma como visto para o acoplador planar, define-se a seguinte expressão para o coeficiente de acoplamento:

$$C = \frac{\omega \epsilon_0 \int_{-\infty}^{+\infty} (N^2 - N_2^2) E_1^* \cdot E_2 dx}{\int_{-\infty}^{+\infty} u_z \cdot (E_1^* \times H_1 + E_1 \times H_1^*) dx} \quad (3.32)$$

Desenvolvendo a Equação (3.32), encontra-se a expressão analítica para o coeficiente de acoplamento:

$$C = \frac{\lambda \cdot U^2 \cdot K_0\left(W \cdot \frac{d}{a}\right)}{2 \cdot \pi \cdot a^2 \cdot n_1 \cdot V^2 \cdot K_1^2(W)} \quad (3.39)$$

Logo a expressão, utilizada para gerar os dados de treinamento, que fornece o valor da distância de acoplamento é dada por [2,18],

$$L_C = \frac{\pi \cdot a^2 \cdot n_1 \cdot V^2 \cdot K_1(W)}{2 \cdot \lambda \cdot U^2 \cdot K_0\left(W \cdot \frac{d}{a}\right)} \quad (3.40)$$

Onde, $W = ak_0(n_{\text{eff}}^2 - n_1^2)^{1/2}$, $U = ak_0(n_2^2 - n_{\text{eff}}^2)^{1/2}$, a é o raio das fibras, d é o afastamento entre as fibras, k_0 é o número de onda dado por $2\pi/\lambda$, λ é o comprimento de onda, n_1 e n_2 são os índices de refração dos guias e do substrato, respectivamente. K_0 e K_1 são funções de *Bessel*. A direção de propagação é no eixo z . A operação do acoplador é completamente caracterizada pelos modos normais da estrutura, quando conhecidos, e pelas condições de excitação. Um acoplador direcional constituído por guias monomodo semelhantes é uma estrutura com dois modos guiados, Figura 3.9.




Figura 3.10. Representação esquemática dos modos de um acoplador de dois guias uniformes.

Estão representados, Figura 3.10, o campo de entrada, os modos dos guias individuais e os modos da estrutura composta. Onde β_i representa a constante de propagação do modo próprio do guia isolado, e β_e e β_0 representam as constantes de propagação dos modos normais da estrutura.

$$\beta_0 = k_0 \cdot n_{\text{eff}1} \quad (3.41)$$

$$\beta_e = k_0 \cdot n_{\text{eff } 2} \quad (3.42)$$

O campo de entrada concentrado no guia 1 pode ser expresso como a soma (ou a diferença) dos modos guiados pela estrutura composta (modos compostos ou supermodos), desprezando os modos de radiação. Contudo a sobreposição dos dois modos próprios guiados da estrutura não representa, de forma exata, o campo de entrada usado para excitar um dos guias. Para se representar rigorosamente o campo de entrada é necessário incluir os modos de radiação; quando um dos guias é excitado, parte da energia de excitação é radiada.

A fase relativa dos modos da estrutura (que têm constantes de propagação β_e e β_0) altera-se ao longo da propagação no acoplador direcional [18]; assumindo os campos a eles associados em fase em $z=0$, após propagação na distância $z = L_c \equiv \frac{\pi}{\beta_e - \beta_0}$, os

campos estão em oposição de fase. Se, em $z=0$, o campo no acoplador é a soma (diferença) dos modos compostos, em

$z = \frac{\pi}{\beta_e - \beta_0}$ é a diferença (soma). A potência que inicialmente estava concentrada na

região do guia 1 (2) transferiu-se para a região do guia 2 (1), após propagação na distância L_c , chamada distância de acoplamento L_c (ou comprimento de transferência máxima de potência). O campo numa seção transversal do acoplador, $z = L_c$, é o resultado da interferência dos modos compostos.

Podem ser observados os supermodos, do acoplador baseado em fibras ópticas, nos gráficos com distribuição dos campos obtidos através do *software Surfer 8®*, Figuras 3.11 e 3.12.

Para as simulações analíticas (possui funções que descrevem os comportamentos) e numéricas (aproximam para uma função a partir do comportamento) realizadas foi utilizada uma fibra com núcleo de 13,5% de GeO_2 e 86,5% de SiO_2 , e casca de SiO_2 .

São adotados os índices efetivos dos dois primeiros supermodos para calcular a distância de acoplamento pela seguinte relação:

$$L_c = \frac{\lambda}{2(n_{\text{eff } 1} - n_{\text{eff } 2})} \quad (3.43)$$

onde n_1 e n_2 são os índices efetivos dos supermodos simétrico e assimétrico, respectivamente.




Figura 3.11. Supermodo simétrico: Distância entre centros = $5,65\mu\text{m}$; Raio das Fibras = $1,7\mu\text{m}$; Comprimento de Onda = $1,55\mu\text{m}$ [21]




Figura 3.12. Supermodo assimétrico: Distância entre centros = $5,65\mu\text{m}$; Raio das Fibras = $1,7\mu\text{m}$; Comprimento de Onda = $1,55\mu\text{m}$ [21]

Estes supermodos da estrutura são determinados, aproximadamente, em termos dos modos próprios dos guias individuais. A sua solução por técnicas numéricas aproximadas não é, muitas vezes, satisfatória, pois a quantidade de interesse, $\beta_e - \beta_0$, é a diferença de dois números quase igual, que pode tornar-se bastante imprecisa.

Contudo, conhecidos os modos dos dois guias isolados e a geometria do acoplador, é possível calcular $\beta_e - \beta_0$ muitas vezes com melhor precisão, aplicando a teoria de acoplamento de modos de um acoplador direcional.

Conclusão do Capítulo

Apresentou-se a teoria sobre acopladores direcionais com intuito de possibilitar o entendimento sobre o acoplador planar e o de fibra, quanto as suas estruturas, parâmetros e funcionamento. A teoria dos modos acoplados é utilizada para mostrar como são encontradas as equações utilizadas no trabalho e quais os parâmetros que podem ser utilizados como entradas ou saídas das redes neurais artificiais implementadas.

Capítulo 4

4. Análise e Síntese de Acopladores Direcionais Utilizando RNA

Neste capítulo apresentam-se as configurações de redes neurais artificiais utilizadas neste trabalho para a análise e síntese dos acopladores vistos no capítulo anterior, bem como os seus resultados numéricos.

4.1. Configurações das Redes Neurais

As redes neurais têm sido usadas na modelagem de acopladores de fibras ópticas [22] e também para análise e síntese de antenas diretivas (*patch antennas*) na região de microondas [11,23]. A maior vantagem do uso de modelos baseados em redes neurais é a sua simplicidade, o pouco tempo e esforço computacional requeridos, além da sua aplicação em problemas de síntese.

Em geral, métodos numéricos como o método dos elementos finitos, podem ser utilizados para modelagem dessas estruturas, mas isso requer conhecimento da teoria eletromagnética avançada, grande domínio, recurso e esforço computacional.

Propõe-se realizar a análise e síntese de acopladores direcionais planares e de acopladores baseados em fibras ópticas proporcionando assim um estudo dos modelos obtidos quanto a simplicidade e custo computacional.

A análise dos dispositivos (predição do comportamento), Figura 4.1, consiste em apresentar entradas (parâmetros ópticos e geométricos dos dispositivos) a fim de obter o comportamento desejado dos mesmos.




Figura 4.1. Configuração das variáveis de entrada e saída na Análise

Para a análise do acoplador planar, a distância de acoplamento foi considerada como variável de saída e as variáveis geométricas (largura e afastamento entre os

guias) e ópticas (índices de refração do substrato e dos guias e o comprimento de onda de operação) foram consideradas como variáveis de entrada, a rede foi configurada com sete neurônios na camada oculta com função de ativação tangente hiperbólica e um neurônio na camada de saída com a função de ativação linear, Figuras 4.2 e 4.3.




Figura 4.2. Configuração da rede neural e as variáveis de entrada e saída para análise do acoplador planar com guias de sílica e silício.




Figura 4.3. Configuração das variáveis entrada e saída na análise do acoplador planar com guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$.

Para a análise do acoplador baseado em fibras ópticas, considerou-se a distância de acoplamento como variável de saída e as variáveis geométricas (distância entre os núcleos e o raio das fibras) e ópticas (índices de refração do núcleo e da casca e o comprimento de onda de operação) foram consideradas como variáveis de entrada, a rede neural configurada possui dez neurônios na camada oculta com função de ativação tangente hiperbólica e um neurônio na camada de saída com função de

ativação linear, Figura 4.4.




Figura 4.4. Configuração da rede neural e as variáveis de entrada e saída para análise do acoplador baseado em fibras ópticas

O processo de síntese (projeto do dispositivo conhecendo o seu comportamento pré-determinado), Figura 4.5, que consiste em selecionar a saída desejada do projeto e colocá-la como uma das entradas da rede, e como saída algum dos outros parâmetros restantes.




