



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
DE COMPUTAÇÃO



Pesquisa e Desenvolvimento de uma Nova Técnica de Síntese de Circuitos Planares Ativos de Micro-ondas

Patric Lacouth da Silva

Orientador: Prof. Dr. Adaildo Gomes D'Assunção

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

Número de ordem PPgEEC: D239

Natal, RN, Março de 2019

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Silva, Patric Lacouth da.

Pesquisa e desenvolvimento de uma nova técnica de síntese de circuitos planares ativos de micro-ondas / Patric Lacouth da Silva. - 2019.

111 f.: il.

Tese (doutorado) - Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Natal, RN, 2019.

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

1. Antenas - Tese. 2. Otimização baseada em enxame de abelhas - Tese. 3. Superfícies seletivas em frequência - Tese. 4. Estruturas reconfiguráveis - Tese. I. D'Assunção, Adaildo Gomes. II. Título.

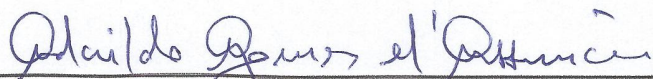
RN/UF/BCZM

CDU 621.396.67

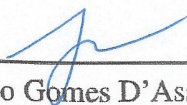
Pesquisa e Desenvolvimento de uma Nova Técnica de Síntese de Circuitos Planares Ativos de Micro-ondas

Patric Lacouth da Silva

Tese de Doutorado aprovada em 14 de Março de 2019 pela banca examinadora composta pelos seguintes membros:



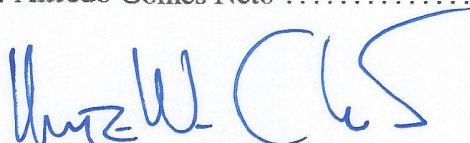
Prof. Dr. Adaildo Gomes D'Assunção (orientador) UFRN



Prof. Dr. Adaildo Gomes D'Assunção Júnior IFPB



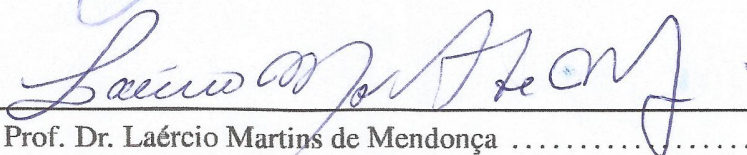
Prof. Dr. Alfrêdo Gomes Neto IFPB



Prof. Dr. Hertz Wilton de Castro Lins UFRN



Prof. Dr. José Alfredo Ferreira Costa UFRN



Prof. Dr. Laércio Martins de Mendonça UFRN

À Giovanna Weizel

Agradecimentos

À minha família pelo apoio durante esta jornada.

Ao meu orientador, professor Adaildo, sou grato pela orientação.

Aos professores do IFPB Alfrêdo Gomes e Emmanuel Dupouy pela ajuda nas medições dos protótipos no laboratório GTEMA/IFPB.

Aos demais colegas de pós-graduação, pelas críticas e sugestões.

À CAPES e ao IFPB, pelo apoio financeiro.

Resumo

O trabalho desenvolvido nesta tese tem como objetivo principal contribuir para o desenvolvimento de estruturas reconfiguráveis através da aplicação de técnicas de otimização inspiradas no comportamento de enxames de abelhas. Uma vasta revisão bibliográfica é realizada de forma a estabelecer os principais conceitos relacionados a estruturas de micro-ondas reconfiguráveis e algoritmos de otimização. Um conjunto de resultados é apresentado ao longo do trabalho discutindo as dificuldades e as soluções propostas para cada problema. Por fim é apresentada uma nova técnica de síntese de circuitos planares de micro-ondas, capaz de oferecer novos resultados e maior eficiência comparada as técnicas similares. Resultados simulados e medidos são obtidos certificando a precisão dos projetos desenvolvidos.

Palavras-chave: Otimização Baseada em Enxame de Abelhas, Antenas, Superfícies Seletivas em Frequência, Estruturas Reconfiguráveis.

Abstract

The work developed in this thesis has as main objective to contribute to the development of reconfigurable structures through the application of optimization techniques inspired by bee swarm behavior. An extensive literature review is conducted in order to establish the main concepts related to reconfigurable microwave structures and optimization algorithms. A set of results is presented discussing the difficulties and the solutions proposed for each problem. Finally, a new technique for the synthesis of planar microwave circuits is presented, capable of offering new results and greater efficiency compared to similar techniques. Simulated and measured results are obtained ensuring the accuracy of the developed projects.

