

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

TESE DE DOUTORADO

**SÍNTESE DE SUPERFÍCIES SELETIVAS DE FREQUÊNCIA PARA
MICRO-ONDAS UTILIZANDO OTIMIZAÇÃO MULTI OBJETIVO
BIOINSPIRADA**

MIÉRCIO CARDOSO DE ALCÂNTARA NETO

TD 09/2015

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil

2015

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

MIÉRCIO CARDOSO DE ALCÂNTARA NETO

**SÍNTESE DE SUPERFÍCIES SELETIVAS DE FREQUÊNCIA PARA
MICRO-ONDAS UTILIZANDO OTIMIZAÇÃO MULTIOBJETIVO
BIOINSPIRADA**

TD 09/2015

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2015

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

MIÉRCIO CARDOSO DE ALCÂNTARA NETO

**SÍNTESE DE SUPERFÍCIES SELETIVAS DE FREQUÊNCIA PARA
MICRO-ONDAS UTILIZANDO OTIMIZAÇÃO MULTI OBJETIVO
BIOINSPIRADA**

Tese submetida à Banca Examinadora do Programa de Pós-graduação em Engenharia Elétrica da UFPa para a obtenção do Grau de Doutor em Engenharia Elétrica, elaborada sob a orientação do Prof. Dr. Gervásio Protásio dos Santos Cavalcante e coorientação do Prof. Dr. Adaildo Gomes d'Assunção.

UFPa / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2015

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da Universidade, do Orientador, do Coorientador e do Autor.

Miércio Cardoso de Alcântara Neto

Graduou-se em Engenharia de Telecomunicações pelo Instituto de Estudos Superiores da Amazônia (2010), mestrado em Engenharia Elétrica pela Universidade Federal do Pará (2013).

Alcântara Neto, Miércio Cardoso de

Síntese de superfícies seletivas de frequência para micro-ondas utilizando otimização multiobjetivo bioinspirada / Miércio Cardoso de Alcântara Neto; orientador, Gervásio Protásio dos Santos Cavalcante; co-orientador, Adaildo Gomes D'Assunção. - 2015.

Tese (Doutorado) – Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2015.

1. Dispositivos de micro-ondas. 2. Eletromagnetismo. 3. Superfícies seletivas em frequência. I. Orientador. II. Título.

CDD 22. ed. 621.3813

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA ELÉTRICA

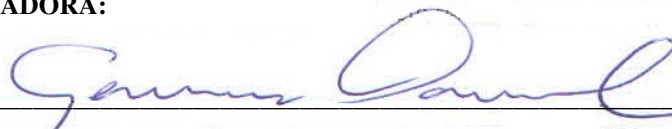
“SÍNTESE DE SUPERFÍCIES SELETIVAS DE FREQUÊNCIA PARA MICRO-ONDAS UTILIZANDO
OTIMIZAÇÃO MULTIOBJETIVO BIOINSPIRADA”

AUTOR: MIÉRCIO CARDOSO DE ALCÂNTARA NETO

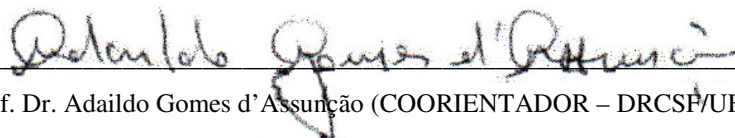
TESE DE DOUTORADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO COLEGIADO DO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO JULGADA ADEQUADA
PARA A OBTENÇÃO DO GRAU DE DOUTOR EM ENGENHARIA ELÉTRICA NA ÁREA DE
TELECOMUNICAÇÕES.

APROVADA EM: 19/08/2015

BANCA EXAMINADORA:



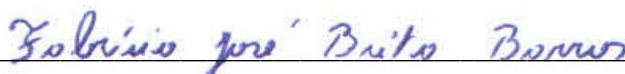
Prof. Dr. Gervásio Protásio dos Santos Cavalcante (ORIENTADOR – PPGEE/UFPA)



Prof. Dr. Adaildo Gomes d'Assunção (COORIENTADOR – DRCSF/UFRN)



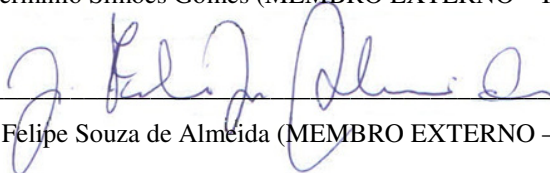
Prof. Dr. Alfredo Gomes Neto (MEMBRO EXTERNO – IFPB)



Prof. Dr. Fabrício José Brito Barros (MEMBRO EXTERNO – CAMPUS TUCURUI/UFPA)



Prof. Dr. Hermínio Simões Gomes (MEMBRO EXTERNO – ICEN/UFPA)



Prof. Dr. José Felipe Souza de Almeida (MEMBRO EXTERNO – ICIBE/UFRA)

VISTO:



Prof. Dr. Evaldo Gonçalves Pelaes – Coordenador do PPGEE/ITEC/UFPA

À Memória de um Exemplo de Vida meu Avô Miércio
Cardoso de Alcântara e, a memória dos Grandes
Amigos Graça Santos e Néreo Ribeiro.

Ao Esforço e Dedicção de meus Pais Sr. Ermes
Velame e Sra. Ruth Alcântara.

À minhas Amadas Avós Sras. Adrina Castro e Lourdes
Passos e, Irmãs Mariana Velame e Lourdes Velame.

Agradecimentos

Agradeço primeiramente a Deus, por possibilitar grandes vitórias em minha vida e, por colocar companheiros de caminhada ainda mais grandiosos ao longo dessa jornada.

Aos meus pais o Sr. Ermes Passos Velame e a Sra. Maria Ruth S. C. de Alcântara, que sempre serão o meu alicerce, modelo de luta e perseverança em todas as etapas de minha vida, às minhas irmãs Mariana Velame e Lourdes Velame, minhas avós Adrina Castro e Lourdes Passos, familiares e amigos por estarem sempre ao meu lado me apoiando em todos os momentos.

Ao grande “colocador de placas” meu mestre e orientador Professor Gervásio Protásio, por sua orientação, amizade, confiança, paciência, acolhimento e por se postular como exemplo profissional.

A grande amiga e companheira de pesquisa Professora Jasmine Araújo, sem sua crucial contribuição esse trabalho não teria ocorrido.

A lenda viva Professor Adaildo d’Assunção, por me conceder a honra de sua coorientação e por sua fundamental participação no desenvolvimento dessa pesquisa.

Ao grande amigo Professor Fabrício José Brito Barros, pela credibilidade a mim atribuída, por sua amizade e por valiosas contribuições ao trabalho.

Meu agradecimento especial ao Professor Felipe Almeida, que me acompanha desde a graduação e, por ser meu um dos maiores incentivadores ao longo dessa jornada acadêmica.

Aos Professores Hermínio e Alfredo, por abdicarem de seu tempo para participarem da banca examinadora. Em especial ao Professor Alfredo e ao Laboratório de Micro-ondas do Grupo de Telecomunicações e Eletromagnetismo Aplicado (GTEMA).

A minha noiva Ana Carolina Monteiro, por seu companheirismo, paciência e pela criteriosa revisão do texto aqui apresentado. E, ao seu pai e meu grande amigo Sr. Raimundo Carlos (Zamba), pelo apoio, amizade e todo suporte a mim dispensado nesses anos.

Aos amigos que fiz ao longo dessa jornada de trabalho, Marcelo Kawakatsu e Thais Tavares, pela parceria e por valiosas contribuições ao trabalho.

Aos meus amigos e companheiros de luta do Laboratório de Computação e Telecomunicações – LCT.

A todos os demais profissionais do programa de Pós-graduação em Engenharia Elétrica e da Universidade Federal do Pará.

Educai as crianças e não será preciso punir os homens.
(Pitágoras)

Sumário

Lista de Ilustrações	<i>xii</i>
Lista de Tabelas	<i>xiv</i>
Lista de Símbolos e Abreviaturas	<i>xv</i>
Resumo	<i>xvii</i>
Abstract	<i>xviii</i>
Capítulo 1. Introdução	19
<i>1.1. Contextualização</i>	21
<i>1.2. Hipótese</i>	26
<i>1.3. Objetivos</i>	26
<i>1.3.1. Objetivo Geral</i>	26
<i>1.3.2. Objetivos Específicos</i>	27
<i>1.4. Contribuições do Trabalho</i>	27
<i>1.5. Estrutura do Documento</i>	28
Capítulo 2. Superfícies Seletivas de Frequência	30
<i>2.1. Características que Influenciam na Resposta de FSS</i>	32
<i>2.2. Formas Geométricas Comuns para FSS</i>	32
<i>2.3. Estruturas Propostas para as FSS</i>	34
<i>2.4. Síntese do Capítulo</i>	36
Capítulo 3. Ferramentas de Inteligência Computacional Bioinspirada	37
<i>3.1. Otimização Multiobjetivo</i>	38
<i>3.2. Redes Neurais Artificiais</i>	39
<i>3.2.1. Rede Neural de Regressão Geral</i>	40
<i>3.3. Algoritmo Genético</i>	43
<i>3.4. Algoritmo de Ecolocalização dos Morcegos</i>	45
<i>3.4.1. Movimento Virtual dos Morcegos</i>	45
<i>3.5. Algoritmo de Busca Cuco</i>	48
<i>3.5.1. Algoritmo de Busca Cuco Multiobjetivo</i>	52

3.6. Síntese do Capítulo	56
Capítulo 4. Resultados	57
4.1. Caracterização do Projeto	57
4.1.1. Setup para Medição das FSS	63
4.2. Aplicação dos Algoritmos de Otimização	63
4.2.1. Implementação do Algoritmo Genético	64
4.2.2. Implementação do Algoritmo de Ecolização do Morcego	68
4.2.3. Implementação do Algoritmo de Busca Cuco	71
4.3. Síntese do Capítulo	78
Capítulo 5. Plano de Trabalho e Cronograma de Execução	79
Referências Bibliográficas	82

Lista de Ilustrações

Figura 2.1. FSS periódicas bidimensionais do tipo rejeita faixa, (a) arranjo e (b) estrutura periódica.	30
Figura 2.2. FSS usadas na recepção de sinais de satélite.	31
Figura 2.3. Formas de elementos de FSS.	33
Figura 2.4. FSS de <i>patch</i> triangular (a) célula unitária, (b) arranjo e (c) fotografia.	35
Figura 2.5. FSS de espira triangular (a) célula unitária, (b) arranjo e (c) fotografia.	35
Figura 3.1. Relação de dominação para a função custo.	39
Figura 3.2. Diagrama em bloco global da rede GRNN.	41
Figura 3.3. Configuração da rede GRNN utilizada.	42
Figura 3.4. Fluxograma de um AG tradicional.	43
Figura 3.5. Pseudocódigo do algoritmo morcego.	48
Figura 3.6. Pseudocódigo do algoritmo de busca cuco.	51
Figura 3.7. Voo de Lévy 2D com 100 passos.	53
Figura 3.8. Pseudocódigo do algoritmo de busca cuco multiobjetivo.	55
Figura 4.1. Fluxograma geral do projeto.	58
Figura 4.2. Fluxograma modificado pela introdução da técnica de otimização.	59
Figura 4.3. Resposta da rede GRNN para frequência de ressonância (a) e largura de banda (b) em função dos parâmetros estruturais W e t da estrutura do tipo <i>patch</i> triangular.	61
Figura 4.4. Resposta da rede GRNN para frequência de ressonância (a) e largura de banda (b) em função dos parâmetros geométricos W e t da estrutura do tipo espira triangular.	62
Figura 4.5. Esquemático do <i>setup</i> de medição.	63
Figura 4.6. Fluxograma do AG Multi.	64
Figura 4.7. Evolução do <i>fitness</i> no processo de síntese das FSS via AG Multi, estruturas otimizadas para $f_r = 11,0$ GHz e $BW = 4,0$ GHz.	65
Figura 4.8. Coeficiente de transmissão para FSS de <i>patch</i> triangular otimizada para $f_r = 11,0$ GHz e $BW = 4,0$ GHz através do AG Multi. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,57$ mm; $t = T_x = T_y \approx 12,3$ mm e $W \approx 11,6$ mm.	66

- Figura 4.9.** Coeficiente de transmissão para FSS de espira triangular para $f_r = 11,0$ GHz e $BW = 4,0$ GHz através do AG Multi. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,57$ mm; $t = T_x = T_y \approx 9,2$ mm e $W \approx 6,4$ mm. 67
- Figura 4.10.** Fluxograma do algoritmo de ecolocalização de morcego multiobjetivo utilizado. 68
- Figura 4.11.** Evolução do *fitness* no processo de síntese das FSS via MOBA, estruturas otimizadas para $f_r = 11,0$ GHz e $BW = 4,0$ GHz. 69
- Figura 4.12.** Coeficiente de transmissão para FSS de *patch* triangular otimizada para $f_r = 11,0$ GHz e $BW = 4,0$ GHz através do MOBA. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,57$ mm; $t = T_x = T_y \approx 12,8$ mm e $W \approx 11,6$ mm. 70
- Figura 4.13.** Coeficiente de transmissão para FSS de *patch* triangular otimizada para $f_r = 11,0$ GHz e $BW = 4,0$ GHz através do MOBA. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,57$ mm; $t = T_x = T_y \approx 9,6$ mm e $W \approx 6,5$ mm. 71
- Figura 4.14.** Fluxograma do algoritmo de busca cuco multiobjetivo utilizado. 73
- Figura 4.15.** Evolução do *fitness* no processo de síntese via MOCS, estruturas otimizadas para $f_r = 11,0$ GHz e $BW = 4,0$ GHz. 75
- Figura 4.16.** Coeficiente de transmissão para FSS de *patch* triangular otimizada para $f_r = 11,0$ GHz e $BW = 4,0$ GHz via MOCS. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,57$ mm; $t = T_x = T_y \approx 12,3$ mm e $W \approx 11,6$ mm. 76
- Figura 4.17.** Coeficiente de transmissão para FSS de espira triangular otimizada para $f_r = 11,0$ GHz e $BW = 4,0$ GHz via MOCS. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,57$ mm; $t = T_x = T_y \approx 9,2$ mm e $W \approx 6,4$ mm. 77

Lista de Tabelas

Tabela 2.1. Parâmetros Estruturais das FSS	34
Tabela 4.1. Tempo de execução do AG Multi para a 1ª estrutura	65
Tabela 4.2. Tempo de execução do AG Multi para a 2ª estrutura	66
Tabela 4.3. Tempo de execução do MOBA para a 2ª estrutura	69
Tabela 4.4. Tempo de execução do MOBA para a 2ª estrutura	70
Tabela 4.5. Tempo de execução do MOCS para a 1ª estrutura	75
Tabela 4.6. Tempo de execução do MOCS para a 2ª estrutura	76

Lista de Símbolos e Abreviaturas

ϵ_r	Permissividade relativa.
$\tan(\delta)$	Tangente de perda.
AG	Algoritmo Genético.
AG Multi	Algoritmo Genético Multiobjetivo.
ANN	<i>Artificial Neural Network.</i>
BAT	<i>Bat Algorithm.</i>
BIC	<i>Bioinspired Computation.</i>
CPMA	<i>Circularly Polarized Microstrip Antennas.</i>
CS	<i>Cuckoo Search.</i>
dB	Decibel.
MOCS	<i>Cuckoo Search Multi-objective.</i>
EM	Eletromagnético.
FFT	<i>Fast Fourier Transform.</i>
FIT	<i>Finite Integration Technique.</i>
FSS	<i>Frequency Selective Surface.</i>
GA	<i>Genetic Algorithms.</i>
GA Multi	<i>Genetic Algorithms Multi-objective.</i>
GRNN	<i>General Regression Neural Network.</i>
LM	Levenberg-Marquardt.
MFA	<i>Multiple Functions Antenna.</i>
MLP	<i>Multilayer Perceptrons.</i>
MOBA	<i>Multiobjective Bat Algorithm.</i>
MOCS	<i>Cuckoo Search Multiobjective.</i>
MoM	<i>Method of Moments.</i>
PCB	<i>Printed Circuit Boards.</i>
PSO	<i>Particle Swarm Optimization.</i>
QoS	<i>Quality of Service.</i>
RB	Rede Bayesiana.
RBFN	<i>Radial Basis Function Networks.</i>
RBFNN	<i>Radial Basis Function Neural Network.</i>
RNA	Rede Neural Artificial.

ROI	<i>Region of Interest.</i>
S-FLC	<i>Sugeno-type fuzzy logic controllers.</i>
UWB	<i>Ultra Wide Band.</i>
WLAN	<i>Wireless Local Area Network.</i>

Resumo

A evolução da computação tem possibilitado avanços substanciais em pesquisas relacionadas à engenharia e em projetos industriais. Nestas áreas, o emprego de ferramentas computacionais tem se intensificado para simulação e obtenção de determinados parâmetros do projeto. No entanto, a crescente demanda por precisão e o aumento gradativo da complexidade das estruturas e sistemas, resulta num processo de simulação cada vez mais demorado, pois a avaliação de um único critério pode consumir várias horas, bem como vários dias ou até mesmo semanas. Logo, um método que minimize o tempo de simulação e otimização, pode, assim, economizar tempo e dinheiro. Nesse contexto, a computação bioinspirada (*bioinspired computing* - BIC), se apresenta precisa e eficiente, onde muitos métodos computacionais tradicionais falham e, consiste em novo mecanismo para suprir tais dificuldades. Assim, neste trabalho, é realizado um estudo acerca de alguns dos algoritmos BIC mais utilizados na atualidade para projeto e otimização de problemas gerais na engenharia e na indústria. Doravante, se vislumbra desenvolver um código de otimização meta-heurístico multiobjetivo que apresente menor custo computacional e, conseqüentemente, menor tempo para processamento dos dados. Inicialmente, é realizada uma investigação eletromagnética das superfícies seletivas de frequência triangulares estudadas, através de simulações computacionais. A análise numérica de onda completa é feita pela técnica das integrais finitas com o auxílio de um *software* comercial muito utilizado para simulações em eletromagnetismo. O processo de síntese consiste em sintonizar a frequência de ressonância das estruturas e a largura de banda de acordo com os objetivos inseridos na função custo dos algoritmos de otimização. A modelagem das estruturas é realizada por uma rede neural artificial e o processo de otimização é realizado por algoritmos meta-heurísticos. Os resultados obtidos por esses códigos são comparados aos simulados pelo *software* comercial e aos medidos. Observou-se boa concordância entre os resultados simulados e medidos, bem como uma substancial redução no menor tempo de processamento das estruturas. Por fim, são apresentadas as conclusões e as propostas para trabalhos futuros.

Palavras-chave: superfície seletiva de frequências, computação bioinspirada, otimização multiobjetivo, técnica híbrida, rede neural de regressão geral, algoritmo genético, algoritmo de ecolocalização do morcego, algoritmo de busca cuco.