Figura 4.5. Configuração das variáveis de entrada e saída na Síntese

Para a síntese ou projeto, acoplador planar com guias de sílica e silício, dois casos são considerados. Primeiro todos os parâmetros são conhecidos, exceto o afastamento entre os guias. A rede neural foi configurada com nove neurônios na camada oculta com função de ativação tangente hiperbólica e um neurônio na camada de saída com função de ativação linear, Figura 4.6. No segundo caso, todos os parâmetros são conhecidos, exceto a largura dos guias, cuja rede possui a mesma configuração anterior, Figura 4.7.




Figura 4.6. Configuração da rede neural e as variáveis de entrada e saída para a 1ª síntese do acoplador planar com guias de sílica e silício.




Figura 4.7. Configuração da rede neural e as variáveis de entrada e saída para a 2ª síntese do acoplador planar com guias de sílica e silício.

Para a síntese ou projeto, acoplador planar com guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$, dois casos foram considerados. Primeiro todos os parâmetros eram conhecidos, exceto o afastamento entre os guias. A rede neural foi configurada com nove neurônios na camada oculta com função de ativação tangente hiperbólica e um neurônio na camada de saída com função de ativação linear, Figura 4.8. No segundo caso, todos os parâmetros eram conhecidos, exceto a largura dos guias, cuja rede possui a mesma configuração anterior, Figura 4.9.




Figura 4.8. Configuração das variáveis de entrada e saída para a 1ª síntese do acoplador planar com guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$.




Figura 4.9. Configuração das variáveis de entrada e saída para a 2ª síntese do acoplador planar com guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$.

Para o primeiro processo de síntese ou projeto, do acoplador baseado em fibras ópticas, todos os parâmetros eram conhecidos, exceto a distância entre os núcleos, a rede neural configurada possui dez neurônios na camada oculta com função de ativação tangente hiperbólica e um neurônio na camada de saída com função de ativação linear, Figura 4.10.




Figura 4.10. Configuração da rede neural e as variáveis de entrada e saída para a 1ª síntese do acoplador baseado em fibras ópticas.

O segundo processo de síntese, todos os parâmetros eram conhecidos, exceto o raio das fibras, a rede neural configurada possui a mesma configuração anterior, Figura 4.11.




Figura 4.11. Configuração da rede neural e as variáveis de entrada e saída para a 2ª síntese do acoplador baseado em fibras ópticas.

Apresenta-se a validade e utilidade da aplicação de redes neurais no processo de análise e a síntese do acoplador direcional (2D) juntamente com o do acoplador direcional baseado em fibras ópticas na próxima seção.

4.2. Resultados Numéricos

Os acopladores considerados neste trabalho, Figura 3.1, composta por acopladores direcionais 2D (com guias de silício/sílica e $\text{Al}_x\text{Ga}_{1-x}\text{As}$) e de Fibras, foram analisados e projetados, levando em consideração a dependência dos índices de refração dos

materiais em relação a temperatura e ao comprimento de onda, usando redes neurais. Os modelos obtidos são muito simples e requerem menos esforço computacional que as técnicas numéricas clássicas geralmente usadas para esse tipo de problema.

A rede neural utilizada é a *Multilayer Perceptron* (MLP) com uma camada oculta. O número de camadas, neurônios e as variáveis de entrada, bem como as respectivas funções de ativação estão apresentados nas Figuras 4.2- 4.4 e 4.6- 4.11.

4.2.1. Acoplador Direcional Planar com Guias de Sílica e Silício

Os dados de treinamento utilizados para o acoplador planar, com guias de sílica e silício, para cada variável estão contidos nos intervalos: λ $[1,27 \mu\text{m}, 1,59 \mu\text{m}]$; w $[0,424466 \mu\text{m}, 0,784475 \mu\text{m}]$; n_1 $[1,44391, 1,4476]$; n_2 $[3,47456, 3,5101]$; d $[0,1 \mu\text{m}, 0,5 \mu\text{m}]$, Figura 4.12, e a distância de acoplamento no intervalo L_c $[19,6582 \mu\text{m}, 12909,5 \mu\text{m}]$. Obteve-se o conjunto de amostras utilizando o *software Mathematica®* (código encontra-se no anexo I). Um cuidado especial foi tomado de forma a manter os guias de onda obtidos em operação monomodo.




Figura 4.12. Parâmetros utilizados para a análise e síntese do acoplador planar com guias de sílica e silício, com seus respectivos intervalos.

Para a análise, obter a distância de acoplamento foi obtido um conjunto de 270 amostras, das quais foram separadas 224 para o treinamento e 46 amostras retiradas aleatoriamente do conjunto, tendo o cuidado de manter dentro do intervalo de treinamento. A rede neural foi configurada para executar 6000 iterações e os resultados convergiram após 5196 iterações com um erro médio quadrático de $8,002416 \times 10^{-8}$. Os resultados da rede neural e os analíticos são apresentados na Figura 4.13, com correlação igual a 0,9999802.




Figura 4.13. Comparação dos resultados obtidos de soluções analíticas e obtidos na saída da rede neural para a análise da distância de acoplamento (acoplador 2D com guias de sílica e silício)

Apresenta-se, Figura 4.13, a comparação dos 46 possíveis valores para a distância de acoplamento do acoplador planar que foram separados e utilizados para testar a rede neural resultante.

No primeiro problema de síntese para encontrar o afastamento entre os guias, obteve-se um conjunto de 162 amostras, das quais 130 foram separadas para o treinamento e 32 amostras separadas aleatoriamente, dentro do intervalo de treinamento, para testar a rede resultante. A rede neural foi configurada para executar 6000 iterações, convergindo em 3614 iterações com erro médio quadrático igual a $2,699763 \times 10^{-8}$. Os resultados dos possíveis valores de saída da rede neural e analíticos podem ser vistos na Figura 4.14, com correlação igual a 0,9999889.

Apresenta-se, Figura 4.14, a comparação dos 32 possíveis valores para o afastamento entre os guias, assim como o caso anterior, foram separados para testar a rede neural resultante.

No segundo problema de síntese, para encontrar a largura dos guias, a rede neural foi configurada para executar 6000 iterações e os resultados convergiram após 5266 iterações com erro médio quadrático igual a $4,359483 \times 10^{-8}$. Os resultados da rede neural e os analíticos são apresentados na Figura 4.13, e apresentam uma correlação igual a 0,9999969.




Figura 4.14. Comparação dos resultados obtidos de soluções analíticas e obtidos na saída da rede neural para a síntese do afastamento entre os guias (acoplador 2D com guias de sílica e silício)




Figura 4.15. Comparação dos resultados obtidos de soluções analíticas e obtidos na saída da rede neural para a síntese da largura dos guias (acoplador 2D com guias de sílica e silício)

Apresenta-se, Figura 4.15, a comparação dos 32 possíveis valores para a largura dos guias separados para testar a rede resultante.

4.2.2. Acoplador Direcional Planar com Guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$

Para o treinamento e teste das Redes de análise e sínteses do acoplador planar com guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$ foram obtidos os dados analíticos com ajuda do *software Mathematica®*, sendo gerados 400 dados entrada/saída no total (código encontra-se no anexo II), em que entre estes, 300 dados entrada/saída foram usados para treinamento e os 100 dados restantes foram utilizados para o teste das Redes Neurais Artificiais treinadas.

Os intervalos dos parâmetros de entrada/saída são: $\lambda[1,3\mu\text{m}; 1,6\mu\text{m}]$; $w[0,35\mu\text{m}; 0,7\mu\text{m}]$; $x[0,5; 1,0]$; $y[0,1; 0,6]$; $d[0,7\mu\text{m}; 1,2\mu\text{m}]$; $L_c [0,05\text{mm}; 20,0\text{mm}]$, Figura 4.16.




Figura 4.16. Parâmetros utilizados para a análise e síntese do acoplador planar com guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$, com seus respectivos intervalos.

Porém, deve-se satisfazer que a diferença entre os índices de refração dos guias e do substrato não pode ser menor que 0,2 para que não ocorra reflexão da onda incidente. Logo, respeita-se a inequação $(n_2 - n_1 \geq 0,2)$.

Para que essa inequação seja satisfeita é necessário que a diferença entre as frações de alumínio para o guia e para o substrato seja de no mínimo 0,4 e com o guia possuindo uma fração maior que a do substrato. Dessa forma, teremos que atender à inequação dada por $(y - x \geq 0,4)$.

Na análise da distância de acoplamento a Rede Neural é treinada usando-se oito neurônios na camada intermediária e um na saída, com as funções de ativação sendo a tangente hiperbólica e a linear respectivamente. A rede convergiu com um erro médio quadrático de aproximadamente 3×10^{-8} e realizando 926 iterações ao término do treinamento. Os resultados (100 dados utilizados para o teste) da rede

neural e os analíticos são apresentados na Figura 4.17, e possuem uma correlação igual a 0,999948.