Keywords: Bee Swarm Optimization, Antennas, Frequency Selective Surfaces, Reconfigurable Structures.

Sumário

Sumário	i
Lista de Figuras	v
Lista de Tabelas	ix
Lista de Símbolos e Abreviaturas	xi
1 Introdução	1
1.1 Organização do texto	4
2 Rádios Definidos por <i>Software</i> e Rádios Cognitivos	5
2.1 Rádio Definido por <i>Software</i>	5
2.2 Rádio Cognitivo	6
2.3 Antenas Reconfiguráveis	9
2.4 Superfícies Seletivas de Frequência	11
2.5 Modelos iniciais	14
2.5.1 Proposta de antena multibanda	14
2.5.2 Proposta de antena reconfigurável	15
2.5.3 Proposta de FSS reconfigurável	16
3 <i>Particle Swarm Optimization</i>	19
3.1 O processo de otimização	19
3.2 O Otimizador	19
3.2.1 A linguagem do PSO	20

3.2.2	PSO versus AG	22
3.2.3	O algoritmo	23
3.2.4	Descrição do algoritmo PSO	25
3.3	PSO - Binário	27
3.3.1	BPSO - Implementação	27
3.4	A função <i>fitness</i>	30
3.5	Otimização Multiobjetivo	32
3.5.1	Estratégia da soma ponderada	32
3.5.2	Estratégia dos múltiplos enxames	33
3.5.3	A fronteira de Pareto	33
3.6	O otimizador híbrido	34
4	O PSO e Antenas	37
4.1	Projeto de uma antena multibanda	38
4.1.1	Otimização das frequências de ressonância	39
4.2	Projeto de antena reconfigurável	43
4.3	Otimização da frequência de ressonância e do ganho	47
4.3.1	O Algoritmo VEPSO	47
4.3.2	Antena de microfita suspensa	49
5	Contribuição para o <i>Particle Swarm Optimization</i>	55
5.1	HPSO com zona negativa	55
5.2	Aplicação do algoritmo HPSO-NZ	62
5.2.1	Antena <i>Dual-Band</i>	62
5.2.2	Antena <i>Tri-Band</i>	66
5.2.3	Antena reconfigurável	67
6	O HPSO-NZ e Superfícies Seletivas de Frequência	71

6.1	Superfícies Seletivas de Frequência	71
6.1.1	Estruturas Reconfiguráveis	72
6.1.2	Projeto de uma FSS reconfigurável	74
7	Conclusões	81
	Referências bibliográficas	84

Lista de Figuras

2.1	Diferenças entre os modos de entrelaçamento e sobreposição de espectro .	8
2.2	Exemplo do protótipo de uma antena diretiva utilizando FSS	13
2.3	Exemplo da célula de uma FSS ativa	13
2.4	Exemplo do modelo de antena multibanda proposto	14
2.5	Exemplo do modelo de antena reconfigurável proposto	16
2.6	Exemplo da proposta para uma FSS reconfigurável	17
3.1	Ilustração gráfica do mecanismo de atualização da partícula	25
3.2	Função Sigmoid intermediária	29
4.1	Fluxograma de implementação do algoritmo de otimização	38
4.2	Ilustração do mecanismo de identificação e correção de conexões diagonais	39
4.3	Antena base para a otimização	40
4.4	Evolução do BPSO ao longo das iterações.	41
4.5	Geometria obtida pelo algoritmo.	41
4.6	Resultado simulado do S_{11} para a geometria apresenta na Figura 4.5. . . .	42
4.7	Ganho simulado para a antena da Figura 4.5 na frequência de 2,4GHz . . .	42
4.8	Ganho simulado para a antena da Figura 4.5 na frequência de 1,8GHz . . .	43
4.9	Exemplo do modelo de antena reconfigurável proposto	44
4.10	Geometria obtida para uma antena reconfigurável	45
4.11	Comparação entre o resultado simulado e medido da antena reconfigurável	45
4.12	Protótipo da antena reconfigurável	46
4.13	Geometria Obtida pelo Algoritmo para a segunda otimização.	48

