



Universidade Federal do Rio Grande do Norte
Centro de Tecnologia
Programa de Pós-Graduação em Engenharia Elétrica
e de Computação



Síntese de Superfícies Seletivas de Frequência Através de Técnicas de Computação Natural

Wellington Candeia de Araujo

Orientador: Prof. Dr. Adaildo Gomes d'Assunção

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação (área de concentração: Telecomunicações) como parte dos requisitos para obtenção do título de Doutor em Ciências.

Número de ordem PPgEEC: D112
Natal, RN, março de 2014

UFRN / Biblioteca Central Zila Mamede.
Catalogação da Publicação na Fonte

Araujo, Wellington Candeia de.

Síntese de superfícies seletivas de frequência através de técnicas de computação natural / Wellington Candeia de Araujo. – Natal, RN, 2014.
81 f.: il.

Orientador: Prof. Dr. Adaildo Gomes d'Assunção.

Tese (Doutorado) – Universidade Federal do Rio Grande do Norte.
Centro de Tecnologia. Programa de Pós-Graduação em Engenharia Elétrica e de Computação.

1. Algoritmos genéticos – Tese. 2. Redes neurais artificiais – Tese.
3. Superfícies seletivas de frequência – Tese. 4. Otimização – Tese.
5. Computação natural – Tese. I. D'Assunção, Adaildo Gomes.
II. Universidade Federal do Rio Grande de Norte. III. Título.

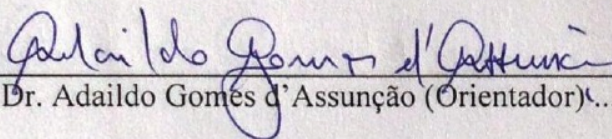
RN/UF/BCZM

CDU 004.421

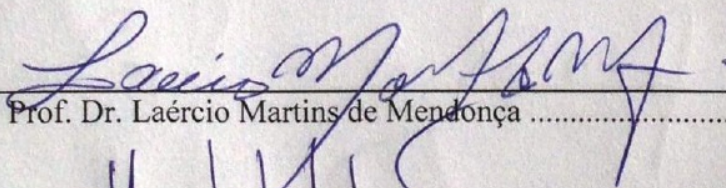
Síntese de Superfícies Seletivas de Frequência Através de Técnicas de Computação Natural

Wellington Candeia de Araujo

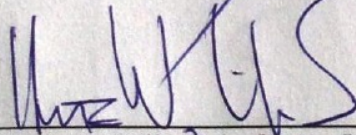
Tese de doutorado aprovada em 17 de Março de 2014 pela banca examinadora
composta dos seguintes membros:



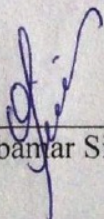
Prof. Dr. Adaildo Gomes d'Assunção (Orientador).....UFRN



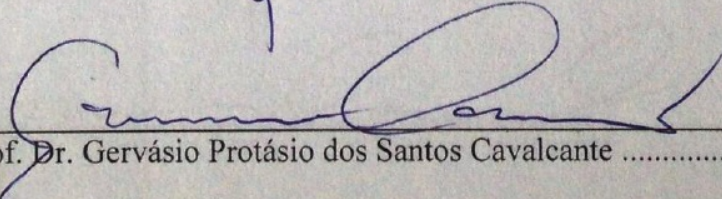
Prof. Dr. Laércio Martins de MendonçaUFRN



Prof. Dr. Hertz Wilton de Castro LinsUFRN



Prof. Dr. José de Ribamar Silva OliveiraIFRN



Prof. Dr. Gervásio Protásio dos Santos CavalcanteUFPA

Para minha Família.

Agradecimentos

Agradeço a Deus por viver e ter a possibilidade de aprender.

Aos meus pais por tudo que eles fazem pelo melhor da Família.

Aos meus irmãos por compartilhar da união e companheirismo.

À Bruna por sua paciência, companheirismo e sabedoria.

Ao meu orientador, Professor Dr. Adaildo Gomes d'Assunção, por todo o apoio, ajuda e visão; por seu imenso conhecimento compartilhado e humildade. Por ajudar a transformar sonhos em realidade. Sou muito grato.

Ao Professor Dr. Laércio Martins de Mendonça e ao Professor Dr. Ribamar por suas contribuições durante o trabalho e qualificação.

Aos Professores do INP/ENSEEIH/LAPLACE (Laboratoire Plasma et Conversion d'Energie) Henri Baudrand e Nathalie Raveu por toda paciência, ajuda e compreensão no período em que trabalhamos juntos.

Aos amigos Albanisa, Clarissa, Leilane, Jannayna, Chiquinho, Diego, Hertz, Marcelo, Robson.

Aos amigos do LAPLACE, Adnan, Ahmad, Bilel, Latifa, Luciana, Mustafa e Ounis.

Aos funcionários do PPgEEC, Prof. Luiz Marcos, Paulo Yvens e Santana.

Ao INCT-CSF (Instituto Nacional de Ciência e Tecnologia de Comunicações Sem Fio) pelo suporte e estrutura.

À UEPB por disponibilizar o tempo para capacitação.

À CAPES, pelo apoio financeiro durante o período no exterior.

A todos que não pude citar, mas que me apoiaram e contribuíram.

Resumo

A superfície seletiva de frequência (FSS) tem sido objeto de intensa pesquisa nas duas últimas décadas, sendo utilizada em diversas aplicações que vão desde sistemas de micro-ondas e antenas até aplicações em *radomes* e comunicações via satélite. Uma superfície seletiva de frequência é um arranjo periódico que se constitui de elementos dos tipos *patch*, abertura, ou combinações de *patch* e abertura, e exibe reflexão, ou transmissão, total na frequência ressonante, comportando-se dessa maneira como um filtro rejeita-faixa, ou passa-faixa. A necessidade de estruturas com comportamento eletromagnético adequado em dispositivos de micro-ondas tem sido estudada pelos pesquisadores da área. Essas estruturas requerem, em sua análise de características espectrais, técnicas rigorosas e elevada complexidade computacional em sua implementação. Estas estruturas são complexas requerendo uma análise por técnicas de onda completa, como o método dos momentos (MoM), o método das diferenças finitas no domínio do tempo (FDTD) ou o método dos elementos finitos (FEM). Para superar o esforço computacional relacionado ao tempo de processamento das técnicas de onda completa, podem ser utilizadas como alternativa as técnicas de computação natural. Algumas características como robustez, generalização, adaptabilidade e rápida convergência contribuem para o aumento significativo do emprego destas técnicas em aplicações na área de comunicações móveis. Os modelos neurocomputacionais desenvolvidos para as FSS fornecem excelentes resultados e em concordância com valores obtidos através de medições em laboratório. Neste trabalho, é realizada uma investigação numérica e experimental, consistindo do projeto, simulação, construção e medição de estruturas de FSS. Esta tese aborda o projeto de FSS através de redes neurais artificiais e outros algoritmos de computação natural selecionados, com aplicações na faixa de micro-ondas. A precisão dessa técnica é investigada experimentalmente e comparada com simulações efetuadas pelos softwares comerciais *Ansoft Designer* e *Ansoft HFSS* utilizados na análise numérica do comportamento eletromagnético das FSS através do Método dos Momentos e do Método dos Elementos Finitos, respectivamente. É realizado um estudo teórico das FSS, bem como um estudo das redes neurais artificiais, algoritmos genéticos e outros algoritmos de otimização natural (vaga-lumes e morcegos). Particularmente, é efetuada a otimização de estruturas de FSS através de algoritmos genéticos contínuos, além de dois

novos algoritmos mais recentes, “o de morcegos” e “o de vaga-lumes”, que se mostraram precisos e eficientes quando comparados com outras técnicas ou medições. Isto se constitui uma das contribuições desta tese. São apresentadas propostas para a continuidade deste trabalho.

Palavras-chaves: Algoritmos Genéticos, Redes Neurais Artificiais, Superfícies Seletivas de Frequência, Otimização, Computação Natural.

Abstract

The frequency selective surfaces have been the subject of research widely applied in the two last decades and are used in diverse applications ranging from microwave and antenna systems to applications in radomes and satellite communications. A frequency selective surface is a periodic array of elements which consists of metallic *patches* or apertures, or even a combination of both, and displays the total reflection or transmission at the resonant frequency, thus behaving as a stop band or pass band filter. The need for structures with electromagnetic behavior suitable for microwave devices has been widely studied by researchers. These structures require, in the analysis of his spectral characteristics, accurate techniques and high computational complexity in their implementation. These FSS are investigated numerically and experimentally and their electromagnetic characteristics are simulated and measured using computer programs, optimization techniques and equipments. These structures are quite complex demanding an analysis by full-wave techniques, such as the method of moments (MoM), the finite difference time domain (FDTD), or finite element method (FEM). To overcome the computational and time costs of full-wave techniques, natural computing techniques may be used as an alternative. Some characteristics such as robustness, generalization, adaptability and fast convergence contribute to the significant increase in the use of these techniques in applications in mobile communications. The developed neurocomputational models for FSS analysis provide excellent results that are in agreement with measured results. In this work, a numerical and experimental investigation, consisting of design, computational simulation, construction and measurement of FSS structures is performed. This thesis addresses the design of FSS through artificial neural networks and other selected natural computing algorithms, with applications in microwaves. The accuracy of this technique is experimentally carried out and compared with simulations made by the commercial software *Ansoft Designer* and *Ansoft HFSS*, used in the numerical analysis of the electromagnetic behavior of FSS by the Method of Moments and Finite Element Method (FEM), respectively. A literature review on the theory of FSS is performed, as well as the study of artificial neural networks, genetic algorithms and other natural optimization algorithms (firefly and bat). In particular, the optimization of FSS structures is performed through continuous genetic algorithms, and two new algorithms, "bat" and

"fireflies", which proved accurate and efficient when compared by other techniques or measurements. This constitutes one of the contributions of this research. This study also explores the solution of the appropriate architecture network design, training algorithms, parameters of the algorithms as the number of neurons in layers and number of layers in networks, as well as the parameters and functions suitable for natural optimization algorithms. Proposals for the continuity of this study are presented.

Word-keys: Genetic Algorithms, Artificial Neural Networks, Frequency Selective Surfaces, Optimization, Natural Computing.

SUMÁRIO

Resumo	vi
Abstract	viii
Lista de Figuras	xii
Lista de Tabelas	xiv
Lista de Símbolos e Abreviaturas.....	xv
Capítulo 1 Introdução	17
Capítulo 2 Superfícies Seletivas de Frequência	20
2.1 FSS e Aplicações	20
2.2 Representação Geométrica dos Elementos de FSS.....	22
2.3 Técnicas de Análise	25
2.4 Síntese do Capítulo	26
Capítulo 3 Computação Natural	27
3.1 Introdução a Computação Natural	27
3.2 Redes Neurais Artificiais	29
3.2.1 Redes Perceptron de Multicamadas	31
3.2.2 Treinamento em Redes Neurais Artificiais	32
3.3 Algoritmos Genéticos	33
3.3.1 Principais Parâmetros dos Algoritmos Genéticos	36
3.4 Algoritmo Baseado na Bioluminescência de Vaga-lumes (<i>Firefly Algorithm</i>).....	37
3.4.1 Principais Parâmetros do Algoritmo de Vaga-lume.....	39
3.5 Algoritmo de Ecolocalização de Morcegos (<i>Bat Algorithm</i>).....	42

3.5.1 Principais Parâmetros do Algoritmo de Morcego	44
3.6 Síntese do Capítulo	45
Capítulo 4 Resultados.....	46
4.1 Apresentação do Modelo	46
4.2 FSS Circular com Anéis Integrados e Elementos Dipolos Centralizados	48
4.3 Aplicação do Algoritmo Genético	52
4.4: Aplicação do Algoritmo Bioinspirado em Vaga-lume	57
4.5: Aplicação do Algoritmo de Ecolocalização de Morcego	62
4.6 Comparativo entre as Técnicas	67
4.7 Síntese do Capítulo	72
Capítulo 5 Conclusões	73
Referências Bibliográficas	75

Lista de Figuras

Figura 2.1: Aplicações de FSS. (a) Na atividade aeronáutica. (b) Na navegação marítima.....	21
Figura 2.2: FSS atuando como sub-refletor para sistema Cassegrain.	22
Figura 2.3: Formas geométricas de elementos de FSS.....	23
Figura 2.4: FSS com elementos do tipo espira integrada com dipolo.	24
Figura 2.5: Ilustração do <i>setup</i> experimental.....	25
Figura 3.1: Abordagens da Computação Natural.	28
Figura 3.2: Representação funcional de um neurônio artificial.....	30
Figura 3.3: Topologia genérica de uma rede MLP.....	31
Figura 3.4: Fluxograma do processo de execução de um algoritmo genético.....	34
Figura 3.5: Pseudocódigo para o algoritmo de vaga-lume.	39
Figura 3.6: Pseudocódigo do algoritmo de morcego.....	43
Figura 4.1: Visão geral de um projeto de FSS.....	47
Figura 4.2: Fluxograma da proposta de otimização.	48
Figura 4.3: FSS de espiras integradas com dipolos. (a) Célula unitária. (b) Geometria do arranjo.....	49
Figura 4.4: Modelo da rede Perceptron multicamada.....	50
Figura 4.5: Resposta da rede MLP (generalização) para a largura de banda em função dos parâmetros geométricos W e t	51
Figura 4.6: Resposta da rede MLP (generalização) para a frequência de ressonância em função dos parâmetros geométricos W e t	51
Figura 4.7: Fluxograma do algoritmo genético.	52
Figura 4.8: Resultados medidos e simulados do coeficiente de transmissão versus frequência da FSS otimizada para $f_r = 11,0$ GHz e $BW = 3$ GHz. Parâmetros estruturais: $\epsilon_r = 4,4$, $h = 1,5$ mm, $t = 15,0$ mm, $W = 1,999$ mm, $R = 6,0$ mm e $r = 3,13$ mm.....	55
Figura 4.9: Avaliação do ótimo global durante as iterações.....	56
Figura 4.10: Resultados medidos e simulados do coeficiente de transmissão versus frequência da FSS otimizada para $f_r = 9$ GHz e $BW = 3$ GHz. Parâmetros estruturais: $\epsilon_r = 4,4$, $h = 1,5$ mm, $t = 22,66$ mm, $W = 1,5$ mm, $R = 6,0$ mm e $r = 3,13$ mm.....	57
Figura 4.11: Fluxograma do algoritmo de vaga-lume proposto.	58

Figura 4.12: Resultados medidos e simulados do coeficiente de transmissão versus frequência da FSS otimizada para $f_r = 11,0$ GHz e $BW = 3$ GHz. Parâmetros estruturais: $\epsilon_r = 4,4$, $h = 1,5$ mm, $t = 15,0$ mm, $W = 2,0$ mm, $R = 6,0$ mm e $r = 3,13$ mm.....	60
Figura 4.13: Avaliação do ótimo global durante as iterações.....	61
Figura 4.14: Resultados medidos e simulados do coeficiente de transmissão versus frequência da FSS otimizada para $f_r = 9,0$ GHz e $BW = 0,6$ GHz. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,5$ mm, $t = 22,48$ mm, $W = 1,5$ mm, $R = 6,0$ mm e $r = 3,13$ mm.....	62
Figura 4.15: Fluxograma do algoritmo de ecolocalização de morcego proposto.....	63
Figura 4.16: Resultados medidos e simulados do coeficiente de transmissão versus frequência da FSS otimizada para $f_r = 11$ GHz e $BW = 3$ GHz. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,5$ mm, $t = 15,0$ mm, $W = 2,0$ mm, $R = 6,0$ mm e $r = 3,13$ mm.....	65
Figura 4.17: Avaliação do ótimo global durante as iterações.....	66
Figura 4.18: Resultados medidos e simulados do coeficiente de transmissão versus frequência da FSS otimizada para $f_r = 9,0$ GHz e $BW = 0,6$ GHz. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,5$ mm, $t = 22,48$ mm, $W = 1,5$ mm, $R = 6,0$ mm e $r = 3,13$ mm.....	67
Figura 4.19: Superfície de contorno com o percurso para os três algoritmos. (a) Início e fim dos percursos dos algoritmos de busca baseados nas melhores soluções encontradas sobre a função custo. (b) Aproximação da vista superior do gráfico.	69
Figura 4.20: Evolução da função custo para os três algoritmos implementados.....	70
Figura 4.21: Superfície de contorno com o percurso para os três algoritmos. (a) Início e fim dos percursos dos algoritmos de busca baseados nas melhores soluções encontradas sobre a função custo. (b) Aproximação da vista superior do gráfico.	71

Lista de Tabelas

Tabela 3.1: Principais termos dos algoritmos genéticos.....	35
Tabela 3.2: Parâmetros e definições do algoritmo bioinspirado em vaga-lumes	38
Tabela 4.1: Parâmetros da FSS de espiras integradas com dipolos.....	49
Tabela 4.2: Resultados otimizados para a FSS de espiras integradas com dipolos através de algoritmo genético e rede neural artificial.....	54
Tabela 4.3: Resultados otimizados para a FSS de espiras integradas com dipolos através de algoritmo de vaga-lume e rede neural artificial.....	59
Tabela 4.4: Resultados otimizados para a FSS de espiras integradas com dipolos através de algoritmo de morcego e rede neural artificial.....	64
Tabela 4.5: Comparação dos resultados dos algoritmos.....	72