Figura 4.17. Resultado do treinamento da Rede Neural relativa à análise da distância de acoplamento.

Na primeira síntese, distância entre os guias, a RNA é treinada utilizando-se sete neurônios na camada intermediária e um na saída, com as funções de ativação sendo a logaritmo sigmoide e a linear respectivamente. A rede convergiu com um erro médio quadrático de aproximadamente 4.5×10^{-8} , realizando 809 iterações ao término do treinamento. Os resultados (100 dados utilizados para o teste) da rede neural e os analíticos são apresentados na Figura 4.18, e apresentam uma correlação igual a 0,999995.

Na segunda síntese, largura dos guias, a rede foi treinada usando-se oito neurônios na camada oculta e um na saída, com as funções de ativação sendo a tangente hiperbólica e a linear respectivamente. A rede convergiu com um erro médio quadrático de aproximadamente 1×10^{-8} e sendo feitas 3029 iterações ao término do treinamento. Os resultados (100 dados utilizados para o teste) da rede neural e os analíticos são apresentados na Figura 4.19, e possuem uma correlação igual a 0,999999.




Figura 4.18. Resultado do treinamento da Rede Neural relativa à síntese do afastamento entre os guias.




Figura 4.19. Resultado do treinamento da Rede Neural relativa à síntese da largura dos guias.

4.2.3. Acoplador Direcional Baseado em Fibras Ópticas

Os acopladores baseados em fibras ópticas consistem de duas fibras ópticas com núcleos de sílica dopada com germânio e casca de sílica pura, n_1 e n_2 . Esses índices

são obtidos através das equações de *Sellmeier*.

Os dados de treinamento ficaram contidos nos intervalos: $V < 2,405$, $\lambda [1,3 \mu\text{m}, 1,6 \mu\text{m}]$; $a [1,5 \mu\text{m}, 2,0 \mu\text{m}]$; $n_1 [1,46498, 1,46817]$; $n_2 [1,44379, 1,44726]$; $d [3,15 \mu\text{m}, 9,2 \mu\text{m}]$ e a distância de acoplamento no intervalo $L_c [13,0067 \mu\text{m}, 9248,79 \mu\text{m}]$, Figura 4.20. Obteve-se o conjunto de amostras utilizando o *software Mathematica®* (código encontra-se no anexo III). Um cuidado especial foi tomado de forma a manter os guias de onda obtidos em operação monomodo.




Figura 4.20. Parâmetros utilizados para a análise e síntese do acoplador planar com seus respectivos intervalos.

De forma a realizar o processo de análise, encontrar a distância de acoplamento, do acoplador baseado em fibras ópticas obteve-se um conjunto de 399 amostras, das quais 329 foram separadas para o treinamento e 70 amostras, contidas no intervalo de treinamento, separadas para testar a rede resultante. A rede neural foi configurada para executar 5000 iterações e os resultados convergiram após 2390 iterações com erro médio quadrático igual a $1,949516 \times 10^{-8}$. A comparação entre a saída da rede neural e os resultados analíticos são observados na Figura 4.21, com correlação igual a 0,9999987.




Figura 4.21. Comparação dos resultados obtidos de soluções analíticas e obtidos na saída da rede neural para a análise da distância de acoplamento (acoplador à fibra)

Apresenta-se, Figura 4.21, a comparação dos 70 possíveis valores para os raios das fibras que foram separados de forma a testar a rede resultante.

Para encontrar a distância entre os núcleos das fibras, obteve-se um conjunto de 182 amostras, das quais 142 foram separadas para o treinamento e 36 amostras separadas aleatoriamente, dentro do intervalo de treinamento, para testar a rede resultante. A rede neural foi configurada para executar 5000 iterações e os resultados convergiram após 338 iterações com erro médio quadrático igual a $1,691229 \times 10^{-8}$. A comparação entre os resultados analíticos e os resultantes pela rede neural são observados na Figura 4.22, com uma correlação igual a 0,9999997.

Como as amostras foram retiradas aleatoriamente notam-se intervalos entre os 36 possíveis valores de saída da rede neural, Figura 4.22, que foram utilizados para testar a rede resultante.

No segundo problema de síntese, para encontrar o raio das fibras, obteve-se um conjunto de 182 amostras, das quais 146 separadas para o treinamento e 36 amostras foram separadas, aleatoriamente obedecendo ao intervalo de treinamento, para testar a rede resultante. A rede neural foi configurada para executar 5000 iterações e os resultados convergiram após 207 iterações com erro médio quadrático igual a $1,338263 \times 10^{-8}$. Na Figura 4.23, é apresentada a comparação entre os resultados analíticos e os resultados obtidos através da rede, com uma correlação igual a 0,9999575.




Figura 4.22. Comparação dos resultados obtidos de soluções analíticas e obtidos na saída da rede neural para a síntese do afastamento entre os guias (acoplador à fibra)




Figura 4.23. Comparação dos resultados obtidos de soluções analíticas e obtidos na saída da rede neural para a síntese do raio das fibras (acoplador à fibra)

Apresenta-se, Figura 4.23, a comparação dos 36 possíveis valores para os raios das fibras, que assim como o caso anterior, foram separados para testar a rede resultante.

Conclusão do Capítulo

Neste capítulo foram apresentados os resultados decorrentes da aplicação das redes neurais na análise e síntese dos acopladores 2D e Fibra, bem como as configurações utilizadas em cada uma das RNA's. Os dados utilizados, para ambos os casos, foram obtidos através do *software Mathematica®*. Os resultados obtidos são satisfatórios, pois além da ótima correlação (aproximadamente 1,0 (um)), entre os resultados obtidos pela rede com os obtidos pelos métodos numéricos, possuem menor esforço computacional e simplicidade no processo de sintetização, do que as técnicas clássicas.

Capítulo 5

5. Dispersão Cromática em Fibras Ópticas Microestruturadas

Neste capítulo será apresentada a teoria de fibras microestruturadas, dispersão cromática nas mesmas, análise e modelagem de fibras de cristais fotônicos, utilizando redes neurais e comparando com os resultados da literatura.

5.1. Fibras Ópticas Microestruturadas

O avanço dos cristais fotônicos, no começo da década de 80, impulsionou o interesse pelo desenvolvimento de fibras ópticas microestruturadas (MOFs – *microstructured optical fibers*) [24]. Estes cristais são estruturas formadas a partir de materiais com diferentes índices de refração, ordenados de forma periódica, na escala do comprimento de onda da luz.

Nas fibras ópticas microestruturadas, um cristal fotônico bidimensional é formado por uma distribuição periódica de capilares, os quais percorrem o eixo longitudinal da fibra. Pode-se criar um defeito na rede cristalina de forma a permitir níveis de propagação dentro da banda proibida do cristal [25]. Um defeito pode ser criado através da eliminação de um dos capilares ou retirando sílica de uma determinada região, violando, assim, a periodicidade da estrutura. No caso particular das fibras ópticas microestruturadas, este defeito será capaz de guiar a luz, constituindo-se como o núcleo da fibra [25,26].

Alguns grupos de pesquisadores, durante a década de noventa, trabalharam este conceito de cristais fotônicos, estendendo para a região do infravermelho (IR) e comprimentos de onda no visível. Isso foi possível ao alterar as dimensões do cristal ou o tipo de material a ser empregado na fabricação dos dispositivos. No ano de 1996, pesquisadores da Universidade de Bath, na Inglaterra, liderados por P.St.J. Russell [27] fabricaram a primeira fibra óptica microestruturada, Figura 5.1.

Podemos observar na Figura 5.1 que a região da casca é composta por uma estrutura complexa, formada pela presença de capilares ordenados de forma periódica, os quais percorrem o eixo longitudinal da fibra. Na região central, denominada núcleo, ocorre a quebra da periodicidade desse cristal, ou seja, ocorre à substituição de um capilar por um bastão sólido de sílica. Assim, a fibra apresenta núcleo sólido e a luz será guiada na região de sílica.

Esta classe de fibras ópticas pode ser denominada como fibra óptica microestruturada (MOF – *microstructured optical fiber*), fibra perfurada (HF – *holey fiber*) ou ainda, fibra de cristal fotônico (PCF – *photonic crystal fiber*) [25].




Figura 5.1. Seção transversal de uma fibra óptica microestruturada com núcleo sólido [25].

Em 1999, R.F. Cregan e colaboradores [28], também pertencentes ao grupo de P.St.J. Russell fabricaram outra forma possível para as fibras de cristal fotônico (fibras microestruturadas), Figura 5.2, apresentando um núcleo de ar onde a luz será guiada.