Abstract

The evolution of computing has made possible substantial advances in research related to engineering and industrial projects. In these areas, the use of computational tools has been intensified for simulation and obtaining certain parameters of the project. However, the growing demand for precision and the gradual increase of the complexity of the structures and systems, results in a simulation process increasingly time-consuming, because the evaluation of a single criterion can consume several hours, as well as several days or even weeks. Therefore, a method that maximizes the time of simulation and optimization, can thus save time and money. In this context, bioinspired computing (BIC), presents accurate and efficient, where many traditional computational methods fail and consists of new mechanism to address such difficulties. Thus, in this work, a study about some of the algorithms used today for BIC design and optimization of general problems in engineering and industry. From now on, one sees develop a meta-heuristic optimization code to provide lower-cost computational multiobjective and, consequently, less time for data processing. Initially, an electromagnetic research of frequency selective surfaces with triangular patch elements is done by computer simulations. The numerical analysis is carried out using a full-wave technique based on finite integrals implemented on commercial software performed for simulations in electromagnetism. The synthesis process consists of tuning the resonant frequency of the structures and the bandwidth according to the objectives in the cost function optimization algorithms. The modeling of structures is performed by an artificial neural network and optimization process is performed by meta-heuristics algorithms. The results obtained by these codes are compared to simulated ones by commercial software and measured. A good agreement between simulated and measured results was obtained, as well as a substantial reduction in the processing time of the structures. Finally, conclusions and proposals for further works are presented.

Index-terms: frequency selective surface, bioinspired computing, multi-objective optimization, hybrid technique, general regression neural network, genetic algorithm, bat echolocation algorithm, cuckoo search algorithm.

Capítulo 1

Introdução

O desenvolvimento da computação tem possibilitado avanços substanciais na indústria e nas áreas mais tradicionais da engenharia, especialmente, em engenharia de antenas, caracterizando um crescente emprego de modelos de otimização como paradigmas para problemas de tomada de decisão em projetos de estruturas eletromagnéticas, tais como, superfícies seletivas de frequência (*frequency selective surface* – FSS), antenas e filtros. Assim, se destacam os simuladores de campo eletromagnético tridimensional de onda completa, que possibilitam a análise de estruturas complexas, e viabilizam a substituição do processo de projeto experimental iterativo.

O emprego desses simuladores, que utilizam técnicas numéricas precisas para análises de onda completa, tais como, método dos momentos (*method of moments* – MoM) [1] e a técnica da integração finita (*finite integration technique* – FIT) [2], na análise de FSS para aplicações em micro-ondas, contabilizam um alto custo computacional, além de requererem, em muitos casos, um elevado tempo para processamento das geometrias projetadas. Isso, por envolver uma variedade de formatos, dimensões e periodicidade dos elementos [3].

A computação bioinspirada (*bioinspired computation* – BIC) e algoritmos meta-heurísticos, por conseguinte, se destacam como promissoras ferramentas da ciência da computação moderna, pois são adequadas para resolver tais dificuldades. Estes algoritmos são inspirados no comportamento de sistemas biológicos e/ou sistemas físicos da natureza, constituindo-se em poderosos métodos para solução de problemas complexos nas diversas áreas da engenharia e da indústria [4], [5].

O fato desses algoritmos lidarem eficientemente com problemas arbitrários de otimização e, serem quase sempre, auto organizáveis, adaptáveis e tolerantes a defeitos aleatórios [4], justifica o crescente interesse por parte dos pesquisadores da comunidade do eletromagnetismo [6].

Dentre estes códigos se destacam os clássicos algoritmo genético (*genetic algorithms* – GA), a rede neural artificial (*artificial neural network* – ANN) e, a otimização por enxame

de partículas (*particle swarm optimization* – PSO), ambos utilizados com sucesso no processo de otimização.

Na busca por combinar as principais vantagens dos algoritmos clássicos, pesquisadores estão propondo em seus trabalhos novos algoritmos meta-heurísticos, seja para acelerar o processo de desenvolvimento do projeto, ou para melhorar as características físicas dos dispositivos projetados, tais como: ganho, largura de banda, diagrama de radiação em antenas, ou para geometrias com dimensões reduzidas mais adequadas para o projeto de antenas e de FSS. Nesse cenário, se destacam os algoritmos de busca cuco (*cuckoo search* – CS) proposto por Yang e Deb [7] em 2009 e, o algoritmo de ecolocalização do morcego ou (*bat algorithm* – BAT) proposto por Yang [8] em 2010.

Ao explorar as potencialidades dessas ferramentas computacionais, pesquisadores planejam redes neurais artificiais (RNA) para trabalharem em conjunto com algoritmos de otimização, esta técnica é denominada de método híbrido [9]. Nesta disposição, a RNA após ser treinada com os dados eletromagnéticos (EM), calculados pelo método numérico empregado, cria um espaço de busca denominado de região de interesse e, nessa região, os algoritmos de otimização realizam buscas das melhores soluções que atendam a função objetivo (ou função custo) do projeto.

Esse processo viabiliza maior robustez e flexibilidade ao projeto, garantindo resultados ainda mais precisos e, em alguns casos, maximiza o tempo de processamento das estruturas, o que contribuiu para o aumento significativo do emprego desta técnica em aplicações na área de micro-ondas [3], [10].

Neste trabalho, é implementado o processo de otimização híbrida em FSS triangulares do tipo *patch*, com geometrias simplificadas e baixo custo de fabricação, por meio do projeto de uma rede neural artificial, que atuará em conjunto com os algoritmos de otimização.

As FSS abrangem uma grande área das telecomunicações e têm sido largamente utilizadas devido a seu baixo custo de fabricação, peso reduzido e possibilidade de se integrar com outros circuitos de micro-ondas [11]. Uma das aplicações mais importantes das FSS é projetar estruturas com características passa-faixa ou rejeita-faixa usando elementos do tipo abertura ou *patch*, respectivamente. E, elas são especialmente importantes para diversas aplicações, como suporte a comunicação de aviões, foguetes, mísseis, *radomes*, sistemas de antenas, entre outras [12].

Neste estudo, especificamente, são desenvolvidas técnicas híbridas multiobjetivo para otimização bioinspirada capazes de prover rápida convergência para a solução da função custo,

quicá viabilizar a redução do tempo necessário para processamento das estruturas estudadas. Logo, serão desenvolvidos algoritmos de otimização multiobjetivo, a saber: algoritmo genético, algoritmo de ecolocalização dos morcegos e algoritmo de busca cuco.

Estes algoritmos realizam a síntese das FSS triangulares investigadas, para aplicações em micro-ondas, estas serão sintonizadas na faixa de frequências pertencentes a banda X, com suas respectivas frequências de ressonância centradas em 11,0 GHz e suas larguras de banda em aproximadamente 4,0 GHz, a partir da variação da periodicidade do arranjo t e da dimensão física W que correspondem ao lado do *patch* triangular da célula unitária.

Os resultados otimizados pelas técnicas híbridas desenvolvidas foram utilizados para fabricação de protótipos das FSS estudadas. Estas foram impressas em substrato de fibra de vidro (FR-4) com permissividade relativa $\epsilon_r = 4,4$, tangente de perda $\tan(\delta) = 0,02$ e espessura de $h = 1,57$ mm. E, em seguida, realizou-se medições no Laboratório de Micro-ondas do Grupo de Telecomunicações e Eletromagnetismo Aplicado (GTEMA) do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba (IFPB) para validar o modelo desenvolvido.

As frequências de corte superior e inferior utilizadas para controle da frequência de ressonância e largura de banda foram obtidas em -10 dB. Após as medições, foi verificado que os resultados medidos e simulados apresentam boa concordância, validando a metodologia desenvolvida.

1.1. Contextualização

As RNA têm atraído o interesse de pesquisadores da área de engenharia de antenas para projeto de suas dimensões físicas, bem como, para arranjo desses dispositivos ressonantes por possibilitar o tratamento simultâneo de diversos parâmetros do projeto. E, a partir de um conjunto de restrições, que atendam aos objetivos do projeto, garantir uma modelagem precisa a um baixo custo computacional.

Rama *et al* [13] desenvolveu em seu trabalho, uma nova abordagem para projeto de arranjo de antenas de múltiplas funções (*multiple functions antenna* – MFA) utilizando a rede neural com função de base radial (*radial basis function neural network* – RBFNN), esta foi treinada com os pares de entradas/saídas dos dados calculados e, após os testes, a rede apresentou uma taxa de sucesso de 98%.

Angelo Freni *et al* [14], da mesma forma, abordou em seu trabalho um modelo de RNA simplificada, para modelagem de componentes elementares de arranjo refletivo de antenas. Esta foi introduzida com o objetivo de melhorar a eficiência numérica nas diferentes fases do projeto

e no processo de otimização da estrutura, sem que houvesse perda de precisão dos resultados. Os autores concluíram que, os resultados obtidos validaram a técnica desenvolvida, e observaram que a utilização da RNA possibilita redução drástica no tempo para processamento computacional, sem alterar a precisão da solução.

Como as RNA possibilitam o tratamento simultâneo de diversos parâmetros no projeto de antenas, Zhongbao Wang e Shaojun Fang [15], propuseram um modelo de RNA para aplicação no projeto de uma antena de microfita de canto truncado, circularmente polarizada e alimentação simples (*circularly polarized microstrip antennas* – CPMA), com um gap de ar separando o substrato dielétrico do plano de terra *patch* para aplicações em banda larga. Os autores utilizaram dois tipos de rede neural para cálculo das dimensões físicas da antena: uma do tipo MLP e redes com função de base radial (*radial basis function networks* – RBFN). Para isso, empregaram seis algoritmos para aprendizagem/treinamento da MLP. Além disso, estes autores, ao comparar as RNA, MLP e RBFN, salientaram que estas redes quando treinadas com algoritmo de Levenberg-Marquardt (LM), identificam que a MLP apresentou melhor resultado para a síntese da CPMA. O modelo desenvolvido foi validado pelas simulações EM e medições.

Nesse contexto, algoritmos meta-heurísticos multiobjetivos também se destacam no projeto de antenas, tal como investigado por C. Moreno *et al* [16], no qual foi aplicado um algoritmo genético multiobjetivo para projeto de uma nova estrutura de antena *bowtie*, com aplicação em banda ultra larga (*ultra wide band* – UWB), isso foi alcançado através da otimização do perfil da impedância de carga e do ângulo de sinalização da antena. Ao final do projeto, foi fabricado um protótipo e as simulações numéricas foram validadas através de medições.

O eletromagnetismo (EM) tem sido um tema de intensa investigação e, o desenvolvimento de novos dispositivos para rádio comunicação, tem resultado em um espectro de frequências cada vez mais poluído por diversas fontes de comunicação sem fio. O controle da propagação de ondas EM, através de superfícies ou camadas de fronteira é um assunto de grande interesse em pesquisas no âmbito do eletromagnetismo aplicado. É nesse cenário que as FSS se destacam, devido a sua capacidade de controlar características como intensidade, polarização e fase de propagação da onda em certas faixas de frequência [17]. Isso justifica o desenvolvimento de técnicas para análise, projeto e o desenvolvimento de novas formas geométricas de FSS para aplicações em diferentes padrões de frequências e sistemas [18].

No projeto destes dispositivos, técnicas numéricas para cálculo das propriedades eletromagnéticas são bastante exploradas. Todavia, há um grande esforço computacional e

elevado consumo de tempo para alcançar as soluções desejadas, desse modo, algoritmos BIC se apresentam como solução viável no processo de otimização desses dispositivos.

Esta nova área da inteligência computacional é explorada com sucesso no desenvolvimento e na otimização de FSS, tal como pode ser encontrada em Cruz *et al* [19], na qual uma rede neural do tipo MLP foi desenvolvida para modelagem de filtros do tipo rejeita faixa para operação nas frequências pertencentes aos padrões da banda X (8 – 12 GHz) e banda Ku (12 – 18 GHz). A rede desenvolvida foi treinada com os dados EM calculados através do *software* comercial *Ansoft Designer*TM, cujos resultados experimentais e simulados foram comparados com sucesso e validaram o modelo de MLP desenvolvido.

Wellington *et al* [9] e Paulo *et al* [20], tão logo, utilizaram o mesmo processo de modelagem e treinamento desenvolvidos em [19], aplicando-os a FSS do tipo rejeita faixa para banda X. Também foram propostas técnicas de otimização híbrida que associam a rede MLP ao AG e ao PSO, respectivamente. Em ambos os casos foi conseguida boa concordância entre resultados simulados e medidos para as estruturas otimizadas.

Estruturas de FSS multicamadas ou, em cascata, têm contribuído significativamente para a melhora do desempenho dos circuitos de comunicação, porém, a questão da largura de banda continua sendo um dos principais problemas na teoria de FSS. Nesse contexto, Lins *et al* [21] aplica os algoritmos meta-heurísticos GA e PSO, com o objetivo de alcançar o desempenho ótimo de banda larga no acoplamento entre duas estruturas de FSS. O AG foi aplicado para otimizar os elementos condutores constituídos por dipolos cruzados e, o PSO para determinar o valor ótimo do gap de ar que separa as duas camadas. Com isso, se observou boa concordância entre os resultados medidos e simulados.

A robustez e a precisão dos resultados obtidos através de técnicas híbridas são igualmente explorados na transmissão de dados por rádio difusão, tal como pode ser encontrado em Araújo *et al* [22], onde foi desenvolvida uma precisa estratégia para planejamento e otimização de redes locais sem fio (*wireless local area network* – WLAN), ao considerar os efeitos da interferência que podem degradar os parâmetros de QoS (*quality of service*) das aplicações provindas dos usuários. Outrossim, empregaram técnicas híbridas de otimização, nas quais utilizaram Redes Bayesianas (RB) para diagnóstico de problemas, tal como no efeito da interferência ocorrida na transmissão dos dados e, a exploração de técnicas de otimização baseadas na rede neural de regressão geral (*general regression neural network* – GRNN) e AG. Após medições e testes, estes autores alcançaram resultados satisfatórios que validaram a técnica aplicada.

O processo de otimização basicamente consiste em minimizar o esforço computacional requerido ou maximizar as vantagens desejadas no projeto [3], ou seja, buscar soluções que resultem no valor mínimo ou máximo da função objetivo. Tais métodos de otimização são utilizados com sucesso em problemas distribuídos em áreas diversas da engenharia e da indústria.

Neste interim, o algoritmo meta-heurístico de busca cuco (CS) merece destaque, pois se trata de um dos mais recentes algoritmos BIC, e tem atraído atenção de pesquisadores nas mais diversas áreas por apresentar rápida convergência para otimização da função custo, e simplicidade na determinação dos parâmetros iniciais.

Saeed Balochian e Eshagh Ebrahimi [23] aplicaram o CS para ajuste dos parâmetros ótimos de controladores lógicos *fuzzy* do tipo Sugeno (*Sugeno-type fuzzy logic controllers – S-FLC*), que são utilizados no controle do nível de líquido. Estes autores concluíram, claramente, sob os resultados obtidos que a FLC otimizada via CS possui melhor desempenho, quando comparado a ajustes manuais dos parâmetros de controle do sistema, para diferentes conjuntos de dados.

A eficiência energética se tornou uma importante meta para o projeto de equipamentos em redes de transmissão de energia, por isso, muitos elementos e funções dos equipamentos desse tipo de rede estão sendo remodelados para melhorá-la.

Attia A. El-Fergany e Almoataz Y. Abdelaziz [24], desenvolveram em seu trabalho uma abordagem baseada na otimização via CS, para alocação de capacitores em derivação estática ao longo de uma rede de distribuição radial. A função objetivo foi aplicada para minimizar o custo de operação do sistema durante seu carregamento, sob diferentes condições e, para melhorar o perfil de tensão do sistema. Além disso, com o fim de encontrar a melhor localização e os valores ótimos para fixação os capacitores de comutação nessas redes, com diferentes níveis de carga, através do algoritmo proposto. A confiabilidade geral e a metodologia desenvolvida, foram validadas por meio de testes em sistemas de distribuição radiais com diferentes topologias, de tamanhos e complexidades variadas. Os autores concluíram que a precisão dos resultados apresentados pelo método proposto, superaram os resultados de algoritmos heurísticos encontrados na literatura, quando aplicados na solução do mesmo problema.

O CS é um novo algoritmo evolutivo inspirado na natureza para resolver problemas de otimização. Quando comparado a outros algoritmos meta-heurísticos, o CS proporciona características mais amigáveis ao utilizador, por ser facilmente compreendido e implementado

com um número reduzido de parâmetros a serem ajustados [7]. Fatores estes que viabilizam a aplicação desse algoritmo em engenharia de antenas e eletromagnetismo.

Majid Khodier [25], empregou o CS no projeto do arranjo de antenas. Este autor concluiu, que as respostas do algoritmo CS podem se equipara ou, em alguns casos, é melhor em relação aos algoritmos clássicos (AG e PSO).

O algoritmo citado também se destaca na indústria de manufatura, em particular na fabricação de produtos eletrônicos, onde quase sempre é inevitável a perfuração das placas de circuito impresso (*printed circuit boards* – PCB). Pois, o caminho percorrido pela broca influencia diretamente no tempo total da produção dessas PCB, gerando custos e desperdício a medida em que for produzida uma quantidade maior desses dispositivos.

Visando maximizar a produtividade, reduzir custos e minimizar o tempo de produção por meio da otimização da rota percorrida pela broca de perfuração, Wei Chen *et al* [26], desenvolveram em sua pesquisa um algoritmo de busca combinatória cuco para otimização deste percurso. O algoritmo proposto foi testado, e se mostrou eficiente em localizar o caminho ótimo a ser percorrido pela broca durante a perfuração da PCB, dessa forma, maximizar as vantagens no processo de fabricação.

Xin-She Yang e Suash Deb [27] apresentaram uma nova formulação para este algoritmo meta-heurístico, originando o algoritmo de busca cuco multiobjetivo (*cukoo search multiobjective* – MOCS), para otimização global de projetos em engenharia. O método foi validado através de funções de teste multiobjetivo e, em seguida aplicando-o na solução de problemas estruturais, tais como, o projeto de viga soldada e o projeto de disco de freio. Os autores concluíram que o MOCS é superior quando comparado a outros algoritmos de otimização, devido ao fato da busca cuco utilizar uma combinação de mutação vetorizada, permutações cruzadas por voos de Lévy e elitismo seletivo entre as melhores soluções.

Desta forma, será desenvolvido neste trabalho um código MOCS para otimização das dimensões geométricas das FSS a serem sintonizadas em faixa de frequências e largura de banda indicadas na função custo do projeto. Em seguida, os resultados das estruturas otimizadas serão comparados com resultados obtidos através de um *software* comercial muito utilizado por pesquisadores para simulações de estruturas eletromagnéticas e, serão validados por meio de medições.

1.2. Hipótese

Diante do exposto, é constatado que diversas técnicas de otimização BIC têm sido apresentadas como uma opção favorável para obtenção das especificações desejadas no projeto. E, que estes algoritmos são ferramentas poderosas de otimização aplicadas a problemas na engenharia e na indústria.

Inserido nesse contexto, este trabalho se baseia na hipótese da necessidade do estudo e análise desses códigos, bem como das técnicas híbridas propostas para combinação e eficácia da precisão dessas ferramentas de otimização. Assim, aqui se vislumbra determinar qual algoritmo meta-heurístico dentre o AG, BAT e MOCS apresentará melhor resposta para suprir as dificuldades impostas durante o projeto das FSS estudadas.

Como resultado, objetiva-se uma redução significativa no tempo total de processamento das estruturas por meio da técnica híbrida e do código multiobjetivo, ambos desenvolvidos neste estudo.