Lista de Símbolos e Abreviaturas

α	Constante de <i>momentum</i> da rede neural artificial / Elemento de aleatoriedade do algoritmo de vaga-lume
β	Atratividade
γ	Coefficiente de absorção
Δ	Valor de atualização dos pesos sinápticos
f_r	Frequência de ressonância
ϵ_r	Permissividade elétrica relativa
η	Coefficiente de aprendizagem
Γ	Coefficiente de reflexão
λ	Comprimento de onda
∇	Gradiente
θ	Bias
I	Entrada da rede neural
O	Saída da rede neural
S_{21}	Coefficiente de Transmissão
h	Altura do substrato
t	Periodicidade da FSS
W	Largura do dipolo
AG	Algoritmo Genético (<i>Genetic Algorithm</i>)
ANN	Rede Neural Artificial (<i>Artificial Neural Network</i>)
BAT	Algoritmo baseado na Ecolocalização de Morcegos (<i>Bat Algorithm</i>)
BW	Largura de banda (<i>bandwidth</i>)
FDTD	Método das Diferenças Finitas no Domínio do Tempo (<i>Finite-Difference Time Domain</i>)
FEM	Método dos Elementos Finitos (<i>Finite Element Method</i>)
FFA	Algoritmo de Vaga-Lume (<i>Firefly Algorithm</i>)
FSS	Superfície Seletiva de Frequência (<i>Frequency Selective Surface</i>)
HFSS	<i>High Frequency Structural Simulator</i>
MLP	Perceptron de Multicamadas (<i>Multilayer Perceptron</i>)

MoM	Método dos Momentos (<i>Method of Moments</i>)
PSO	Otimização por Enxame de Partículas (<i>Particle Swarm Optimization</i>)
Radome	<i>Radar Antenna Dome Cover</i>
RNA	Rede Neural Artificial
WCIP	<i>Wave Concept Iterative Process</i>

Capítulo 1

Introdução

As aplicações em comunicações móveis evoluem rapidamente, demandando frequentemente novos projetos de estruturas que funcionem de maneira satisfatória, como diferentes modelos de antenas de microfita e superfícies seletivas de frequência (FSS), por exemplo. Diversas características dessas estruturas são requeridas, como: funcionamento em uma ou mais frequências, miniaturização, compatibilidade eletromagnética, novos materiais dielétricos, etc. O projeto dessas estruturas envolve o estudo dos parâmetros físicos para obter características de funcionamento desejadas. Para esse desenvolvimento, geralmente há o processo de tentativa e erro, onde a experiência do pesquisador é considerada um fator importante para o sucesso do projeto.

A análise de superfícies seletivas de frequência para aplicações em micro-ondas é caracterizada por um alto custo computacional e de tempo, na definição das geometrias, o que envolve uma variedade de formatos, dimensões e periodicidade dos elementos. Para o cálculo dessas estruturas é necessário utilizar uma análise numérica precisa, mas com custo de tempo elevado, através de técnica de onda completa como o método dos elementos finitos, o método dos momentos, o método das diferenças finitas no domínio do tempo, etc. [1], [2].

Neste contexto, algoritmos de computação natural, como algoritmos genéticos, têm sido aplicados com sucesso no desenvolvimento e otimização dessas estruturas de micro-ondas [3]. Os métodos híbridos que usam simultaneamente técnicas como, por exemplo, variações de algoritmos genéticos (AG), redes neurais artificiais (RNA) ou otimização com enxame de partículas (PSO) também são utilizados em cenários de otimização. Algumas características como robustez e flexibilidade de projeto

contribuem para o aumento significativo do emprego destas técnicas em aplicações na área de micro-ondas [4]-[6].

Otimização, basicamente, é o processo de minimizar o esforço requerido ou maximizar a vantagem desejada no projeto [7]. Ela pode ser definida como o processo de buscar soluções que resultem no valor mínimo ou máximo de uma função denominada função objetivo, que é a função que representa o objetivo a ser alcançado no projeto. Métodos de otimização são utilizados com sucesso em problemas distribuídos em áreas diversas, tais como: engenharia, matemática, inteligência artificial, biologia, etc.

Nas últimas décadas, os métodos de otimização têm sido aplicados também no projeto de estruturas planares na área de micro-ondas, como antenas e FSS [3]-[6]. Geralmente estes métodos buscam auxiliar no projeto destas estruturas, seja acelerando o processo do desenvolvimento do projeto, seja melhorando características físicas tais como ganho, largura de banda e diagrama de radiação em antenas, ou geometrias mais adequadas para o projeto, reduzindo as dimensões de antenas e FSS, por exemplo.

Esta tese apresenta a definição e a implementação do processo de otimização em FSS, com o projeto de uma rede neural artificial trabalhando em conjunto com algoritmos de computação natural. O processo de otimização tem o objetivo de identificar dimensões geométricas adequadas para que as FSS possam ser utilizadas em frequências específicas e com larguras de banda adequadas. O resultado obtido no processo de otimização foi comparado com o resultado de softwares comerciais mais utilizados na área, com o resultado das medições das estruturas utilizadas e, ainda, com o resultado de método numérico conhecido como WCIP [8], [9].

Basicamente, o WCIP é um método de onda completa baseado na incidência de uma onda plana e seu espalhamento nos meios situados nos dois lados de uma interface localizada entre dois dielétricos. As principais vantagens desta técnica iterativa são a capacidade de analisar circuitos planares de geometrias complexas, habilidade de trabalhar com estruturas de multicamadas, facilidade de implementação e rapidez na execução [8]. Nesta tese, os resultados do WCIP são utilizados para validar os resultados obtidos pelos algoritmos híbridos de otimização implementados e os resultados das medições.

Adicionalmente, os resultados da otimização executada pelos algoritmos híbridos são utilizados para o projeto e construção dos protótipos das estruturas FSS, para validação das técnicas de otimização. Os resultados das medições também são comparados com os resultados das técnicas híbridas e com os resultados do WCIP. Esta comparação é efetuada para a frequência e largura de banda da FSS otimizada. Observa-se que as técnicas híbridas apresentam resultados coerentes, de acordo com os resultados das simulações e medições.

Este documento está organizado da seguinte forma:

O capítulo 2 apresenta um breve estudo sobre superfícies seletivas de frequência. São demonstradas algumas aplicações das FSS e apresentadas as formas geométricas mais comuns dos seus elementos. As principais técnicas de análise são descritas e comentadas.

No capítulo 3, tem-se uma descrição das principais técnicas de otimização desenvolvidas neste trabalho utilizando inteligência computacional. São apresentados os algoritmos selecionados, suas descrições e estruturas.

No capítulo 4, são apresentados os resultados obtidos com as técnicas desenvolvidas neste estudo. É feita a descrição das técnicas híbridas implementadas para a otimização das FSS. São apresentados e discutidos os resultados obtidos. Também é feita uma discussão sobre as limitações e vantagens das técnicas propostas.

Finalmente, no capítulo 5 são indicadas as conclusões principais desta tese. Sugestões de trabalhos futuros são apresentadas para a continuidade da pesquisa.

Capítulo 2

Superfícies Seletivas de Frequência

2.1 FSS e Aplicações

Uma superfície seletiva de frequência é um arranjo periódico de *patches* ou aberturas, que pode exibir um determinado comportamento de filtragem de frequência. Este comportamento de filtragem, ou sua seletividade em frequência, é alcançado no projeto da estrutura e permite a reflexão ou a transmissão de sinais em uma determinada faixa de frequência. Aplicações comuns de FSS envolvem projetos de melhoria de compatibilidade eletromagnética, prevenção de interferência eletromagnética entre duas antenas operando em conjunto, redução de ruído em radar, ou mesmo tornar uma antena mais resistente às variações climáticas e aumentar a largura de banda de arranjos de antenas, por exemplo [1]-[11].

O projeto e a análise de FSS têm sido temas frequentes nas duas últimas décadas, tendo destaque na literatura científica, com o desenvolvimento de FSS com diversas geometrias, através de técnicas e materiais diversos.

Na história do desenvolvimento das FSS, têm-se os *radomes* (*radar antenna dome covers*), que são os precursores das FSS. São estruturas que circundam ou são dispostas próximas das antenas para protegê-las de intempéries, choques mecânicos, entre outros fatores que possam danificar as antenas ou gerar interferências eletromagnéticas.

Estruturas periódicas como as FSS podem ser projetadas para que sejam transparentes em certas faixas de frequência, e opacas em outras faixas, como por exemplo, em aplicações navais [12]-[13] ou espaciais [14]-[17] como ilustrado na Figura 2.1 [1]. Na Figura 2.1 (a), uma FSS cônica é acoplada à parte dianteira da aeronave, circundando a antena do radar e na Figura 2.1 (b), uma FSS planar é montada no mastro de um navio, protegendo também a antena do radar. Nestes exemplos, a FSS é projetada para ser transparente apenas ao sinal para

o qual a antena opera. A onda eletromagnética incidente fora da banda é refletida com um determinado ângulo de resposta.

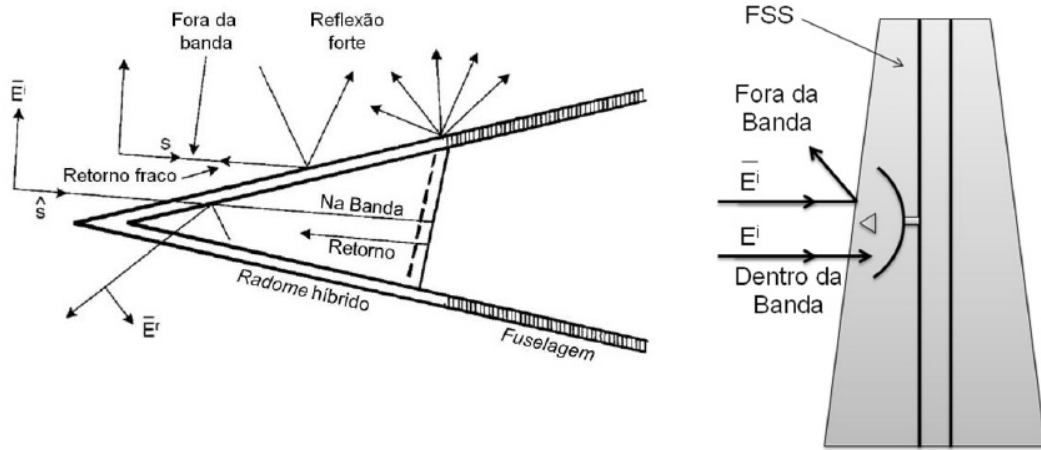


Figura 2.1: Aplicações de FSS. (a) Na atividade aeronáutica. (b) Na navegação marítima.

FSS são utilizadas também no projeto de absorvedores e refletores dicróicos, como em um sistema Cassegrain [1], por exemplo, onde o sub-refletor é uma estrutura dicróica o qual é uma estrutura periódica transparente em uma determinada banda de frequência e opaca em outra banda de frequência. O uso de FSS como sub-refletor faz com que um refletor parabólico possa trabalhar com dois alimentadores ao mesmo tempo. Na Figura 2.2, a superfície dicróica é transparente à frequência f_1 e opaca à frequência f_2 . Isto permite colocar dois alimentadores no ponto focal do refletor principal, operando na frequência f_1 e operando na frequência f_2 , reduzindo dessa maneira, os custos e o espaço para os refletores.




Figura 2.2: FSS atuando como sub-refletor para sistema Cassegrain.

2.2 Representação Geométrica dos Elementos de FSS

Para o estudo de FSS, pode-se encontrar na literatura científica um grande número de trabalhos cujos elementos apresentam formas geométricas diversas. A Figura 2.3 ilustra algumas das formas mais comuns encontradas na literatura para o projeto de FSS: elemento *patch* retangular ou quadrado, dipolo retangular, dipolo cruzado, elemento *patch* em anel, espira quadrada, cruz de Jerusalém, espira quadrada dupla, entre outras formas comumente utilizadas, como a estrutura fractal, por exemplo, e a geometria utilizada neste trabalho, a espira integrada com dipolo




Figura 2.3: Formas geométricas de elementos de FSS.

A Figura 2.4 mostra uma foto dos protótipos de FSS desenvolvidas nesta tese, utilizando a FSS de espira integrada com dipolo, com periodicidade $t = T_x = T_y = 15$ mm, substrato dielétrico FR-4 (fibra de vidro) com permissividade relativa (ϵ_r) igual a 4,4, altura (h) igual a 1,57 mm e tangente de perdas $\delta=0,02$.




Figura 2.4: FSS com elementos do tipo espira integrada com dipolo.

Na Figura 2.5 está ilustrado *setup* experimental utilizado para as medições das estruturas de FSS na incidência normal.

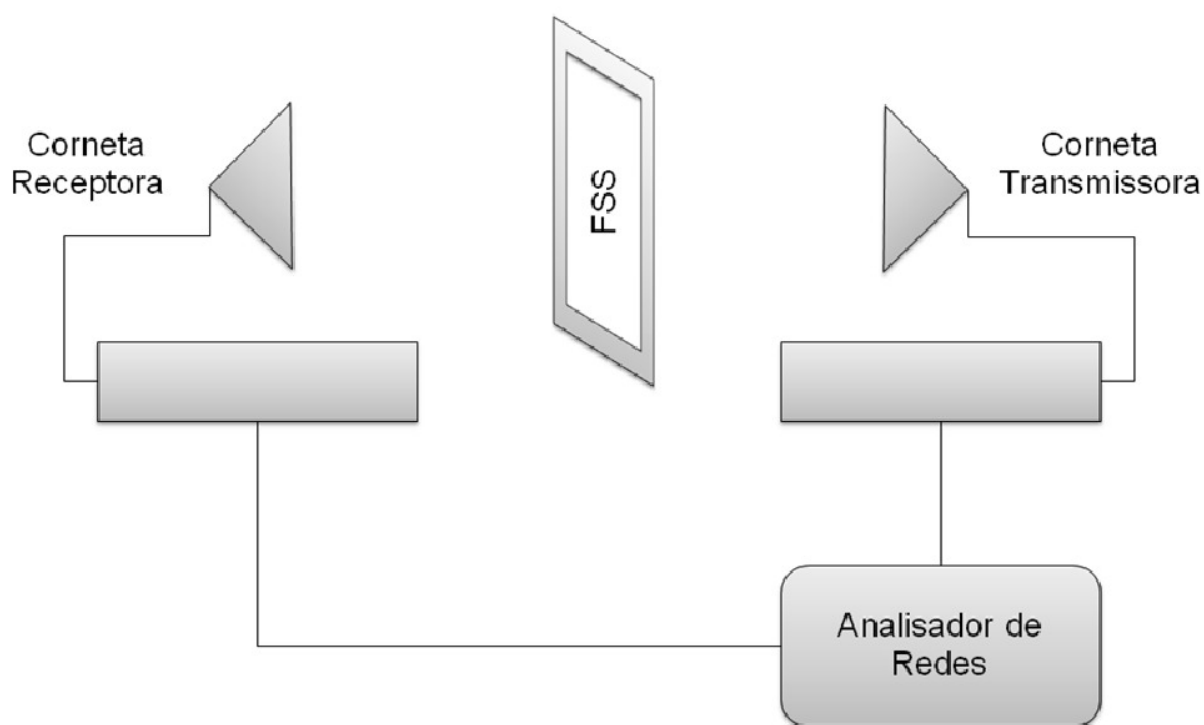


Figura 2.5: Ilustração do *setup* experimental.

2.3 Técnicas de Análise

Com o crescente interesse na pesquisa de estruturas de FSS, houve a necessidade de desenvolver ferramentas que fornecessem resultados precisos, em relação às medições, e que permitissem reduzir o esforço computacional.

Um método menos complexo, geralmente utilizado, com resultados satisfatórios é o modelo do circuito equivalente [18]. Neste modelo, os vários segmentos de fita do arranjo que compõem o elemento *patch* são representados como elementos capacitivos e/ou indutivos, conectados por linhas de transmissão. Com a solução deste circuito, têm-se as informações sobre transmissão e reflexão da FSS. Uma descrição geral desse método está apresentada em [18].

Alguns métodos baseados na discretização espacial como o método dos elementos finitos (*FEM*), o método dos elementos finitos no domínio do tempo [*FDTD*] e o método das ondas (*WCIP*) também são utilizados para analisar e projetar FSS. Nestes métodos, devem-se incorporar em seu cálculo as condições de contorno de paredes periódicas. Assim, o cálculo

deve ser feito a partir de uma única célula, representando toda a estrutura. De acordo com essa representação, a faixa de frequência determinada para a análise e as condições de contorno impostas irão influenciar na precisão do cálculo, dificultando o desenvolvimento do projeto.