Figura 5.2. Fibra óptica com banda fotônica proibida e núcleo de ar (PBG) [25].

O desenvolvimento das fibras ópticas microestruturadas permitiu obter efeitos ópticos (como guiamento por banda fotônica proibida – *photonic band gap* (PBG)) que, até então, não eram possíveis de se alcançar com as fibras ópticas convencionais.

As fibras PBG oferecem muitas aplicações promissoras, como transporte de altas potências sem o risco de danificar a fibra, como sensores de gás ou para guiamento no vácuo com o mínimo de perdas. Além disso, elas apresentam menos perdas por curvatura, mesmo para raios de curvatura muito pequena facilitando a instalação residencial e também permite a obtenção de altos valores de dispersão cromática, na ordem de milhares de $ps/nm/km$.

Para caracterizar as fibras ópticas microestruturadas é necessário definir os seus parâmetros físicos e geométricos. Conforme apresentado na Figura 5.3, os parâmetros geométricos são: o diâmetro dos capilares d , e o espaçamento entre os centros dos capilares (*pitch hole*) Λ . Os parâmetros físicos atribuídos a fibra são: o índice de refração do núcleo, n_{co} , e o índice efetivo da casca, n_{cl} . Outro parâmetro muito utilizado é a relação entre o diâmetro dos capilares d , e o espaçamento Λ , definido como $f = d/\Lambda$, o qual fornece a proporção entre ar e sílica presentes na estrutura.




Figura 5.3. Esquemático de uma fibra óptica microestruturada e seus parâmetros

Basicamente, as fibras ópticas microestruturadas podem ser divididas em duas categorias relacionadas ao mecanismo de guiamento de luz. Na primeira, encontram-se as fibras com núcleo sólido, Figura 5.1 e 5.3, denominadas fibras com guiamento por índice (IG – *index guiding*) [29]. O guiamento da luz é obtido com base na diferença de índices de refração entre casca e o núcleo, ou seja, o índice de refração da área central (núcleo) é maior do que o índice de refração efetivo do conjunto ao redor do núcleo (casca). Este guiamento é por reflexão interna total, semelhante ao que

ocorre nas fibras ópticas convencionais [30]. Na segunda categoria, encontram-se as fibras que apresentam uma estrutura geométrica periódica, Figura 5.2, capazes de exibir uma banda fotônica proibida. Então, pode-se criar um defeito nesta estrutura de forma a quebrar essa periodicidade. Este defeito tem a propriedade de criar níveis de propagação dentro da banda proibida do cristal. A luz permanece confinada dentro do defeito, devido à existência da banda fotônica proibida, mantendo o confinamento mesmo na presença de curvaturas. Assim, neste defeito, será possível guiar a luz, funcionando, portanto, como o núcleo da fibra. Por este motivo são denominadas de fibras com banda fotônica proibida (do inglês, PBG - *photonic band gap*) [31].

Devido ao mecanismo de guiamento não usual, estas fibras possuem características únicas e a perspectiva de guiar luz na região de ar é interessante, pois serão minimizados os efeitos como dispersão cromática, os efeitos não-lineares e a absorção óptica [30,31].

Estas categorias de fibras ópticas microestruturadas vêm chamando a atenção dos pesquisadores nos últimos anos, principalmente, pela liberdade que proporcionam na manipulação dos seus parâmetros físicos e geométricos. Desta forma, as MOFs podem ser trabalhadas de maneira a permitir:

- manejo das curvas de dispersão [29-31],
- operação monomodo em uma larga faixa de comprimentos de onda [32,33]
- possibilidade de ajuste da área efetiva [34],
- controle dos efeitos ópticos não-lineares [35]-[37],
- controle da birrefringência [38].

Sua propriedade de apresentar um guiamento monomodo em uma larga faixa de comprimentos de onda foi a primeira característica explorada nas MOFs, possibilitando, assim, manter o seu comportamento monomodo e variar a frequência de operação. Uma fibra óptica é efetivamente monomodo quando o parâmetro V é mantido abaixo de 2,405 [32,33], Figura 5.4. Nas MOFs, este efeito pode ser explicado fisicamente devido ao fato do índice de refração médio do conjunto da casca ser em função do comprimento de onda [27]. A luz tende a permanecer mais confinada no núcleo da fibra, para comprimentos de onda curtos, penetrando menos na região dos capilares. Esta interação menor entre o campo eletromagnético e a região de ar (menor índice de refração) aumenta o índice efetivo da região da casca, diminuindo a diferença entre os índices da casca e do núcleo.




Figura 5.4. Frequência normalizada em função do afastamento entre o centro dos capilares normalizado

Inversamente, para comprimentos de onda mais longos, o confinamento da luz na região do núcleo diminui. A luz tem uma interação maior com a região de ar, neste caso, o que tende a diminuir é o índice efetivo da casca, aumentando a diferença entre os índices do núcleo e da casca. Consegue-se dessa forma, projetar fibras com arranjos periódicos capazes de manter o valor V praticamente constante e abaixo de 2,405, mantendo o guiamento monomodo em uma extensa faixa espectral [27,33].

Outra característica extremamente explorada nas fibras ópticas microestruturadas é o controle da dispersão cromática.

5.2. Dispersão cromática: conceitos fundamentais

Um dos principais fatores limitantes nos atuais sistemas de transmissão de dados em fibras ópticas é a dispersão cromática. À medida que a taxa de transmissão atinge valores a partir de 10Gbits/s este efeito torna-se ainda mais crítico [39]. É de fundamental importância a aplicação de técnicas capazes de compensar esse efeito indesejado. A dispersão cromática é nula na segunda janela espectral em fibras ópticas monomodo convencionais à base de sílica, ou seja, em torno do comprimento de onda de 1300nm [40,41]. Entretanto, essas fibras monomodo convencionais apresentam a atenuação espectral mínima na terceira janela, em torno do comprimento de onda de 1550nm . A migração da segunda para a terceira janela em transmissões a longas distâncias foi efetivamente possível no início da década de 90, com o surgimento dos amplificadores ópticos de fibra dopada com Érbio [40,41].

Nessa faixa específica de $1550nm$ consegue-se uma combinação entre atenuação espectral mínima, da ordem de $0,2dB/km$ [38], com a possibilidade da amplificação do sinal em banda larga e em regime totalmente óptico. Vale mencionar que a faixa espectral de comunicações ópticas foi dividida em bandas, Figura 5.5. A segunda janela espectral corresponde à banda *O* ($1260-1360nm$) e a terceira janela espectral foi subdividida nas bandas *S* ($1460-1530nm$), *C* ($1530-1560nm$) e *L* ($1560-1630nm$).

As fibras ópticas convencionais operando na região espectral da terceira janela exibem penalidade devido ao efeito da dispersão cromática, a qual, em $1550nm$, é de aproximadamente $+17ps/(nm\ km)$ [42,43].

Foi necessário desenvolver técnicas capazes de minimizar o efeito da dispersão cromática acumulada ao longo de um enlace óptico.




Figura 5.5. Ilustração das faixas espectrais em comunicações ópticas e da separação de canais em sistema WDM

Está relacionada com as características materiais e estruturais das fibras ópticas a origem do fenômeno dispersivo. Ao serem lançadas na fibra óptica as componentes espectrais que formam um pulso óptico, viajam com diferentes velocidades. Estas componentes estarão atrasadas entre si e o pulso estará temporalmente alargado após uma determinada distância de propagação, [39,44,45]. Examinando as características da velocidade de grupo dos modos guiados pode ser explicado este efeito, no qual a velocidade de grupo é a velocidade com que a energia de um pulso viaja pela fibra [44]. As diferentes velocidades de propagação das componentes espectrais resultam na ‘dispersão da velocidade de grupo’ (*group velocity dispersion* (GVD)), ou simplesmente ‘dispersão cromática’ (*chromatic dispersion*).

(CD)), que é a medida do alargamento temporal do pulso, em uma faixa espectral, após sua propagação por um determinado comprimento de fibra [44,45].

A dispersão cromática em fibras ópticas monomodo é resultado da superposição de dois efeitos: dispersão de material e dispersão de guia de onda. A dispersão do material está relacionada a variação do índice de refração em relação ao comprimento de onda e a dispersão de guia de onda, por sua vez, é dependente da estrutura geométrica da fibra óptica e pode ser ajustada pelas dimensões do raio do núcleo, ou pela diferença entre os índices de refração núcleo-casca [45]. A dispersão cromática total pode ser calculada por meio da expressão [44,45]:

$$D_t = -\frac{\lambda}{c} \frac{d^2 n_{eff}(\lambda)}{d\lambda^2} \quad [ps / (nm \cdot km)], \quad (5.2)$$

Onde c é velocidade da luz no vácuo e n_{eff} é o índice efetivo em função do comprimento de onda λ . Este cálculo permite obter o valor da dispersão cromática em comprimentos de onda específicos.