1.3. Objetivos

1.3.1. Objetivo Geral

Minimizar o esforço computacional e o tempo demandado para processamento das propriedades EM durante o processo de otimização das FSS triangulares aqui investigadas. Para tal, se utilizará uma técnica híbrida, na qual uma RNA do tipo GRNN será desenvolvida para criação do espaço de busca. Nesta região, os algoritmos de otimização deverão realizar o tratamento das melhores soluções.

As mesmas condições de simulação bem como a mesma técnica híbrida utilizando a GRNN serão aplicadas a todos os casos a serem analisados (GRNN + GA; GRNN + BAT; GRNN + MOCS), viabilizando uma posterior comparação entre os resultados obtidos nas respectivas etapas.

1.3.2. Objetivos Específicos

Esta proposta concentra seus estudos a cerca de:

- ✓ Desenvolver uma nova geometria para FSS capaz de operar como filtros espaciais para aplicações em micro-ondas nas frequências pertencentes à banda X;

- ✓ Analisar as respostas das FSS quando submetidas a alterações de seus parâmetros geométricos, tais como: periodicidade (t) das células unitárias, comprimento e largura (W) dos elementos condutores;
- ✓ Reduzir o esforço computacional e tempo para processamento exigido por programas comerciais durante o processo de otimização de FSS, substituindo-os por ferramentas meta-heurísticas, tais como: rede neural artificial para modelagem das FSS e algoritmos de otimização multiobjetivos BIC como os algoritmos genéticos, algoritmo de ecolocalização do morcego e algoritmo de busca cuco.

1.4. Contribuições do Trabalho

Constituem as contribuições dessa proposta:

- i.* Apresentar uma nova geometria de FSS capaz de operar em toda faixa de frequências pertencentes ao padrão da banda X;
- ii.* Apresentar um código meta-heurístico multiobjetivo, derivado do MOCS apresentado em [27] para otimização das estruturas investigadas e, que apresente menor tempo para processamento quando comparado às demais técnicas aqui analisadas, haja vista que, este algoritmo foi pouco explorado na área de engenharia de antenas e, até a presente data, não foi explorado em trabalhos referentes a aplicações em FSS, atentando ao fato de que, no levantamento do estado da arte não foram encontradas publicações que utilizem tal técnica;
- iii.* Outra contribuição reside no fato de que, ainda não foram propostas técnicas híbridas utilizando RNA do tipo GRNN associadas a algoritmos meta-heurísticos no problema estudado neste trabalho, para otimização de arranjo de antenas e/ou FSS. Com isso, se pretende obter maior precisão nos resultados calculados pelo CS, através da técnica desenvolvida, a um menor custo computacional quando comparado aos algoritmos meta-heurísticos AG e BAT.

1.5. Estrutura do Documento

No capítulo 1 se faz uma breve introdução, através da qual, se salienta os avanços da BIC, esta, que emerge como alternativa para superar dificuldades que entravam o desenvolvimento do projeto de estruturas tal como FSS e, viabiliza maximizar o tempo de processamento, bem como, o custo computacional exigido para o cálculo das propriedades eletromagnéticas, por meio de técnicas numéricas de onda completa.

Ainda no capítulo 1 se comenta alguns artigos disponíveis na literatura, nos quais são empregados os códigos meta-heurísticos que alicerçam o desenvolvimento do estudo apresentado nessa proposta.

O capítulo 2 se destina a conceituação de FSS, bem como suas características de operação (rejeita faixa ou passa faixa), também, se apresenta as formas geométricas mais comuns disponíveis no estado da arte. Por fim, são apresentadas as estruturas de FSSs triangulares a serem investigadas nessa proposta.

No capítulo 3 se desenvolveu a teoria referente às ferramentas de inteligência computacional bioinspirada utilizadas neste estudo, as redes neurais artificiais e os algoritmos de otimização natural. Com relação às redes neurais estas serviram como ferramenta de modelagem no projeto das FSS. A discussão inclui redes neurais do tipo GRNN.

No que diz respeito aos algoritmos de otimização natural, são destacados os algoritmos: genético, de ecolocalização do morcego e o de busca cuco. As principais características e equações relacionadas com cada um desses algoritmos são mencionadas e discutidas, com o intuito de facilitar o entendimento de sua aplicação como técnica de otimização das FSS.

No Capítulo 4 são apresentados os resultados preliminares obtidos com as técnicas desenvolvidas nesta proposta. É realizada uma descrição do passo a passo do processo de desenvolvimento das técnicas híbridas implementadas para a otimização das FSS e, apresentados e discutidos os resultados obtidos. Também é feita uma discussão sobre as vantagens e desvantagens das técnicas propostas.

E, finalizando, o capítulo 5 se destina as conclusões do estudo desenvolvido, bem como a análise dos resultados obtidos e as propostas para trabalhos futuros.




Capítulo 2


Superfícies Seletivas de Frequência

As superfícies seletivas de frequência (FSS) são arranjos periódicos tipicamente bidimensionais, que atuam como filtros espaciais [9], [28], [29]. Seu comportamento depende da geometria dos elementos condutores, do tamanho da célula unitária, do material utilizado em sua manufatura, da espessura do substrato e, podem apresentar características de filtro rejeita ou passa faixa de acordo com o tipo de elemento condutor, planar (*patch*) ou abertura (*slot*), respectivamente [9], [30], [31].

Esquemáticos de tais estruturas planares periódicas bidimensionais do tipo rejeita faixa são apresentados na Fig. 2.1.



(a)



(b)

Figura 2.1. FSS periódicas bidimensionais do tipo rejeita faixa, (a) arranjo e (b) estrutura periódica.

A principal aplicação de FSS está diretamente relacionada à filtragem de ondas para faixas de frequências especificadas no projeto, sendo facilmente encontrado seu emprego em sistemas de comunicações por rádio difusão.

Na faixa de micro-ondas, FSS podem ser utilizadas para tornar o uso das antenas mais eficientes, por exemplo, em antenas refletoras, permitindo o uso simultâneo de mais de uma fonte na mesma refletora. Nesse caso, estas são utilizadas como cobertura protetora das antenas (*radomes*) [28], [29], [32] – [34], como ilustra a Fig. 2.2, na qual foram aplicadas duas FSS em satélites para filtragem de sinais oriundos de fontes operantes nas bandas X e Ku, respectivamente.




Figura 2.2. FSS usadas na recepção de sinais de satélite [35].

Neste capítulo, se comenta as principais características que podem influenciar na resposta em frequência e largura de banda de uma FSS. Em seguida se apresenta algumas das formas geométricas para FSS mais comuns disponíveis na literatura especializada, e, por fim, se apresenta as estruturas investigadas neste trabalho.

2.1. Características que Influenciam na Resposta de uma FSS

A forma geométrica dos elementos utilizados em uma FSS está diretamente relacionada com sua frequência de trabalho. Comportamento semelhante se observa no estudo de antenas planares, onde o aumento de sua superfície efetiva é característica capaz de impor modificações no seu funcionamento [36] - [38]. Em FSS, o elemento condutor ressoará e espalhará a energia quando suas dimensões forem múltiplas do comprimento da onda incidente [39].

Outra característica comum em ambos os casos (FSS e antenas) é o fato da influência exercida pela espessura, permissividade e isotropia do substrato utilizado, pois estes fatores alteram o comprimento de onda efetivo, modificando dessa forma a frequência de trabalho da FSS [40].

De acordo com Lima *et al* [41], através da troca de fluídos no substrato, também é possível alterar sua permissividade e, conseqüentemente, a frequência de ressonância da FSS.

Outros exemplos da influência exercida pelo substrato sobre a operação de FSS podem ser encontrados em Li *et al* [42] e Chang *et al* [43], cujos dispositivos foram construídos sobre substratos ferromagnéticos.

2.2. Formas Geométricas Comuns para FSS

Os estudos acerca da teoria de FSS se intensificaram desde a década de 1960 [12], embora haja registro de patente de FSS realizado por Marconi [44] em 1919.

Está disponível no estado da arte, grande extensão de pesquisas que trabalham com formas geométricas diversas para atender a critérios de projetos, como: nível de atenuação, frequência de operação, largura de banda, tipo de aplicação (rejeita ou passa faixa), sensibilidade à onda eletromagnética e ângulo de incidência, pois dentre estas formas, o elemento apropriado é escolhido.

A Fig. 2.3 mostra algumas das principais formas de elementos usados em estruturas de FSS [35]:




Figura 2.3. Formas de elementos de FSS.

Dentre as estruturas investigadas para uma FSS se pode destacar o estudo realizado por T. A. Cwik e R. Mittra [45], no qual se aplicou o método iterativo de transformada rápida de Fourier (*fast Fourier transform* – FFT) para cálculo aproximado dos campos espalhados, por um arranjo infinito de estruturas *patch* retangular.

Outro estudo referente a essa mesma geometria foi realizado por Chen [46], que se concentrou no problema dos valores de fronteira em uma série de placas finas organizadas sobre uma grade duplamente periódica. Logo, são propostas técnicas de projeto que combinam mais de um elemento condutor que dão origem a novas formas geométricas e, são amplamente utilizadas em FSS, tal como a cruz de Jerusalém analisada por R. Cahill e E.A. Parker [47] e, em Parker *et al* [48]. Ou por combinações de dipolos originando os chamados “tripolos” analisados por J. C. Vardaxoglou e E. A. Parker [49], Au *et al* [50] e, M. M. Mokhtar e E. A. Parker [51]. Ainda relacionado a dipolo, pode-se citar o estudo realizado por Araújo *et al* [9], no qual foram aplicadas técnicas de computação natural para análise e otimização de um dipolo integrado com uma espira em anel.

Variações de geometrias como espiras quadradas também são facilmente encontradas na literatura, um bom exemplo disso pode ser encontrado em R. Cahill e E. A. Parker [52] e, T. K. Wu [53].

Nesse contexto, outra geometria que se destaca é o fractal [54]. A utilização dessas estruturas apresenta uma particular vantagem em relação à redução do tamanho da célula unitária [55]. Tão logo, Cruz *et al* [19] e Silva *et al* [20] investigaram uma estrutura de FSS com elemento do tipo *Koch Island patch*, em ambos os estudos, foram aplicadas técnicas de computação natural para modelagem e otimização dos protótipos. E, em Silva *et al* [29] pode ser encontrado outro bom exemplo de estrutura fractal, aplicado a filtragem de ondas eletromagnéticas, nesse estudo, foi analisado o elemento do tipo *Gosper prefractal*.

De acordo com o comentado na seção anterior, as propriedades do material do substrato utilizado alteram a resposta em frequência e largura de banda de FSS, tal como em antenas impressas. Atento a esse fato, Cavalcante *et al* [31] propôs em seu trabalho a utilização de substrato têxtil, no qual fixaram estruturas do tipo dipolo cruzado, loop quadrado e *patch* triangular.

Constitui parte deste trabalho, o projeto de estruturas triangulares para filtragem em micro-ondas, especificamente na faixa de frequências pertencentes à banda X.

2.3. Estruturas Propostas para as FSS

Neste estudo serão investigadas FSS de *patches* triangulares. Para as simulações, os elementos serão considerados impressos em substrato dielétrico de fibra de vidro (FR-4) com permissividade relativa (ϵ_r) igual a 4,4, altura (h) igual a 1,57 mm e tangente de perdas $\tan(\delta)=0,02$.

A Fig. 2.4 apresenta a geometria da FSS de *patch* triangular.

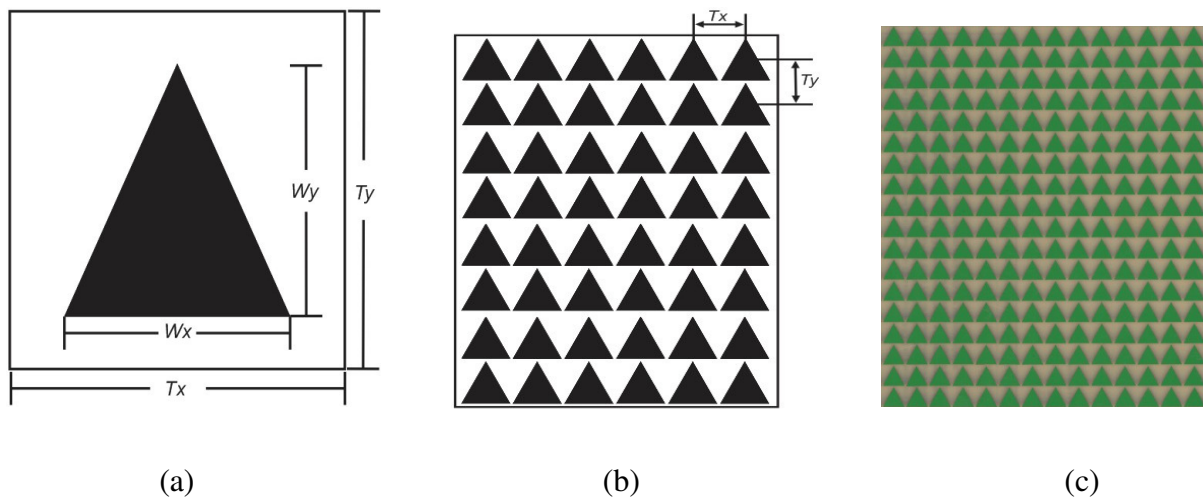


Figura 2.4. FSS *patch* triangular (a) célula unitária, (b) arranjo e (c) fotografia.

Um dos objetivos do processo de síntese das FSS desenvolvidas neste trabalho consiste em sintonizar a frequência de ressonância em 11,0 GHz. A Fig. 2.5 apresenta a estrutura projetada, FSS de espira triangular. A largura da espira triangular é igual a 1 mm, como indicado na Fig. 2.5 (a).

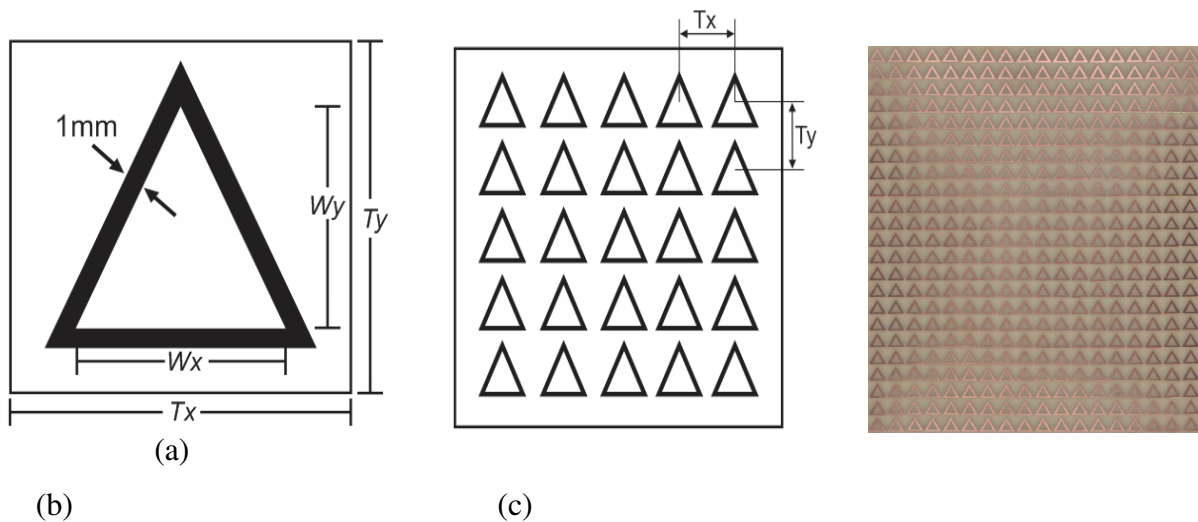


Figura 2.5. FSS de espira triangular (a) célula unitária, (b) arranjo e (c) fotografia.

Os resultados otimizados pelas técnicas híbridas desenvolvidas foram utilizados para fabricação de protótipos das FSS investigadas. Os elementos dos arranjos das FSS forma impressos sobre substrato isotrópico de fibra de vidro (FR-4). Em seguida foram realizadas medições para validar o modelo desenvolvido.

Na Tabela 2.1 têm-se os parâmetros utilizados.

TABELA 2.1. Parâmetros Estruturais das FSS

Parâmetros da FSS	Valor
Periodicidade 1ª estrutura (mm)	$t=T_x=T_y=[12; 12,5; 13; 13,5; 14; 14,5; 15]$
Periodicidade 2ª estrutura (mm)	$t=T_x=T_y=[10; 10,5; 11; 11,5; 12,5; 13; 13,5; 14]$
Dimensões 1ª estrutura (mm)	$W=W_x=W_y=[10; 10,5; 11; 11,5]$
Dimensões 2ª estrutura (mm)	$W=W_x=W_y=[4; 4,5; 5; 5,5]$
Altura Substrato (mm)	$h = 1,57$
Permissividade relativa do substrato	$\epsilon_r = 4,4$

As frequências de corte inferior e superior utilizadas para controle da frequência de ressonância e largura de banda foram obtidas em -10 dB. Após as medições, foi verificado que os resultados medidos e simulados apresentam boa uma concordância, validando a metodologia desenvolvida.

2.4. Síntese do Capítulo

Neste capítulo, destaca-se fatores que podem influenciar na resposta de uma FSS, bem como foram apresentadas algumas das formas geométricas mais comuns de elementos da célula unitária para FSS. Outrossim, foram apresentadas as geometrias e os parâmetros estruturais das FSS triangulares investigadas neste trabalho, as quais foram escolhidas por possibilitar fabricação simplificada, e apresentarem respostas satisfatórias em largura de banda e frequência de ressonância.

Capítulo 3

Ferramentas de Inteligência Computacional

Bioinspirada

A computação bioinspirada (BIC) é um novo paradigma da ciência da computação moderna inspirado no comportamento de organismos vivos. As ideias extraídas de sistemas naturais já vêm sendo utilizadas com sucesso para o desenvolvimento de ferramentas tecnológicas capazes de resolver problemas gerais de complexidade elevada na engenharia e na indústria [4] - [5].

A BIC tem buscado inspirações na natureza para lidar com os mais diversos tipos de problemas de otimização. Esta compreende algoritmos e ferramentas que se baseiam, por exemplo, na capacidade computacional do sistema nervoso para resolver problemas de reconhecimento de padrões, quando se trabalha com redes neurais artificiais (RNA).

A computação evolutiva busca espelhando-se na evolução natural, melhorar a adaptação dos indivíduos ao ambiente, no decorrer de várias gerações, este é o caso dos algoritmos genéticos (AG). Por meio da análise das propriedades emergentes do voo alçado por algumas espécies de morcegos. O percurso realizado por esses mamíferos quando utilizam seu dispositivo de sonar para ecolocalização, se aproxima da ideia da inteligência de enxames de partículas, muito semelhante ao PSO. Outrossim, pelo interessante comportamento apresentado pela ave cuco que, durante sua ninhada, podem vir a parasitar ninhos de outras espécies de aves para aumentar a probabilidade da eclosão de seus próprios ovos, através da técnica do elitismo seletivo para identificação dos melhores ninhos.

Este capítulo se destina a detalhar os códigos BIC supracitados, dado que se comenta inicialmente as redes neurais artificiais, seguidas pelo algoritmo genético, pelo algoritmo de ecolocalização do morcego e, por fim, pelo algoritmo de busca cuco.

3.1. Otimização Multiobjetivo

A crescente demanda por precisão e o aumento gradativo da complexidade das estruturas e sistemas, resulta num processo de simulação cada vez mais demorado. Em engenharia de antenas, por exemplo, durante o projeto e análise de novos dispositivos para rádio difusão, tal como FSS, a avaliação de um único critério pode consumir várias horas ou até mesmo dias.