O método da equação integral, mais comumente utilizado, é mais preciso. É mais rigoroso em sua formulação, porém uma de suas desvantagens é o elevado custo computacional. Uma descrição detalhada deste método é apresentada em [18].

Algoritmos inspirados em computação natural, como algoritmos genéticos e algoritmo de ecolocalização de morcegos, por exemplo, têm sido utilizados e gerado bons resultados na análise e síntese de FSS e outras aplicações em micro-ondas [19]-[32].

2.4 Síntese do Capítulo

Este capítulo apresentou a fundamentação teórica das FSS consideradas neste trabalho. Os tipos mais comuns de elementos para o projeto de FSS foram apresentados, assim como destacadas suas aplicações principais. Também foram discutidas as principais técnicas de análise numérica.

Capítulo 3

Computação Natural

3.1 Introdução a Computação Natural

A Computação Natural refere-se ao processo computacional de extrair ideias da natureza para desenvolver sistemas computacionais, ou utilizar materiais encontrados na natureza (por exemplo, moléculas) para efetuar a computação [33], [34]. Em sua definição, divide-se em:

- I. **Computação inspirada na natureza:** os programas ou algoritmos dessa categoria baseiam-se nos fenômenos da natureza para desenvolver técnicas de solução de problemas. As técnicas mais comumente utilizadas são: redes neurais artificiais, computação evolucionária e inteligência de enxames.
- II. **Simulação e emulação da natureza por meios computacionais:** nesta categoria as técnicas formulam um processo artificial com o intuito de sintetizar padrões, formas, comportamentos e organismos similares aos que são encontrados na natureza. As técnicas mais comuns incluem a geometria fractal e vida artificial.
- III. **Computação com materiais encontrados na natureza:** corresponde à utilização de novos materiais provenientes da natureza para realizar a computação. Tem o objetivo de substituir ou complementar, através desses novos materiais, computadores baseados em silício. Como exemplos, tem-se a computação quântica e computação com base em DNA.

Por sua natureza multidisciplinar, a Computação Natural envolve conceitos e definições científicas de áreas diversas, além de profissionais de diferentes campos de pesquisa, como biólogos, físicos, químicos, engenheiros, cientistas da computação, entre outros. Essa cooperação torna-se necessária para que os objetivos da Computação Natural sejam alcançados. A integração entre os diversos ramos da ciência pela Computação Natural

seja na investigação experimental ou teórica, observações empíricas da natureza, fatos ou processos, pode ser visualizada na Figura 3.1.

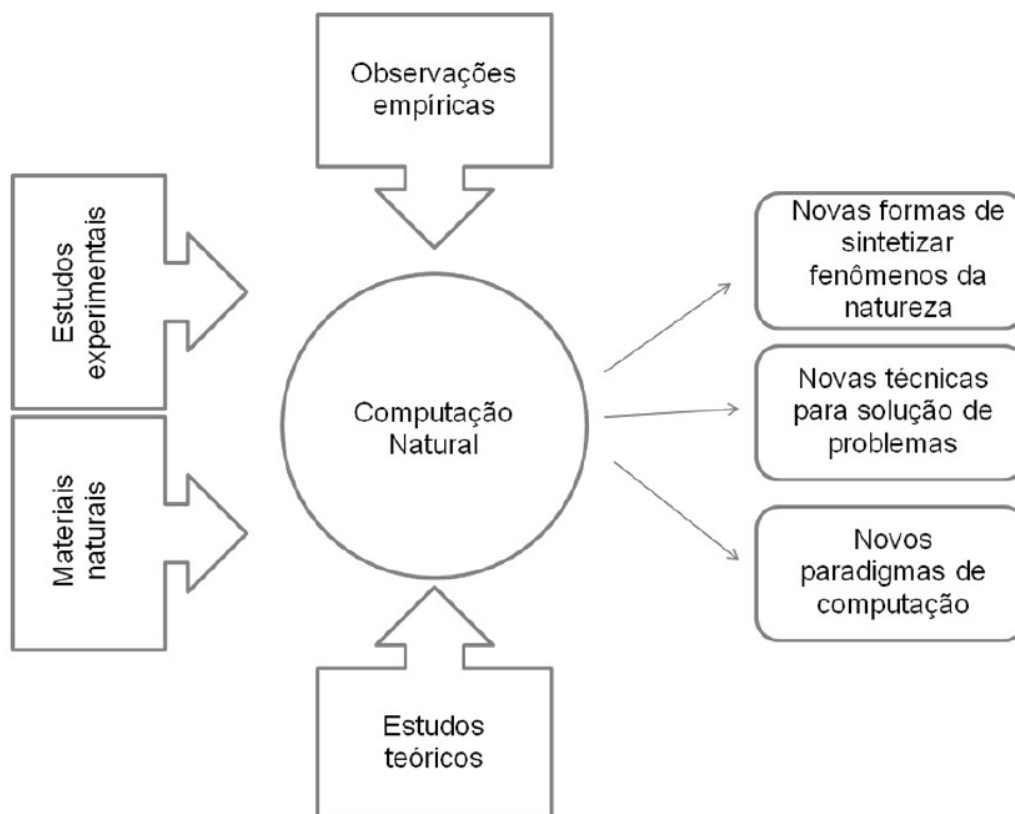


Figura 3.1: Abordagens da Computação Natural.

É importante ressaltar que a Computação Natural em geral trata de modelos simplificados dos processos e mecanismos presentes no fenômeno natural. Esta simplificação torna-se necessária pelo fato de que um grande número de elementos faz parte da computação, na maioria das técnicas utilizadas. Como exemplo, podem ser citadas as redes neurais artificiais, que contêm um conjunto de neurônios para simular o funcionamento do cérebro humano.

3.2 Redes Neurais Artificiais

As redes neurais artificiais fazem parte das técnicas de inteligência computacional e têm sido aplicadas em diversos problemas da engenharia e ciência, tais como: reconhecimento de padrões, otimização, mineração de dados, veículos autônomos, análise de antenas, finanças, entre outros [35].

Essas redes se baseiam na estrutura do cérebro humano e têm o propósito de realizar automaticamente tarefas que só são possíveis com a intervenção humana. Possuem a capacidade de aprendizado a partir de exemplos e a capacidade de generalização de regras gerais que descrevem o problema e assim podem aplicar essas regras subsequentemente a casos não trabalhados anteriormente.

Segundo Haykin em [35], as redes neurais artificiais são processadores maciçamente distribuídos, compostos de unidades de processamento simples, os neurônios, que têm uma tendência natural para armazenar o conhecimento proveniente da experiência através de um processo de aprendizagem. Esse processo de aprendizagem, realizado por um algoritmo de aprendizagem, se assemelha ao cérebro em dois aspectos:

- 1) O conhecimento é extraído do ambiente através de um processo de aprendizagem ou treinamento;
- 2) O conhecimento adquirido é armazenado nos pesos das conexões entre os neurônios (pesos sinápticos).

O neurônio artificial foi desenvolvido inspirado no neurônio biológico. Utilizando do conhecimento das estruturas do neurônio biológico, o modelo matemático foi desenvolvido com a finalidade de reproduzir o comportamento do neurônio humano no que se refere à forma em que ocorre a aquisição de conhecimento.

Os neurônios artificiais são unidades de processamento que formam a estrutura básica de uma rede neural artificial. Cada neurônio constitui-se de entradas, que recebem os estímulos provenientes do ambiente; de uma função de ativação, que realiza a combinação dos valores obtidos nas entradas, e de saídas, que transmitem os estímulos recebidos e processados ao ambiente. Para cada entrada existe um valor denominado peso, que é um valor numérico que determina a força das conexões existentes entre os neurônios. A ativação de um neurônio realiza o somatório de todas as entradas multiplicadas por seus respectivos pesos, denominados de *pesos sinápticos*, acrescido de um valor especial, denominado *bias*. O

resultado obtido no somatório é enviado para uma função de ativação que por sua vez gera a saída resultante.

McCulloch e Pitts [36] apresentaram o primeiro neurônio artificial em 1943. O modelo consiste em um combinador linear com uma função de ativação não linear do tipo degrau (*threshold*). A Figura 3.1 ilustrada abaixo mostra a estrutura funcional de um neurônio artificial.

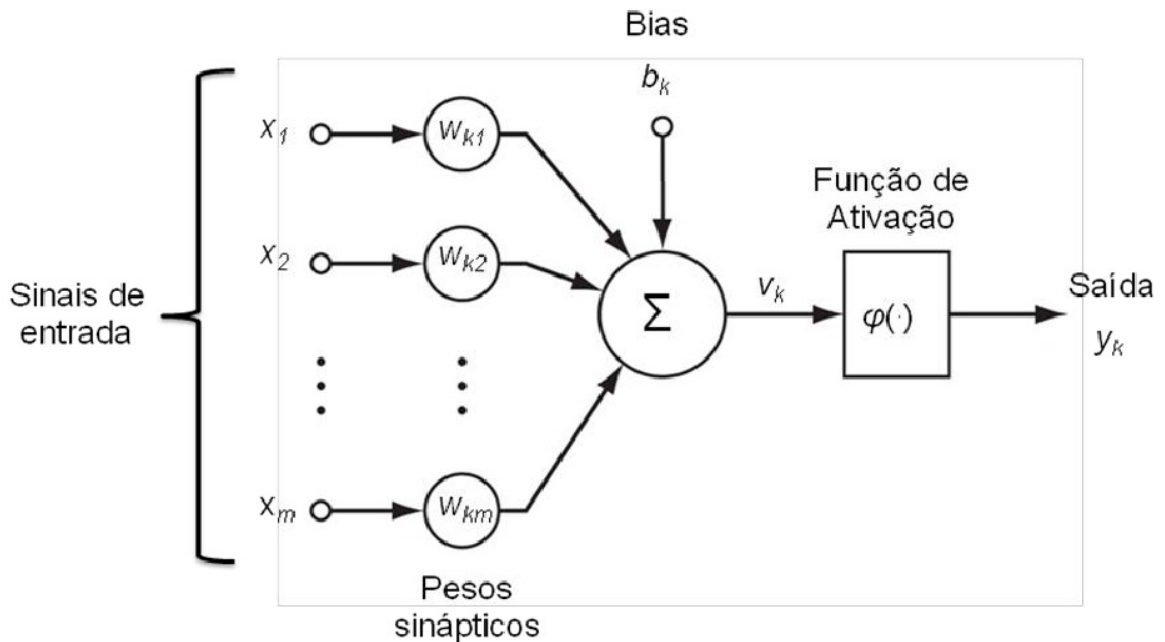


Figura 3.2: Representação funcional de um neurônio artificial.

Cada sinal x_1, x_2, \dots, x_m de entrada é multiplicado por um peso w correspondente e o resultado dessa multiplicação é passado a um somador Σ . Esta soma é avaliada pela função de ativação $\varphi(\cdot)$ e produz a saída final do neurônio y_k . Assim, esta saída pode ser reutilizada por outro neurônio da próxima camada, por exemplo, em uma rede de neurônios.

Nesta tese foi utilizada a rede neural artificial denominada de *perceptron* de multicamadas (do inglês *Multilayer Perceptron* – MLP).

3.2.1 Redes Perceptron de Multicamadas

As redes MLP são um tipo de rede que pertencem a uma classe de estruturas chamadas redes alimentadas diretamente com múltiplas camadas. Nestas redes, os neurônios são agrupados em camadas. Apresentam grande poder computacional de processamento não-linear e armazenagem de informação, devido a inserção de camadas intermediárias, diferente do modelo *Perceptron* original de Rosenblat, que possui apenas um nível de neurônios conectados à camada de saída. Dessa maneira, com o emprego das redes MLP, é possível solucionar problemas do tipo linearmente separáveis, isto é, problemas com padrões em lados opostos de um hiperplano [35].

A primeira e última camadas em redes MLP são usualmente chamadas de camada de entrada e camada de saída, respectivamente. As demais camadas são camadas ocultas, escondidas ou intermediárias. Uma MLP típica consiste em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, como visto na Figura 3.3.




Figura 3.3: Topologia genérica de uma rede MLP.

Cada neurônio numa rede MLP possui uma função de ativação não-linear que é continuamente diferenciável [37]. Existem diversas funções de ativação para redes MLP. As

principais são a função sigmoide, a função a tangente hiperbólica e a função linear, expressas em (3.1 a 3.3), respectivamente:

$$\varphi(net) = \frac{1}{1 + \exp(-net)} \quad (3.1)$$

$$\varphi(net) = \frac{(\exp(net) - \exp(-net))}{(\exp(net) + \exp(-net))} \quad (3.2)$$

$$\varphi(net) = a(net) + b \quad (3.3)$$

A função de ativação é definida com um limiar aplicado ao neurônio, da seguinte forma:

$$net_j = \sum_i w_{ji} \cdot a_i + b_j \quad (3.4)$$

onde b_j é o “bias”, valor especial acrescido a função de ativação, a_i representa os valores de entrada da rede e w_{ji} os pesos, que assim como o bias, são ajustados durante o treinamento.

Neste trabalho, a função utilizada é a tangente hiperbólica para os neurônios da camada oculta e a função linear para os neurônios da camada de saída.

3.2.2 Treinamento em Redes Neurais Artificiais

No projeto de redes neurais, o objetivo é encontrar um conjunto ótimo de pesos w (que representam as conexões da rede), de maneira que $y = y(x,w)$ possa representar o comportamento do problema, ou seja, a rede neural adquira o aprendizado, onde x representa a entrada e y representa a saída. Esse objetivo é alcançado através do processo de treinamento da rede neural. Um conjunto de dados, denominado conjunto de treinamento, é apresentado a rede neural artificial. O conjunto de treinamento são pares de (x_k, d_k) , $k = 1, 2, \dots, n$, onde d_k

representa a saída desejada do projeto para entrada x_k , e n é o número total de elementos do conjunto de treinamento.

O treinamento efetua o cálculo do erro no aprendizado da rede neural artificial, possibilitando à rede ter seu desempenho avaliado (computado). Esse cálculo é feito com base na diferença entre as saídas calculadas pela rede e as saídas desejadas, para todo o conjunto de treinamento. Matematicamente, tem-se:

$$E = \frac{1}{2} \sum_{k \in T_r} \sum_{j=1}^m [y_j(x_k, w) - d_{jk}]^2 \quad (3.5)$$

onde d_{jk} é o j -ésimo elemento de d_k , $y_j(x_k, w)$ é a j -ésima saída da rede neural artificial para a entrada x_k , e T_r é o índice relacionado ao conjunto de treinamento. Os pesos w são ajustados durante o treinamento, enquanto a taxa de erro é minimizada.

Em [38] foi proposto o algoritmo *Backpropagation*. As redes MLPs treinadas com este algoritmo tornaram-se muito populares após a divulgação deste trabalho. Este algoritmo permite a utilização do método do gradiente no processo de aprendizagem da rede, pois as funções de ativação utilizadas podem ser diferenciáveis o que não ocorre com a função degrau utilizada no modelo inicial de neurônio citado na seção 3.2.

Uma formulação mais detalhada encontra-se em [35], [37] e [39].

3.3 Algoritmos Genéticos

Algoritmos genéticos são uma técnica de busca populacional inspiradas em processos evolucionários da natureza. Através de sucessivas gerações, a população evolui de acordo com os princípios da seleção natural e sobrevivência do mais apto, semelhante ao definido por Charles Darwin em "A Origem das Espécies" [40]. Fazendo uma analogia a esse processo de seleção natural, os algoritmos genéticos podem resolver problemas do mundo real de maneira a encontrar soluções que evoluem dentro do processo até a solução mais adequada. A Figura 3.4, adaptada de [41], ilustra de maneira geral o processo executado pelo algoritmo genético para encontrar a solução ótima de um problema.