A inclinação da dispersão S (*dispersion slope*) é outra questão que deve ser abordada, calculada por [37]:

$$S = \frac{dD_t}{d\lambda} \quad [ps / (nm^2 \cdot km)] \quad (5.3)$$

É fundamental o conhecimento dos parâmetros D e S na execução do projeto, visando à compensação da dispersão cromática em banda larga. É possível estimar a faixa de compensação óptica da fibra conhecendo-se o valor da dispersão cromática e da sua inclinação. Nos atuais sistemas de transmissão WDM esta caracterização é importante, principalmente, quando vários comprimentos de onda são transmitidos simultaneamente, Figura 5.5. As fibras ópticas projetadas para compensação da dispersão precisam, obrigatoriamente, apresentar um valor negativo de D e um valor específico da inclinação S para que a compensação ocorra em uma faixa de comprimentos de onda. A compensação da dispersão acumulada ao longo de um enlace óptico é obtida inserindo-se neste enlace um determinado comprimento da fibra óptica compensadora e gradativamente o efeito da dispersão cromática é reduzido.

A seguinte relação entre inclinação e dispersão na fibra deve ser satisfeita para se obter a compensação da dispersão em banda larga [40]:

$$RDS = \frac{S_{dc}}{D_{dc}} = \frac{S_s}{D_s} \quad [1 / nm] \quad (5.4)$$

Onde D_{dc} e S_{dc} são os respectivos valores de dispersão e inclinação da dispersão na fibra compensadora. D_s e S_s são os respectivos valores de dispersão e inclinação da dispersão na fibra utilizada no enlace óptico, a qual se deseja compensar. É denominada de ‘inclinação relativa da dispersão’ (*relative dispersion slope* (RDS)) a relação entre inclinação da dispersão e a dispersão [40].

Portanto, é possível distinguir entre as fibras compensadoras em banda estreita e as fibras projetadas para compensação em banda larga no projeto das fibras compensadoras de dispersão.

Torna-se fundamental o desenvolvimento de dispositivos capazes de compensar o efeito da dispersão cromática em um enlace óptico, devido à constante busca por uma maior taxa de transmissão de dados a longas distâncias. Fibras projetadas para atuar como compensadoras da dispersão têm-se mostrado extremamente eficientes ao longo dos anos e, por isso, têm sido amplamente investigadas [40-48].

5.3. Resultados Numéricos PCF

Há aproximadas relações empíricas para obter a dispersão cromática de fibras, tais como [19,21]. Entretanto, as técnicas numéricas, como o método dos elementos finitos, são a abordagem mais apropriadas e largamente utilizadas para a modelagem dessas estruturas embora exijam o conhecimento da teoria eletromagnética e também grande esforço computacional e recursos. Utilizaremos as redes neurais artificiais no intuito de tornar o processo de modelagem de PCFs simples, reduzindo o tempo e o esforço computacional. Neste trabalho, configurações de redes neurais são implementadas para a modelagem das configurações geométricas de PCF's mostradas na Figura 5.3. Para demonstrar a validade e a utilidade da aplicação de redes neurais, a análise da dispersão cromática de uma PCF é apresentada. A configuração de rede utilizada gerou resultados que foram comparados com os anteriormente publicados [6], possibilitando a criação de mapas de dispersão cromática através de um modelo de RNA.

A rede neural utilizada foi a *Multilayer Perceptron* (MLP) com duas camadas ocultas, apresentando convergência rápida e de elevada eficiência durante o processo de treinamento da RNA. Diversas configurações foram testadas e a de melhor resultado utiliza 7 e 23 neurônios nas camadas escondidas, respectivamente. As funções de ativação utilizadas em todos os casos são a tangente hiperbólica para as camadas ocultas e a linear na saída, respectivamente. O processo de treinamento foi realizado com o algoritmo de Levenberg-Maquardt. As variáveis de entrada consideradas são o comprimento de onda de operação λ , a distância entre o centro dos capilares Λ e o diâmetro dos capilares d . A variável de saída é a dispersão cromática, Figura 5.6. Os dados de treinamento são obtidos a partir de [6].





Figura 5.6. Variáveis de entrada e saída da RNA para análise da dispersão cromática de PCFs.

A fim de validar a abordagem proposta, a fibra de cristal fotônico mostrado na Figura 5.3, foi analisada e sua dispersão cromática foi computada. Esta fibra é composta por sílica fundida (SiO_2), com vários anéis concêntricos dispostos de buracos de ar em uma estrutura hexagonal. A dispersão cromática necessária para o treinamento da rede neural foi obtida a partir de [6], onde a dispersão do material foi levada em conta, usando as equações de Sellmeier em $T = 300\text{ K}$. Os dados de treinamento utilizados para cada variável mostrada na Figura 5.6 estão contidos no intervalo: λ [$1,2\text{ }\mu\text{ m}$, $1,8\text{ }\mu\text{ m}$]; Λ [$0,2\text{ }\mu\text{ m}$, $1,6\text{ }\mu\text{ m}$]; d [$0,1\text{ }\mu\text{ m}$, $0,5\text{ }\mu\text{ m}$], como resultado a dispersão cromática no intervalo D [$-38\text{ ps.nm}^{-1}.\text{km}^{-1}$, $140\text{ ps.nm}^{-1}.\text{km}^{-1}$]. Obtivemos um conjunto de 273 amostras, sendo que 147 para o treinamento e 126 separadas para testar a rede resultante.


A rede neural (código encontra-se no anexo IV) foi configurada para executar 7000 iterações e os resultados convergiram após 6432 iterações, no intervalo de 210 segundos. E o critério de parada foi um erro menor que 10^{-9} .

Os resultados da rede neural são colocados junto aos dados obtidos a partir de [52] nas Figuras 5.7-5.9. Os pontos vermelhos e azuis correspondem aos dados de treinamento e validação, respectivamente, e as linhas sólidas correspondem aos dados obtidos a partir de [6]. É possível observar uma excelente concordância entre os dados da RNA e os já publicados em [6], também foi observado um comportamento não-linear entre a dispersão cromática e os parâmetros da PCF. O erro entre os valores indicados em [6] e do modelo de RNA são menores que $1\text{ ps.nm}^{-1}.\text{km}^{-1}$.

Com os resultados da rede neural foram gerados mapas com curvas de nível da dispersão cromática em todos os intervalos considerados, Figuras 5.10-5.12.




(a)




(b)

Figura 5.7. Dispersão cromática obtida pelo treinamento e validação dos dados através da RNA para o afastamento entre os capilares de 2μm, (a) Superfície 3D e (b) Projeção 2D.




(a)




(b)

Figura 5.8. Dispersão cromática obtida pelo treinamento e validação dos dados através da RNA, para o afastamento entre os capilares de 2,5μm, (a) Superfície 3D e (b) Projeção 2D.



(a)



(b)

Figura 5.9. Dispersão cromática obtida pelo treinamento e validação dos dados através da RNA, para o afastamento entre os capilares de 3μm, (a) Superfície 3D e (b) Projeção 2D




Figura 5.10. Mapa da dispersão cromática para espaçamento entre os capilares de $2\mu\text{m}$




Figura 5.11. Mapa da dispersão cromática para espaçamento entre os capilares de $2,5\mu\text{m}$




Figura 5.12. Mapa da dispersão cromática para espaçamento entre os capilares de $3\mu\text{m}$

Conclusão do Capítulo

Foi apresentada a teoria de fibras ópticas microestruturadas, sua análise da dispersão cromática e a modelagem de uma PCF, utilizando redes neurais. Os resultados obtidos foram comparados com os encontrados na literatura [6], sendo satisfatórios e a partir deles elaboraram-se mapas de níveis da dispersão cromática que permitirão projetar fibras com determinado comportamento de dispersão cromática.

Conclusões

Ao longo desta dissertação descreveu-se uma metodologia eficiente e robusta para a análise e síntese de dispositivos fotônicos através de redes neurais artificiais. Os principais objetivos traçados, desde o início e durante o desenvolvimento desta dissertação foram alcançados.

O objetivo principal consistiu na obtenção de configurações de redes neurais capazes de realizar o processo de análise e síntese de dispositivos fotônicos, simplificando o processo de sintetização e com esforço computacional menor que as das técnicas clássicas. Os resultados obtidos aqui foram, em geral, satisfatórios, mostrando concordância, quando possível com os obtidos através de outros métodos numéricos.

Acopladores direcionais 2D e de Fibra foram analisados e projetados, levando em consideração a dependência dos índices de refração dos materiais em relação ao comprimento de onda, usando redes neurais artificiais.

Adicionalmente, um modelo de rede neural foi utilizado na análise da dispersão cromática e modelagem de uma fibra de cristas fotônicas (PCFs), comparando os resultados obtidos com os encontrados na literatura e a partir dos resultados encontrados elaboraram-se mapas de níveis da dispersão cromática que permitirão projetar fibras conhecendo-se a sua dispersão.