4.14	Resultado simulado do S_{11} para a geometria apresenta na Figura 4.13. . . .	48
4.15	Ganho Simulado para a antena da Figura 4.13 na frequência de 2,4 GHz .	49
4.16	Ganho Simulado para a antena da Figura 4.13 na frequência de 1,8 GHz .	49
4.17	<i>Layout</i> da estrutura de uma antena suspensa.	50
4.18	Geometria final obtida pelo BPSO.	51
4.19	Protótipo com a configuração obtida	52
4.20	Comparação entre os valores medido e simulados para a antena suspensa.	52
4.21	(a) Simulação do ganho em 1.8 GHz e (b) Simulação do ganho em 2.4 GHz.	53
5.1	Representação de um enxame em busca da melhor solução em um espaço bidimensional. Os círculos cinzas ilustram as possíveis zonas negativas onde as partículas são repelidas. O X simboliza o objetivo da otimização.	57
5.2	Topologia bidimensional da função Rastrigin	57
5.3	Histograma das soluções encontradas pelo HSPO em 200 testes independentes	59
5.4	Histograma das soluções encontradas pelo HSPO-NZ em 200 testes independentes	59
5.5	Comparação entre as médias das melhores partículas em 200 testes independentes para HPSO-NZ, HPSO , BPSO, BGA e RPSO para a solução da função Rastrigin	60
5.6	Geometria da antena suspensa	62
5.7	Configuração interna de <i>patches</i> obtida pelo HPSO para uma antena multibanda (1.8 GHz/2.4 GHz)	64
5.8	Configuração interna de <i>patches</i> obtida pelo HPSO-NZ para uma antena multibanda (1.8 GHz/2.4 GHz)	64
5.9	Comparação entre a evolução do g_{best} ao longo da otimização para os algoritmos HPSO e HPSO-NZ	65

5.10	Resultado simulado do parâmetro S_{11} para as configurações obtidas pelos algoritmos HPSO e HPSO-NZ	65
5.11	Configuração interna de <i>patches</i> obtida pelo HPSO-NZ para antena multibanda (1.8 GHz/2.4 GHz/3.5 GHz)	66
5.12	Resultado simulado para antena multibanda (1.8 GHz/2.4 GHz/3.5 GHz) obtida pelo HPSO-NZ	67
5.13	Configuração interna de <i>patches</i> obtida pelo HPSO-NZ para antena reconfigurável (1.8 GHz/2.4 GHz)	68
5.14	Simulação do parâmetro S_{11} da geometria da Figura 5.14	68
6.1	Célula básica de uma FSS reconfigurável e as respostas simuladas	73
6.2	Conceito de um <i>patch</i> binário de FSS	73
6.3	Configuração de <i>patches</i> internos para a otimização em 7 GHz.	75
6.4	Resultados simulados e medidos do coeficiente de transmissão para a FSS otimizada em 7 GHz	75
6.5	Foto do protótipo da FSS otimizada em 7GHz	76
6.6	Configuração de <i>patches</i> internos para a otimização em 3 GHz.	77
6.7	Resultados simulados e medidos do coeficiente de transmissão para a FSS otimizada em 3 GHz	78
6.8	Setup de medição utilizado para a medição das FSS	79

Lista de Tabelas

2.1	Possíveis especificações para RDS	5
2.2	Propriedades elétricas dos elementos de chaveamento	12
3.1	Principais parâmetros de implementação do HPSO	35
5.1	Comparação entre 6 algoritmos para otimização da Função Rastrigin - (10 agentes, 200 iterações, 200 testes)	60
5.2	Comparação entre 6 algoritmos para otimização da Função Rastrigin - (20 agentes, 500 iterações, 200 testes)	61
5.3	Comparação entre os algoritmos HPSO e HPSO-NZ para otimização da Função Rastrigin - (10 agentes, 1000 testes)	61
5.4	Comparação entre os algoritmos HPSO e HPSO-NZ para otimização da Função Rastrigin - (15 agentes, 1000 testes)	62
5.5	Parâmetros da Antenna	63
6.1	Principais parâmetros de implementação do HPSO-NZ	74