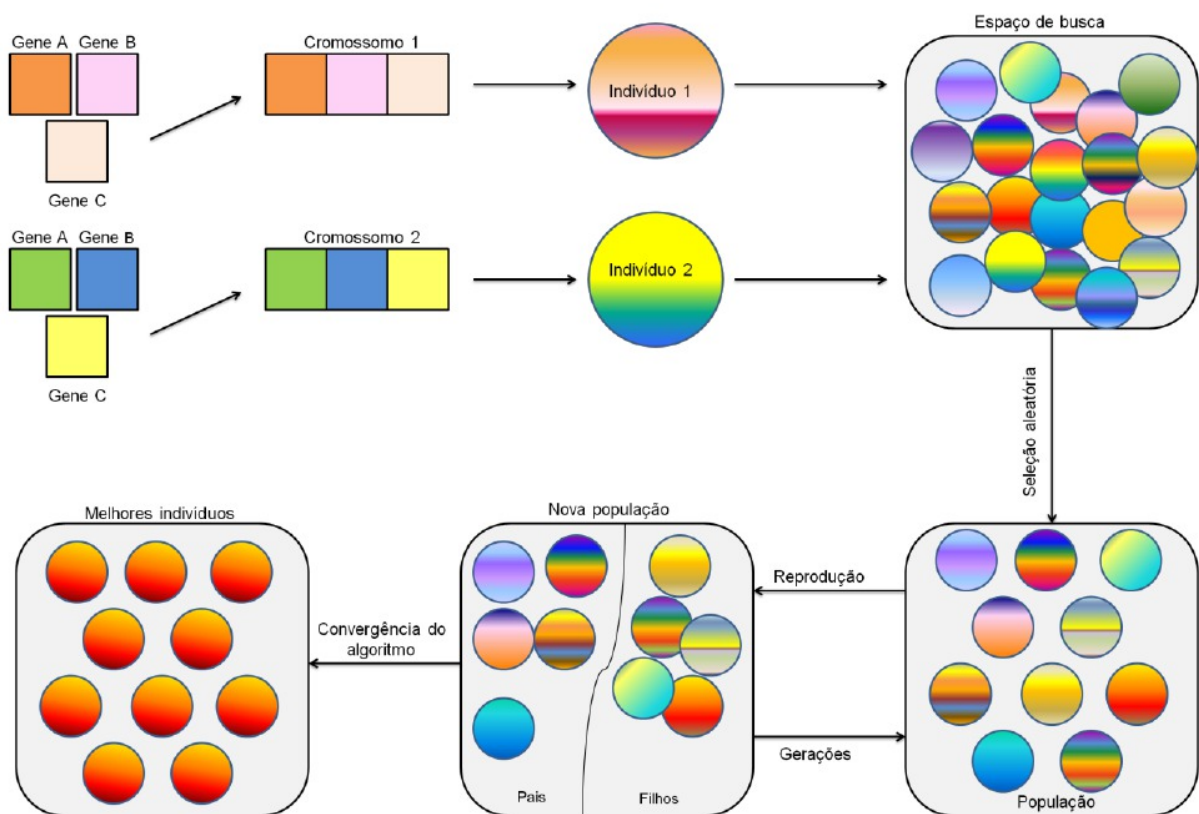


Figura 3.4: Fluxograma do processo de execução de um algoritmo genético.

Um indivíduo da população é representado pelo cromossomo, uma estrutura de dados, que contém uma possível solução para o problema. O cromossomo pode ser visto como uma sequência de variáveis ou cadeias de caracteres. Cada elemento que compõe esta sequência é denominado gene. Cada valor atribuído a um gene é chamado de alelo. Finalmente, a posição de um gene na estrutura do cromossomo é chamada de *locus*. O processo de evolução consiste em uma busca em um espaço de soluções potenciais para o problema. Nesse tipo de busca, há um balanço aceitável entre o aproveitamento de melhores soluções e exploração do espaço de busca [42], [43].

A Tabela 3.1 apresenta a nomenclatura dos principais termos dos algoritmos genéticos.

Tabela 3.1: Principais termos dos algoritmos genéticos.

Parâmetro	Definição
Gene	Parte do indivíduo
Indivíduo	Solução potencial do problema
Cromossomo	Conjunto de genes
População	Conjunto de indivíduos
Geração	População em um dado instante de tempo
Função de aptidão	Computa a qualidade do indivíduo
Recombinação	Probabilidade de troca de material genético entre dois indivíduos
Mutação	Probabilidade de inserção de material genético novo na solução

Devido ao paralelismo intrínseco, nos AG há uma busca multidirecional com vários pontos no espaço de busca analisados simultaneamente. Para diferenciar as soluções, há uma função de avaliação (aptidão) única para cada problema, que mede a qualidade de uma possível solução.

No algoritmo clássico de Holland [44] a codificação do indivíduo em uma população é binária, com base na teoria dos esquemas. No entanto, para diversas aplicações práticas, essa codificação mostrou-se insatisfatória em seu desempenho. Para problemas onde haja a necessidade de elevada precisão numérica e em várias dimensões, outros tipos de representação apresentam desempenho superior, como a representação em ponto flutuante, por exemplo.

Entretanto, trabalhos posteriores mostraram que apenas o espaço de busca não determina a eficiência do AG [45]. Espaços de busca cuja dimensão é elevada podem ser explorados de maneira eficiente, enquanto espaços de busca com dimensões reduzidas podem apresentar dificuldades significativas.

3.3.1 Principais Parâmetros dos Algoritmos Genéticos

Para iniciar a execução do algoritmo é necessário criar uma população inicial de possíveis soluções. O tamanho da população determina o número de indivíduos criados a cada geração. Para iniciar a execução do algoritmo, o método geralmente utilizado é a inicialização aleatória dos indivíduos. Com o conhecimento prévio, caso haja, da distribuição da população, pode-se utilizá-lo em sua inicialização.

Algoritmos genéticos executam uma série de etapas que representam a reprodução, através dos seus operadores genéticos: seleção, cruzamento (recombinação) e mutação.

Na etapa de seleção o AG seleciona quais indivíduos de uma população (soluções candidatas) estão aptos a passar à próxima geração. Os indivíduos selecionados nesta etapa são chamados de pais.

O método de seleção utilizado nesse trabalho é a amostragem estocástica uniforme (*Stochastic Universal Sampling*). Neste método, todos os indivíduos de uma população são mapeados em um segmento contíguo de linha, em que o tamanho de cada segmento é proporcional ao valor da avaliação do indivíduo que está sendo mapeado. Suponha N o número de indivíduos a escolher, a distância entre os ponteiros será $1/N$ e a posição do primeiro ponteiro é gerada aleatoriamente entre $(0, 1/N)$. Exemplificando: para 6 indivíduos a escolher, a distância entre os ponteiros é de $1/6 = 0,167$.

Existem outros tipos de seleção que podem ser aplicadas nos AG: *ranking*, roleta, aleatória, híbrida, torneio, mapeamentos lineares e não-lineares, diversidade, entre outros [42], [43].

Em conjunto ao método de seleção, tem-se o elitismo. No elitismo o melhor indivíduo da geração em curso é mantido para a geração seguinte. Isso é uma maneira de resolver o inconveniente da perda do melhor indivíduo da população durante a seleção.

Na etapa de reprodução, os indivíduos-filho são gerados, substituindo os indivíduos da geração anterior. Para criar novos indivíduos durante o processo de evolução a cada geração, tem-se o chamado operador de cruzamento. Este operador genético cria novos indivíduos combinando dois ou mais indivíduos da população corrente, trocando informações entre diferentes possíveis soluções.

Após o cruzamento, o operador de mutação faz uma modificação em um ou mais genes de um cromossomo, geralmente baseado em uma probabilidade conhecida por taxa de mutação, com o intuito de introduzir novo material genético na população. Em geral, essa taxa

possui valores baixos, para que seja criada uma diversidade extra na população, sem que atrapalhe o progresso obtido com a busca e evitar a convergência prematura. Esta convergência determina a condição ou critério de parada do algoritmo. Esse critério de parada poder ser determinado por parâmetros diversos, dependendo do projeto do algoritmo: número de gerações, valor calculado da função custo, tempo de execução do algoritmo, etc.

Esta tese utiliza o cruzamento disperso [26]. Este operador cria um vetor binário de maneira aleatória e seleciona os genes onde o vetor possui valor 1 para o primeiro pai e os genes onde o valor do vetor é zero para o segundo pai, combinando os genes para formar o filho. É semelhante ao cruzamento uniforme, a diferença é que após o cruzamento surgirá apenas um filho. Outros tipos de operadores de cruzamento existentes são o cruzamento de 2 pontos, aritmético ou de ponto flutuante, por exemplo [42], [43].

3.4 Algoritmo Baseado na Bioluminescência de Vaga-lumes (*Firefly Algorithm*)

O algoritmo de vaga-lume proposto por [46] é baseado na bioluminescência de vaga-lumes. De acordo com Yang, existem cerca de duas mil espécies de vaga-lumes e a maioria produz emissões curtas e ritmadas de luzes. Este padrão de emissão é único para cada espécie. Apesar de os cientistas ainda debaterem o papel destas emissões luminosas, pode-se identificar algumas utilidades:

- Função de comunicação e atração de parceiro para acasalamento;
- Isca para atração de potenciais presas para o vaga-lume;
- Mecanismo de alerta para potenciais predadores sobre o gosto amargo dos vaga-lumes.

As emissões ritmadas (*flashes*), a taxa de emissão e o tempo despendido, ou seja, a intensidade e intermitência da bioluminescência são os componentes que formam o sistema de comunicação entre os vaga-lumes, seja para atração entre parceiros, seja para comunicação entre todo o grupo, tendo assim uma sociedade auto-organizada.

Entre dois vaga-lumes existe um limite em seu campo visual (ou linha de visada). A intensidade da luz decai com o quadrado da distância e o ar no ambiente absorve luz a qual se torna de intensidade mais fraca conforme a distância aumenta. São fatores importantes considerados na modelagem do algoritmo, que influenciam na comunicação entre os vaga-lumes.

Algumas regras básicas foram idealizadas para desenvolver o algoritmo bioinspirado em vaga-lumes:

- Os vaga-lumes possuem um único sexo, de maneira que qualquer um poderá atrair outro ou ser atraído;
- Atratividade é proporcional em direção ao brilho emitido, assim, para dois vaga-lumes, o de menor brilho deve se mover ao de maior brilho. Esta atratividade diminui conforme aumenta a distância entre os vaga-lumes;
- O brilho de um vaga-lume é afetado ou determinado por sua avaliação conforme a função objetivo.

A Tabela 3.2 apresenta a nomenclatura dos principais termos da técnica e seu equivalente computacional [46].

Tabela 3.2: Parâmetros e definições do algoritmo bioinspirado em vaga-lumes

Parâmetro	Definição
Alfa (α)	Elemento de aleatoriedade
Beta (β)	Atratividade
Gama (γ)	Coefficiente de absorção
Brilho/Luminosidade	Função objetivo
Número de vaga-lumes	População
Número de gerações	Iterações

Com base nestas informações foi desenvolvido o algoritmo de vaga-lume baseado em [46], com o pseudocódigo visto na Figura 3.5.

```

Função objetivo  $f(x)$ ;  $x = (x_1, \dots, x_d)^T$ 
Geração aleatória da população inicial  $x_i$  ( $i = 1, 2, \dots, n$ )
Intensidade luminosa  $I_i$  em  $x_i$  determinada por  $f(x_i)$ 
Definição do coeficiente de absorção  $\gamma$ 
Enquanto  $t <$  número máximo de gerações (ou outro critério de convergência)
  Para  $i = 1 : n$ 
    Para  $j = 1 : n$ 
      Se  $(I_i < I_j)$ , mova o vaga-lume  $i$  em direção a  $j$  na dimensão  $d$ 
        Atratividade varia através da distância  $r$  com  $\exp[-\gamma r]$ 
        Avalie novas soluções e atualize a intensidade luminosa
      Fim do laço para  $j$ 
    Fim do laço para  $i$ 
  Avaliação dos vaga-lumes e seleção do melhor global  $g^*$  até o momento
  Fim do laço enquanto
Pós-processamento dos resultados e visualização

```

Figura 3.5: Pseudocódigo para o algoritmo de vaga-lume.

3.4.1 Principais Parâmetros do Algoritmo de Vaga-lume

Neste algoritmo há dois pontos importantes: a variação da luminosidade (brilho) e a formulação da atratividade. Por questões práticas, pode-se assumir geralmente que a atratividade de um vaga-lume é função de sua luminosidade e está relacionada à função objetivo [47]. O brilho de cada vaga-lume é proporcional à qualidade da solução.

A intensidade luminosa varia de acordo com [46]:

$$I(r_{ij}) = \frac{I_s}{r_{ij}^2} \quad (3.6)$$

onde I_s é a intensidade luminosa na fonte, r_{ij} é a distância Euclidiana entre os vaga-lumes i e j .

Para um determinado meio, com coeficiente de absorção luminoso γ , a intensidade luminosa I varia com a distância r_{ij} entre os vaga-lumes i e j da seguinte forma:

$$I(r_{ij}) = I_0 \exp(-\gamma r_{ij}) \quad (3.7)$$

onde I_0 é a intensidade luminosa original emitida. Para evitar a divisão por zero em $r_{ij} = 0$, na expressão 3.6, pode-se utilizar uma aproximação gaussiana da forma:

$$I(r_{ij}) = I_0 \exp(-\gamma r_{ij}^2) \quad (3.8)$$

Sabe-se que a atratividade de um vaga-lume é proporcional à intensidade de luz percebida por vaga-lumes adjacentes. Assim, a atratividade β de um vaga-lume é dada por:

$$\beta(r_{ij}) = \beta_0 \exp(-\gamma r_{ij}^2) \quad (3.9)$$

onde β_0 é a atratividade em $r_{ij} = 0$. Para acelerar o cálculo, geralmente é melhor calcular $\frac{1}{1+r^2}$ do que a forma exponencial, o cálculo em 3.9, que pode ser modificado para:

$$\beta(r_{ij}) = \frac{\beta_0}{1 + \gamma r_{ij}^2} \quad (3.10)$$

Ambas as expressões 3.9 e 3.10 definem uma distância característica $\Gamma = \frac{1}{\sqrt{\gamma}}$ sobre a qual a atratividade é alterada significativamente de β_0 para $\beta_0 \exp(-1)$ da expressão 3.9 ou $\frac{\beta_0}{2}$ da expressão 3.10.

Na implementação atual, a função de atratividade $\beta(r_{ij})$ pode ser uma função monotonicamente decrescente qualquer, como por exemplo, a generalização:

$$\beta(r_{ij}) = \beta_0 \exp(-\gamma r_{ij}^m), \quad (m \geq 1). \quad (3.11)$$

Para um valor fixo de γ , seu comprimento característico torna-se:

$$\Gamma = \gamma^{-1/m} \rightarrow 1, m \rightarrow \infty. \quad (3.12)$$

Alternativamente, para uma dada escala de comprimento Γ em um problema de otimização, o parâmetro γ pode ser utilizado com um valor típico inicial. Tem-se:

$$\gamma = \frac{1}{\Gamma^m} \quad (3.13)$$

A distância entre dois vaga-lumes i e j nas posições x_i e x_j , respectivamente, é a distância Euclidiana:

$$r_{ij} = \|x_i - x_j\| = \sqrt{\sum_{k=1}^d (x_{i,k} - x_{j,k})^2} \quad (3.14)$$

onde x_{ik} é o k -ésimo componente da coordenada espacial x_i do i -ésimo vaga-lume e d é o número de dimensões do problema.

No caso de duas dimensões, tem-se:

$$r_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (3.15)$$

O movimento do vaga-lume i que é atraído por outro vaga-lume j , com mais poder de atração (atratividade), isto é, mais brilhante, é dado por:

$$x_i = x_i + \beta_0 \exp(-\gamma r_{ij}^2)(x_j - x_i) + \alpha \varepsilon_i \quad (3.16)$$

onde o primeiro termo representa a posição atual de um vaga-lume, o segundo termo representa a atratividade entre os vaga-lumes e o terceiro é o termo com a utilização do fator de aleatoriedade α e o vetor ε_i de número aleatórios gerados a partir de uma distribuição gaussiana ou uma distribuição uniforme, ambas no intervalo $[0, 1]$. Este termo é utilizado no caso de não haver algum vaga-lume mais brilhante. Normalmente, tem-se $\varepsilon_i = (\text{rand} - 0.5)$, onde rand é uma função de geração de números aleatórios uniformemente distribuídos em $[0; 1]$.

No segundo termo o parâmetro γ caracteriza a variação da atratividade na execução do algoritmo. Seu valor é fundamentalmente decisivo e importante, pois determina a velocidade de convergência do algoritmo, bem como no resultado. Em teoria, $\gamma \in [0, \infty)$, mas para a maioria dos projetos se utiliza $[0,01; 100]$.

Quando $\gamma \rightarrow 0$, observa-se que a luminosidade não diminui com a distância. Assim, localiza-se facilmente um mínimo local ótimo. Os vaga-lumes se encontram em um ambiente sem ruídos, sem dispersão de luz, onde cada vaga-lume enxerga o outro. Se o laço mais interno para j , da Figura 3.5, for removido, o algoritmo se assemelha a um caso particular de outro algoritmo populacional, o PSO [46]. No entanto, quando $\gamma \rightarrow \infty$, os vaga-lumes se encontram em um ambiente muito ruidoso, como uma neblina, por exemplo, com extrema dispersão de luz e a atratividade entre dois vaga-lumes tende a zero. Os vaga-lumes não se veem e a técnica torna-se completamente aleatória.

Por fim, uma solução candidata encontrada pelo algoritmo, representada pela posição de cada vaga-lume x_i , é apresentada no pós-processamento.

3.5 Algoritmo de Ecolocalização de Morcegos (*Bat Algorithm*)

Este algoritmo criado por Yang [48] em 2010 é inspirado na ecolocalização (ou biossonar) dos morcegos durante seu voo. Os morcegos são capazes de emitir ondas ultrassônicas pelas narinas ou pela boca, dependendo da espécie.