No processo de otimização de tais dispositivos, muitas vezes deseja-se atender a mais de uma condição objetivo. Logo, esse processo de otimização multiobjetivo envolve a minimização ou maximização da função objetivo, que está sujeita a um conjunto de restrições [56] - [57]. O aumento da largura de banda, ressonância em frequência específica e ajuste da impedância de entrada em estruturas ressonantes, são exemplos comuns de objetivos a serem alcançados nesses projetos.

Os primeiros resultados no campo da otimização multiobjetivo foram apresentados por Pareto em seu trabalho relacionado a economia "*Cours d'Economie Politique*" [58], onde foi introduzido o conceito de solução eficiente.

Quando duas ou mais soluções são consideradas, tem-se que algumas delas podem ser melhores que outras em relação a todos os objetivos considerados, tais soluções são chamadas de soluções não dominadas. Em geral, problemas de otimização multiobjetivo requerem a definição alternativa do "valor ótimo" ou valor de referência. Sendo o "valor ótimo" o conjunto frente Pareto que pode ser definido ao se considerar o problema multiobjectivo a seguir:

$$\text{Max } \{f_1(x), f_2(x), \dots, f_n(x)\} \quad \because \quad X \in \Omega \subset \mathbb{R}^m \quad (3.1).$$

Se $X_0 \in \Omega$, tal que $f_i(x_0) \geq f(x) \forall X \neq X_0 \in \Omega$, para algum i então X_0 é dito não dominado em Ω . Todos os pontos X_0 que satisfaçam a propriedade acima chama-se Frente de Pareto.

Na relação de dominação, se x_1 e $x_2 \in \mathbb{R}$, onde \mathbf{R} é uma região viável de soluções, tem-se que x_2 domina x_1 se $f(x_2)$ é tomado como sendo parcialmente maior ou maior que $f(x_1)$, ou seja,

$$f_i(x_1) \leq f_i(x_2), \forall i = 1, 2, \dots, n \quad (3.2)$$

e,

$$f_i(x_1) < f_i(x_2), \exists i = 1, 2, \dots, n \quad (3.3)$$

Caso não haja algum $x_i \in \mathbb{R}$ que domine x_2 , então x_2 é assumido como uma solução ótima de Pareto, a Fig. 3.1 mostra um exemplo dessa relação de dominação. Nesta, o ponto destacado em verde representa a solução não-dominada (solução ótima), os demais pontos são as soluções dominadas, sendo o ponto destacado em vermelho o pior caso.

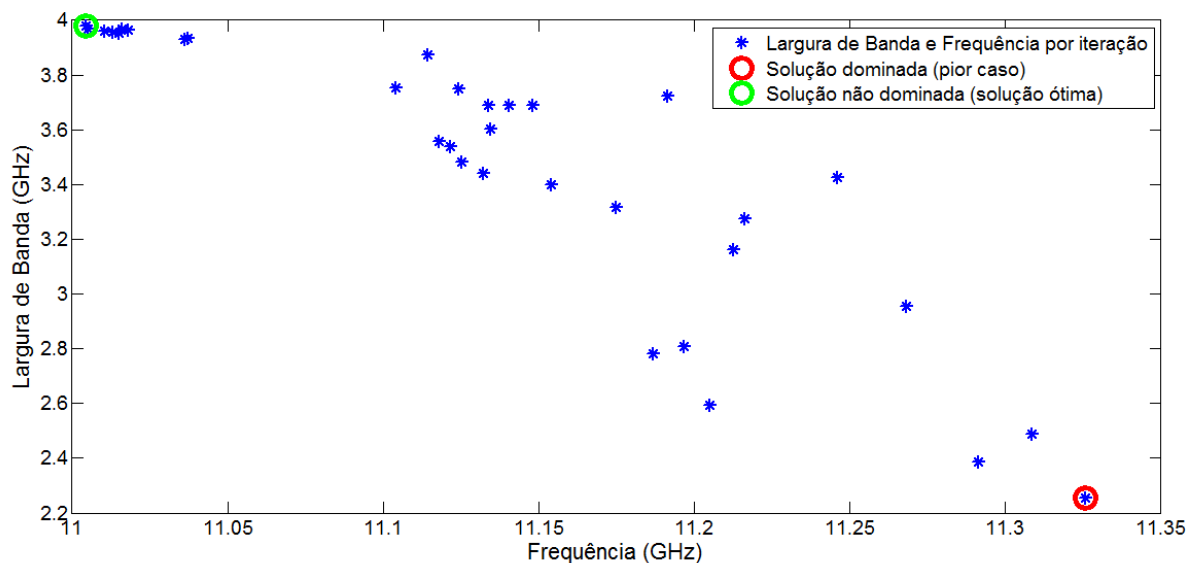


Figura 3.1. Relação de dominação para a função custo.

O conjunto de todas as soluções não dominadas define a fronteira ótima de Pareto. Obtida essa fronteira, o “*decisor*” escolhe a solução mais adequada (solução *tradoff*) que atenda aos objetivos do projeto.

3.2. Redes Neurais Artificiais

Uma rede neural artificial (RNA) consiste em técnicas computacionais não lineares que apresentam um modelo matemático, inspirado na estrutura neural de organismos inteligentes, e que adquirem conhecimento através da experiência ou treinamento [59]. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento ou neurônios artificiais.

Nesta proposta será utilizada uma rede neural de regressão geral (*general regression neural network* – GRNN) [60]. O *software* computacional CST® *Microwave Studio* será utilizado para calcular os dados de entrada empregados para treinamento/aprendizagem da rede, este *software* aplica a técnica de análise de onda completa FIT.

A rede será configurada de modo que, ao se aplicar o conjunto de dados de entrada, sejam produzidas saídas que atendam a função custo. Dessa forma, criar-se-á a região de interesse (*region of interest* – ROI), na qual os algoritmos de otimização deverão realizar buscas pela melhor solução.

3.2.1. Rede Neural de Regressão Geral

Em 1964 foi introduzida a rede neural de regressão generalizada por Nadaraya [61] e Watson [62]. E, em 1991, essa rede foi remodelada por Specht [60] para realizar regressões gerais (linear ou não linear), originando a rede neural de regressão geral (*general regression neural network* – GRNN). A fundamentação teórica da GRNN se baseia no conceito da estimativa não paramétrica, comumente utilizada em estatística [63] - [66].

Redes neurais do tipo GRNN são derivadas das redes neurais radiais de base (*radial basis neural network* – RBFN) e, segundo Specht [60], a GRNN necessita apenas de parte dos dados para treinamento da rede, sendo desnecessária a *backpropagation* [67]. Ainda, segundo este autor, a utilização desta rede é especialmente vantajosa devido a sua capacidade de convergir para a função subjacente dos dados, com apenas algumas amostras disponíveis para treinamento.

Neste tipo de rede, o conhecimento adicional necessário para se obter o ajuste de forma satisfatória é relativamente pequeno e pode ser feito sem a inserção de novos dados por parte do utilizador. Isto faz da GRNN uma ferramenta muito útil para realizar aproximações de funções, previsões e comparações de desempenho de sistemas na prática.

A Fig. 3.2 ilustra o diagrama em bloco global da GRNN.

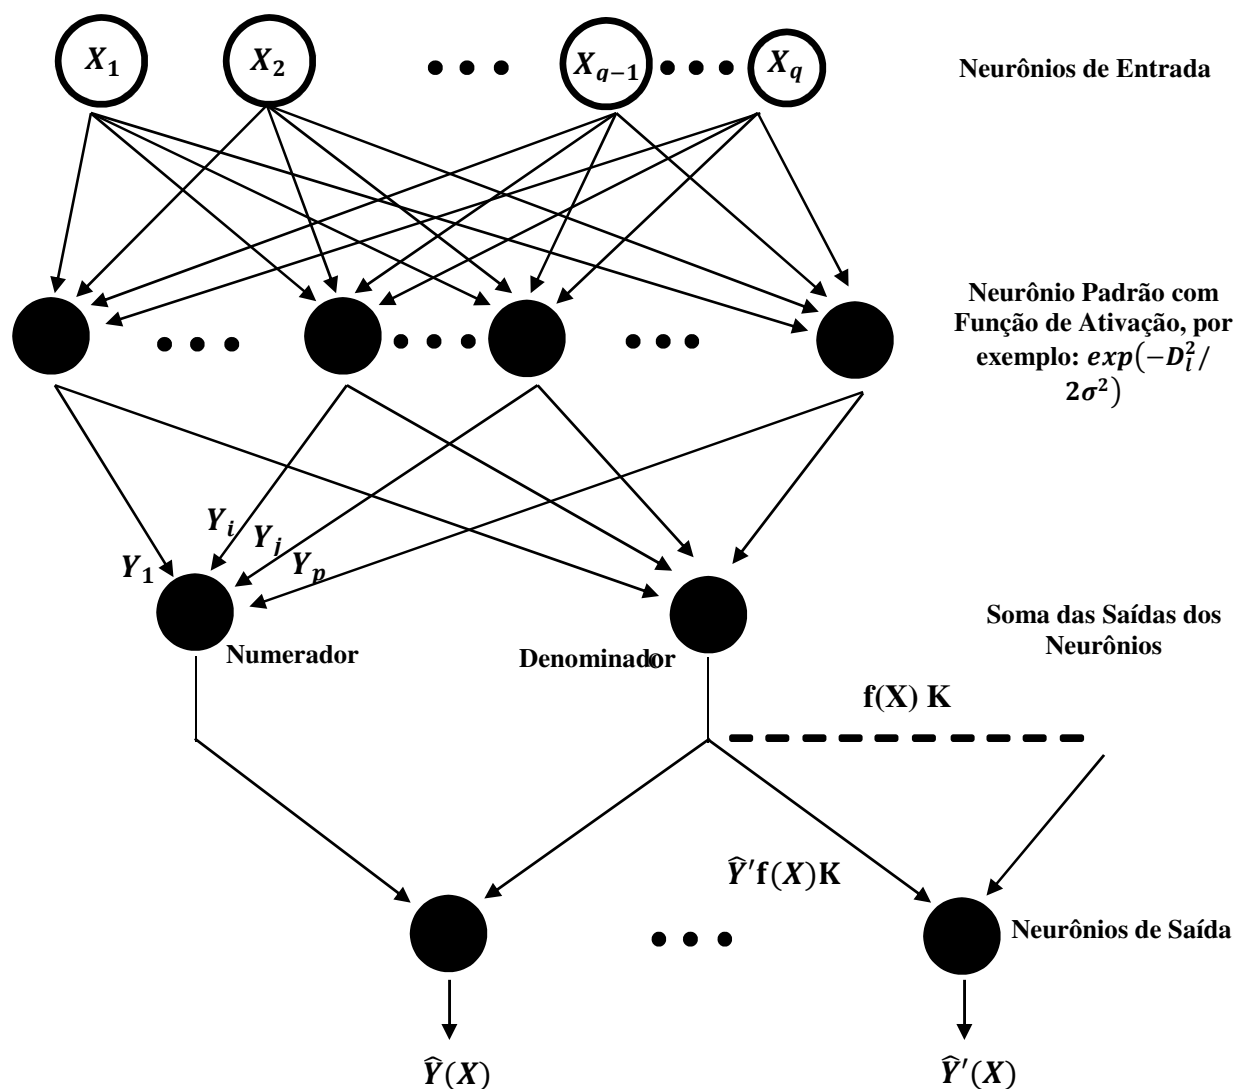


Figura 3.2. Diagrama em bloco global da rede GRNN.

Os círculos apenas transferem os valores das variáveis para os neurônios seguintes. A distribuição normal é utilizada como função de base radial pela GRNN e, é dada por:

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y_i \exp\left(-\frac{D_i^2}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{D_i^2}{2\sigma^2}\right)} \quad (3.4)$$

sendo,

$$D_i^2 = (X - X_i)^T(X - X_i) \quad (3.5)$$

onde cada amostra X_i é tomada como a média de uma distribuição e D_i é a distancia entre a amostra de treinamento e o ponto de predição X . A função ativação normalmente utilizada é uma exponencial, como a apresentada em [68, tabela 1].

Para projeto das FSS investigadas aqui, foi utilizada uma rede GRNN com quatro entradas na primeira camada, uma camada oculta com cinco neurônios e dois nós de saída referentes à frequência central e largura de banda desejada. A arquitetura da rede desenvolvida é exibida na Fig. 3.3.




Figura 3.3. Configuração da GNRR utilizada.

O aprendizado da GRNN desenvolvido consiste no treinamento da unidade de saída. A rede deve responder ao conjunto de restrições inserido nas entradas, ou seja, devem ser apresentadas nas saídas valores de t (periodicidade) e W (altura/largura dos elementos condutores) que atendam aos objetivos pré-estabelecido.

Neste paradigma, o sistema é disposto para descobrir estatisticamente características salientes da população de entrada criando uma região de interesse, onde serão buscados os dados pelos algoritmos de otimização.

3.3. Algoritmo Genético

Os algoritmos genéticos (AG) são procedimentos de busca baseados na mecânica da genética e da seleção natural, com aplicabilidade em problemas gerais de otimização e, mais particularmente, no aprendizado automático. Este algoritmo foi introduzido por Holland [69] em 1975 e, popularizado por seu aluno Goldberg [70] em 1989. Os AG seguem o princípio da seleção natural e sobrevivência do mais apto, declarado em 1859, pelo naturalista e fisiologista inglês Charles Darwin em seu livro “A Origem das Espécies”.

Os AG buscam a melhor solução para um dado problema, tentando várias soluções e se utilizando das informações do próprio domínio para encontrar soluções cada vez melhores [71].

A ideia básica do funcionamento de um AG pode ser resumida no seguinte fluxograma:

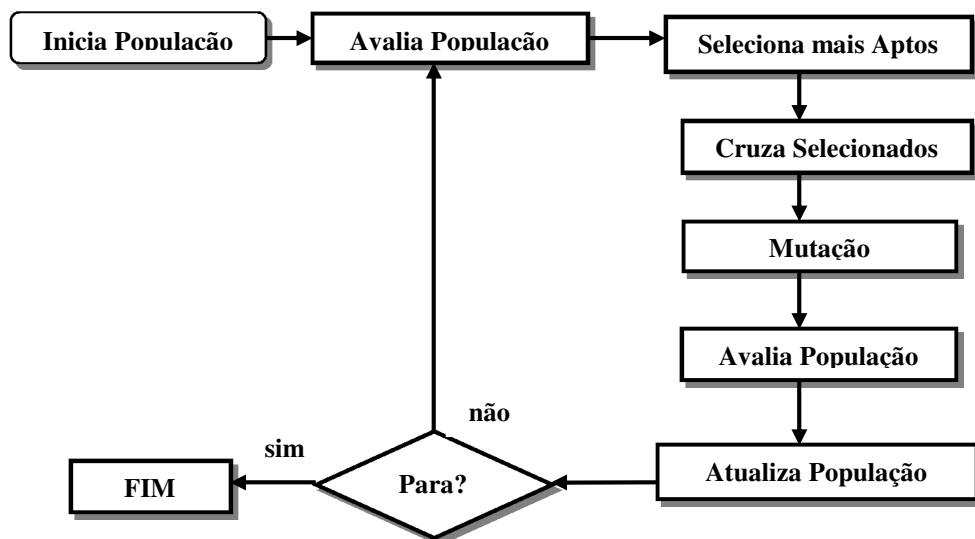


Figura 3.4. Fluxograma de um AG tradicional.

O processo inicia através da geração da população cromossômica, formada por um conjunto aleatório de cromossomos, que representam possíveis soluções para o problema. Durante o processo evolutivo, esta população passa por uma função de avaliação (função *fitness*), e cada cromossomo recebe uma nota (aptidão), classificando-o quanto a qualidade de sua solução. Em geral, os cromossomos mais aptos são selecionados e os menos aptos são descartados, bem como dispõe a Lei de Darwin. Os membros selecionados podem sofrer modificações em suas características através dos operadores de *crossover* e mutação, gerando descendentes para a próxima geração. Este processo é repetido até que uma solução satisfatória seja encontrada.

Os AG têm sido empregados em problemas complexos de otimização, fundamentalmente, em virtude dos seguintes fatores [71]:

- i.* Funcionam tanto com parâmetros contínuos como discretos, ou ainda com uma combinação dos mesmos;
- ii.* Realizam buscas simultâneas em várias regiões do espaço de busca, pois trabalham com uma população e não com um único ponto. Na verdade, se deve a existência do paralelismo intrínseco do algoritmo;
- iii.* Utilizam informações de custo ou recompensa e não de funções derivadas ou outro conhecimento auxiliar;
- iv.* Otimizam parâmetros de funções objetivos com superfícies complexas, reduzindo a probabilidade de se cair em mínimos locais;
- v.* Existe a opção de se trabalhar com uma codificação do conjunto de parâmetros e não com os próprios parâmetros;
- vi.* Fornecem uma lista de parâmetros ótimos e não uma simples solução;
- vii.* São fáceis de serem implementados;
- viii.* São modulares e portáteis, no sentido que o mecanismo de evolução é separado da representação particular do problema considerado. Assim, eles podem ser transferidos e facilmente adaptáveis de um problema para outro;
- ix.* São também facilmente combinados com outras técnicas heurísticas.

As técnicas de AG resolvem problemas de otimização e de busca, onde os métodos tradicionais falham. As técnicas tradicionais, frequentemente, iniciam o processamento com um único candidato (indivíduo) manipulado, utilizando alguma heurística, na maioria das vezes estática, diretamente ligadas ao problema a ser solucionado.

No caso do AG, são realizadas operações em paralelo sobre uma população de candidatos (vários indivíduos) e, a busca é feita, em diferentes áreas do espaço de solução, selecionando um número apropriado de membros para a busca, em várias regiões.

3.4. Algoritmo de Ecolocalização dos Morcegos

Esse algoritmo foi introduzido por Yang [8] em 2010 e se baseia na ecolocalização, ou seja, localização por eco durante voo de algumas espécies de morcegos. O morcego emite ondas ultrassônicas, geralmente na ordem de 25 kHz a 150 kHz, pelas narinas ou pela boca, dependendo da espécie, essas ondas atingem obstáculos no ambiente e retorna na forma de eco com frequência superior a emitida, pois as velocidades do morcego e do eco são somadas.

Com base no tempo de atraso e na frequência relativa dos ecos, os morcegos percebem se há obstáculos no caminho, assim como suas distâncias, formas e velocidades relativas. Isso é especialmente útil para caçar insetos voadores. Entretanto, espécies de morcegos com outros hábitos alimentares também se utilizam bastante desse sentido.

Por questões de simplicidade foram idealizadas as seguintes regras para desenvolvimento do código computacional:

- i.* 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 ele se encontra;
- ii.* 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_{min} 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.
- iii.* Embora a amplitude possa variar de várias maneiras, assume-se normalmente que a amplitude varia na faixa $[A_{min}, A_{max}]$.

3.4.1. Movimento Virtual dos Morcegos

Inicialmente, é gerada aleatoriamente uma população de morcegos respeitando as regras de posicionamento x_i e velocidade v_i no espaço de busca n -dimensional.

Tal como no AG, a população é avaliada e classificada de acordo com sua aptidão para solução da função objetivo especificada.