Lista de Símbolos e Abreviaturas

G_i :	Ganho intrínseco
G_r :	Ganho real
S :	Parâmetro de espalhamento
ϵ_{eff} :	Constante dielétrica efetiva
η :	Constante aleatória
\mathbf{G} :	Matriz do g_{best} do enxame
\mathbf{P} :	Matriz dos p_{best} do enxame
\mathbf{V} :	Matriz de velocidade das partículas
\mathbf{X} :	Matriz das posições atuais das partículas do enxame
c_1 :	Constante de influência do p_{best}
c_2 :	Constante de influência do g_{best}
g_{best} :	<i>Global Best</i>
p_{best} :	<i>Personal Best</i>
$\tan \delta$:	Tangente de perdas do meio
w :	Peso inercial
AG:	Algoritmo Genético

BPSO: *Binary Particle Swarm Optimization*

CDMA: *Code Division Multiple Access*

COM: *Component Object Model*

FM: *Frequency Modulation*

FSS: *Frequency Selective Surfaces*

GPS: *Global Positioning System*

GSM: *Global System for Mobile Communications*

HFSS: *High Frequency Electromagnetic Field Simulation*

HPSO-NZ: *Hybrid Particle Swarm Optimization with Negative Zones*

HPSO: *Hybrid Particle Swarm Optimization*

ISM: *Industrial, Scientific and Medical radio bands*

LNA: *Low Noise Amplifier*

PSO: *Particle Swarm Optimization*

RDS: *Rádio Definido por Software*

RF-MEMS: *Radio-Frequency MicroElectroMechanical Systems*

RF: *Rádio Frequência*

UWB: *Ultra-wideband*

WiFi: *Wireless Fidelity*

WLAN: *Wireless Local Area Network*

WRAN: *Wireless Rural Area Network*

Capítulo 1

Introdução

Os sistemas de comunicação sem fio estão evoluindo para uma nova geração de plataformas multi-funcionais que oferecem serviços de alta qualidade que demandam uma alta taxa de transmissão de dados como aplicações de GPS, transmissões de vídeo e áudio, internet e outras. Todos esses serviços necessitam do desenvolvimento de dispositivos e circuitos capazes de se adaptar a diferentes condições de taxa de transmissão, interferências e desvanecimento (Habib et al. 2009).

Rádio definido por software e rádio cognitivo são dois conceitos novos em comunicações sem fio que irão mudar a forma que sistemas de rádio são projetados e operados (Hall et al. 2012).

O sistema de rádio cognitivo na sua essência irá requerer o desenvolvimento de dispositivos como antenas, filtros e redes de alimentação que sejam capazes de operar em diferentes faixas frequências e intensidade. Quando implementado para ser utilizado nas faixas de frequências já em operação, exige equipamentos que possam detectar e operar nas “zonas brancas”, ou seja, frequências que estejam livres em determinado momento (Tawk et al. 2014*b*). Sendo a reconfiguração de uma antena obtida através da mudança deliberada da sua frequência de operação, da sua polarização ou das suas características de irradiação (Christodoulou et al. 2012), essa mudança pode ser obtida por diversas técnicas que redistribuem a corrente sobre a antena, permitindo alterar os campos eletromagnéticos produzidos pela antena.

O processo de projeto e desenvolvimento de antenas reconfiguráveis requer a integração apropriada de vários componentes na estrutura da antena, como RF-MEMS (*Radio-Frequency MicroElectroMechanical Systems*), diodos PIN, *varicaps*, dentre outros, na superfície irradiante da antena ou no seu circuito de alimentação. Isso se apresenta como um desafio uma vez que é necessário considerar durante a fase de projeto todas as influências causadas pelos componentes de chaveamento e pelas suas trilhas de ativação na resposta final da antena (Tawk et al. 2014b).

Tipicamente, antenas são projetadas através da modificação de projetos e geometrias existentes e em geral envolvem um processo de “tentativa e erro” para obter os resultados desejados. No entanto, para resolver os desafios e requisitos apresentados por esses sofisticados sistemas de comunicação sem fio, existe a necessidade de desenvolver novas soluções e estratégias para o projeto de antenas e dispositivos de radiofrequência. Uma das abordagens mais promissoras propostas para resolver esse tipo de problema de uma maneira sistemática é a integração de *softwares* de análise eletromagnética, como o Ansys HFSS, com diferentes técnicas de otimização (Rahmat-Samii et al. 2012).