Nem todos os morcegos utilizam a ecolocalização. Os morcegos tipicamente pequenos (da subordem *Microchiroptera*) são os que a utilizam mais extensivamente [49]. São da ordem de 4 a 16 cm de comprimento, enquanto que os morcegos maiores (da subordem *Megachiroptera*), não a utilizam devido à perda da capacidade durante o processo evolutivo da família *Pteropodidae* [50].

A ecolocalização é utilizada pelos morcegos para detectar presas e/ou desviar de obstáculos. Após uma onda ultrassônica ser emitida, o morcego é capaz de calcular o tempo de retorno da onda refletida no alvo até ele. Como a maioria destes morcegos procura por pequenos insetos, a onda emitida deve ter seu comprimento de onda da ordem de milímetros, implicando em altas frequências, geralmente na ordem de 25 kHz a 150 kHz.

Baseado na diferença entre o tempo de emissão e reflexão da onda (detecção do eco), a diferença de tempo percebida entre os dois ouvidos, e a variação de volume (amplitude) do eco, o morcego constrói um cenário tridimensional onde ele se localiza naquele instante de tempo. Ele pode ainda detectar a distância e a orientação do alvo, o tipo de presa, e até mesmo a velocidade relativa de movimento da presa, como pequenos insetos [50].

Semelhante ao algoritmo de vaga-lumes, inicialmente algumas regras básicas foram criadas para desenvolver o algoritmo:

- Todos os morcegos fazem uso da ecolocalização para perceber e calcular a distância além de conhecer a diferença entre sua comida/presa e condições de limite no espaço onde ela se encontra;
- Os morcegos percorrem o espaço de busca com velocidade v_i na posição x_i (onde x_i é uma solução para o problema) com uma frequência fixa f_{min} (ou comprimento de onda λ), variando o comprimento de onda λ (ou frequência f) e amplitude (do som emitido) A_0 ao buscar a presa. Eles podem ajustar automaticamente o comprimento de onda (ou frequência) de seus pulsos emitidos e ajustar a taxa de emissão de pulso $r \in [0,1]$, dependendo da proximidade do alvo;
- Embora a amplitude possa variar em várias maneiras, assume-se normalmente que a amplitude varia de um elevado valor A_0 a um mínimo valor A_{min} .

Ainda em relação a essas regras, utilizam-se também por simplicidade as seguintes aproximações:

- Em geral a frequência f em uma determinada faixa de frequência $[f_{\min}, f_{\max}]$ corresponde à faixa do comprimento de onda $[\lambda_{\min}, \lambda_{\max}]$. Por exemplo, para [20 kHz, 500 kHz] tem-se a faixa de comprimento de onda variando de 0,7 mm até 17 mm.

Por questões práticas de implementação se utiliza $f \in [0, f_{\max}]$. A taxa de emissão de pulso está no intervalo $r \in [0,1]$ onde zero significa que não há emissão e um significa valor máximo de emissão.

Com base nestas informações foi desenvolvido o algoritmo de morcego [48], com o pseudocódigo visto na Figura 3.6.

```
Função objetivo  $f(x)$ ,  $x = (x_1, \dots, x_d)^T$ 
Inicialização aleatória da população de morcegos  $x_i$  ( $i = 1, 2, \dots, n$ ) e velocidade  $v_i$ 
Definição da frequência  $f_i$  na posição  $x_i$ 
Inicialização da taxa de emissão de pulso  $r_i$  e amplitude  $A_i$ 
Enquanto  $t <$  número máximo de gerações (ou outro critério de convergência)
  Gerar novas soluções ajustando a frequência,
  e atualizar velocidade e localização/solução [de acordo com expressões 3.17 a 3.18]
  Se  $rand > r_i$ 
    Selecionar uma solução entre as melhores soluções
    Gerar uma solução local próxima da melhor solução já escolhida
  Fim da condição Se
  Gerar uma nova solução através de voo aleatório
  Se  $(rand < A_i \ \& \ f(x_i) < f(x^*))$ 
    Aceitar as novas soluções
    Elevar valor de  $r_i$  e diminuir valor de  $A_i$ 
  Fim da condição Se
Ordenar os morcegos e selecionar o melhor atual  $x^*$ 
Fim do laço enquanto
Pós-processamento dos resultados e visualização
```

Figura 3.6: Pseudocódigo do algoritmo de morcego.

3.5.1 Principais Parâmetros do Algoritmo de Morcego

O algoritmo inicia com geração aleatória da população de morcegos, respeitando os limites determinados na implementação. Através da função objetivo, a população é avaliada e classificada de acordo com sua aptidão para resolver o problema (melhores soluções). A cada iteração as posições x_i e velocidades v_i no espaço n -dimensional são atualizadas.

As novas soluções x_i^t e velocidades v_i^t na iteração t são dadas pelas seguintes expressões [48]:

$$f_i = f_{mín} + (f_{máx} - f_{mín})\beta \quad (3.17)$$

$$v_i^t = v_i^{t-1} + (x_i^t - x_*)f_i \quad (3.18)$$

$$x_i^t = x_i^{t-1} + v_i^t \quad (3.19)$$

onde a frequência de cada morcego está distribuída entre $[f_{mín}, f_{máx}]$, β é um valor escalar aleatório com distribuição uniforme $\beta \in [0;1]$ e x_* é a melhor localização (solução) encontrada após a comparação com as outras soluções entre todos os morcegos na iteração.

Com os parâmetros de frequência, velocidade e posição dos morcegos atualizados, a próxima etapa é avaliar a taxa de emissão de pulso emitida por cada morcego. É feita a comparação da taxa de emissão de pulso r_i com um ruído aleatório (gerado pela função *rand*). Se a taxa de emissão de pulso possuir um valor inferior a este ruído aleatório, quer dizer que o i -ésimo morcego está distante da solução. Assim, executa-se uma busca local. Esta busca local dá flexibilidade ao projeto. Pode ser implementada utilizando diversas estratégias, de acordo com a adequação ao projeto.

A busca local, neste caso, sorteia uma solução entre as melhores e uma nova solução para cada morcego é gerada localmente através do chamado passeio aleatório:

$$x_{novo} = x_{anterior} + \varepsilon_i A^t \quad (3.20)$$

onde, neste caso, $\varepsilon_i \in [-1, 1]$ é um escalar aleatório e A^t é a média da amplitude de todos os morcegos na iteração t .

Já com o conjunto de soluções atualizado, o algoritmo continua. Inicialmente, faz uma verificação se as soluções satisfazem os limites mínimos e máximos determinados e sua correção, caso seja necessária. Após isso, compara a solução anterior com a atual para

selecionar a melhor solução (melhor valor de aptidão). Compara também o valor da amplitude do pulso (volume) com um volume aleatório (*rand*). Caso o valor do volume aleatório seja menor que o valor do volume A_i do i -ésimo morcego, significa que este morcego (solução) está mais próximo da presa/alvo (melhor solução).

Com as condições acima satisfeitas, as soluções são aceitas e são atualizadas as taxas de emissão r_i e amplitude A_i na iteração t , segundo as expressões:

$$r_i^{t+1} = r_i^0 [1 - \exp(-\gamma t)] \quad (3.21)$$

$$A_i^{t+1} = \alpha A_i^t \quad (3.22)$$

onde α e γ são constantes no intervalo $0 < \alpha < 1$ e $\gamma > 1$, isto é

$$A_i^t \rightarrow 0, \text{ e } r_i^t \rightarrow r_i^0, \text{ com } t \rightarrow \infty. \quad (3.23)$$

Como estratégia de caça, conforme o morcego se aproxima do alvo, a amplitude A do pulso emitido diminui enquanto sua taxa de emissão r aumenta. Com $A_{min} = 0$, tem-se o momento em que o morcego chegou ao alvo e temporariamente parou de emitir qualquer som.

Assim, os parâmetros A e r são atualizados somente se as novas soluções são melhores que as anteriores, o que significa que os morcegos estão se deslocando no espaço de busca em direção à solução ótima.

3.6 Síntese do Capítulo

Nesse capítulo, algumas técnicas de programação inspiradas na Biologia, conhecidas como Computação Natural foram apresentadas. Estas técnicas já vêm sendo utilizadas há algumas décadas com os algoritmos genéticos, inspirados na Teoria da Evolução e Seleção Natural, por exemplo. O uso desses modelos é uma forma de incorporar os benefícios da inteligência computacional na análise das referidas estruturas. Os conceitos fundamentais sobre essas técnicas de otimização foram discutidos.

Capítulo 4

Resultados

Os capítulos anteriores descreveram a fundamentação teórica necessária para o entendimento de conceitos importantes para a compreensão do trabalho. As estruturas de FSS foram explicadas no Capítulo 2 e agora serão detalhados os aspectos principais das FSS utilizadas nesta pesquisa.

A teoria de elementos de Computação Natural foi apresentada no Capítulo 3, bem como os algoritmos escolhidos para implementação. Detalhes dos algoritmos implementados neste trabalho também serão descritos nas próximas seções.

4.1 Apresentação do Modelo

Este trabalho utiliza técnicas de otimização inspiradas na natureza para calcular parâmetros físicos de estruturas FSS, precisamente frequência de ressonância e largura de banda. Os algoritmos são implementados de maneira a otimizar a célula unitária de uma FSS para alcançar largura de banda e frequência desejadas.

O projeto de uma estrutura FSS geralmente segue as etapas mostradas na Figura 4.1.

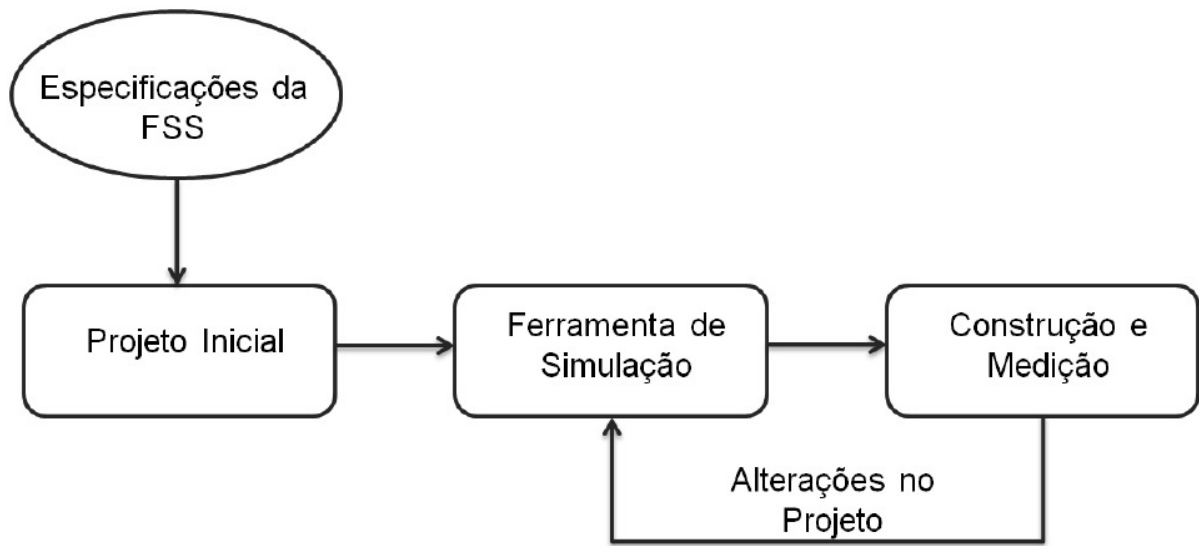


Figura 4.1: Visão geral de um projeto de FSS.

O projeto de caracterização e construção de FSS se inicia com as características eletromagnéticas requeridas como frequência e largura de banda, e a definição da estrutura da célula unitária da FSS. Definida a estrutura, uma análise paramétrica de onda completa é efetuada utilizando alguma das técnicas de análise citadas na seção 2.3. Neste trabalho foi utilizado o Método dos Momentos (MoM). Esta análise é efetuada com o programa comercial *Ansoft Designer*®. Esta fase de análise geralmente possui elevado esforço computacional, bem como repetidas simulações até o fim do projeto, devido aos cálculos dos parâmetros eletromagnéticos.

Na Figura 4.2 pode-se observar uma alteração sugerida por esta tese, na estrutura geral das etapas. Há a inclusão da etapa que utiliza as ferramentas de computação natural (otimização). Neste modelo de projeto, após as etapas iniciais de caracterização da estrutura, o módulo de otimização substitui as várias simulações da ferramenta de análise de onda. Uma rede neural artificial é treinada para mapear os valores dos parâmetros eletromagnéticos retornados pelo cálculo do MoM e assim criar o espaço de busca para os algoritmos de computação natural. Esse processo de otimização possui uma fase de busca e uma fase de análise. Nesta técnica o algoritmo de otimização executa a operação de busca e a RNA, treinada com dados obtidos de cálculo através do método dos momentos, executa a operação de análise. Nestas fases existe uma interação contínua: para cada novo conjunto de parâmetros de projeto que o algoritmo de busca retorna, a fase de análise efetua a computação necessária

e determina o valor de um novo ponto no espaço de busca. Finalmente os protótipos são construídos e medidos a fim de verificar a precisão da técnica.

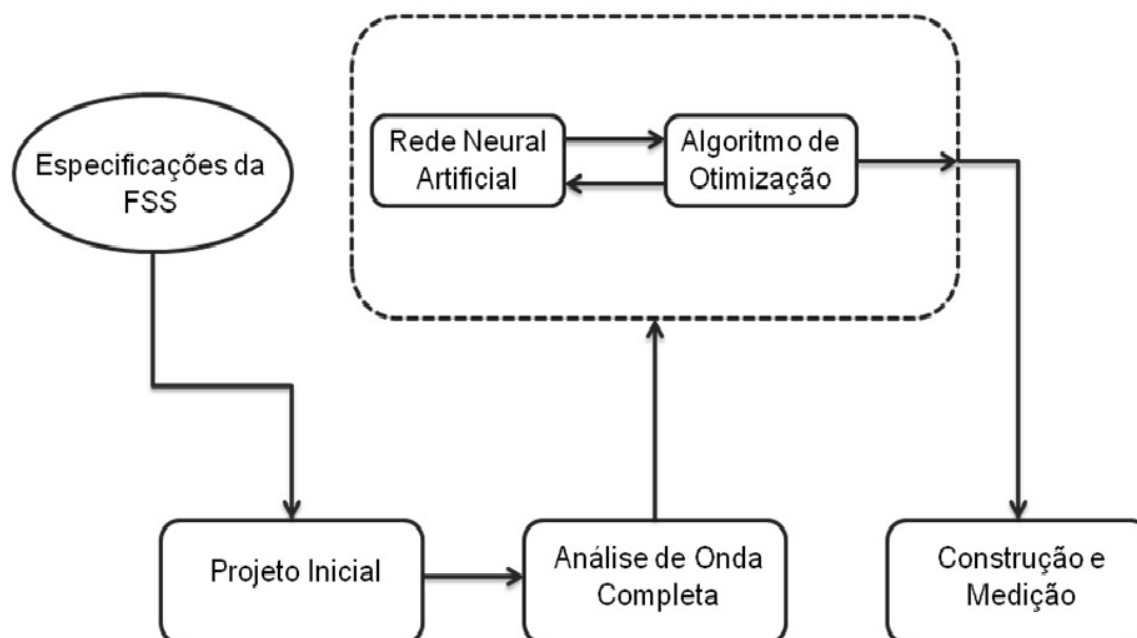


Figura 4.2: Fluxograma da proposta de otimização.

Para a utilização da RNA, é necessário criar os dados de treinamento da rede na região de interesse, isto é, o espaço de busca para os algoritmos de otimização. A próxima seção detalha este processo, bem como a estrutura utilizada.

4.2 FSS Circular com Anéis Integrados e Elementos Dipolos Centralizados

A Figura 4.3 mostra a geometria da FSS utilizada com elementos condutores circulares e dipolos centralizados. Na Tabela 4.1 têm-se os parâmetros utilizados.




Figura 4.3: FSS de espiras integradas com dipolos. (a) Célula unitária. (b) Geometria do arranjo.

Tabela 4.1: Parâmetros da FSS de espiras integradas com dipolos.

Parâmetro da FSS	Valor
Periodicidade	$t = T_x = T_y = [15; 20; 25; 30]$ mm
Largura do dipolo	$W = [1,5; 1,7; 1,9; 2,0]$ mm
Altura do Substrato	$h = 1,5$ mm
Raio externo	$R = 6,0$ mm
Raio interno	$r = 3,13$ mm
Permissividade	$\epsilon_r = 4,4$

Nesta tese foi utilizada uma rede MLP, com o algoritmo *Levenberg-Marquardt*. Para o treinamento da rede utilizou-se dados obtidos da análise paramétrica de onda completa, por simulações realizadas utilizando o software *Ansoft Designer*®. Observa-se a partir da Tabela 4.1, que foram utilizados quatro protótipos para o treinamento da rede.