As novas soluções x_i^t e velocidades v_i^t na iteração t são dadas por [8]:

$$f_i = f_{min} + (f_{max} - f_{min})\beta \quad (3.6)$$

$$v_i^t = v_i^{t-1} + (x_i^t - x_*)f_i \quad (3.7)$$

$$x_i^{t-1} = x_i^{t-1} + v_i^t \quad (3.8)$$

onde 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 corrente. Inicialmente, a frequência de cada morcego é distribuída aleatoriamente entre $[f_{min}, f_{max}]$.

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. Em seguida, é realizada uma 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, se executa uma busca local, atribuindo dessa forma, flexibilidade ao projeto, esta 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:

$$x_{novo} = x_{anterior} + \xi A^t \quad (3.9)$$

onde $\xi \in [-1, 1]$ é um número aleatório uniformemente distribuído e A^t é a média da amplitude de todos os morcegos na iteração t .

Semelhante ao PSO, o procedimento de atualização das velocidades e posições dos morcegos é similar ao padrão de controle do ritmo e amplitude do movimento das partículas, porém, o algoritmo do morcego considera uma combinação equilibrada da otimização por exame de partículas e a pesquisa por intensidade sonora, controlados pelo volume e taxa de pulsação.

Além disso, 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 do 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 isso, as soluções são aceitas e são atualizadas as taxas de emissão r_i e amplitude A_i na iteração t , segundo as expressões:

$$r_i^{t+1} = r_1^0 [1 - \exp(-\gamma t)] \quad (3.10)$$

$$A_i^{t+1} = \alpha A_i^t \quad (3.11)$$

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

$$A_i^t \rightarrow 0, \text{ e } r_i^t \rightarrow r_i^0, \text{ com } t \rightarrow \infty \quad (3.12)$$

Assim, 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.

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

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 $[20 \text{ kHz}, 500 \text{ kHz}]$ tem-se a faixa de comprimento de onda variando de 0,7 mm até 17 mm.

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

A Fig. 3.5 apresenta o pseudocódigo desenvolvido em [8]:

Função objetivo $f(x)$, $x = (x_1, \dots, x_d)^T$
Inicialização aleatória da população dada pelas posições dos 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 [Eq. 3.3 a 3.5]
 se $\text{rand} > r_i$
 Selecionar uma solução entre as melhores soluções
 Gerar uma solução local próxima da melhor solução já escolhida
 fim se
 Gerar uma nova solução através de voo aleatório
 se $(\text{rand} < A_i \ \& \ f(x_i) < f(x_*))$
 Aceitar as novas soluções
 Elevar valor de r_i e diminuir valor de A_i
 fim se
 *Ordenar os morcegos e selecionar o melhor atual x_**
fim enquanto
Pós-processamento dos resultados e visualização

Figura 3.5. Pseudocódigo do algoritmo morcego.

3.5. Algoritmo de Busca Cuco

Esse código é um dos mais recentes algoritmos meta-heurístico inspirado na natureza, que foi desenvolvido por Yang e Deb [7] em 2009. O mesmo é usado eficientemente para soluções globais de problemas na engenharia e na indústria. O código se baseia no parasitismo durante a ninhada de algumas espécies dessas aves como Ani e Guira, que colocam seus ovos em ninhos comunais.

Algumas vezes, o cuco pode desejar se livrar dos ovos da ave hospedeira (dona do ninho) para aumentar a probabilidade de incubação de seus próprios ovos [72], caracterizando o parasitismo. São três tipos básicos de parasitismo:

- i.* Parasitismo intraespecífico de ninhada;
- ii.* Reprodução cooperativa;
- iii.* Ninho por aquisição.

Algumas aves hospedeiras podem se envolver em conflito direto com os cucos intrusos, contudo, caso um pássaro hospedeiro descubra os ovos que não são de sua ninhada, eles podem desejar se livrar desses ovos “alienígenas” ou simplesmente abandonar o seu ninho e construir um novo ninho em outro local.

Determinadas espécies de cuco como a *Tapera*, tem evoluído de tal forma com a experiência que, ao parasitar os ninhos, algumas fêmeas dessa espécie são especializadas no mimetismo da cor e do padrão dos ovos de um conjunto de espécies de aves hospedeiras [72]. Isto reduz a probabilidade de seus ovos serem descartados e, portanto, aumenta a probabilidade de sua reprodução.

Além disso, o cuco parasita muitas vezes escolhe um ninho onde o pássaro hospedeiro colocou apenas seus próprios ovos. Em geral, os ovos do cuco eclodem ligeiramente mais cedo do que os ovos do hospedeiro. Uma vez que o primeiro filhote de cuco é chocado, a primeira ação instintiva desse filhote, é a de expulsar os ovos da ave hospedeira, jogando-os para fora do ninho. Tal ação aumenta a participação do filhote cuco nos alimentos fornecidos pelo pássaro hospedeiro.

Estudos mostram que um filhote cuco também pode imitar o padrão de chamada de acolhimento para ganhar acesso ao alimento. Por padrão, o algoritmo CS é idealizado em três regras básicas [7], [73]:

- i.* Cada cuco coloca um ovo por vez e o deposita em um ninho escolhido aleatoriamente;
- ii.* Os ninhos, com ovos de alta qualidade, serão escolhidos para as próximas gerações;
- iii.* O número de ninhos disponível é fixo e o ovo colocado por um cuco é descoberto pelo pássaro hospedeiro com probabilidade $p_a \in [0, 1]$. Neste caso, a ave hospedeira pode desejar se livrar do ovo ou simplesmente abandonar o ninho e construir um novo.

Esta última hipótese também pode ser aproximada por meio da indicação de que uma fração p_a dos n ninhos das aves hospedeiras são substituídos por novos ninhos (com novas soluções aleatórias).

O código CS é reforçado pela construção de trajetórias conhecidas como voos de Lévy [74]. Ou seja, ao gerar novas soluções $x^{(t+1)}$ para, por exemplo, um cuco i , um voo de Lévy é realizado,

$$x_i^{(t+1)} = x_i^{(t)} + \alpha \oplus \text{Lévy}(\beta) \quad (3.13)$$

onde i indica o número de gerações atuais (1, 2, 3,..., ciclo máximo) e t a iteração corrente, o ciclo máximo indica o número máximo de gerações e, $\alpha > 0$ é o tamanho do passo, que deve ser relacionado à escala do problema de interesse, na maioria dos casos, pode-se usar $\alpha = 1$.

A Eq. (3.10) é essencialmente a equação estocástica do passeio aleatório e, em geral, um passeio aleatório é uma cadeia de Markov cujo próximo estado/local só depende da localização atual (o primeiro termo da equação) e da probabilidade de transição (o segundo termo). O produto \oplus significa as multiplicações de entrada, este produto é semelhante ao utilizado no PSO, porém, no CS o passeio aleatório auxiliado por voo Lévy é mais eficiente em explorar o espaço de busca.

O voo de Lévy fornece essencialmente um passeio aleatório enquanto que o comprimento do passo aleatório é traçado a partir de uma distribuição de Lévy,

$$\text{Lévy} \approx u = t^{-1-\beta}, \quad (1 < \beta \leq 3) \quad (3.14)$$

com média e variância infinita.

Para a realização do voo Lévy, por exemplo, usando $\beta = 2$ pode ser explicado tomando-se r um número aleatório uniformemente distribuído no intervalo [0, 1) (facilmente calculado nos computadores). Calcula-se em seguida o número $d = r^{-3}$, d será a distância potencialmente percorrida pelo cuco. Isso faz com que o cuco possa percorrer pequenas distância ou distância muito grandes, pois essa distribuição possui média infinita. Com isso, o algoritmo poderá percorrer um espaço de busca praticamente ilimitado.

Algumas das novas soluções devem ser geradas, através do passeio de Lévy em torno da melhor solução obtida em determinado instante, pois isso acelera a busca local. No entanto, uma fração substancial das novas soluções deve ser gerada de forma aleatória no campo

distante, cujas localizações devem ser suficientemente afastadas da melhor solução atual, garantindo que o sistema não se detenha a um ótimo local.

A Fig. 3.6 apresenta o pseudocódigo desenvolvido em [7]:

Início

Função objetivo $f(x)$, $x = (x_1, \dots, x_d)^T$

Geração da população inicial dos

n ninhos hospedeiros x_i ($i = 1, 2, \dots, n$)

enquanto ($t < \text{GeraçãoMax}$) ou (critério de parada)

obter um cuco aleatoriamente por voo de Lévy

avaliar sua qualidade/aptidão F_i

Escolher aleatoriamente um ninho entre n (por exemplo, j)

se ($F_i > F_j$)

substitua j pela nova solução;

fim

Uma fração (p_a) dos piores ninhos

são abandonados e novos são construídos;

Mantenha as melhores soluções

(ou ninhos com soluções de qualidade)

Classifique as soluções e encontre o melhor atual

fim enquanto

Resultados pós processamento e visualizações

fim

Figura 3.6. Pseudocódigo do algoritmo de busca cuco.

Além disso, cada ninho pode representar um conjunto de novas soluções. O CS pode, dessa forma, ser estendido para a classe de algoritmo de meta-população.

Ao se visualizar rapidamente esse processo, pode parecer que o CS se assemelha a uma combinação randomizada em larga escala, entretanto, existem algumas diferenças significativas:

- i.* Em primeiro lugar, o CS é um algoritmo baseado em uma população inicial, tal como o AG e o PSO, mas que utiliza uma espécie de elitismo e/ou seleção semelhante ao utilizado na pesquisa harmônica;

- ii. Em segundo lugar, a randomização é mais eficiente, quando comparado ao AG e ao PSO, no que tange ao comprimento do passo e, qualquer grande passo é possível;
- iii. Em terceiro lugar, o número de parâmetros a serem sintonizados é inferior ainda em relação ao AG e ao PSO e, portanto, é potencialmente mais simples de ser adaptado a uma classe mais ampla de problemas de otimização.

3.5.1. Algoritmo de Busca Cuco Multiobjetivo

Para otimização de problemas com n objetivos diferentes via CS ou algoritmo de busca cuco multiobjetivo (*multiobjective cuckoo search* – MOCS) é necessário à alteração da primeira e da última regra do código CS de modo a incorporar o multiobjetivo [27]:

- i. Cada cuco põe k ovos por vez e, os deposita em um ninho escolhido aleatoriamente. O ovo k corresponde à solução do k -ésimo objetivo;
- ii. Os melhores ninhos com ovos (soluções) de alta qualidade serão escolhidos para as próximas gerações;
- iii. O número de ninhos disponível é fixo e, a ave hospedeira poderá descobrir um ovo “alienígena” com uma probabilidade $p_a \in [0, 1]$. Neste caso, a ave hospedeira pode livrar-se do ovo ou abandonar o ninho, de modo a construir um novo ninho em um novo local.

Por simplicidade, esta última regra pode ser aproximada ao se assumir, que uma fração p_a dos n ninhos, ao invés de serem abandonados, serão substituídos por novos ninhos (com novas soluções aleatórias em novos locais). Para a maximização dos objetivos, a qualidade ou adequação de uma solução pode ser simplesmente proporcional a cada função objetivo e se deve buscar uma solução não dominada.

A estrutura do algoritmo MOCS inclui duas operações principais, sendo uma busca direta baseada nos voos de Lévy, e uma pesquisa aleatória baseada na probabilidade de um pássaro hospedeiro descobrir um ovo “alienígena” em seu ninho. Dessa forma, cada ninho representa uma solução diferente e uma população de ninhos é usada para encontrar a melhor solução do problema, tal como outros métodos de pesquisa populacional meta-heurística.

O voo de Lévy é uma busca espacial eficiente em que as mudanças de direção são isotrópicas e aleatórias, os seguimentos da trajetória são retilíneos e seus comprimentos seguem uma distribuição de Lévy. Os tubarões, por exemplo, alternam entre o movimento browniano

quando a caça é abundante em uma determinada região próxima e o movimento guiado por voo de Lévy quando a caça está escassa nessa região [75]. Um exemplo do voo de Lévy com 100 passos pode ser observado na Fig. 3.7.




Figura 3.7. Voo de Lévy 2D com 100 passos.

Matematicamente falando, a primeira regra, pode ser entendida como um processo aleatório, de modo que uma nova solução possa ser gerada por meio do voo de Lévy. Para cada ninho, pode haver k ovos (soluções) que podem ser gerados da mesma forma da Eq. (3.10). Simultaneamente, uma permutação aleatória é realizada através do cruzamento das melhores soluções encontradas.

Na maioria dos casos, tem-se que $\alpha > 0$ para a Eq. (3.10). Este é o tamanho do passo que deve se relacionar com a escala do problema de interesse ou, em alguns casos, se pode utilizar $\alpha = 0$.

Para se verificar as diferentes qualidades entre as soluções, se pode utilizar,

$$\alpha = \alpha_0(x_j^{(t)} - x_i^{(t)}) \quad (3.15)$$

onde α_0 é uma constante, enquanto os demais termos correspondem a diferença entre duas soluções aleatórias. O mimetismo entre os ovos do cuco e os da ave hospedeira torna-os menos propensos a serem descobertos, assim, novas soluções são geradas pela proporcionalidade entre as diferenças.

A segunda regra, essencialmente, corresponde ao elitismo, assim que as melhores soluções são escolhidas, passa-se para a próxima geração. Tal escolha ajuda a garantir que o algoritmo convirja adequadamente.

Além disso, a terceira regra também pode ser considerada como uma mutação, de modo que as piores soluções sejam descartadas e, novos ovos (soluções) sejam gerados, de acordo com a semelhança entre as soluções. Isto implica que a mutação é um operador vetorizado através da combinação dos voos de Lévy e a diferenciação entre as qualidades das soluções. Este processo combinacional se faz necessário, para garantir a eficiência do algoritmo proposto.

O voo de Lévy proporciona, fundamentalmente, um passeio aleatório, enquanto que seus passos aleatórios são dados pela distribuição de Lévy para grandes passos, tal como dado na Eq. (3.11).

Uma fração p_a dos piores ninhos, então, pode ser abandonada de modo que novos ninhos possam ser construídos em outros locais obtidos pelos passeios aleatórios. A mistura dos ovos (soluções) pode ser realizada pela permutação aleatória de acordo com a semelhança/diferença em relação aos ovos da ave hospedeira.

Consequentemente, para se chegar ao tamanho do passo s para geração das amostras utilizando voos Lévy não é um processo tão trivial. Um esquema simplificado é abordado em detalhes por Yang [76] - [78] e pode ser resumido como,

$$s = \alpha_0(x_j^{(t)} - x_i^{(t)}) \oplus \text{Lévy}(\beta) \approx 0,01 \frac{u}{|v|^{1/\beta}} (x_j^{(t)} - x_i^{(t)}) \quad (3.16)$$

onde u e v são obtidos pela distribuição normal. Ou seja,

$$u \approx N(0, \sigma_u^2) \quad \therefore \quad v \approx N(0, \sigma_v^2) \quad (3.17)$$

com σ_u e σ_v iguais a 1.

Com base nas três regras discutidas anteriormente, os passos básicos do MOCS podem ser resumidos em um pseudocódigo apresentado na Fig. 3.8.

Início

Inicialize a função objetivo $f_1(x), \dots, f_k(x), x = (x_1, \dots, x_d)^T$

Gere uma população inicial de n ninhos hospedeiros x_i , e cada um com k ovos

quando ($t < \text{MaxGeração}$) ou (critério de parada)

Obtenha um Cuco (denominado i) aleatoriamente por voo de Lévy

Avalie e cheque se este é o valor ótimo de Pareto

Escolha um ninho entre n (denominado j) aleatoriamente

Avalie as k soluções para o j -ésimo ninho

se os ninhos i dominam as novas soluções dos ninhos j

Substitua o ninho i pelo novo conjunto de soluções do ninho j

fim

Abandone uma fração (p_a) dos piores ninhos

Mantenha as melhores soluções (ou conjunto de ninhos não dominados)

Classifique e encontre a atual solução ótima de Pareto

fim

Resultados pós processamento e visualizações

Fim

Figura 3.8. Pseudocódigo do algoritmo de busca cuco multiobjetivo.

Em suma, o algoritmo MOCS apresenta características singulares, tal como: a exploração/mutação por voo Lévy e a obtenção de diferentes soluções vetorizadas, a permutação aleatória seletiva e, o elitismo. O CS se utiliza fundamentalmente de uma boa combinação de todas essas ferramentas e, portanto, é potencialmente mais robusto quando confrontado a algoritmos que se utilizam somente de algumas destas ferramentas. Como no caso do PSO que pode se utilizar de uma atualização do vetor velocidade, como no termo de $\varepsilon(x_i - g^*)$, que é a diferença entre a solução atual x_i e a melhor solução global atual g^* . Esta é sua principal forma de randomização, pois limita os passos que são proporcionais as diferentes soluções [27].

Por conseguinte, no CS, a randomização pode ser mais eficiente, como no caso do tamanho dos passos, que obedecem a uma distribuição de Lévy e podem ser aproximados pela lei da potência. Assim, as etapas de busca consistem em vários pequenos passos e, ocasionalmente, em grandes passos e, a longa distância, em saltos. Comparando-o novamente ao PSO, estes longos saltos podem aumentar a eficiência do CS significativamente especialmente em casos multimodais e problemas não lineares.

3.5. Síntese do Capítulo

Nesse capítulo, se apresentou e discutiu em detalhes as técnicas de computação Bioinspirada que foram implementadas nesse estudo. O uso desses modelos é uma forma de incorporar os benefícios da inteligência computacional na análise das estruturas de FSS investigadas.

Capítulo 4

Resultados

A análise das características eletromagnéticas (EM) de uma FSS, geralmente, demanda a aplicação de rigorosas técnicas numéricas para análise de onda completa. Entretanto, esta análise requer alto custo computacional, acarretando um elevado gasto de tempo para execução dos cálculos das propriedades destes dispositivos.

Pesquisadores, em alguns casos, ainda optam pelo processo de tentativa e erro [78], até alcançar determinado critério do projeto. Obviamente, este procedimento é trabalhoso e dependente da intervenção humana.

A modelagem e otimização computacional BIC, no entanto, se apresenta como um importante paradigma com uma vasta gama de aplicações na engenharia e na indústria. Áreas estas em que, quase sempre, se tem interesse em otimizar algo, seja para minimizar o custo e o consumo de energia, ou para maximizar o lucro, a produção, desempenho e eficiência.

Nesse contexto, esse trabalho traz como proposta o desenvolvimento de um algoritmo meta-heurístico multiobjetivo, que atenda às necessidades comentadas ao longo de todo o texto explanado nos capítulos anteriores.

Neste capítulo, apresentar-se-á informações concernentes à configuração dos algoritmos implementados, bem como os resultados alcançados após a realização de simulações, através da utilização das técnicas computacionais investigadas. Para validação dos resultados simulados, foram construídos protótipos das estruturas e realizadas medições.

4.1. Caracterização do Projeto

Neste trabalho, se empregam técnicas híbridas de otimização BIC para calcular parâmetros estruturais ótimos de FSS triangulares, com o objetivo de sintonizar a frequência de ressonância em 11,0 GHz e largura de banda em 4,0 GHz em ambas as estruturas.