A otimização através do enxame de partículas (*Particle Swarm Optimization - PSO*) tem se mostrado efetiva na otimização de problemas multidimensionais em uma grande variedade de áreas (Eberhart & Shi 2001). Em meados de 2002, essa técnica foi aplicada com sucesso ao projeto de antenas (Robinson et al. 2002). Além disso, essa técnica estocástica de computação bioinspirada, baseada no movimento e inteligência de enxames, mostrou em determinadas situações um desempenho superior comparada a outras técnicas de otimização como Algoritmos Genéticos (Kennedy & Spears 1998).

Desenvolvido em 1995 por Kennedy e Eberhart (Kennedy & Eberhart 1995), o PSO pode ser compreendido através de uma analogia similar aquela que levou ao seu desenvolvimento. Imagine um enxame de abelhas em um campo. O seu objetivo é encontrar no campo a localização com maior densidade de flores. Sem qualquer conhecimento anterior do campo, as abelhas começam em locais aleatórios com velocidades aleatórias a

procurar por flores. Cada abelha consegue lembrar a localização que ela encontrou mais flores, e de alguma forma ela conhece os locais onde as outras abelhas encontraram mais flores. Dividida entre retornar ao local onde ela própria encontrou mais flores, ou explorar os locais com mais flores relatados pelas outras abelhas, a obstinada abelha acelera nas duas direções alterando a sua trajetória para voar para algum lugar entre os dois pontos, dependendo se a nostalgia ou a influência social domina a sua decisão. Ao longo da sua caminhada, uma abelha pode encontrar um local com uma maior concentração de flores do que ela havia descoberto até aquele momento. Ela então se sentirá atraída para essa nova localização ao mesmo tempo que é atraída para a posição com mais flores descoberta pelo enxame (Kennedy & Eberhart 1995).

Ocasionalmente, uma abelha irá encontrar um local com mais flores do que qualquer outro local já encontrado pelas outras abelhas. O enxame por completo será então atraído para essa nova localização, bem como para cada descoberta pessoal. Dessa forma as abelhas exploram o campo: sobrevoam locais com uma maior concentração de flores, então passam a ser atraídas em direção por esses locais. Constantemente, as abelhas verificam o território que elas estão sobrevoando em comparação com o território previamente encontrado com maior concentração de flores, com a esperança de encontrar a maior concentração absoluta de flores. Eventualmente, o voo das abelhas irá levar elas para o local no campo com maior concentração de flores.

Na tentativa de modelar esse comportamento, Kennedy e Eberhart (Kennedy & Eberhart 1995), perceberam que tinham encontrado um algoritmo otimizador. Nas próximas seções são apresentadas a linguagem usada no PSO, uma explicação detalhada do algoritmo, a importância de alguns parâmetros, discussão sobre versões híbridas do algoritmo, apresentação um uma contribuição para o algoritmo PSO e exemplos de otimizações efetuadas em circuitos de micro-ondas.

Algoritmos de otimização como o PSO (*Particle Swarm Optimization*), Algoritmos Genéticos e Redes Neurais Artificiais, dentre outros, têm sido largamente utilizados para

o projeto e desenvolvimento de estruturas passivas na faixa de frequência de micro-ondas (Jin & Rahmat-Samii 2007) (da Silva et al. 2007).

A proposta deste trabalho é apresentar uma metodologia de projeto de antenas e estruturas de micro-ondas que seja flexível e capaz de atender os requisitos necessários para o desenvolvimento de sistemas de rádios cognitivos.

1.1 Organização do texto

O Capítulo 2 apresenta os conceitos básicos de rádios definidos por *software* e a possibilidade de usar essa plataforma para o desenvolvimento de sistemas de rádios cognitivos. Esse capítulo mostra ainda a importância de estruturas de micro-ondas reconfiguráveis e apresenta a proposta de três novos dispositivos.

No Capítulo 3 são explicados os algoritmos escolhidos para criar o processo de otimização dos dispositivos de micro-ondas necessários para a operação de um sistema de comunicação baseado em rádios cognitivos.

O Capítulo 4 apresenta os resultados preliminares obtidos do processo de otimização apresentado no Capítulo 3 aplicado sobre as estruturas propostas, incluindo os resultados da construção de protótipos e as suas medições.

Com os resultados e conhecimento consolidado dos Capítulos 3 e 4 o Capítulo 5 apresenta uma nova contribuição ao desenvolvimento e aplicação do algoritmo PSO em estruturas de micro-ondas.