As conclusões deste trabalho estão resumidas a seguir:

No Capítulo 2, apresentou-se a teoria de redes neurais artificiais, sua utilização em outras áreas de conhecimento, suas arquiteturas e a comparação entre os algoritmos de treinamentos de modo a escolher o mais eficiente para o nosso problema.

No Capítulo 3, apresentou-se uma revisão bibliográfica de acopladores direcionais com seus respectivos parâmetros e funcionamento. Introdução a teoria dos modos acoplados, mostrando como são encontradas as equações utilizadas no trabalho e quais os parâmetros que podem ser utilizados como entradas ou saídas das redes neurais artificiais implementadas.

No Capítulo 4, Apresentou-se as configurações utilizadas nas redes neurais para a análise e síntese dos acopladores 2D (com guias de Sílica/Silício e com guias de $\text{Al}_x\text{Ga}_{1-x}\text{As}$) e Fibra. Os resultados obtidos são satisfatórios, mais simples e o esforço computacional utilizado foi menor que os das técnicas clássicas.

No Capítulo 5, foi apresentada uma revisão bibliográfica, introdução a teoria de fibras ópticas microestruturadas, sua análise da dispersão cromática e a modelagem de uma PCF, utilizando redes neurais artificiais. Compararam-se resultados obtidos com os encontrados na literatura [6], sendo satisfatórios, e a partir deles elaboraram-se mapas de níveis da dispersão cromática que permitirão projetar fibras com determinado comportamento de dispersão cromática.

Sugestões e Trabalhos Futuros

As redes neurais são ferramentas poderosas e foram utilizadas com sucesso na modelagem de dispositivos fotônicos. Para trabalhos futuros sugere-se a modelagem e síntese de outras geometrias mais complexas de acopladores direcionais ópticos como acopladores baseados em guias de estruturas fotônicas cristalinas ou guias tipo costela (*rib waveguides*), bem como outras arquiteturas de PCFs, explorando o seu arranjo e possíveis variações dos diâmetros dos capilares em cada anel que compõem a sua estrutura.

Referências

- [1] José R. de Almeida Amazonas, *Projeto de sistemas de comunicações ópticas*, Manole, Barueri, 2005.
- [2] Herwig Kogelnik, “An Introduction to Integrated Optics,” *IEEE Transactions on microwave theory and techniques*, Vol. MTT-23, n°1, pp. 2-16, Janeiro 1975.
- [3] Vitaly Félix Rodríguez Esquerre, “Modelagem de estruturas fotônicas por elementos finitos 2D no domínio do tempo”, Tese de Doutorado, Universidade Estadual de Campinas - Faculdade de Engenharia Elétrica e Computação, Campinas, São Paulo, Abril 2003.
- [4] G. Keiser, *Optical Fiber Communications*, 2a edição, McGraw Hill, New York, pp. 97-113, 1991.
- [5] G.P Agrawal, *Nonlinear Fiber Optics*. 2a edição, Inc. Academic Press, Boston, pp. 7-15, 1989.
- [6] K Saitoh, M Koshiba, “Empirical relations for simple design of photonic crystal fibers,” *Opt Express* , n° 13, 267274 (2005) .doi: 10.1364 /OPEX. 13.000267
- [7] Almir Wirth Júnior Lima, “Aclopadores Direcionais de Fibras Ópticas com perfis de dispersão”, Dissertação de Mestrado, Universidade Federal do Ceará, Fortaleza, Ceará, 2007.
- [8] Simon, Haykin, *Redes Neurais: Princípios e Prática*, Bookman, 2000.
- [9] Ludemir Braga e Carvalho, *Redes Neurais Artificiais: Teoria e Aplicações*, LTC, 2000.
- [10] Cairo Lúcio, Nascimento Júnior e Takaashi Yoneyama, *Inteligência Artificial em Controle e Automação*, 1ª edição, Ed. Edgard Blücher LTDA, São Paulo, 2000.
- [11] A. Ouchar, R. Aksas e H. Baudrand. “Artificial neural network for computing the resonant frequency of circular patch antennas”, *Microwave and Optical Technology Letters*, Vol. 47, n° 6, pp. 564-566, 2005.
- [12] Neural Networks Toolbox Matlab R2009a, Version 6.0.2 (R2009a) Neural Network.pdf

- [13] Cassia Yuri Tatibana e Deise Yuki Kaetsu, Homepage de Redes Neurais, Disponível em < <http://www.din.uem.br/ia/neurais> >, Acesso em 09 de nov. 2010.
- [14] H. I. V. Gonçalves, R. C.M. Coimbra, M. Ladeira e H. A do Prado, “Ferramenta de Regressão Não-linear Múltipla com Redes Neurais Artificiais,” *XXV Congresso da Sociedade Brasileira de Computação*, São Leopoldo – RS, 2005.
- [15] Carmen Dalla Rosa Bittencourt, “Classificação Automática do Acabamento de Gordura em Imagens Digitais de Carcaças Bovinas”, Dissertação de Mestrado, Universidade Federal de Brasília, Brasília – DF, 2009.
- [16] V. F. R. Esquerre, J. P. da Silva, C. E.R. Mercedes, J. J. I. de Lima, H. E. H. Figueroa, “Temperature Dependence Analysis of Photonic Devices em Integrated Photonics and Nanophotonics Research and Applications,” *Proceedings do IPNRA2008*, Boston, pp. IWB, 2008.
- [17] G. Lifante, *Integrated Photonics Fundamental*, Wiley, 2003.
- [18] K. Okamoto, *Fundamentals of Optical Waveguides*, 2a edição, Elseiver, 2006.
- [19] D. L. Lee, *Electromagnetics Principles of Integrated Optics*, Wiley and Sons, New York, 1986.
- [20] BATOP opteletronics, Disponível em: <http://www.batop.de/information/n_AlGaAs.html>, Acesso em 09 de abr. 2010.
- [21] Bruno Simões G. Nunes Pereira, “Análise de Dispositivos WDM: Comparação entre soluções Analíticas Aproximadas e Método Numérico”, Monografia de Graduação, Universidade Federal da Bahia, Salvador-BA, 2010.
- [22] Jiusheng Li, Zhenwu Bao, “Neural network model of optical fiber direction coupler design,” in *Proceedings of the SPIE*, Vol. 5178, pp. 238-245, 2004.
- [23] Nurhan Türker, Filiz Güneş e Tülay Yildirim, “Artificial. Neural Networks Applied to the Design of Microstrip Antennas,” *Microwave Review*, Junho 2006.
- [24] E. Yablonovitch, “Inhibited Spontaneous Emission in Solid-State Physics and Electronics,” *Physical Review Letters*, Vol. 58, n° 20, pp. 2060-2062, Maio 1987.
- [25] D.H. Spadoti, “Proposição e Estudo de Fibras Ópticas Microestruturadas Tipo D: Gerenciamento de Dispersão e Alta Birrefringência” Tese de Doutorado, Escola de Engenharia de São Carlos, Universidade Federal de São Paulo, São Carlos, 2008.

- [26] P.C. Daianese Júnior, “Espalhamento Brillouin em Fibras de Cristal Fotônico”, Tese de Doutorado, Universidade Estadual de Campinas, Campinas-SP, 2006.
- [27] J.C. Knight, T.A. Birks, P.St.J. Russell e D.M. Atkin, “All-silica single-mode optical fiber with photonic crystal cladding,” *Optics Letters*, Vol. 21, n° 19, pp. 1547-1549, Outubro 1996.
- [28] R.F. Cregan, B.J. Mangan, J.C. Knight, T.A. Birks e P.St.J. Russell, “Single-Mode Photonic Band Gap Guidance of Light in Air,” *Science*, Vol. 285, pp. 1537-1539, Setembro 1999.
- [29] F. Brechet, J. Marcou, D. Pagnoux e P. Roy, “Complete Analysis of the Characteristics of Propagation into Photonic Crystal Fibers, by the Finite Element Method,” *Optical Fiber Technology* 6, pp. 181-191, 2000.
- [30] K. Saitoh, M. Koshiba, “Numerical Modeling of Photonic Crystal Fibers,” *J. of Light. Techno Lett.*, Vol. 23, n° 11, Novembro 2005.
- [31] J. Broeng, D. Mogilevstev, S.E. Barkou, A. Bjarklev, “Photonic Crystal Fibers: A New Class of Optical Waveguides,” *Optical Fiber Technology* 5, pp. 305-330, 1999.
- [32] T.F. Krauss, R.M. De La Rue, “Photonic crystal in the optical regime – past, present and future,” *Progress in Quantum Electronics* 23, pp.51-96, 1999.
- [33] T.A. Birks, J.C. Knigh, P.St.J. Russell, “Endlessly single-mode photonic crystal fiber,” *Optics Letters*, Vol. 22, n° 13, pp. 961-963, Julho 1997.
- [34] N.A. Mortensen, “Effective area of photonic crystal fibers,” *Optics Express*, Vol. 8, n° 7, Abril 2002.
- [35] G.P. Agrawal, *Fiber-Optic Communication Systems*, 2a edição, John Wiley. 1992.
- [36] A.M. Zheltikov, “Holey Fibers,” *Physics-Uspekhi* , Vol. 43,n° 11, pp. 1125-1136, 2000.
- [37] F. Poli, A. Cucinotta, M. Fuochi, S. Selleri, L. Vincetti, “Characterization of microstructured optical fibers for wideband dispersion compensation,” *J. of Opt. Soc. Am.*, Vol. 20, n° 10, Outubro 2003.