Os dados eletromagnéticos (EM) de entrada, para treinamento da GRNN, foram obtidos via *software* computacional *CST® Microwave Studio*, ao considerar nas simulações as FSS impressas em substrato isotrópico de fibra de vidro (FR-4) com permissividade relativa $\epsilon_r = 4,4$, tangente de perda $\tan(\delta) = 0,02$ e espessura de $h = 1,57$ mm, respeitando as

condições apresentadas na Tabela 2.1 disponível no Capítulo 2. Este *software* aplica a técnica das integrações finitas (*finite integrations* – FIT) para análise numérica de onda completa.

A rede, após ser treinada, é responsável pela análise dos dados EM e pela criação da região de interesse, na qual os algoritmos de otimização deverão realizar buscas pela melhor solução para a função custo, havendo uma contínua interação entre a GRNN e os algoritmos de otimização nessa etapa. Logo, para cada novo conjunto de parâmetros do projeto que o algoritmo retornar, a etapa de análise executa o cálculo necessário e determina o valor de um novo ponto no espaço de busca. As simulações foram realizadas em um computador com CPU *Clock* 2,53 GHz e 4 GB de RAM.

O projeto segue o diagrama apresentado na Fig. 4.1.

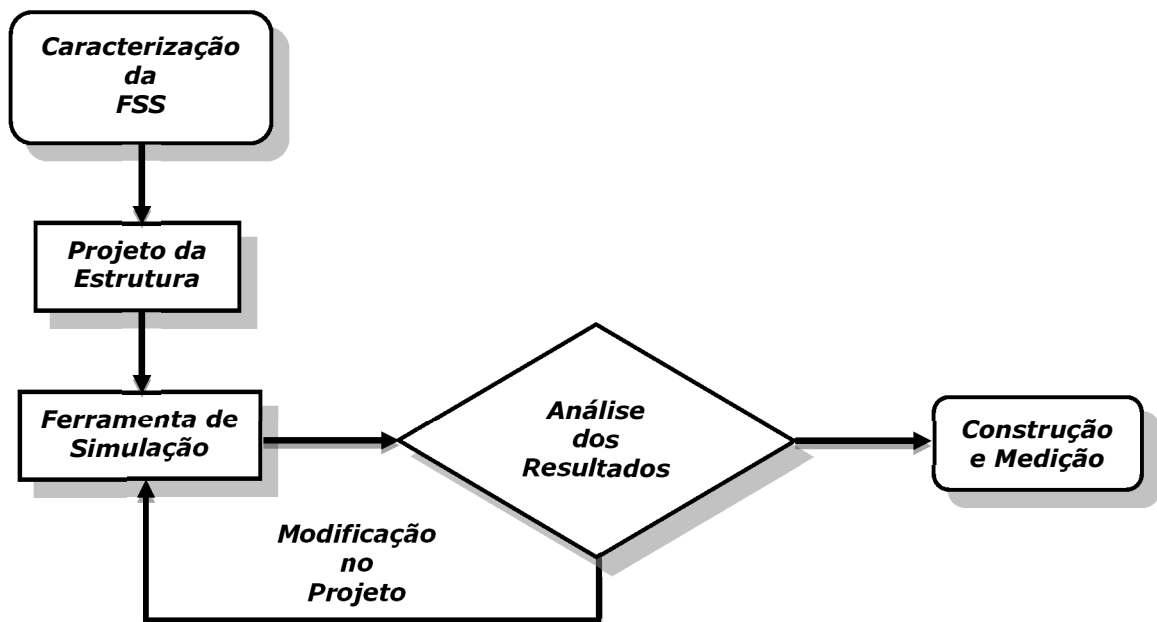


Figura 4.1. Fluxograma geral do projeto.


No modelo de projeto desenvolvido neste estudo, ao se transpor as etapas iniciais de caracterização das estruturas, o módulo de otimização substitui as repetidas simulações exigidas por técnicas de análise de onda completa.

Na Fig. 4.2, é possível observar uma alteração na estrutura geral das etapas apresentadas acima. Nesta, foi incluída a etapa em as ferramentas de computação natural (otimização) serão empregadas.


O processo de otimização possui uma fase de busca e uma fase de análise, sendo o algoritmo de otimização responsável pela operação de busca e, a GRNN treinada, responsável pela operação de análise, resultando em uma interação contínua nesta etapa. Assim, para cada novo conjunto de parâmetros do 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 na região de interesse, isto é, no espaço de busca para os algoritmos de otimização. Dessa forma, o objetivo é minimizar a diferença entre a resposta dada pela rede e os valores especificados para o projeto. Neste paradigma, o ideal seria encontrar valores próximos ou iguais a zero para a função custo.

As Fig. 4.3 e 4.4 mostram os resultados obtidos pela GRNN desenvolvida para a 1ª e a 2ª estrutura de FSS analisadas, respectivamente. Nestas, as linhas pontilhadas indicam a resposta da rede e as demais linhas, diferenciadas por símbolos, representam o conjunto de treinamento.

Ao analisar a resposta da GRNN desenvolvida, se observa uma grande capacidade de generalização para a configuração estudada, conseqüentemente, também se observa que, com o aumento da área efetiva do condutor W das FSS, se deslocam as frequências de ressonância para frequências mais baixas, ao passo que a largura de banda aumenta. Tal comportamento se assemelha ao das antenas planares, nas quais o aumento da superfície efetiva do condutor é uma característica capaz de impor modificações em seu funcionamento [80] - [81]. Um exemplo disso é o aumento da largura de banda e o deslocamento da frequência de ressonância.




(a)




(b)

Figura 4.3. Resposta da rede GRNN para frequência de ressonância (a) e largura de banda (b) em função dos parâmetros estruturais W e t da estrutura da estrutura *patch* triangular. As dimensões estão em milímetro.



(a)



(b)

Figura 4.4. Resposta da rede GRNN para frequência de ressonância (a) e largura de banda (b) em função dos parâmetros geométricos W e t da estrutura de espira triangular. As dimensões estão em milímetros.

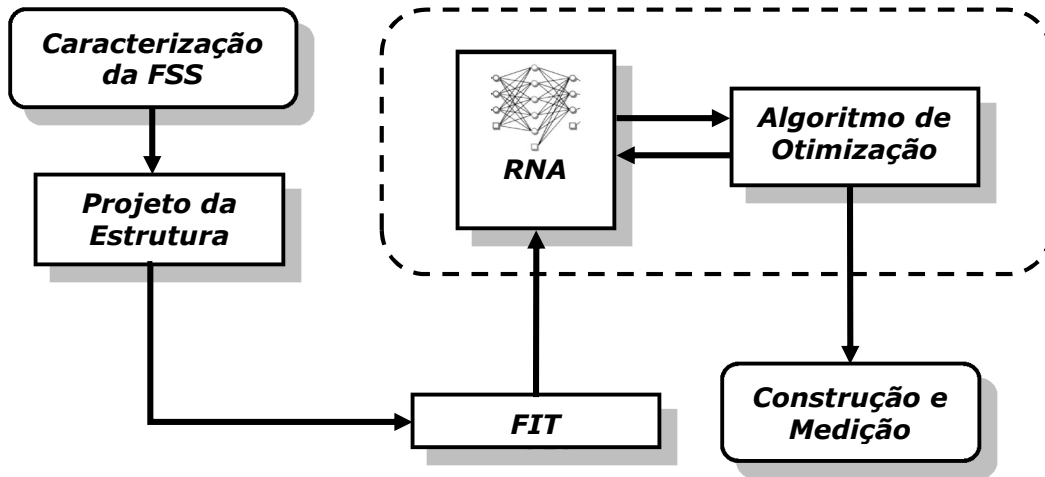


Figura 4.2. Fluxograma modificado pela introdução da técnica de otimização.

A GRNN utilizada possui quatro entradas em sua primeira camada, uma camada oculta com cinco neurônios e dois nós de saída, referentes à frequência central e largura de banda. Essa arquitetura foi exibida na Fig. 3.2 (Capítulo 3).

As entradas e as saídas do modelo desenvolvido de GRNN podem ser representadas por:

$$x = [W, t, \varepsilon_r, h]^T \quad (4.1)$$

$$y = [f_r, BW]^T \quad (4.2)$$

na Eq. (4.1), W é a altura e a largura do elemento condutor, t a periodicidade do arranjo da FSS, ε_r a permissividade relativa do substrato e h a altura do substrato. E, na Eq. (4.2), f_r é a frequência ressonância e BW a largura de banda da FSS.

Os objetivos consistem em minimizar a função custo a seguir [80]:

$$F = [f_1(x), f_2(x)] \quad (4.3)$$

onde,

$$f_1 = \|f_{r, \text{desejado}} - f_{r, \text{obtido}}\| \quad (4.4)$$

$$f_2 = \|BW_{\text{desejado}} - BW_{\text{obtido}}\| \quad (4.5)$$

Com base nestes resultados, a próxima etapa é a aplicação dos algoritmos de busca para identificar o melhor balanceamento entre a periodicidade t e a área efetiva do condutor W da célula unitária das FSS de modo a atender aos objetivos do projeto.

4.1.1. Setup para Medição das FSS

Os resultados experimentais foram obtidos no Laboratório de Micro-ondas do Grupo de Telecomunicações e Eletromagnetismo Aplicado (GTEMA) do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba (IFPB).

Foram utilizados para as medições um analisador de redes de duas portas Agilent E5071C e dois pares de antenas tipo corneta (SAS-571 de 0,7 - 18,0 GHz).

O esquemático do *setup* de medições é apresentado na Fig. 4.5.




Figura 4.5. Esquemático do *setup* de medição.

4.2. Aplicação dos Algoritmos de Otimização

Após o treinamento da GRNN e a criação do espaço de buscas, dar-se-á sequência ao estudo avançando a etapa de implementação dos algoritmos de otimização. Nesta seção, será detalhada a configuração de cada código desenvolvido.

4.2.1. Implementação do Algoritmo Genético

A partir do exposto na seção 3.2, se implementou um algoritmo genético multiobjetivo (AG Multi), este algoritmo foi adaptado ao problema estudado a partir do *genetic algorithm multiobjective* (GA Multi) utilizado por Fonseca [82].

O modelo desenvolvido nesta proposta é utilizado para otimizar os valores das estruturas contidos nas especificações delimitadas pela região de interesse gerada pela GRNN, sendo este, responsável pela escolha dos melhores valores para as dimensões dos condutores triangulares W e periodicidade t da célula unitária, apresentados na Tabela 2.1 disponível no Capítulo 2.

A Fig. 4.6 apresenta o fluxograma do AG Multi desenvolvido neste estudo.

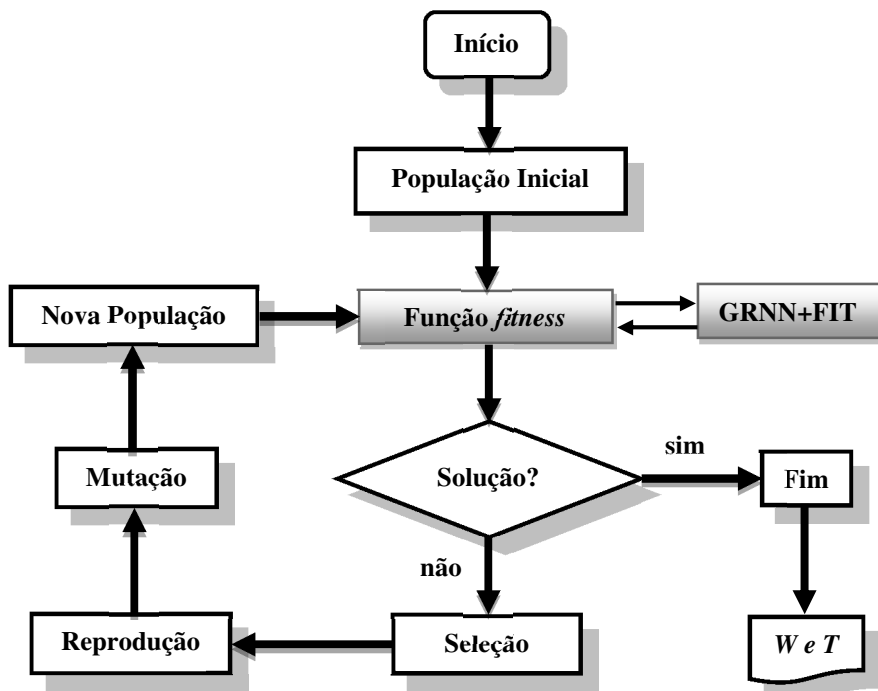


Figura 4.6. Fluxograma do AG Multi.

Este trabalho se utiliza do operador de cruzamento de ponto flutuante, a população dos cromossomos (N_{pop}) é representada por $x = [x_1, x_2, \dots, x_{N_{pop}}]^T$, onde cada $x_i = [P_1, \dots, P_{i-1}, P_{i+1}, \dots, P_{iN_{pop}}]$ representa o ponto da nova solução. A geração inicial de indivíduos é dada por:

$$x_i = P_{i,min} + rand(P_{i,max} - P_{i,min}) \quad (4.6)$$

onde a função *rand* é responsável por gerar números aleatórios distribuídos uniformemente no intervalo $[0, 1]$ e, para as especificações desejadas da FSS, o objetivo é minimizar a função custo da Eq. (4.3).

A população dos cromossomos possui tamanho $N_{pop} = 25$ e 2 desses para controle do elitismo. O número de cromossomos membros da elite foi limitado a uma fração de 0,7 da frente de Pareto.

O AG Multi elitista sempre favorece os indivíduos com melhor valor de *fitness* (ranque) e, também procura favorecer os indivíduos que possam ajudar a aumentar a diversidade da população, mesmo quando estes possuem um valor de aptidão mais baixo. Há uma particular preocupação em manter a diversidade da população de modo a garantir a convergência para uma frente ótima de Pareto. A diversidade se mantém pelo controle dos membros da elite da população, de acordo com o progresso de algoritmo.

A Fig. 4.7 mostra a evolução do *fitness* no processo de síntese via AG Multi para as estruturas investigadas. Durante esse processo, o valor da função custo apresenta uma diminuição gradativa em relação ao seu valor inicial. A linha pontilhada representa a média do *fitness* para a população cromossômica e a linha sólida representa a melhor solução individual. O algoritmo necessitou de 44 iterações para convergir para solução ótima.




Figura 4.7. Evolução do *fitness* no processo de síntese das FSS via AG Multi, estruturas otimizadas para $f_r = 11,0$ GHz e $BW = 4,0$ GHz.

A Fig. 4.8 apresenta os resultados para o coeficiente de transmissão, em função da frequência, obtidos via *software CST*®, pela técnica híbrida (GRNN+AG Multi) e as medições do para a FSS de *patch* triangular otimizada.




Figura 4.8. Coeficiente de transmissão para FSS de *patch* triangular otimizada para $f_r = 11,0$ GHz e BW = 4,0 GHz através do AG Multi. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,57$ mm; $t = T_x = T_y \approx 12,3$ mm e $W \approx 11,6$ mm.

Na Tabela 4.1 são apresentados os tempos de execução das principais etapas do código após 44 iterações.

TABELA 4.1. Tempo de execução do AG Multi para a 1ª estrutura

Função	Chamadas	Tempo Individual	Tempo Total
GRNN	5.764	0,03 s	172,9 s
Mutação	14.893	0,02 s	297,9 s
<i>Fitness</i>	2.881	0,1 s	288,1 s
Tempo de Execução	-	-	758,9 s

A Fig. 4.9 apresenta os resultados para o coeficiente de transmissão, em função da frequência, obtidos via *software CST*®, pela técnica híbrida (GRNN+AG Multi) e as medições para a FSS de espira triangular otimizada.




Figura 4.9. Coeficiente de transmissão para FSS de espira triangular otimizada para $f_r = 11,0$ GHz e $BW = 4,0$ GHz através do AG Multi. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,57$ mm; $t = T_x = T_y \approx 9,2$ mm e $W \approx 6,4$ mm.

Na Tabela 4.2 são apresentados os tempos de execução das principais etapas do código após 44 iterações.

TABELA 4.2. Tempo de execução do AG Multi para a 2ª estrutura

Função	Chamadas	Tempo individual	Tempo Total
GRNN	4.164	0,03 s	124,9 s
Mutação	16.095	0,02 s	321,9 s
<i>Fitness</i>	2.081	0,1 s	208,1 s
Tempo de Execução	-	-	654,9 s

4.2.2. Implementação do Algoritmo de Ecolocalização do Morcego

A partir da fundamentação teórica apresentada na seção 3.3, foi implementado um código híbrido, multivariável e multiobjetivo, que originou o algoritmo multiobjetivo do morcego (*multiobjective bat algorithm* – MOBA).

O fluxograma para o algoritmo utilizado é apresentado na Fig. 4.10.

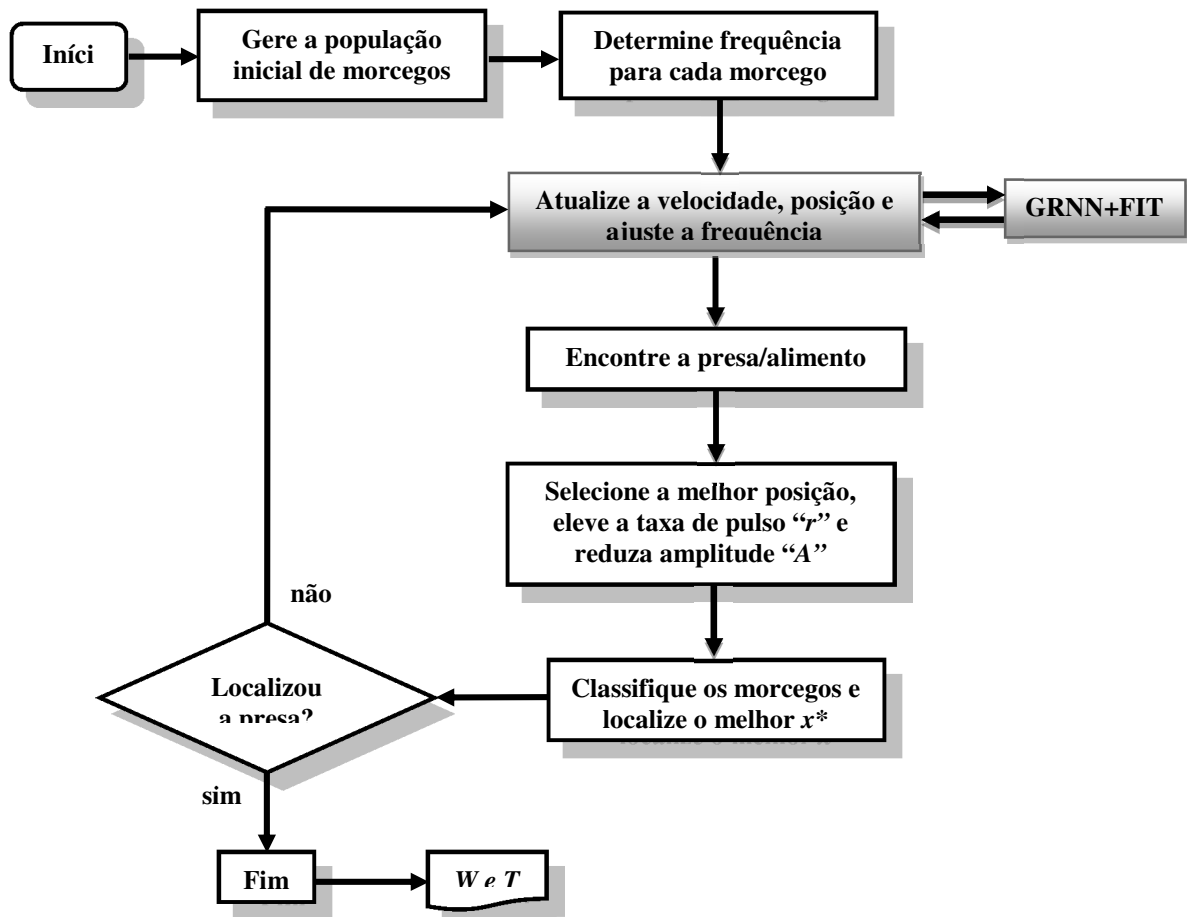


Figura 4.10. Fluxograma do algoritmo de ecolocalização de morcego multiobjetivo utilizado.