Dando continuidade a aplicação dos conceitos desenvolvidos, o Capítulo 6 introduz otimizações de Superfícies Seletivas de Frequência ativas, incluindo a simulação e medição de protótipos para o uso ao longo da faixa de frequência de sistemas UWB.

No Capítulo 7 são feitas as considerações finais sobre a tese e os trabalhos futuros.

Capítulo 2

Rádios Definidos por *Software* e Rádios Cognitivos

2.1 Rádio Definido por *Software*

O Rádio definido por *software* (RDS) é uma tecnologia concebida para desenvolver sistemas de rádio flexíveis, de múltiplos padrões, com multibanda, reconfigurável e programável por *software* (Buracchini 2000).

A flexibilidade de um sistema de rádio definido por *software* consiste na sua capacidade de operar em um ambiente de múltiplos serviços, sem estar limitado a um padrão em particular, mas ser capaz de oferecer, em teoria, serviços de qualquer outra padronização.

Não há ainda nenhum padrão para a utilização de RDS, mas possíveis especificações já foram sugeridas. A Tabela 2.1 (Hall et al. 2012) apresenta uma lista de parâmetros para RDS.

Tabela 2.1: Possíveis especificações para RDS

Parâmetro	Especificações
Banda de frequência de rádio	100 MHz até 2.2 GHz
Largura do canal	<8MHz
Potência de transmissão	<1 Watt

O parâmetro de maior interesse para o projeto de antenas é com certeza a faixa de frequência, que aproximadamente cobre a faixa de FM, de rádio amador, de transmis-

6 CAPÍTULO 2. RÁDIOS DEFINIDOS POR SOFTWARE E RÁDIOS COGNITIVOS

são de TV e faixas de telefonia celular. É possível que sejam incluídas as faixas ISM (Indústria, Ciência e Médica) usadas por WiFi e outras aplicações. Contudo, devido a regulamentações sobre a utilização do espectro RDS pode ser obrigado a operar em faixas mais estreitas.

A possibilidade de ser ter RDS operando em uma banda de frequência ultra-larga ser torna atrativa por cobrir diversos padrões, incluindo GSM, CDMA, WLAN, Bluetooth, UWB e etc. Mas para se obter tal sistema, projetar um amplificador de baixo ruído (LNA) com largura de banda suficiente, com alta linearidade e baixa potência é uma tarefa crítica e desafiadora (Lou & Luong 2008), pois sérios problemas ainda são encontrados com relação a ruído e distorção causados pela banda larga do sistema. Além disso, antenas para cobrir toda a banda de frequências desejada dificilmente podem ser incorporadas em aparelhos portáteis e mesmo em estações fixas.

Por isso, antenas reconfiguráveis em frequência capazes de oferecer uma largura de banda limitada mas instantânea podem ser uma solução viável, reduzindo os problemas de ruído e distorção. O desejo de evitar o uso de filtros convencionais sugere que a pesquisa em antenas reconfiguráveis é vital para o desenvolvimento de sistemas RDS (Hall et al. 2012).

2.2 Rádio Cognitivo

Os rádios cognitivos são vistos como uma nova abordagem para melhorar a utilização do espectro de frequências eletromagnéticas. O rádio cognitivo, construído a partir de rádios definidos por *software*, é definido como um sistema de comunicação sem fio que é consciente do seu ambiente e é capaz de aprender e se adaptar as variações estatísticas do canal de comunicação, com dois objetivos principais (Haykin 2005):

- Comunicação confiável independente da situação;
- Eficiente utilização do espectro eletromagnético;

De acordo (Axell et al. 2012) diversas medições do espectro de frequências em áreas urbanas mostram subutilização de recursos espectrais como frequência, espaço e tempo. O conceito por trás dos rádios cognitivos é exatamente explorar esses recursos subutilizados através do reuso de espectro livre de uma forma oportunista.

A necessidade de reconfiguração em sistemas de rádio cognitivo é provida pela capacidade de adaptação dos rádios definidos por *software*, por isso os RDS servem como plataforma de implementação para os sistemas de rádio cognitivo.