Para a modelagem da FSS foi utilizada uma rede MLP com três entradas na primeira camada, uma camada oculta com 5 neurônios e dois nós de saída referentes à frequência central e largura de banda. A arquitetura da rede é exibida na Figura 4.4. A escolha do número de camadas ocultas, bem como o número de neurônios, se deu de com base em testes de

execução com valores diferentes, comparando o desempenho geral do procedimento com a taxa mínima de erro definida.




Figura 4.4: Modelo da rede Perceptron multicamada.

As entradas são normalizadas para manter a proporção entre os pesos e diminuição da variância, além de melhorar a convergência da rede. Na camada oculta utilizou-se função de ativação sigmoide e na camada de saída função linear.

As Figuras 4.5 e 4.6 mostram os resultados da rede MLP desenvolvida neste trabalho. As linhas pontilhadas representam a resposta da rede e as quatro linhas contínuas em cada figura representam o conjunto de treinamento. Observa-se uma grande capacidade de generalização para a configuração utilizada da rede neural artificial. Com base nestes resultados, a próxima etapa é a aplicação dos algoritmos de busca.




Figura 4.5: Resposta da rede MLP (generalização) para a largura de banda em função dos parâmetros geométricos W e t.




Figura 4.6: Resposta da rede MLP (generalização) para a frequência de ressonância em função dos parâmetros geométricos W e t.

4.3 Aplicação do Algoritmo Genético

A partir dos fundamentos de algoritmos genéticos, descritos na seção 3.3, foi construído um algoritmo genético híbrido e multiobjetivo. Este algoritmo é capaz de encontrar os valores ótimos de largura de banda e adequação a frequência central de operação para a FSS proposta. O modelo desenvolvido nesse trabalho é utilizado para otimizar estruturas que operem nas especificações delimitadas pela região de interesse, explicada na seção 4.1. Consiste na escolha de melhores valores da espessura do dipolo W entre [1,5 e 2,0] mm e periodicidade da célula T entre [15 e 30] mm, para uma frequência e uma largura de banda desejadas.

Para validar os resultados, simulações foram feitas com os parâmetros fixos para uma estrutura com frequência central $f_r = 11,0$ GHz e largura de banda $BW = 3$ GHz, comparando os resultados com o *Ansoft Designer*®. Além disso, foram construídas FSS com as especificações do algoritmo, para validar a técnica.

O fluxograma do algoritmo genético é mostrado na Figura 4.7.



Figura 4.7: Fluxograma do algoritmo genético.

Nesta técnica o AG inicia a operação a partir de uma população inicial gerada aleatoriamente. A geração inicial de indivíduos segue a seguinte fórmula sugerida em [42]:

$$P = [1.5 + 0.5 * rand(20,1); 15 + 15 * rand(20,1)]^T \quad (4.1)$$

onde a função *rand* gera números aleatórios distribuídos uniformemente no intervalo (0,1); a primeira coluna refere-se ao valor de W e a segunda coluna ao valor de t.

Para as especificações desejadas da FSS o objetivo é minimizar a função custo abaixo:

$$F = \left[\sqrt{f_1 + f_2} \right] \quad (4.2)$$

Onde as funções f_1 e f_2 estão representadas por:

$$f_1 = (fr_{desejado} - fr_{obtido})^2 \quad (4.3)$$

$$f_2 = (BW_{desejado} - BW_{obtido})^2 \quad (4.4)$$

Para o algoritmo genético neste trabalho, os cromossomos foram codificados utilizando ponto flutuante, população de tamanho $N_{pop} = 20$ e 2 cromossomos elitistas. A função de seleção é por amostragem estocástica uniforme; a taxa de mutação é do tipo gaussiana e a taxa de cruzamento dispersa. Como ponto inicial no espaço de busca, o indivíduo $P = [1,55 \ 24,0]$ foi fixado neste ponto, para que possa ser feita a comparação com a execução dos outros algoritmos de busca.

Para avaliar a função custo, a rede MLP é utilizada para computar as relações entre frequência e largura de banda da função custo (aptidão) 4.2. O objetivo é minimizar a diferença entre a resposta dada pela rede em relação aos valores especificados para o projeto. Um cenário ideal seria encontrar valores próximos ou iguais à zero para a função de custo.

A Tabela 4.2 apresenta o primeiro caso (Caso 1), exibindo os cinco resultados para otimização da FSS, com mesmo objetivo ($f_r = 11.0$ GHz e $BW = 3$ GHz), e retornando valores de W e t, além dos seus respectivos resultados retornados pelo *Ansoft Designer*®, para f_r e BW .

Na tabela 4.2, cada teste corresponde a uma execução do algoritmo genético. Seus resultados otimizados obtidos podem variar em relação ao número de gerações, o percurso e o tempo computacional. Por esta razão os resultados são apresentados com três casas decimais.

É feita uma comparação com a implementação do algoritmo genético padrão, sem a utilização de redes neurais. Os índices nos parâmetros indicam respectivamente a técnica híbrida proposta nesta tese (índice 1) e a implementação do algoritmo genético padrão (índice 2) sem utilização de redes neurais.

Tabela 4.2: Resultados otimizados para a FSS de espiras integradas com dipolos através de algoritmo genético e rede neural artificial.

Parâmetro da FSS	Teste 1	Teste 2	Teste 3	Teste 4	Teste 5
W_1 (mm)	2,000	2,000	1,999	1,998	1,999
t_1 (mm)	15,005	15,002	15,000	15,000	15,003
f_{r1} (GHz)	11,000	11,000	11,000	11,000	11,000
BW_1 (GHz)	3,032	3,034	3,034	3,051	3,032
W_2 (mm)	1,674	1,761	1,931	1,754	1,741
t_2 (mm)	15,357	15,086	15,034	15,024	15,164
f_{r2} (GHz)	10,795	10,886	10,972	10,889	10,882
BW_2 (GHz)	2,807	2,978	3,029	3,014	2,934

A Figura 4.8 mostra a comparação com o resultado medido, a técnica híbrida (RNA + AG), o AG e WCIP do coeficiente de transmissão e frequência para a FSS otimizada para $f_r = 11,0$ GHz e $BW = 3$ GHz. Os parâmetros estruturais são: $\epsilon_r = 4,4$, $h = 1,5$ mm, $t = T_x = T_y = 15,0$ mm, $W = 1,999$ mm, $R = 6,0$ mm e $r = 3,13$ mm. A técnica híbrida proposta exhibe resultados concordantes com os resultados medidos, bem como com os outros resultados para AG e WCIP, para frequência e largura de banda.

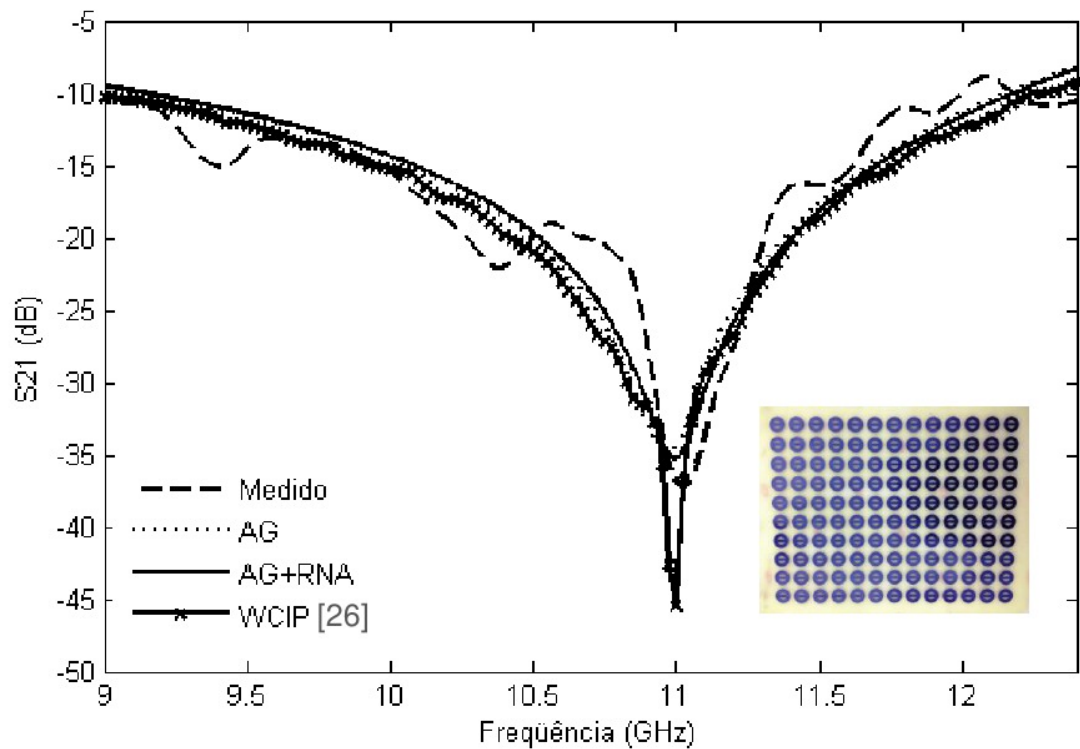


Figura 4.8: Resultados medidos e simulados do coeficiente de transmissão versus frequência da FSS otimizada para $f_r = 11,0$ GHz e $BW = 3$ GHz. Parâmetros estruturais: $\epsilon_r = 4,4$, $h = 1,5$ mm, $t = 15,0$ mm, $W = 1,999$ mm, $R = 6,0$ mm e $r = 3,13$ mm.

A Figura 4.9 apresenta a evolução da avaliação da função custo no processo de síntese da FSS. Durante o processo de síntese, o valor da função custo apresentada diminui. A linha tracejada mostra a média do custo para a população e a linha sólida representa a evolução do melhor indivíduo.




Figura 4.9: Avaliação do ótimo global durante as iterações.

Para a FSS em 9 GHz, como ponto inicial no espaço de busca, o indivíduo $P = [1,9 \ 17,0]$ foi fixado neste ponto, para que possa ser feita a comparação com a execução dos outros algoritmos de busca.

A Figura 4.10 mostra a comparação com o resultado medido, a técnica híbrida (RNA + AG), o AG e WCIP do coeficiente de transmissão e frequência para outra FSS otimizada para $f_r = 9,0$ GHz e $BW = 0,6$ GHz. Os parâmetros estruturais são: $\epsilon_r = 4,4$, $h = 1,5$ mm, $t = T_x = T_y = 22,66$ mm, $W = 1,5$ mm, $R = 6,0$ mm e $r = 3,13$ mm. Novamente se observa que a técnica híbrida proposta exhibe resultados concordantes com os resultados medidos, bem como com os outros resultados para AG e WCIP, para frequência e largura de banda.




Figura 4.10: Resultados medidos e simulados do coeficiente de transmissão versus frequência da FSS otimizada para $f_r = 9$ GHz e $BW = 3$ GHz. Parâmetros estruturais: $\epsilon_r = 4,4$, $h = 1,5$ mm, $t = 22,66$ mm, $W = 1,5$ mm, $R = 6,0$ mm e $r = 3,13$ mm.

4.4: Aplicação do Algoritmo Bioinspirado em Vaga-lume

Na seção 3.4 foi apresentada a técnica de otimização conhecida por algoritmo de vaga-lume. Com base na teoria, foi construído um algoritmo híbrido, multivariável e multiobjetivo. Semelhante ao algoritmo genético, este algoritmo é capaz de encontrar os valores mais adequados de largura de banda e adequação a frequência central de operação para a FSS proposta. O modelo desenvolvido neste trabalho é utilizado para minimizar a função custo expressa em (4.2) e, dessa maneira, otimizar estruturas que operem nas especificações delimitadas pela região de interesse, explicada na seção 4.1. Consiste na escolha de melhores valores da espessura do dipolo W entre [1,5 e 2,0] mm e periodicidade da célula T entre [15 e 30] mm, para uma frequência e uma largura de banda desejadas.

Para validar os resultados, simulações foram feitas com os parâmetros fixos para uma estrutura com frequência central $f_r = 11$ GHz e largura de banda $BW = 3$ GHz, comparando os

resultados com o *Ansoft Designer*®. Além disso, foram construídas FSS com as especificações do algoritmo, para validar a técnica.

O fluxograma do algoritmo de vaga-lume é mostrado na Figura 4.11.

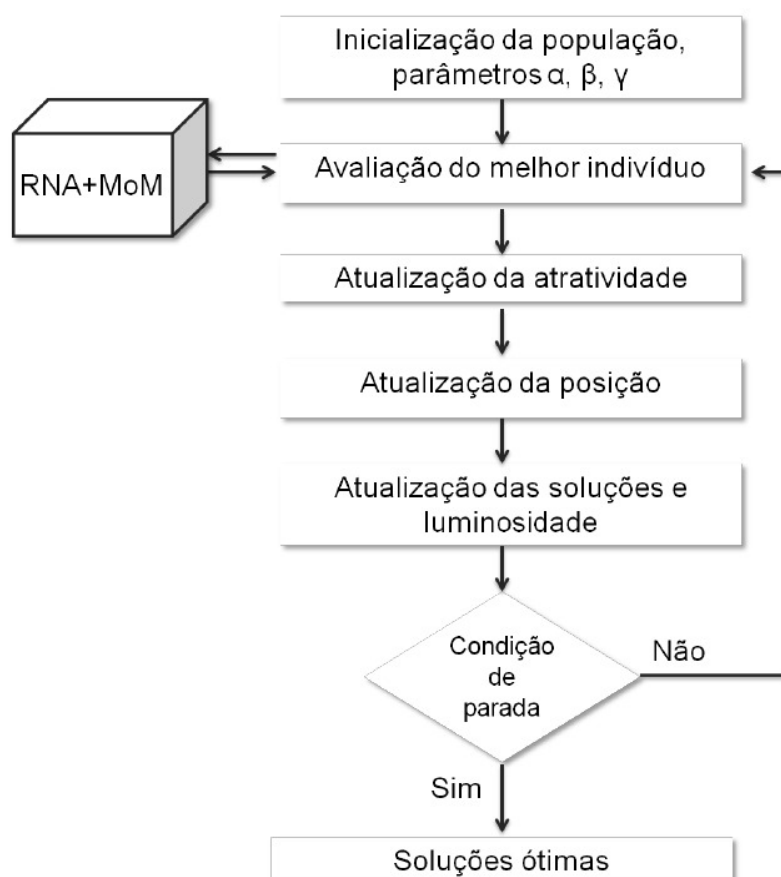


Figura 4.11: Fluxograma do algoritmo de vaga-lume proposto.

Aqui o algoritmo de vaga-lume inicia a operação a partir de uma população inicial gerada aleatoriamente. A geração inicial da população é definida pela expressão 4.1. O objetivo é minimizar a função custo definida em 4.2.

O algoritmo utiliza codificação em ponto flutuante. A população é fixada com tamanho $N_{pop} = 20$, parâmetros $\alpha=0,5$; $\beta=0,2$ e $\gamma=1$. Como ponto inicial no espaço de busca, o indivíduo $P = [1,55 \ 24,0]$ foi fixado neste ponto, para que possa ser feita a comparação com a execução dos outros algoritmos de busca.

Para avaliar a função custo, a rede MLP é utilizada para computar as relações entre frequência e largura de banda da função custo definida em (4.2). O objetivo é minimizar a

diferença entre a resposta dada pela rede em relação aos valores especificados para o projeto. Novamente, valores próximos ou iguais a zero indicam a solução ótima encontrada pelo algoritmo.

A Tabela 4.3 mostra cinco resultados para otimização com mesmo objetivo ($f_r = 11$ GHz e $BW = 3$ GHz), e retornando valores de W e t , além dos seus respectivos resultados retornados pelo *Ansoft Designer*®, para f_r e BW .

Na tabela 4.3, cada teste corresponde a uma execução do algoritmo de vaga-lume. Seus resultados otimizados obtidos podem variar também em relação ao número de iterações, o percurso e o tempo computacional. Por esta razão os resultados são apresentados com três casas decimais.

Tabela 4.3: Resultados otimizados para a FSS de espiras integradas com dipolos através de algoritmo de vaga-lume e rede neural artificial.

Parâmetro da FSS	Teste 1	Teste 2	Teste 3	Teste 4	Teste 5
W (mm)	2	2	2	2	2
t (mm)	15	15	15	15	15
f_r (GHz)	11,00	11,00	11,00	11,00	11,00
BW (GHz)	3,035	3,035	3,035	3,035	3,035

A Figura 4.12 mostra a comparação com o resultado medido, o algoritmo híbrido de vaga-lume com RNA e o WCIP, do coeficiente de transmissão e frequência para a FSS otimizada para $f_r = 11$ GHz e $BW = 3$ GHz. Os parâmetros estruturais são: $\epsilon_r = 4,4$; $h = 1,5$ mm, $t = T_x = T_y = 15,0$ mm, $W = 2,0$ mm, $R = 6,0$ mm e $r = 3,13$ mm. A técnica híbrida proposta exhibe resultados concordantes com os resultados medidos, bem como com os outros resultados para WCIP, para frequência e largura de banda.