O código desenvolvido nessa proposta se utiliza do método das somas ponderadas para combinar os múltiplos objetivos e, assim, minimizar a função custo expressa na Eq. (4.3). A operação se inicia pela geração aleatória da população dos morcegos dada pela Eq. (4.6), tendo o tamanho fixado em $N_{pop} = 25$ e, com os parâmetros de controle $A = 0,15$, $r = 0,5$, $f_{min} = 1,5$, $f_{max} = 3,0$ e uma fração de 0,7 da frente de Pareto.

O algoritmo realiza buscas das especificações das estruturas na região de interesse gerada pela GRNN, tal como o AG Multi.

Os resultados obtidos pelo o processo de otimização realizado pela técnica híbrida (RNA + MOBA) para W e t , em atendimento aos objetivos $f_r = 11$ GHz e $BW = 4$ GHz, serão, posteriormente comparados aos resultados simulados no *software CST*®.

A Fig. 4.11 mostra a evolução do *fitness* no processo de síntese via MOBA para as estruturas investigadas. Durante esse processo, o valor da função custo apresenta uma diminuição gradativa em relação ao seu valor inicial. A linha pontilhada representa a média do *fitness* para a população de morcegos e a linha sólida representa a melhor solução individual (ou posição). O algoritmo necessitou de 52 iterações para convergir para solução ótima.




Figura 4.11 Evolução do *fitness* no processo de síntese das FSS via MOBA, estruturas otimizadas para $f_r = 11,0$ GHz e $BW = 4,0$ GHz.

A Fig. 4.12 apresenta os resultados para o coeficiente de transmissão em função frequência obtidos via *software CST*®, pela técnica híbrida (GRNN+MOBA) e as medições do para a FSS de *patch* triangular.




Figura 4.12. Coeficiente de transmissão para FSS de *patch* triangular otimizada para $f_r = 11,0$ GHz e $BW = 4,0$ GHz através do MOBA. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,57$ mm; $t = T_x = T_y \approx 12,8$ mm e $W \approx 11,6$ mm.

A Tabela 4.3 são apresentados os tempos de execução das principais etapas do código após 52 iterações.

TABELA 4.3. Tempo de execução do MOBA para a 2ª estrutura

Função	Chamadas	Tempo individual	Tempo Total
GRNN	60.220	0,003 s	180,7 s
Etapa de Atualização	240.880	0,0005 s	120,4 s
Descoberta da Presa	421.550	0,0004 s	168,6 s
Tempo de Execução	-	-	469,7 s

A Fig. 4.13 apresenta os resultados para o coeficiente de transmissão em função frequência obtidos via *software CST®*, pela técnica híbrida (GRNN+MOBA) e as medições o para a FSS de espira triangular otimizada.




Figura 4.13. Coeficiente de transmissão para FSS de *patch* triangular otimizada para $f_r = 11,0$ GHz e $BW = 4,0$ GHz através do MOBA. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,57$ mm; $t = T_x = T_y \approx 9,6$ mm e $W \approx 6,5$ mm.

Na Tabela 4.4 são apresentados os tempos de execução das principais etapas do código após 52 iterações.

TABELA 4.4. Tempo de execução do MOBA para a 2ª estrutura

Função	Chamadas	Tempo Individual	Tempo Total
GRNN	60.660	0,004 s	242,6 s
Etapas de Atualização	121.320	0,003 s	363,9 s
Descoberta da Presa	424.628	0,0003 s	127,4
Tempo de Execução	-	-	733,9 s

4.2.3. Implementação do Algoritmo de Busca Cuco

Na seção 3.4 se apresentou a teoria referente ao CS e, na subseção 3.4.1 ao MOCS, fundamentado nessa teoria, se construiu um algoritmo híbrido, multivariável e multiobjetivo. Este algoritmo é capaz de encontrar os valores mais adequados de largura de banda e

aproximação a frequência central de operação desejada para as FSSs estudadas, o código foi desenvolvido para minimizar a função custo dada na Eq. (4.3).

A estrutura do algoritmo MOCS proposto inclui duas operações principais, sendo uma busca direta com base nos voos de Lévy Eq. (3.10), e uma pesquisa aleatória baseada na probabilidade de um pássaro hospedeiro descobrir um ovo “alienígena” em seu ninho, cada ninho representa uma solução diferente e uma população de ninhos é usada para encontrar a melhor solução do problema, tal como outros métodos de pesquisa populacional meta-heurísticas. O fluxograma para o algoritmo utilizado é apresentado na Fig. 4.14.

Antes de iniciar o processo de busca iterativa, o algoritmo CS identifica o padrão da melhor solução x_{melhor} . A geração aleatória inicial dos ninhos hospedeiros é dada pela Eq.(4.6), na qual, P_{min} e P_{max} são os pontos referentes aos ninhos inferiores e superiores limitantes do d -ésimo atributo do reduto do cuco.

Após essa geração, se calcula a nova solução com base nos melhores ninhos x_{melhor} via voos de Lévy, por sua vez, este é calculado pelo algoritmo de Mantegna [83]. A população inicial dos ninhos hospedeiros se define pelo melhor valor de cada ninho x_{melhor} e, o melhor ninho corresponde ao calculado pela função *fitness*, Eq. (4.6), definido como o melhor ninho G_{melhor} entre todos os ninhos da população.

Calcula-se a nova solução individual para cada ninho por:

$$x_{d,i}^{novo} = x_{melhor_i} + \alpha \cdot rand \cdot \Delta x_i^{novo} \quad (4.7)$$

onde $\alpha > 0$ é o tamanho do passo de atualização, neste caso a função *rand* é um número estocástico com distribuição normal e, o valor do incremento Δx_i^{novo} é dado por:

$$\Delta x_i^{novo} = v \cdot \frac{\sigma_x(\beta)}{\sigma_y(\beta)} \cdot (x_{melhor_i} - G_{melhor}) \quad (4.8)$$

e

$$v = \frac{rand_x}{|rand_y|^{1/\beta}} \quad (4.9)$$

onde $rand_x$ e $rand_y$ são duas variáveis estocásticas com distribuição normal e, desvio padrão $\sigma_x(\beta)$ e $\sigma_y(\beta)$ dado pela Eq. (3.15). Sendo $\sigma_y(\beta) = 1$ e β o fator de distribuição ($0,3 \leq \beta \leq 1,99$).

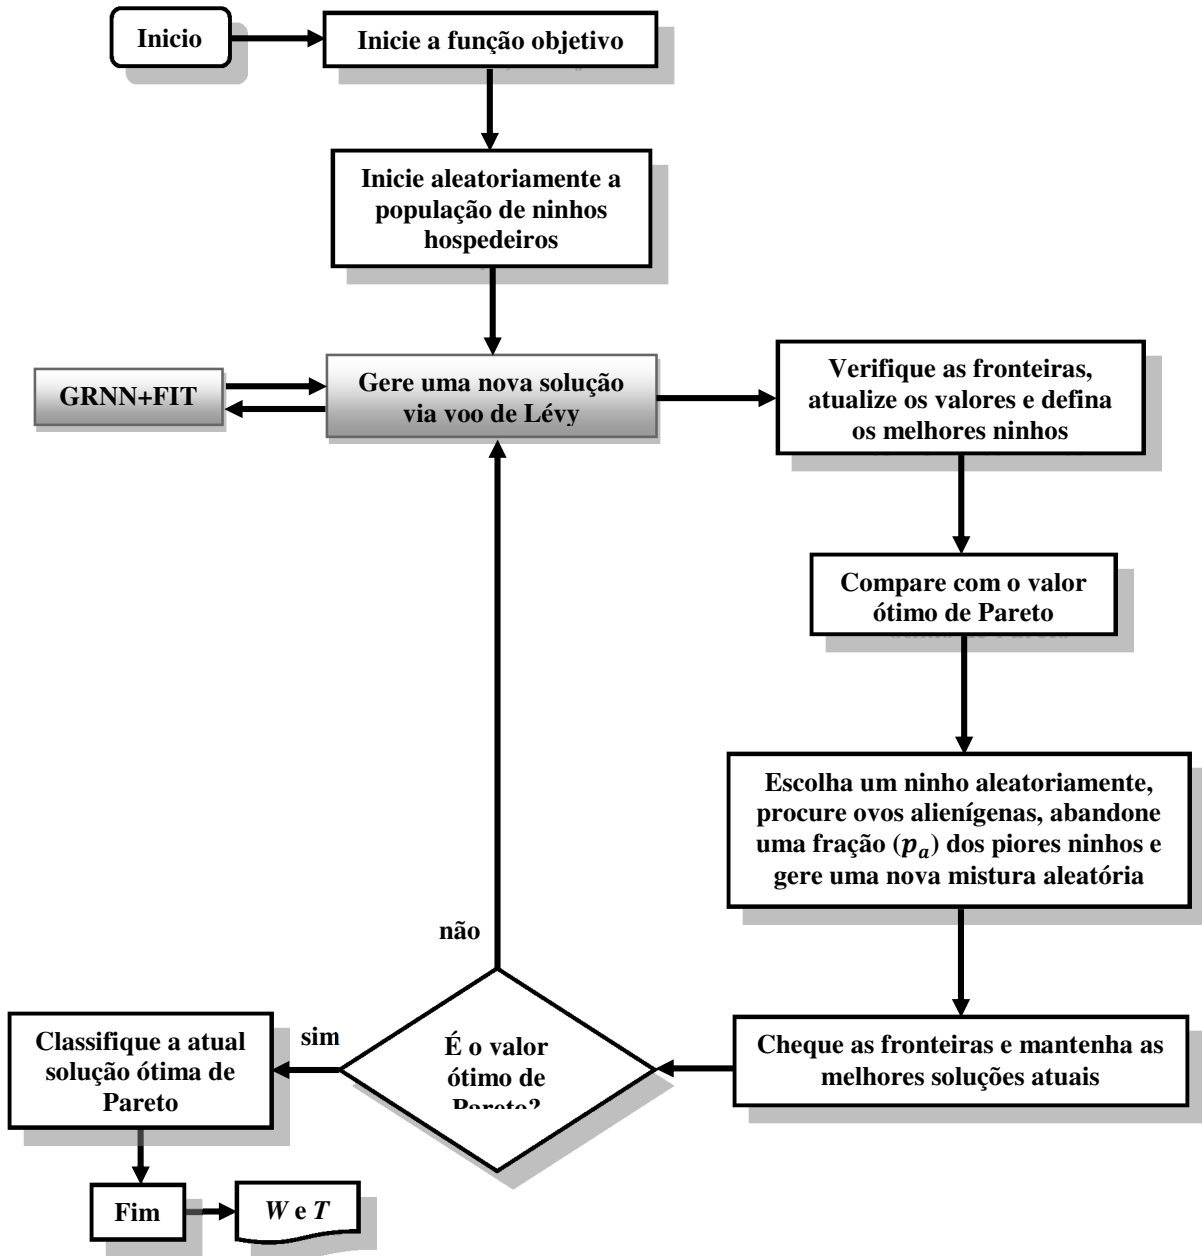


Figura 4.14. Fluxograma do algoritmo de busca cuco multiobjetivo utilizado.

As fronteiras delimitadoras do reduto do cuco são controladas a cada etapa de execução do algoritmo e, os pontos de marcação são dados por $P_{min} = [10; 11,5]$, $P_{max} = [12; 15]$ e $P_{min} = [4; 5,5]$, $P_{max} = [10; 14]$ para a 1ª e a 2ª estruturas, respectivamente.

Para as soluções mais recentes, os atributos desses limites devem ser satisfeitos de acordo com as unidades limitantes,

$$x_{d,i}^{novo} = \begin{cases} P_{i,max} & \text{se } x_{d,i}^{novo} > P_{i,max} \\ P_{i,min} & \text{se } x_{d,i}^{novo} < P_{i,min} \\ x_{d,i} & \text{outros valores,} \end{cases} \quad (4.10)$$

assim, sempre que o valor de um atributo extrapolar os limites do espaço de busca, o valor desse atributo é atualizado para o valor que mais se aproxime ao valor da fronteira. A função *fitness* será avaliada novamente para as novas soluções, de modo a determinar o atual melhor valor de cada ninho $x_{d,melhor}$ e o melhor ninho $G_{d,melhor}$ ao comparar os valores de aptidão.

A ação de descoberta de um ovo “alienígena” com probabilidade p_a no ninho da ave hospedeira, também cria uma nova solução para o problema semelhante ao voo de Lévy. Essa nova solução pode ser calculada de acordo com:

$$x_{d,i}^{alien} = x_{d,melhor} + k \cdot \Delta x_{d,i}^{alien} \quad (4.11)$$

sendo k o coeficiente de atualização, que é determinado com base na probabilidade de alguma ave hospedeira encontrar o ovo “alienígena” em seu ninho,

$$k = \begin{cases} 1 & \text{se } rand < p_a \\ 0 & \text{outros valores} \end{cases} \quad (4.12)$$

e, o valor do incremento $\Delta x_{d,i}^{alien}$ é determinado por:

$$\Delta x_{d,i}^{alien} = rand * [randp_1(x_{d,melhor}) - randp_2(x_{d,melhor})] \quad (4.13)$$

onde as funções *rand* nas Eq. (4.12) e (4.13) são números aleatórios distribuídos entre [0, 1] e, $randp_1$ e $randp_2$ são as permutações aleatórias por posição dos ninhos $x_{d,melhor}$.

Semelhante à solução obtida via voo de Lévy esta nova solução também é redefinida pela Eq. (4.10), caso os valores das fronteiras sejam violados. A atual melhor solução (ninho) $x_{d,melhor}$ e o atual melhor valor entre os ninhos $G_{d,melhor}$ também são determinados com base na comparação do *fitness* calculado pela Eq. (4.6).

Por simplicidade, neste estudo, se assumiu que o cuco possui em seu reduto o número total de ninhos (ou diferentes soluções) $n = 25$, com probabilidade da descoberta do ovo “alienígena” pela ave hospedeira $p_a = 0,25$, o vetor escalar $\beta = 1,5$, uma fração de 0,7 da frente de Pareto foi utilizada com parâmetro para os valores ótimos das soluções.

O código desenvolvido, bem como, o código MOBA, se utiliza do método das somas ponderadas para combinar os múltiplos objetivos e, se encerra quando atinge o número máximo de iterações pré-determinadas.

A Figura 4.15 mostra a evolução do *fitness* no processo de síntese via MOCS para as estruturas investigadas. Durante esse processo, o valor da função custo apresenta uma diminuição gradativa em relação ao seu valor inicial. A linha pontilhada representa a média do *fitness* para a população de ninhos e a linha sólida representa a melhor solução individual. O algoritmo necessitou de apenas 33 iterações para convergir para solução ótima.




Figura 4.15. Evolução do *fitness* no processo de síntese via MOCS, estruturas otimizadas para $f_r = 11,0$ GHz e $BW = 4,0$ GHz.

A Fig. 4.11 apresentada os resultados para o coeficiente de transmissão versus a frequência obtidos via *software CST®*, pela técnica híbrida (GRNN+MOCS) e as medições o para a FSS de *patch* triangular otimizada.




Figura 4.16. Coeficiente de transmissão para FSS de *patch* triangular otimizada para $f_r = 11,0$ GHz e $BW = 4,0$ GHz via MOCS. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,57$ mm; $t = T_x = T_y \approx 12,3$ mm e $W \approx 11,6$ mm.

Na Tabela 4.5 são apresentados os tempos de execução das principais etapas do código após 33 iterações.

TABELA 4.5. Tempo de execução do MOCS para a 1ª estrutura

Função	Chamadas	Tempo Individual	Tempo Total
GRNN	3.350	0,04 s	134,0 s
Voo de Lévy	1.675	0,02 s	33,5 s
Descoberta de ovos “alien”	1.675	0,04 s	67,0 s
Tempo de Execução	-	-	234,5 s

A Fig. 4.17 apresentada os resultados para o coeficiente de transmissão em função da frequência obtidos via *software CST*®, pela técnica híbrida (GRNN+MOCS) e as medições o para a FSS de espira triangular otimizada.




Figura 4.17. Coeficiente de transmissão para FSS de espira triangular otimizada para $f_r = 11,0$ GHz e $BW = 4,0$ GHz via MOCS. Parâmetros estruturais: $\epsilon_r = 4,4$; $h = 1,57$ mm; $t = T_x = T_y \approx 9,2$ mm e $W \approx 6,4$ mm.

Na Tabela 4.6 são apresentados os tempos de execução das principais etapas do código após 33 iterações.

TABELA 4.6. Tempo de execução do MOCS para a 2ª estrutura

Função	Chamadas	Tempo Individual	Tempo Total
GRNN	2050	0,02 s	41,0 s
Voo de Lévy	1025	0,01 s	10,3 s
Descoberta de ovos “alien”	1025	0,02 s	20,5 s
Tempo de Execução	-	-	71, 8 s

4.3. Síntese do Capítulo

Neste capítulo, apresentou-se o *setup* e os equipamentos utilizados para as medições, bem como destacou-se a implementação da técnica híbrida desenvolvida e dos algoritmos de otimização. Também foram apresentados os tempos que cada técnica híbrida necessitou para processamento das propriedades EM das FSS triangulares analisadas.

Capítulo 5

Conclusão

Neste trabalho, foram aplicadas técnicas de inteligência computacional Bioinspirada de otimização híbrida multiobjetivo, que utiliza rede neural do tipo GRNN associada aos algoritmos genético, de ecolocalização do morcego e de busca cuco, na síntese de superfícies seletivas de frequência (FSS).

Geometrias de FSS com elementos triangulares, constituídos por *patches* e espiras, que consistem de arranjos periódicos de elementos impressos sobre uma camada de material dielétrico isotrópico, foram utilizadas pela simplicidade e por permitirem operação em faixas largas de frequências.

A análise eletromagnética foi realizada por meio do método numérico das integrações finitas (*finite integrations technic* – FIT) com o auxílio do *software* comercial CST®. A metodologia que envolve redes neurais artificiais e eletromagnetismo foi aplicada para modelar o comportamento das FSS triangulares, onde um banco de calculado pelo método numérico, é necessário para garantir o aprendizado da rede, disponibilizando o conhecimento adquirido para futuras utilizações.

Além disso, os modelos de GRNN desenvolvidos proporcionaram soluções rápidas e precisas, com um baixo custo computacional, tornando-se uma técnica atrativa para a síntese de estruturas cuja formulação teórica é inexistente ou demanda um elevado custo computacional de implementação e simulação.

A junção de redes neurais artificiais a algoritmos de otimização natural, consiste em um método alternativo de otimização de estruturas eletromagnéticas, caracterizando a técnica denominada de método híbrido, que tem por fim viabilizar características como: eficácia, flexibilidade e eficiência computacional. Resultando em uma poderosa ferramenta de otimização na solução de problemas de espalhamento eletromagnético.