- [38] A. Ortigosa-Blanch, J. C. Knight, W. J. Wadsworth, J. Arriaga, B. J. Mangan, T. A. Birks, P. St. J. Russell, "Highly birefringent photonic crystal fibers," *Optics Letters*, Vol. 25, n° 18, pp. 1325-1328, Setembro 2000.
- [39] M.L. Rocha, "Tutorial 1 – Dispersão". Disponível em: <<http://www.kyatera.fapesp.br/portal/pesquisa/tutoriais>>. Acesso em 07 de nov. 2010.
- [40] M. Nishimura, "Optical fibers and fiber dispersion compensators for high-speed optical communication," *Journal of Optical and Fiber Communications Report*, Vol. 2, pp. 115–139, 2005.
- [41] J.B. Rosolem, "Amplificadores opticos de dupla passagem incorporando fibras compensadoras de dispersao", Tese de Doutorado, Escola de Engenharia de Sao Carlos, Universidade Federal de São Paulo, São Carlos-SP, 2005.
- [42] B.P. Pal, K. Pande, "Optimization of a dual-core dispersion slope compensating fiber for DWDM transmission in the 1480–1610 nm band through G.652 single-mode fibers," *Optics Communications*, Vol. 201, pp. 335–344, Janeiro. 2002.
- [43] V. A. Semenov, A. V. Belov, E. M. Dianov, A. A. Abramov, M. M. Bubnov, S. L. Semjonov, A.G. Shchebunjaev, V. F. Khopin, A. N. Guryanov, N. N. Vechkanov, "Broadband dispersioncompensating fiber for high-bit-rate transmission network use," *Applied Optics*, Vol. 34, n° 24, Agosto 1995.
- [44] G. Keiser, *Optical Fiber Communications*, 2a edição, Inc. McGraw Hill, pp 97-113, 1991.
- [45] G.P. Agrawal, *Nonlinear Fiber Optics*, 2a edição, Inc. Academic Press, San Diego, pp 7-15, 1995.
- [46] J. L. Auguste, J. M. Blondy, J. Maury, J. Marcou, B. Dussardier, G. Monnom, R. Jindal, K. N. Thyagaraja, B. P. Pal, "Conception, Realization, and Characterization of a Very High Negative Chromatic Dispersion Fiber," *Optical Fiber Technology*, Vol. 8, pp. 89–105, 2002.
- [47] L. Gruner-Nielsen, M. Wandel, P. Kristensen, C. Jorgensen, L.V. Jorgensen, B. Edvold, B. Palsdottir, D. Jakobsen, "Dispersion-Compensating Fibers," *Journal of Lightwave Technology*, Vol 23, n° 11, Novembro 2005.

[48] C. Lin, H. Kogelnik, L. G. Cohen, "Optical-pulse equalization of low dispersion transmission in single-mode fibers in the 1.3–1.7 Wm spectral region," *Opt. Lett.*, Vol. 5, n° 11, pp. 476–478, Novembre. 1980.

Anexos

Anexo I

Código do *Mathematica*® para gerar os dados do acoplador planar com guias de sílica e silício.

```
ClearAll["Global`*"];
pi=Pi//N;
um=0.000001;
Do[lambda;
l=lambda/um;
delta=0.000001;
n1=Sqrt[1+(0.6961663*1^2)/(1^2-0.0684043^2)+(0.4079426*1^2)/(1^2-
(0.1162414^2))+(0.8974794*1^2)/(1^2-9.896161^2)];
n2=Sqrt[11.6858+(0.939816/(1^2))+0.00810461*(1.1071^2)/(1^2-1.1071^2)];
n3=Sqrt[1+(0.6961663*1^2)/(1^2-0.0684043^2)+(0.4079426*1^2)/(1^2-
(0.1162414^2))+(0.8974794*1^2)/(1^2-9.896161^2)];
Do[w=numberv*lambda/(2*87I);
k0=2*87I/lambda;
v=k0*w*Sqrt[n2^2-n3^2];
nef=FindRoot[k0*Sqrt[n2^2-neff^2]*w ArcTan[(Sqrt[neff^2-n1^2])/(Sqrt[n2^2-
neff^2])]+ArcTan[(Sqrt[neff^2-n3^2])/(Sqrt[n2^2-neff^2])],{neff,n3+delta,n2-delta}];
nef=nef[[1]][[2]];
k2x=k0*Sqrt[n2^2-nef^2];
ax=k0*Sqrt[nef^2-n1^2];
kz=k0*nef;
Do[d;
c0=ax*k2x^2*Exp[-ax*d]/(kz*0.5*w*(1+2/(ax*w))*(ax^2+k2x^2));
Lc=87I/(2*c0);
Print[w/um," ",d/um," ",l," ",n1," ",n2," ",Lc/um,
{d,0.1 um,0.5 um,0.2 um}],
{numberv,2.1,3.1,0.2}],
{lambda,1.27 um,1.61 um,0.04 um}]
```

Código da rede neural no MATLAB® para o acoplador planar com guias de sílica e silício.

```
clear all
clc
format long;
rand('seed',1);
% Dados de entrada
load dadosd %arquivo com os dados de treinamento e teste
x=entrada;
y=saida;
Range_entrada = [minmax(x)];
Qte_neuron = [5 1];
% Função que cria a rede
net=newff(Range_entrada, Qte_neuron,{'tansig' 'purelin'});
% Parametros do Treinamento
net.trainParam.epochs =20000;
```

```

net.trainParam.goal = 1e-7;
[net,tr] = train(net,x',y');
% Validar a rede
% a) Validando com os dados de treinamento
ynet = sim(net, x(1:32,:)); % Saida calculada pela RNA
comparar=[y(1:32) ynet']
disp('Erro Médio Quadrático com os dados de treinamento')
ErMQ=sum((y(1:32)-ynet').^2)/32
% b) Testando a rede com dados novos
ynet = sim(net, entradav'); % Saida calculada pela RNA
comparar=[saidav ynet']%*1e4
%grafico dos valores obtidos vs valores pretendidos
figure(1)
plot(ynet,saidav,'*b')
xlabel('Saida da Rede Neural')
ylabel('Saída Desejada')
grid on
disp('Erro Médio Quadrático com novos dados')
ErMQ=sum((saidav-ynet').^2)/32