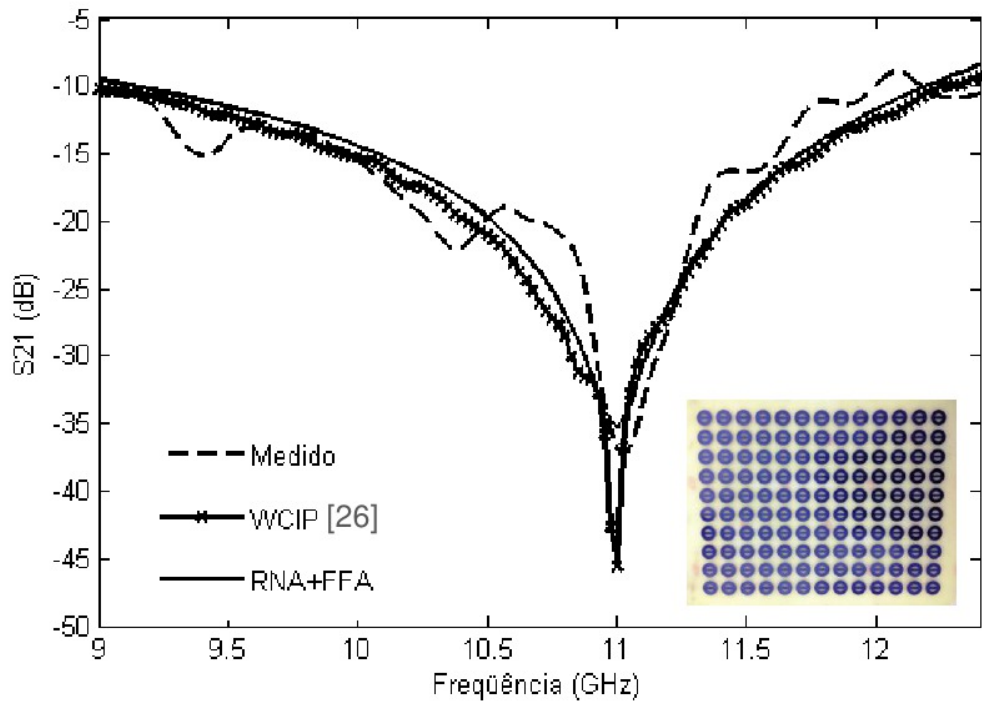


Figura 4.12: Resultados medidos e simulados do coeficiente de transmissão versus frequência da FSS otimizada para $f_r = 11,0$ GHz e $BW = 3$ GHz. Parâmetros estruturais: $\epsilon_r = 4,4$, $h = 1,5$ mm, $t = 15,0$ mm, $W = 2,0$ mm, $R = 6,0$ mm e $r = 3,13$ mm.

A Figura 4.13 apresenta a evolução da avaliação da função custo no processo de síntese da FSS. Durante o processo de síntese, o valor da função custo apresentada diminui. A linha tracejada mostra a média do custo para a população e a linha sólida representa a evolução do melhor indivíduo.




Figura 4.13: Avaliação do ótimo global durante as iterações.

Para o caso da FSS em 9 GHz, como ponto inicial no espaço de busca, o indivíduo $P = [1,9 \ 17,0]$ foi fixado neste ponto, para que possa ser feita a comparação com a execução dos outros algoritmos de busca.

A Figura 4.14 mostra a comparação com o resultado medido, o algoritmo de vagalume híbrido e WCIP, do coeficiente de transmissão e frequência para outra FSS otimizada para $f_r = 9,0$ GHz e $BW = 0,6$ GHz. Os parâmetros estruturais são: $\epsilon_r = 4,4$; $h = 1,5$ mm, $t = T_x = T_y = 22,48$ mm, $W = 1,50$ mm, $R = 6,0$ mm e $r = 3,13$ mm. Novamente se observa que a técnica híbrida proposta exhibe resultados concordantes com os resultados medidos, bem como com os outros resultados para WCIP, para frequência e largura de banda.




Figura 4.14: Resultados medidos e simulados do coeficiente de transmissão versus frequência da FSS otimizada para $f_r = 9,0$ GHz e $BW = 0.6$ GHz. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,5$ mm, $t = 22,48$ mm, $W = 1,5$ mm, $R = 6,0$ mm e $r = 3,13$ mm.

4.5: Aplicação do Algoritmo de Ecolocalização de Morcego

Na seção 3.5 foi apresentada a técnica de otimização conhecida por algoritmo de ecolocalização de morcegos. Com base na teoria, foi construído um algoritmo híbrido, multivariável e multiobjetivo. Semelhante aos algoritmos das seções anteriores, este algoritmo é capaz de encontrar os valores mais adequados de largura de banda e adequação a frequência central de operação para a FSS proposta. O modelo desenvolvido nesse trabalho é utilizado para minimizar a função custo expressa em 4.2 e, dessa maneira, otimizar estruturas que operem nas especificações delimitadas pela região de interesse, explicada na seção 4.1. Consiste na escolha de melhores valores da espessura do dipolo W entre [1,5 e 2,0] mm e periodicidade da célula T entre [15 e 30] mm, para uma frequência e uma largura de banda desejadas.

Para validar os resultados, simulações foram feitas com os parâmetros fixos para uma estrutura com frequência central $f_r = 11,0$ GHz e largura de banda $BW = 3$ GHz, comparando

os resultados com o *Ansoft Designer*®. Além disso, foram construídas FSS com as especificações do algoritmo, para validar a técnica.

O fluxograma do algoritmo de ecolocalização de morcego é mostrado na Figura 4.15.

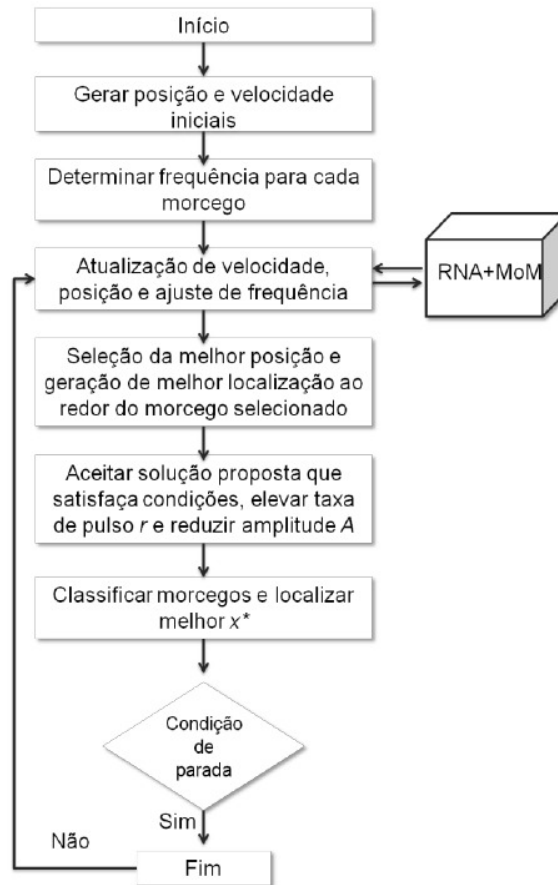


Figura 4.15: Fluxograma do algoritmo de ecolocalização de morcego proposto.

Aqui o algoritmo de morcego inicia a operação a partir de uma população inicial gerada aleatoriamente. A geração inicial da população é definida pela expressão 4.1. O objetivo é minimizar a função custo definida em (4.2).

O algoritmo utiliza codificação em ponto flutuante. A população é fixada com tamanho $N_{pop} = 20$, parâmetros $A=0,5$, $f_{min}=1,5$, $f_{max}=3$ e $r=0,5$. Como ponto inicial no espaço de busca, o indivíduo $P = [1,55 \ 24,0]$ foi fixado neste ponto, para que possa ser feita a comparação com a execução dos outros algoritmos de busca.

Para avaliar a função custo, a rede MLP é utilizada para computar as relações entre frequência e largura de banda da função custo definida em 4.2. O objetivo é minimizar a

diferença entre a resposta dada pela rede em relação aos valores especificados para o projeto. Novamente, valores próximos ou iguais a zero indicam a solução ótima encontrada pelo algoritmo.

A Tabela 4.4 mostra 5 resultados para otimização da FSS, com mesmo objetivo ($f_r = 11$ GHz e $BW = 3$ GHz), e retornando valores de W e t , além dos seus respectivos resultados retornados pelo *Ansoft Designer*®, para f_r e BW .

Na tabela 4.4, cada teste corresponde a uma execução do algoritmo de morcego. Seus resultados otimizados obtidos podem variar em relação ao número de iterações, o percurso e o tempo computacional. Por esta razão os resultados são apresentados com três casas decimais.

Tabela 4.4: Resultados otimizados para a FSS de espiras integradas com dipolos através de algoritmo de morcego e rede neural artificial.

Parâmetro da FSS	Teste 1	Teste 2	Teste 3	Teste 4	Teste 5
W (mm)	2	2	2	2	2
t (mm)	15	15	15	15	15
f_r (GHz)	11,000	11,000	11,000	11,000	11,000
BW (GHz)	3,035	3,035	3,035	3,035	3,035

A Figura 4.16 mostra a comparação com o resultado medido, o algoritmo híbrido de morcego com RNA e o WCIP, do coeficiente de transmissão e frequência para a FSS otimizada para $f_r = 11$ GHz e $BW = 3$ GHz. Os parâmetros estruturais são: $\epsilon_r = 4,4$; $h = 1,5$ mm, $t = T_x = T_y = 15,0$ mm, $W = 2,0$ mm, $R = 6,0$ mm e $r = 3,13$ mm. A técnica híbrida proposta exhibe resultados concordantes com os resultados medidos, bem como com os outros resultados para WCIP, para frequência e largura de banda.

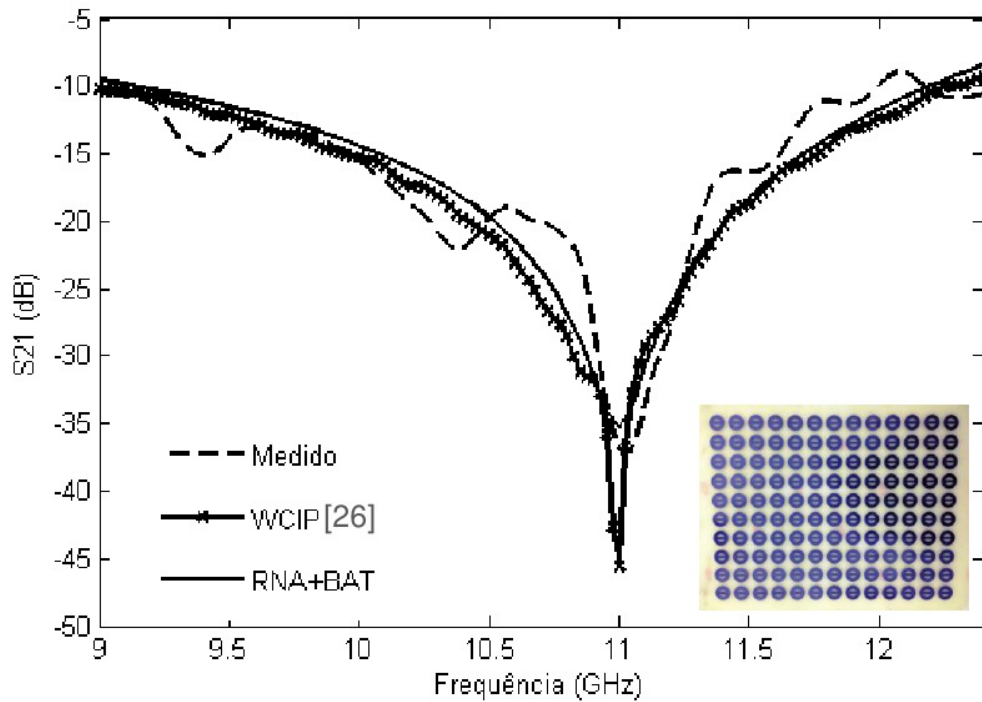


Figura 4.16: Resultados medidos e simulados do coeficiente de transmissão versus frequência da FSS otimizada para $f_r = 11$ GHz e $BW = 3$ GHz. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,5$ mm, $t = 15,0$ mm, $W = 2,0$ mm, $R = 6,0$ mm e $r = 3,13$ mm.

A Figura 4.17 apresenta a evolução da avaliação da função custo no processo de síntese da FSS. Durante o processo de síntese, o valor da função custo apresentada diminui. A linha tracejada mostra a média do custo para a população e a linha sólida representa a evolução do melhor indivíduo.




Figura 4.17: Avaliação do ótimo global durante as iterações.

Para o caso da FSS em 9 GHz, como ponto inicial no espaço de busca, o indivíduo $P = [1,9 \ 17,0]$ foi fixado neste ponto, para que possa ser feita a comparação com a execução dos outros algoritmos de busca.

A Figura 4.18 mostra a comparação com o resultado medido, o algoritmo de morcego híbrido e WCIP, do coeficiente de transmissão e frequência para outra FSS otimizada para $f_r = 9,0$ GHz e $BW = 0,6$ GHz. Os parâmetros estruturais são: $\epsilon_r = 4,4$; $h = 1,5$ mm, $t = T_x = T_y = 22,48$ mm, $W = 1,50$ mm, $R = 6,0$ mm e $r = 3,13$ mm. Novamente se observa que a técnica híbrida proposta exhibe resultados concordantes com os resultados medidos, bem como com os outros resultados para WCIP, para frequência e largura de banda.




Figura 4.18: Resultados medidos e simulados do coeficiente de transmissão versus frequência da FSS otimizada para $f_r = 9,0$ GHz e $BW = 0,6$ GHz. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,5$ mm, $t = 22,48$ mm, $W = 1,5$ mm, $R = 6,0$ mm e $r = 3,13$ mm.

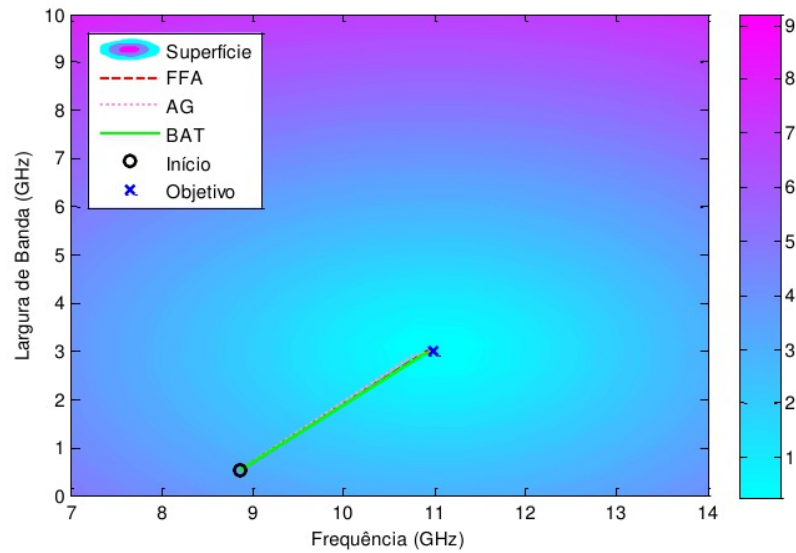
4.6 Comparativo entre as Técnicas

A otimização das estruturas de FSS estudadas aqui, ocorre a partir da minimização da função quadrática de custo. Esta função de custo é diretamente associada aos parâmetros w e T da FSS. A partir da variação destes parâmetros, os algoritmos direcionam os melhores indivíduos (possíveis soluções) da população em direção ao objetivo determinado pelo projeto.


Com o objetivo de verificar a convergência dos três algoritmos implementados, os parâmetros iniciais dos algoritmos foram fixados, como tamanho da população e ponto inicial da busca.

Na Figura 4.19 (a) são apresentados os percursos dos algoritmos, com base nas melhores soluções para cada algoritmo, sobre a função custo. Observa-se que os algoritmos convergem para o mesmo valor, com um percurso semelhante no início da otimização, porém

uma discreta variação próxima da convergência. Com uma aproximação da câmera virtual no gráfico, na Figura 4.19 (b), é observada de maneira mais clara esta variação.



(a)



(b)

Figura 4.19: Superfície de contorno com o percurso para os três algoritmos. (a) Início e fim dos percursos dos algoritmos de busca baseados nas melhores soluções encontradas sobre a função custo. (b) Aproximação da vista superior do gráfico.

Na Figura 4.20 é possível verificar a evolução global do custo para os algoritmos de busca populacionais implementados para a FSS de 11 GHz. É possível observar para o algoritmo genético, começando com uma avaliação baixa e convergindo após 20 iterações. O algoritmo de morcego inicia com uma avaliação superior aos dois algoritmos e converge após 30 iterações. Já o algoritmo de vaga-lume inicia com uma avaliação também baixa, porém com o valor entre os dois algoritmos (genético e morcego), mas com uma convergência rápida, após cinco iterações.






Figura 4.20: Evolução da função custo para os três algoritmos implementados.