Foi realizada a síntese de FSS com elementos triangulares, para operação na faixa de frequências da banda X, com frequência de ressonância centrada em 11,0 GHz e largura de banda de 4,0 GHz, a partir da variação da periodicidade do arranjo e do comprimento do lado do elemento triangular considerado.

Os resultados otimizados pelas técnicas híbridas desenvolvidas na síntese das FSS triangulares foram utilizados na fabricação de protótipos das FSS estudadas, impressas em substrato de fibra de vidro (FR-4). Para validação de resultados, os protótipos de FSS foram medidos, tendo sido verificado uma boa concordância entre os resultados medidos e simulados.

Ademais, de acordo com os resultados simulados neste trabalho, o algoritmo MOCS apresentou um desempenho superior àqueles observados com o AG Multi e o MOBA. O MOCS é caracterizado por ser um algoritmo mais simples de implementar e com poucos parâmetros de ajuste e, se adequa a uma grande classe de problemas de otimização na engenharia e na indústria. Desta forma, o MOCS tornou-se uma ferramenta de otimização robusta na síntese das estruturas de FSS.

A rapidez e a precisão na convergência do MOCS podem ser atribuídas ao fato da busca cuco utilizar combinação de mutação vetorizada, permutações cruzadas por voos de Lévy e, elitismo seletivo entre as melhores soluções (ninhas) baseado na probabilidade de um pássaro hospedeiro descobrir um ovo “alienígena” em seu ninho.

Vale ressaltar que redes do tipo GRNN, ao se pesquisar o estado da arte, ainda não haviam sido aplicadas no processo de otimização de FSS, bem como o algoritmo de busca cuco. Outrossim, neste trabalho, foi proposta uma nova forma geométrica para FSS, a FSS de espira triangular.

Os resultados simulados obtidos pela técnica híbrida para os parâmetros investigados das FSS, ou seja, frequência de ressonância e largura de banda, foram comparados aos simulados pelo *software CST®* e aos obtidos via medições. Foi alcançada boa concordância entre os mesmos, validando a técnica de otimização híbrida multiobjetivo proposta.

A técnica desenvolvida mostrou-se veloz e precisa na solução da função custo, consistindo em mais uma ferramenta viável para o desenvolvimento de projetos de dispositivos de rádio difusão e outros dispositivos ressonantes.

Para a continuidade do trabalho, é proposto o estudo do emprego dessas ferramentas de otimização para a síntese de nano estruturas, de modo a viabilizar redução do esforço computacional e o tempo para processamento destas estruturas. Outrossim, empregar as ferramentas desenvolvidas na otimização de antenas e circuitos eletrônicos para faixa de micro-ondas.

Para a continuidade do trabalho, é proposto o estudo do emprego dessas ferramentas de otimização para o projeto e síntese de nano estruturas, de modo a viabilizar

redução do esforço computacional e o tempo para processamento das estruturas na faixa de frequências em THz. Outrossim, empregar as ferramentas desenvolvidas para otimização de antenas e circuitos eletrônicos para faixa de micro-ondas.

Referências Bibliográficas

- [1] M. Naeem, “Scattering and Absorption Analysis of Radomes Using the Method of Equivalent Dipole Moments, Master’s Thesis, Department of Signals and Systems Chalmers University of Technology”, Göteborg, Sweden, October 2011.
- [2] R. Marklein, “The finite integration technique as a general tool to compute acoustic, electromagnetic, elastodynamic, and coupled wave fields”, University of Kassel, Department of Electrical Engineering/Computer Science, Electromagnetic Field Theory, Wilhelmhöher Allee 71, D-34121 Kassel, Germany, Review of radio Science, 1999.
- [3] W. C. de Araújo, “Síntese de superfícies seletivas de frequência através de técnicas de computação natural”, Tese de Doutorado, Universidade Federal do Rio Grande do Norte, Rio Grande do Norte, Brasil, 2014.
- [4] Z. Cui, R. Alex, R. Akerkar and X. S. Yang, “Recent advances on bioinspired computation”, The Scientific World Journal, vol. 2014, article ID 934890, 2014.
- [5] A. H. Alavi e A. H. Gandomi, “A robust data mining approach for formulation of geotechnical engineering systems”, International Journal of Computer Aided Methods in Engineering-Engineering Computations, vol. 28, no. 3, pp. 242-74, 2011.
- [6] S. Ali, N. Abbadeni, M. Batouche, “Multidisciplinary computational intelligence techniques: applications in business, engineering, and medicine”, IGI Global Snippet, 2012.
- [7] X. S. Yang e S. Deb, “Cuckoo search via Lévy flights”, in: Proc. of World Congress on Nature & Biologically Inspired Computing (NaBic 2009), IEEE Publications, USA, pp. 2010-2014, 2009.

- [8] X. S. Yang, “A new metaheuristic bat-inspired algorithm”, *Nature Inspired Cooperative Strategies for Optimization*, Springer Berlin, vol. 284, pp. 65-74, 2010.
- [9] W. C. Araújo, H. W. C. Lins, A. G. D’Assunção Jr., J. L. G. Medeiros and A. G. D’Assunção, “A bioinspired hybrid optimization algorithm for designing broadband frequency selective surfaces”, *Microwave and Optical Technology Letters*, vol. 56, no. 2, 2014.
- [10] A. Hoorfar, “Evolutionary programming in electromagnetic optimization: a review”, *IEEE Trans. Antenna and Propag.*, pp. 523–537, 2007.
- [11] R. H. C. Maniçoba, “Estudo do acoplamento entre superfícies seletivas de frequência assimétrica em estruturas de multicamadas”, Tese de Doutorado, Universidade Federal do Rio Grande do Norte, Rio Grande do Norte, Brasil, 2012.
- [12] T. L. Silva, “Análise de onda completa de superfície seletiva em frequência do tipo anteparo duplo”, Dissertação de Mestrado, Universidade Federal do Rio Grande do Norte, Rio Grande do Norte, Brasil, 2011.
- [13] B. R. S. Reddy, D. Vakula, N. V. S. N. Sarma, “Design of multiple function antenna array using radial basis function neural network”, *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, vol. 12, no. 1, 2013.
- [14] A. Freni, M. Mussetta and P. Pirinoli, “Neural network characterization of reflect array antennas”, *International Journal of Antennas and Propagation*, article ID 541354, 2012.
- [15] Z. Wang e S. Fang, “ANN synthesis model of single-feed corner-truncated circularly polarized microstrip antenna with an air gap for wideband applications”, *International Journal of Antennas and Propagation*, article ID 392843, 2014.
- [16] C. M. J. V. Coevorden, M. F. Pantoja, S. G. García, A. R. Bretones, R. G. Martín and K. Palmer, “Multiobjective-optimized design of a new UWB antenna for UWB applications”, *International Journal of Antennas and Propagation*, article ID 476878, 2013.

- [17] M. N. Kawakatsu, “Superfícies eletromagnéticas de micro-ondas com controle do regime de trapped-mode”, Tese de Doutorado, Universidade Federal do Pará, Instituto de Tecnologia (ITEC), Pará, 2012.
- [18] B. A. Munk, *Frequency Selective Surfaces: Theory and Design*, US: John Wiley & Sons, 2000.
- [19] R. M. S. Cruz, P. H. F. Silva e A. G. D’Assunção, “Neuromodeling stop band properties of Koch Island patch elements for FSS filter design”, *Microwave and Optical Technology Letters*, vol. 51, no. 12, 2009.
- [20] P. H. F. Silva, R. M. S. Cruz e A. G. D’Assunção, “Blending PSO and ANN for optimal design of FSS filters with Koch Island patch elements”, *IEEE Transactions on Magnetics*, vol. 46, no. 8, 2010.
- [21] 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*, vol. 55, no. 4, 2013.
- [22] J. P. L. Araújo, J. C. Rodrigues, S. G. C. Fraiha, H. Gomes, G. P. S. Cavalcante, C. e R. L. Francês, “A WLAN planning proposal through computational intelligence and genetic algorithms hybrid approach”, *The International Conference on Mobile Technology, Applications & Systems (Mobility Conference)*, pp. 10-12, Ilan, Taiwan, 2008.
- [23] S. Balochian e E. Ebrahimi, “Parameter optimization via cuckoo optimization algorithm of fuzzy controller for liquid level control”, *Journal of Engineering*, article ID 982354, 2013
- [24] A. A. El-Fergany e A. Y. Abdelaziz, “Capacitor allocations in radial distribution networks using cuckoo search algorithm”, *IET Generation, Transmission & Distribution*, vol. 8, ISS. 2, pp. 223–232, 2014.
- [25] M. Khodier, “Optimisation of antenna arrays using the cuckoo search algorithm”, *IET Microwaves, Antennas & Propagation*, vol. 7, ISS. 6, pp. 458–464, 2013.

- [26] W. C. E. Lim, “G. Kanagaraj e S. G. Ponnambalam, PCB drill path optimization by combinatorial cuckoo search algorithm”, *The Scientific World Journal*, article ID 264518, 2014.
- [27] X. S. Yang e S. Deb, “Multiobjective cuckoo search for design optimization”, *Computers and Operations Research*, vol. 40, pp 1616-1624, 2011.
- [28] C. C. Chen, “Transmission of microwave through perforated flat plates of finite thickness”, *IEEE Trans. Microwave Theory Tech.*, vol. MTT-21, pp. 1-6, 1973.
- [29] P. H. F. Silva, A. F. dos Santos, R. M. S. Cruz and A. G. D’Assunção, “Dual-band bandstop frequency selective surfaces with gosper prefractal elements”, *Microwave and Optical Technology Letters*, vol. 54, no. 3, 2012.
- [30] C. C. Chen, “Transmission through a conducting screen perforated periodically with apertures”, *IEEE Trans. Microwave Theory Tech.*, vol. MTT-18, pp. 627-632, 1970.
- [31] G. A. Cavalcante, A. G. D’Assunção Jr. and A. G. D’Assunção, “An iterative full-wave method for designing bandstop frequency selective surfaces on textile substrates”, *Microwave and Optical Technology Letters*, vol. 56, no. 2, 2014.
- [32] S. W. Lee, G. Zarrillo e C. L. Law, “Simple formulas for transmission through periodic metal grids or plates”, *IEEE Trans. on Antennas and Propagation*, vol. 30, n. 5, pp. 904-909, 1982.
- [33] S. W. Lee, “Scattering by dielectric-loaded screen”, *IEEE Trans. Antenna Propagat.*, vol. AP-19, pp. 656-665, 1971.
- [34] B. A. Munk, R. J. Luebbers, and R. D. Fulton, “Transmission through a two-layer array of loaded slots”, *IEEE Trans. Antennas Propagat.*, vol. AP-22, pp. 804-809, 1974.
- [35] R. M. S. Cruz, “Análise e otimização de superfícies seletivas de frequência utilizando redes neurais artificiais e algoritmos de otimização natural”, Tese de Doutorado, Universidade Federal do Rio Grande do Norte, Rio Grande do Norte, Brasil, 2009.

- [36] Y. Rikuta and R. Kohno, “Planar monopole antenna with dual frequency for UWB system”, IEEE Conference on Ultra Wideband Systems and Technologies, pp. 176–179, 2003.
- [37] T. H. Otani, K. R. A. B. Pacheco, A. G. Amorim, J. F. Almeida, “Estudo do efeito pelicular em antenas dipolo”, SBrT, Recife-PE, 2007.
- [38] N. P. Agrawall, G. Kumar and K. P. Ray, “Wide-band planar monopole antennas”, IEEE Antennas Propagation, vol. 46, no.2, pp. 294-295, 1998.
- [39] T. K. Wu, “Frequency selective surface and grid array”, Jonh Wiley & Sons, New York, E.U.A., 1995.
- [40] A. L. P. S. Campos, “Análise do espalhamento em superfícies seletivas em frequência com multicamadas dielétricas anisotrópicas”, Tese de Doutorado, UFPB, 2002.
- [41] A. C. C. Lima, E. A. Parker e R. J. Lagley, “Tunable frequency selective surfaces using liquid substrate”, Electron Lett., pp. 281–282, 1994.
- [42] G. Y. Li, Y. C. Chan, T. S. Mok e J. C. Vardaxoglou, “Analysis of frequency selective surfaces on biased ferrite substrate”, Antennas and Propagation Society International Symposium, vol. 3, pp. 1636–1639, 1955.
- [43] T. K. Chang, R. J. Langley and E. A. Parker, “Frequency selective surfaces on biased ferrite substrate”, Electron Lett., pp. 1193–1194, 1994.
- [44] G. Marconi and C.S. Franklin, “Reflector for use in wireless telegraphy and telephony”, US Patent 1.301.473, 1919.
- [45] T. A. Cwik and R. Mittra, “Scattering from a periodic array of free-standing arbitrary shaped perfectly conducting or resistive patches”, IEEE Transactions on Antennas and Propagation, vol. AP-35, no. 11, 1987.

- [46] C. C. Chen, "Scattering by a two-dimensional periodic array of narrow plates", *Radio Sci.* 2 (11), pp. 1347 – 1359, 1967.
- [47] R. Cahill, E. A. Parker, "Concentric ring and Jerusalem cross arrays as frequency selective surfaces for a 45° incidence diplexer", *Electronic Letters*, vol. 18, no. 8, pp. 313-314, 1982.
- [48] E. A. Parker, S. M. A. Hamdy, R. J. Langley, "Modes of resonance of the Jerusalem cross in frequency selective surfaces", *IEE Proceedings*, Pt. H, vol. 130, no. 3, pp. 203-208, 1983.
- [49] J.C. Vardaxoglou, E.A. Parker, "Performance of two tripole arrays as frequency selective surfaces", *Electronics Letters*, vol. 19, no. 18, pp. 709- 710, 1983.
- [50] P. W. B. Au, L. S. Musa, E. A. Parker, R. J. Langley, "Parametric study of tripole and tripole loop arrays as frequency selective surfaces", *IEE Proceedings Pt. H*, vol. 137, no. 5, pp. 263-268, 1990.
- [51] M. M. Mokhtar, E. A. Parker, "Conjugate gradient computation of the current distribution on a tripole FSS array element", *Electronic Letters*, vol. 26, no. 4, pp. 227-228, 1990.
- [52] R. Cahill, E.A. Parker, "Performance of millimetre-wave frequency selective surfaces in large incident angle quasi-optical systems", *Electronic Letters*, vol. 28, no. 8, pp. 788-789, 1992.
- [53] T. K. Wu, "Four-Band frequency selective surface with double-square-loop patch elements", *IEEE Transactions on Antennas and Propagation*, vol. 42, no. 12, pp. 1659-1663, 1994.
- [54] J. Romeu, Y. Rahmat-Samii, "Fractal FSS: a novel dual-band frequency selective surface", *IEEE Transactions on Antennas and Propagation*, vol. 48, no. 7, 2000.
- [55] E. A. Parker, A. N. A. El Sheikh, "Convolutated array elements and reduced size unit cells for frequency selective surfaces", *IEE Proceedings-H*, vol. 138, no. 1, pp. 19-22, 1991.
- [56] K. Deb, "Multi-objective optimization using evolutionary algorithms", Chichester, UK: John Wiley & Sons, 2001.

- [57] H. Mo, Z. Xu, L. Xu, Z. Wu and H. Ma, “Constrained multiobjective biogeography optimization algorithm”, *The Scientific World Journal*, vol. 2014, article ID 232714, 2014.
- [58] V. Pareto, *Cours d'Economie Politique*, Rouge, 1886.
- [59] S. Haykin, *Neural networks and learning machines*, Prentice-Hall, 2009.
- [60] D. F. Specht, “A general regression neural network”, *IEEE Transactions on Neural Networks*. vol. 2, no. 6, 1991.
- [61] E. A. Nadaraya, “On estimating regression”, *Theory of Probab. Applicat.*, vol. 9, pp. 141–142, 1964.
- [62] G. S. Watson, “Smooth regression analysis”, *Sankhya Series A*, vol. 26, pp. 359–372, 1964.
- [63] L. P. Devroye and L. Györfi, “Nonparametric density estimation: the L_1 view”, U.K.: Wiley, 1983.
- [64] R. L. Eubank, “Spline smoothing and nonparametric regression”, New York and Basel: Marcel Dekker, 1988.
- [65] L. Rutkowski, “Sequential estimates of probability densities by orthogonal series and their application in pattern classification”, *IEEE Trans. Syst., Man, Cybern.*, vol. SMC-10, no. 12, pp. 918–920, 1980.
- [66] L. Rutkowski, “Sequential estimates of a regression function by orthogonal series with applications in discrimination”, in *Lectures Notes in Statistics*, vol. 8. New York, pp. 236–244, 1981.
- [67] 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.

[68] D. F. Specht, “Probabilistic neural networks”, *Neural Networks*, vol. 3, pp. 109 – 118, 1990.

[69] J. H. Holland, “Adaptation in natural and artificial systems”, University of Michigan Press: Ann Arbor, MI, 1975.

[70] D. E. Goldberg, “Genetic algorithms in search, optimization and machine learning”, Addison-Wesley, 1989.

[71] J. P. L. Araújo, “Estratégia de planejamento e otimização de sistemas sem fio, considerando redes interferentes: abordagem baseada em cross-layer”, Tese de Doutorado, Universidade Federal do Pará / PPGEE, Belém, 2011.

[72] R. B. Payne, M. D. Sorenson and K. Klitz,” *The cuckoos*”, Oxford University Press, 2005.

[73] X. S. Yang, S. Deb, “Cuckoo search: recent advances and applications”, *Neural Comput & Applic*, London, 2013.

[74] I. Pavlyukevich, “Lévy flights, non-local search and simulated annealing”, *Journal of Computational Physics*, vol. 226, pp 1830-1844, 2007.

[75] N. E. Humphries et al., “Environmental context explains Lévy and Brownian movement patterns of marine predators”, *Nature* 465, 1066–1069, 2010.

[76] X. S. Yang, S. Deb, “Engineering optimization by cuckoo search”, *Int J Math Modelling Num. Opt.* 2010, 1(4):330–43.

[77] X. S. Yang, “Engineering optimization: an introduction with metaheuristic applications”, John Wiley and Sons, 2010.

- [78] M. R. Silva, “Otimização de superfícies seletivas de frequência com elementos pré-fractais utilizando rede neural MLP e algoritmos de busca populacional”, Tese de Doutorado, Universidade Federal do Rio Grande do Norte, Rio Grande do Norte, Brasil, 2013.
- [79] Xin-She Yang, *Nature-Inspired Metaheuristic Algorithms* 2th edition, Luniver Press, 2010.
- [80] C. M. Su, L. C. Chou, C. I. Lin, K. Lu Wong, “Embedded DTV antenna for laptop application”, *IEEE Antennas and Propagation Society International Symposium*, vol. 4B, pp. 68 – 71, 2005.
- [81] L. C. Esteves, *Antenas Teoria Básica e Aplicações*, McGraw-Hill, 1980.
- [82] C. M. M. Fonseca, “Multiobjective genetic algorithms with application to control engineering problems”, *Doctorate Thesis*, The University of Sheffield, Department of Automatic Control and Systems Engineering, United Kingdom - UK, 1995.
- [83] R.N. Mantegna, “Fast, accurate algorithm for numerical simulation of Levy stable stochastic processes”, *Phys. Rev. E*, 49, (5), pp. 4677–4683, 1994.