```

Anexo II

Código do *Mathematica*® para gerar os dados do acoplador planar com guias de AlGaAs.

```
ClearAll["Global`*"];
um=0.000001;(*variável unidade em micro=10^-6 *)
pi=Pi/N;(*valor aproximado de pi*)
tol=0.00000000001;(*tolerância de 10^-11 usada na equação transcendental do neff *)
Do [i;
  x1=RandomReal[{0.5,1.0}]; (* Porcentagem 1 *)
  x2=RandomReal[{0.1,0.6}]; (* Porcentagem 2 *)
  (* No programa o usuário entra apenas com x1 e x2 em porcentagem (que é a porcentagem de
  Alumínio na Liga metálica) de tal forma que x1-x2>0.4 o que garante que n2-n1>0.2 (condição
  importante para não haver reflexão da
  onda incidente *)
  While[(x1-x2)<0.4,x2=RandomReal[{0.1,0.6}]]; (* Fiz uma condição de Looping até que o programa
  obtenha valor coerente de x2 *)
  l=RandomReal[{1.3,1.6}]; (* Variação de lambda *)
  l=l um;
  w=RandomReal[{0.35,0.70}]; (* Variação da largura dos guias de forma que pi*(d/l)sqrt(n2^2-
  n1^2)<pi/2 > condição imposta *)
  w=w um;
  d=RandomReal[{0.7,1.20}]; (* Variação da distância entre os guias para que tenha certa interferência
  em monomodo *)
  d=d um;
  h=4.1356179*10^(-15); (* Contante de plank em eV.s *)
  c=2.998*10^(8); (* Velocidade da luz no vacuo (valor experimental) *)
  (* Cálculo do n1 em função da porcentagem de alumínio na liga e do lambda segundo o site *)
  A01 =6.3+19.0*x1;
  B01=9.4-10.2*x1;
  E01=1.425+1.155*x1+0.37*x1^2;
  E0D01=1.765+1.115*x1+0.37*x1^2;
  y1=h*c/(l*E01);
  y01=h*c/(l*E0D01);
  f1=(2-Sqrt[1+y1]-Sqrt[1-y1])/(y1^2);
  f01=(2-Sqrt[1+y01]-Sqrt[1-y01])/(y01^2);
  n1=Sqrt[A01*(f1+(f01/2)*(E01/E0D01)^(3/2))+B01];
  (* Calculo do n2 em função da porcentagem de alumínio na liga e do lambda segundo o site *)
  A02 =6.3+19.0*x2;
  B02=9.4-10.2*x2;
  E02=1.425+1.155*x2+0.37*x2^2;
  E0D02=1.765+1.115*x2+0.37*x2^2;
  y2=h*c/(l*E02);
  y02=h*c/(l*E0D02);
  f2=(2-Sqrt[1+y2]-Sqrt[1-y2])/(y2^2);
  f02=(2-Sqrt[1+y02]-Sqrt[1-y02])/(y02^2);
  n2=Sqrt[A02*(f2+(f02/2)*(E02/E0D02)^(3/2))+B02];
  (* Assim, procede-se da mesma forma que foi feito para o arquivo antigo do mathematica no caso
  planar, que é a forma geometrica analisada *)
  Clear[neff];
```

```

k0=2*pi/1;(*Cálculo do número de onda*)
nef=FindRoot[k0*Sqrt[n2^2-neff^2]*w 2*ArcTan[(Sqrt[neff^2-n1^2])/(Sqrt[n2^2-
neff^2])],{neff,n1+tol,n2-tol}];
neff=nef[[1]][[2]];
kx=k0*Sqrt[n2^2-neff^2];(*Cálculo da constante de propagação no núcleo do guia*)
ax=k0*Sqrt[neff^2-n1^2];(*Cálculo da constante de propagação no substrato*)
kz=k0*neff;(*Cálculo da constante efetiva de propagação*)
c0=(ax*kx^2*Exp[-ax*d])/(kz*(w/2)*(1+2/(ax*w))*(ax^2+kx^2));
Lc=pi/(2*c0);
Print[d/um, " ",w/um, " ",l/um, " ",x1, " ",x2, " ",Lc 1000],
{i,1,300,1}]

```

Código da rede neural no MATLAB® para o acoplador planar com guias de AlGaAs

```

clear all
clc
format long;
rand('seed',1);
load dados_planar_Al
x=entrada_planar_treino;
y=saida_planar_treino;
intervalo=[minmax(x)];
neuronios=[8 1];
net=newff(intervalo,neuronios,{'tansig' 'purelin'});
net.trainParam.epochs=5000;
net.trainParam.goal=3e-8;
net.trainParam.min_grad=1e-9;
[net,tr]=train(net,x,y);
%a) Validação:
ynet=sim(net,x(:,1:100));
comparando=[10*10.^(3*y(1,1:100)) 10*10.^(3*ynet')]
disp('Erro quadratico medio dos valores treinados:')
eqm=sum((10*10.^(3*y(1,1:100))-10*10.^(3*ynet)).^2)/100
%b)Teste da RNA:
ynet=sim(net,entrada_planar_teste);
comparando=[10*10.^(3*saida_planar_teste') 10*10.^(3*ynet')]
disp('Erro quadratico medio dos novos valores:')
eqm=sum((10*10.^(3*saida_planar_teste)-10*10.^(3*ynet)).^2)/100
figure(1)
x=[0 3];
y=x;
plot(10*10.^(3*ynet),10*10.^(3*saida_planar_teste),'b',x,y,'k')
xlabel('Saida da Rede Neural em milimetros.')
ylabel('Saída Desejada em milimetros.')
grid on
pesos1=net.IW{1,1};
pesos2=net.LW{2,1};
bias1=net.b{1};
bias2=net.b{2};

```

Anexo III

Código do *Mathematica*® para gerar os dados do acoplador baseado em fibras ópticas.

```
ClearAll["Global`*"];
um=0.000001;
pi=Pi//N;
tol=0.000000000001;
i=1;
Do[lambda;
  l=lambda/um;
  (*SiO2*)
  a1=0.696750;
  l1=0.069066;
  a2=0.408218;
  l2=0.115662;
  a3=0.890815;
  l3=9.900559;
  nsio2 = Sqrt[1 + a1*l^2/(1^2-l1^2) + a2*l^2/(1^2-l2^2) + a3*l^2/(1^2-l3^2)];
  n2=nsio2;
  (*13.5%GeO2,86.5%SiO2*)
  a21=0.711040;
  a22=0.451885;
  a23=0.704048;
  l21=0.064270;
  l22=0.129408;
  l23=9.425478;
  nsige = Sqrt[1 + a21*l^2/(1^2-l21^2) + a22*l^2/(1^2-l22^2) + a23*l^2/(1^2-l23^2)];
  n1=nsige;
  Do[a;
    Clear[neff];
    k0=2*pi/lambda;
    u=a*k0*Sqrt[n1^2-neff^2];
    w=a*k0*Sqrt[neff^2-n2^2];
    nef=FindRoot[u*BesselJ[1,u]/BesselJ[0,u]-w*BesselK[1,w]/BesselK[0,w] 0,{neff,n1-tol,n2+tol}];
    neff=nef[[1]][[2]];
    V=a*k0*Sqrt[n1^2-n2^2];
    ww=a*(0.65+1.619*V^-1.5+2.879*V^-6);
    Do[d;
      c0=(lambda*u^2*BesselK[0,w*(d/a)]/(2*pi*a^2*n1*V^2*BesselK[1,w]^2);
      Lc=pi/(2*c0);
      Print[d/um," ",a/um," ",l," ",n1," ",n2," ",V," ",neff," ",Lc/um],
        {d,2.1 a ,4.6 a,0.5 um}},
        {a,1.5 um,2.0 um,0.1 um}},
        {lambda,1.3 um,1.6 um,0.05 um}]
```

Código da rede neural no MATLAB® para o acoplador baseado em fibras ópticas

```
clear all
clc
format long;
rand('seed',1);
% dados de entrada
load dadosfibrad %arquivo com os dados de treinamento e teste
x=entrada;
y=saida;
Range_entrada = [minmax(x)];
Qte_neuron = [10 1];
% Função que cria a rede
net=newff(Range_entrada, Qte_neuron,{'logsig' 'poslin'});
% Parametros do Treinamento
net.trainParam.epochs =20000;
net.trainParam.goal = 1e-8;
[net,tr] = train(net,x',y');
% Validar a rede
% a) Validando com os dados de treinamento
ynet = sim(net, x(1:70,:)); % Saida calculada pela RNA
comparar=[y(1:70) ynet']
disp('Erro Médio Quadrático com os dados de treinamento')
ErMQ=sum((y(1:70)-ynet').^2)/70
% b) Testando a rede com dados novos
ynet = sim(net, entradav'); % Saida calculada pela RNA
comparar=[saidav ynet']
%grafico dos valores obtidos vs valores pretendidos
figure(1)
plot(ynet,saidav,'*b')
xlabel('Saida da Rede Neural')
ylabel('Saída Desejada')
grid on
disp('Erro Médio Quadrático com novos dados')
ErMQ=sum((saidav-ynet').^2)/70
```

Anexo IV

Código da rede neural no MATLAB® para PCF

```
clear all
clc
format long;
rand('seed',1);
% dados de entrada
load redelaop(1) %arquivo com os dados de treinamento e teste
x=entrada;
y=saida;
Range_entrada = [minmax(x')];
Qte_neuron = [7 23 1];
% Função que cria a rede
net=newff(Range_entrada, Qte_neuron,{'tansig' 'tansig' 'purelin'});
% Parametros do Treinamento
net.trainParam.epochs =20000;
net.trainParam.goal = 1e-8;
[net,tr] = train(net,x',y');
% Validar a rede
% a) Validando com os dados de treinamento
ynet = sim(net, x(1:70,:)); % Saida calculada pela RNA
comparar=[y(1:70) ynet']
disp('Erro Médio Quadrático com os dados de treinamento')
ErMQ=sum((y(1:70)-ynet').^2)/70
% b) Testando a rede com dados novos
%novavalidacao
ynet = sim(net, entradav'); % Saida calculada pela RNA
comparar=[saidav ynet']
%grafico dos valores obtidos vs valores pretendidos
figure(1)
plot(ynet,saidav,'*b')
xlabel('Saida da Rede Neural')
ylabel('Saida Desejada')
grid on
disp('Erro Médio Quadrático com novos dados')
ErMQ=sum((saidav-ynet').^2)/70
```