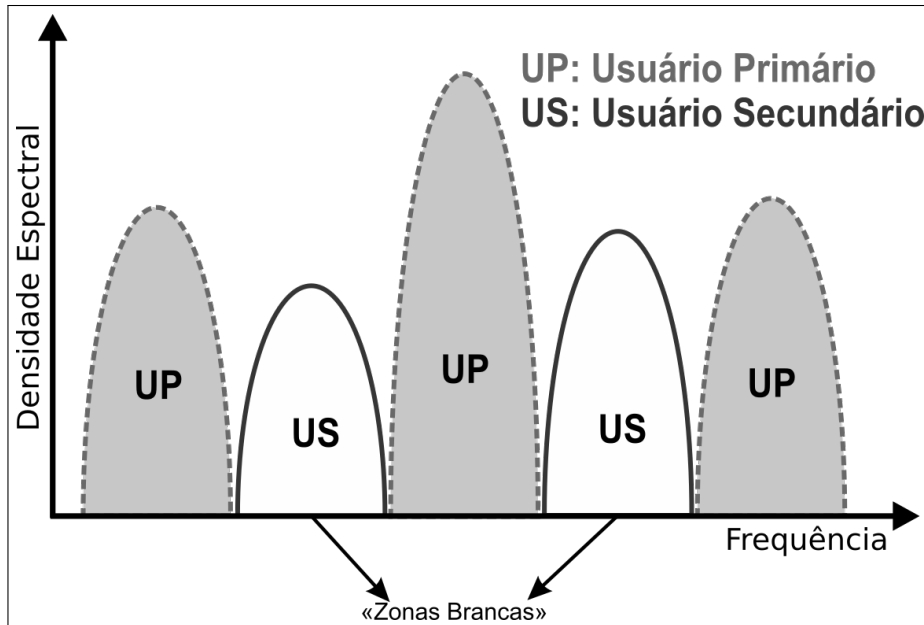
Uma das principais características dos rádios cognitivos é a sua capacidade de aprender a partir de experiências anteriores e da atividade do canal e se adaptar baseado nessa informação. Dessa forma, o objetivo no projeto de sistemas de rádio cognitivo é criar um sistema autônomo que monitora o canal, decide e aprende. Isso vai garantir que o sistema opere no modo mais adequado de forma a obter eficiência de potência e eficiência espectral em condições diversas (Tawk et al. 2014b).

Atualmente o único padrão estabelecido para rádio cognitivos é o IEEE 802.22, *Wireless Rural Area Network* (WRAN), que opera na faixa entre 52 MHz e 862 MHz, faixa utilizada para transmissão de TV. O padrão IEEE 802.22 visa compartilhar a faixa de TV, como um usuário secundário, para distribuir acesso a internet para comunidades rurais.


Como apresentado em (Haykin 2005) existem duas formas de implementação de um sistema de rádios cognitivos: o entrelaçamento ou a sobreposição de espectro.

No modo de entrelaçamento de espectro, o rádio cognitivo procura por partes do espectro de frequências que estejam desocupadas (espaços em branco) e transmite sem restrições de potência. Para esses casos, é necessário ter uma antena para monitorar a disponibilidade do espectro. Essa antena é denominada de antena de detecção. Uma segunda antena é então responsável por operar apenas na frequência determinada pela antena de detecção. Essa antena é chamada de antena de comunicação. Portanto, em um sistema de rádio cognitivo é importante identificar os tipos de usuário: o usuário primário que possui acesso garantido ao espectro à qualquer instante e o usuário secundário que

usa o espectro apenas quando o usuário primário está inativo (Tawk et al. 2014b).



(a)



(b)

Figura 2.1: Espectro de potência de um canal em função da frequência para (a) modo de entrelaçamento de espectro e (b) modo de sobreposição de espectro.

Para os sistemas de rádio cognitivo que operam no modo de sobreposição de espectro, os usuários secundários estão livres para transmitir a qualquer momento desde que o seu sinal esteja dentro do nível de interferência suportado pelos usuários primários. Nesses

casos apenas uma antena, com uma largura de banda adequada e capaz de ajustar a sua frequência central, é necessária. Mas esse modo de operação é possível apenas nos casos em que o usuário primário é capaz de suportar a interferência induzida pelo usuário secundário (Haykin 2005) (Tawk et al. 2014b). A Figura 2.1 ilustra os dois modos possíveis de operação de um sistema de Rádio Cognitivo.

Antenas com frequência reconfigurável são essenciais para os dois modos de operação propostos para sistemas de rádios cognitivos. Projetar antenas reconfiguráveis requer a integração de componentes de chaveamento na estrutura da antena. Os componentes mais comuns incorporados às antenas são diodos PIN, RF MEMS e varicaps (Tawk et al. 2014b).