Na Figura 4.21 (a) são apresentados os percursos dos algoritmos, com base nas melhores soluções para cada algoritmo, sobre a função custo. Observa-se que os algoritmos convergem para o mesmo valor de frequência e próximos de largura de banda, com um percurso semelhante no início da otimização, porém uma discreta variação próxima da convergência. Com uma aproximação da câmera virtual no gráfico, na Figura 4.21 (b), é observada de maneira mais clara esta variação.



(a)



(b)

Figura 4.21: Superfície de contorno com o percurso para os três algoritmos. (a) Início e fim dos percursos dos algoritmos de busca baseados nas melhores soluções encontradas sobre a função custo. (b) Aproximação da vista superior do gráfico.

Como foi apresentada nas seções anteriores, a aplicação das técnicas foi verificada comparando os resultados das simulações com softwares comerciais, com o método WCIP e com o resultado das medições das FSS.

Na Tabela 4.5, é possível observar que os algoritmos híbridos obtiveram resultados semelhantes na otimização da estrutura para frequência de 11 GHz e largura de banda de 3,0 GHz. Apesar de encontrarem o valor adequado para a construção da FSS, a diferença básica para cada algoritmo é o ponto de convergência do algoritmo. Pode-se observar pelas Figuras 4.19 e 4.20 que o algoritmo de vaga-lume teve um desempenho melhor, em relação ao algoritmo genético e o algoritmo de morcego. No algoritmo de vaga-lume, pode-se observar que a partir da quinta iteração, a função custo atinge o valor próximo de zero, indicando o resultado da otimização esperado. No AG, isso só vai acontecer em torno da vigésima iteração (geração). Por fim, no algoritmo de morcego, a função custo começa a estabilizar próximo do valor mínimo após a trigésima iteração.

Tabela 4.5: Comparação dos resultados dos algoritmos

Parâmetro da FSS	AG	FFA	BAT
W (mm)	2,000	2,000	2,000
t (mm)	15,005	15,000	15,000
f_r (GHz)	11,000	11,000	11,000
BW (GHz)	3,032	3,035	3,035

4.7 Síntese do Capítulo

Este capítulo explicou como foram desenvolvidas as técnicas híbridas deste trabalho. Apresentou seus resultados em detalhes e efetuou uma análise geral da utilização destas técnicas em estruturas de micro-ondas, especificamente FSS. Realizou também uma comparação do desempenho dos algoritmos utilizados e seus resultados, através das simulações e medições das FSS, com o objetivo de validar a utilização destas técnicas de otimização.

Capítulo 5

Conclusões

Este trabalho apresentou um estudo de superfícies seletivas de frequência, destacando suas aplicações principais. Foi comentada a importância histórica das FSS no desenvolvimento da área de micro-ondas, iniciada pelos *radomes* até as aplicações atuais. O projeto e análise de superfícies seletivas de frequência foram descritos. Seus parâmetros e características eletromagnéticas foram discutidos e exemplificados com aplicações. Para o projeto de FSS, as suas estruturas com elementos tradicionais também foram comentadas. Além disso, é proposta uma nova estruturas para o projeto de FSS, com espiras integradas com dipolos. Também foram brevemente discutidas as técnicas de análise mais utilizadas no desenvolvimento dos projetos de FSS. Além disso, foram utilizados softwares comerciais de apoio ao projeto de FSS.

Este trabalho apresentou também um conjunto de técnicas de inteligência computacional. Essas técnicas utilizam redes neurais artificiais em conjunto com algoritmos genéticos, algoritmo bioinspirado em vaga-lumes e algoritmo inspirado na ecolocalização dos morcegos. Os algoritmos foram detalhados e expostos nas formas de pseudocódigo e/ou fluxograma. Estes algoritmos foram aplicados na otimização de células de uma FSS. A técnica de otimização geral, cria um novo modelo de algoritmo, chamado de algoritmo híbrido, pois une o benefício da generalização das redes neurais com o poder de exploração da informação dos algoritmos populacionais. Estas técnicas ainda podem ser mais exploradas pela aplicação em outros dispositivos de telecomunicações como, por exemplo: antenas, filtros, guias de onda, etc. A principal vantagem dos algoritmos populacionais é a habilidade de localizar rapidamente regiões onde há potenciais soluções para o problema.

Os algoritmos de Computação Natural implementados nesta tese foram discutidos e detalhados. Os parâmetros de treinamento e de arquitetura da rede foram mantidos constantes para a modelagem das FSS. A abordagem neural que foi utilizada, mostrou-se eficiente e uma alternativa na estimação de parâmetros das FSS, como por exemplo, coeficiente de transmissão e largura de banda. Os resultados obtidos após o treinamento das redes mostraram que a técnica desenvolvida pode ser usada como uma ferramenta computacional de apoio,

contribuindo consideravelmente no estudo de modelagem de estruturas planares como as FSS, bem como outras estruturas de micro-ondas, como as antenas de microfita.

Com base nos resultados obtidos nesta tese, para a síntese de FSS, novos trabalhos poderão ser executados. Uma análise de sensibilidade dos parâmetros dos algoritmos poderá ser realizada. Para os algoritmos genéticos, a exploração do operador de mutação, por exemplo, poderá gerar novos estudos, visto que a variação desse operador influencia na diversidade da busca. Também poderão ser realizados estudos com outras estruturas de FSS, variando a geometria de seus elementos e a periodicidade do arranjo.

Referências Bibliográficas

- [1] B. A. Munk, Frequency-selective surfaces: theory and design. John Wiley & Sons, New York, 2000.
- [2] T. K. Wu, Frequency selective surface and grid array, John Wiley & Sons, New York, 1995.
- [3] C. L. Nóbrega, M. R. Silva, W. C. Araujo, P. H. F. Silva e A. G. D'Assunção, "Analysis of frequency selective surfaces with T-shaped pre-fractals patch elements", SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference (IMOC), 2011, Brazil.
- [4] D. B. Brito, A. G. D'Assunção, R. H. C. Maniçoba e X. Begaud, "Metamaterial inspired fabry-pérot antenna with cascaded frequency selective surfaces", Microwave and Optical Technology Letters (Print), vol. 55, pp. 981-985, 2013.
- [5] M. R. Silva, C. L. Nóbrega, P. H. F. Silva e A. G. D'Assunção, "Dual-polarized band-stop FSS spatial filters using vicsek fractal geometry". Microwave and Optical Technology Letters (Print), vol. 55, pp. 31-34, 2013.
- [6] P. H. F. Silva, A. F. Santos, R. M. S. Cruz e A. G. D'Assunção, "Dual-band bandstop frequency selective surfaces with gosper prefractal elements", Microwave and Optical Technology Letters (Print), vol. 54, pp. 771-775, 2012.

- [7] M. Ohira, H. Deguchi, M. Tsuji e H. Shigesawa, "Multiband single-layer frequency selective surface designed by combination of genetic algorithm and geometry-refinement technique", IEEE Transactions on Antennas and Propagation, vol. 52, n° 11, pp. 2925-2931, 2004.
- [8] A. G. D'Assunção Júnior, G. Fontgalland, M. Titaouine, H. Baudrand e A. Gomes Neto, "Analysis of quasi-square open ring frequency selective surface using the wave concept iterative procedure", SBMO/IEEE MTT-S International Microwave Optoelectronics Conference (IMOC), pp. 735-740, Belém, Brazil, 2009.
- [9] A. G. D'Assunção Júnior, "Análise de circuitos integrados e de superfícies seletivas de frequência pelo método iterativo das ondas para aplicações nas faixas de micro-ondas e de terahertz", Tese de Doutorado, Universidade Federal de Campina Grande, Paraíba, Brasil, 2012.
- [10] W. C. Araujo, A. G. D'Assunção, H. W. C. Lins e J. L. G. Medeiros, "A hybrid optimization technique for the synthesis of a FSS with integrated ring and dipole elements", The 15th Biennial IEEE Conference on Electromagnetic Field Computation (CEFC2012), 2012, Oita, Japan.
- [11] S. Rao, Engineering optimization: theory and practice, Wiley, New York, 3ª ed., 1996.
- [12] N. Fourikis, "A proposal for a novel shared aperture radar suitable for horizon searches," Proceedings of IEEE International Conference on Phased Array Systems and Technology, pp. 433-436, 2000.
- [13] E. Walton, E. Lee, D. Kohlgraf, R. Pavlovicz, G. Bruce e B. Montgomery, "Compact shipboard antenna system for simultaneous communication with three separate satellites," Proceedings of MTS/IEEE OCEANS, pp. 1577-1580, vol. 2, 2005.

- [14] G. Sen, S. Mahato, T. Mandal, S. Mondal, S. Majumdar, e P. P. Sarkar, "Design of a wide band frequency selective surface (FSS) for multiband operation of reflector antenna", 5th International Conference on Computers and Devices for Communication (CODEC), pp. 1-3, 2012.
- [15] C. G. Bin, Q. Y. Ping, Z. Y. Fang e M. J. Gang, "Design of quasi-optical filter for geostationary orbit microwave radiometer," 5th Global Symposium on Millimeter Waves (GSMM), pp. 529-534, 2012.
- [16] S. Monni, A. Neto, G. Gerini, F. Nennie e A. Tijhuis, "Frequency-selective surface to prevent interference between radar and SATCOM antennas," IEEE Antennas and Wireless Propagation Letters, vol. 8, pp. 220-223, 2009.
- [17] T. Smith, U. Gothelf, O. S. Kim e O. Breinbjerg, "An FSS-backed 20/30 GHz circularly polarized reflectarray for a shared aperture L- and ka-band satellite communication antenna," IEEE Transactions on Antennas and Propagation, vol. 62, n° 2, pp. 661-668, 2014.
- [18] D. M. Pozar, Microwave engineering, Wiley, 3rd edition, 2005.
- [19] H. W. C. Lins, E. L. F. Barreto e A. G. D'Assunção, "Enhanced wideband performance of coupled frequency selective surfaces using metaheuristics", Microwave and Optical Technology Letters (Print), vol. 55, pp. 711-715, 2013.
- [20] A. Hoorfar, "Evolutionary programming in electromagnetic optimization: a review," IEEE Transactions on Antennas and Propagation, vol.55, n° 3, pp. 523-537, 2007.
- [21] W. C. Araujo, A. G. D'Assunção e L. M. Mendonça, "Análise de antenas retangulares com fendas através de redes neurais artificiais", XXIX Simpósio Brasileiro de Telecomunicações (SBrT'11), Anais do SBrT'11, Curitiba, 2011.

- [22] W. C. Araujo, A. G. D'Assunção e L. M. Mendonça, "Artificial neural networks for multi-slot microstrip patch antennas", International Conference on Electromagnetics in Advanced Applications (ICEAA 2011), Proceedings of ICEAA 2011, pp. 532-535, Turim, 2011.
- [23] W. C. Araujo, A. G. D'Assunção e L. M. Mendonça, "Analysis of multi-slot microstrip patch antennas using neural networks", 4th European Conference on Antennas and Propagation (EuCAP 2010), Proceedings of EuCAP 2010, vol. 1, pp. 1-3, Barcelona, 2010.
- [24] W. C. Araujo, A. G. D'Assunção e L. M. Mendonça, "Effect of square slot in microstrip patch antennas using artificial neural networks", 14th Biennial IEEE Conference on Electromagnetic Field Computation, Chicago, 2010.
- [25] W. C. Araujo, E. N. R. Q. Fernandes, L. M. Mendonça, A. G. D'Assunção e R. A. Martins, "Análise neurocomputacional de antenas de microfita multibanda para sistemas de comunicação sem fio", MOMAG 2008, 13° SBMO Simpósio Brasileiro de Micro-ondas E Optoeletrônica e 8° CBMAG Congresso Brasileiro de Eletromagnetismo, anais do MOMAG 2008, vol. único, pp. 34-37, Florianópolis, 2008.
- [26] W. C. Araujo, H. W. C. Lins, A. G. D'Assunção, J. L. G. Medeiros e A.G. D'Assunção, "A bioinspired hybrid optimization algorithm for designing broadband frequency selective surfaces", Microwave and Optical Technology Letters, vol. 56, pp. 329-333, 2014.
- [27] W. C. Araujo, H. W. C. Lins, A. G. D'Assunção, C. R. M. Silva e L. M. Mendonça, "Síntese de superfícies seletivas de frequência utilizando uma técnica híbrida de otimização", 15° SBMO Simpósio Brasileiro de Micro-ondas e Optoeletrônica e o 10° CBMag Congresso Brasileiro de Eletromagnetismo, João Pessoa, Paraíba, Brasil, 2012.

- [28] S. Genovesi, R. Mittra, A. Monorchio e G. Manara, "Particle swarm optimization for the design of frequency selective surfaces," *IEEE Antennas and Wireless Propagation Letters*, vol. 5, n° 1, pp. 277-279, 2006.
- [29] A. Fallahi, M. Mishrikey, C. Hafner e R. Vahldieck, "Efficient procedures for the optimization of frequency selective surfaces," *IEEE Transactions on Antennas and Propagation*, vol. 56, n° 5, pp. 1340-1349, 2008.
- [30] R. O. Ouedraogo, E. J. Rothwell, A. R. Diaz, K. Fuchi e J. Tang, "Waveguide band-stop filter design using optimized pixelated inserts", *Microwave and Optical Technology Letters*, vol. 55, pp. 141-143, 2013.
- [31] L. Xie, Y. C. Jiao, Y. Q. Wei, G. Zhao e F. S. Zhang, "A compact UWB slot antenna optimized by genetic algorithm", *Microwave and Optical Technology Letters*, vol. 53, pp. 2135-2139, 2011.
- [32] H. W. C. Lins, "Análise e síntese de antenas e superfícies seletivas de frequência utilizando computação evolucionária e inteligência de enxames", Tese de Doutorado, Universidade Federal do Rio Grande do Norte, Rio Grande do Norte, Brasil, 2012.
- [33] L. N. Castro, *Fundamentals of natural computing: basic concepts, algorithms, and applications*. Chapman & Hall/CRC Computer and Information Science Series, 2006.
- [34] L. N. Castro, "Fundamentals of natural computing: an overview", *Physics of Life Reviews*, vol. 4, pp. 1-36, ISSN 1571-0645, 2007.
- [35] S. Haykin, *Neural networks and learning machines*, Prentice-Hall, 2009.

- [36] W. McCulloch e W. Pitts, "A logical calculus of the ideas immanent in nervous activity", *The Bulletin of Mathematical Biophysics*, Kluwer Academic Publishers, vol. 5, n° 4, pp. 115-133, 1943.
- [37] W. C. Araujo, "Análise neurocomputacional de antenas de microfita multibanda para sistemas de comunicação sem fio", Dissertação de Mestrado, Universidade Federal do Rio Grande do Norte, 2007.
- [38] D. E. Rumelhart, G. E. Hinton e R.J. Williams, "Learning internal representations by error Propagation", D. E. Rumelhart, J. L. McClelland and The PDP Research Group, *Parallel distributed processing: Explorations in the microstructure of cognition*, Foundations, MIT Press, vol. 1, pp. 318-362, Cambridge, MA, 1986.
- [39] M. T. Hagan e M. B. Menhaj, "Training feedforward networks with the Marquardt algorithm", *IEEE Transactions on Neural Networks*, vol. 5, n° 6, pp. 989-993, 1994.
- [40] C. Darwin, *A Origem das Espécies. Clássicos de ouro ilustrados*. Ediouro Publicações, 2004.
- [41] Delichatsios, S. A., "GA optimization for RFID broadband antenna applications," 2006. Disponível em: http://fab.cba.mit.edu/classes/MIT/862.06/students/alki/ga_paper.pdf. Acesso em: 14 nov. 2011.
- [42] L. Haupt e D. H. Werner, *Genetic algorithms in electromagnetics*, John Willey & Sons, New York, 2007.
- [43] L. Haupt e S. E. Haupt, *Practical genetic algorithms*, John Willey & Sons, New Jersey, 2004.

- [44] J. H. Holland, *Adaptation in natural and artificial systems*. 2 ed. MIT Press, 1992.
- [45] D. B. Fogel, "An introduction to simulated evolutionary computation", *IEEE Transactions on Neural Networks*, vol. 5, n° 1, pp. 3-14, 1994.
- [46] X. S. Yang, *Nature-Inspired Metaheuristic Algorithms*, Luniver Press, 2008.
- [47] Sh. M. Farahani, A. A. Abshouri, B. Nasiri e M. R. Meybodi, "A Gaussian Firefly Algorithm," *International Journal of Machine Learning and Computing*, vol. 1, n° 5, pp. 448-453, 2011.
- [48] X. S. Yang, "A new metaheuristic bat-inspired algorithm", *Nature Inspired Cooperative Strategies for Optimization (NICSO 2010)*, (Eds. J. R. Gonzalez et al.), Springer Berlin, vol. 284, pp. 65-74, 2010.
- [49] J. O. Whitaker Jr, H. K. Dannelly e D. A. Prentice, "Chitinase in insectivorous bats", *Journal of Mammalogy*, vol. 85, pp. 15-18, 2004.
- [50] J. D. Altringham, *Echolocation and other senses*. Oxford University Press, New York, 2011.