2.3 Antenas Reconfiguráveis

A reconfiguração de uma antena é obtida através da mudança deliberada da sua frequência de operação, da sua polarização ou das suas características de radiação. Essa mudança pode ser conseguida por diferentes técnicas que redistribuem as correntes sobre a antena e então alteram os campos eletromagnéticos da antena.

As antenas reconfiguráveis têm sido estudadas nos últimos anos para o uso em diversas aplicações e quase todas fazem uso de algum tipo de mecanismo de comutação (Christodoulou et al. 2012).

Para o projeto de antenas reconfiguráveis, três importantes questões devem ser consideradas:

1. Qual propriedade reconfigurável precisa ser modificada? (frequência, diagrama de radiação ou polarização).
2. Como os diferentes elementos de radiação são reconfigurados para obter a mudança desejada?

10 CAPÍTULO 2. RÁDIOS DEFINIDOS POR SOFTWARE E RÁDIOS COGNITIVOS

3. Qual técnica de reconfiguração minimiza os efeitos negativos na impedância característica da antena?

Para responder essas questões é necessário saber quais técnicas de reconfiguração são possíveis e relevantes para o projeto as vantagens e desvantagens de cada uma.

Existem algumas técnicas de comutação mais frequentemente utilizadas no projeto de antenas reconfiguráveis. As antenas que utilizam RF-MEMS (*Radio-Frequency Micro-ElectroMechanical Systems*), diodos PIN e varicaps para redirecionar as suas correntes de superfície são denominadas de antenas eletricamente reconfiguráveis, as antenas que dependem de elementos fotocondutivos são chamadas de antenas opticamente reconfiguráveis. Existem projetos de antenas reconfiguráveis que obtêm o efeito de reconfiguração através de uma alteração mecânica na configuração da antena, em geral, movimentando partes móveis da estrutura. E por fim a reconfiguração pode ser obtida através do uso de substratos especiais como ferrites ou cristais líquidos que quando polarizados mudam de características e afetam a resposta de várias características da antena(Tawk et al. 2014a).

Segundo (Christodoulou et al. 2012) antenas reconfiguráveis podem ser classificadas em quatro categorias:

- *Categoria 1:* Uma antena que é capaz de mudar a sua frequência de operação é denominada de antena reconfigurável em frequência. Esse efeito é obtido através de alguma mudança na impedância característica da antena.
- *Categoria 2:* Uma antena capaz de alterar o seu diagrama de radiação. Nessa categoria o diagrama de radiação da antena é alterado em termos de forma, direção ou ganho.
- *Categoria 3:* Uma antena capaz de mudar a sua polarização (esquerda, direita, linear, circular, elíptica e etc.).
- *Categoria 4:* Essa categoria é uma combinação das categorias anteriores. Por exemplo, uma antena reconfigurável em frequência com mudança de polarização

ao mesmo tempo.

A reconfiguração desejada pode ser obtida pela mudança na distribuição de corrente superficial da antena, por uma mudança na alimentação da antena ou qualquer outra mudança na estrutura física da antena, mas é essencial observar que a mudança de um parâmetro pode afetar outros parâmetros da antena. Por isso o projeto de antena reconfiguráveis é mais complexo e deve considerar todas as características da antena em todos os modos de operação.

As antenas reconfiguráveis são parte importante dos futuros sistemas de comunicação, tanto de rádios definidos por *software* ou de rádios cognitivos, mas há um custo envolvido em adicionar características reconfiguráveis em antena. Esses custos podem ser resumidos:

- Projetar um sistema de alimentação para ativar e desativar os componentes responsáveis pela comutação, adicionando complexidade a estrutura da antena.
- Aumentar o consumo de potência por causa da incorporação de componentes ativos, aumentando o custo do sistema.
- Necessidade de rápido chaveamento para assegurar o correto funcionamento do sistema.

A Tabela 2.2 (Christodoulou et al. 2012) mostra as principais características dos elementos de chaveamento que podem ser utilizados no projeto de antenas reconfiguráveis.

2.4 Superfícies Seletivas de Frequência

Na seção anterior as antenas reconfiguráveis foram classificadas em categorias de acordo com o parâmetro que se deseja alterar. Antenas de categoria 4 são dispositivos que possuem mais de um parâmetro sendo controlado, por exemplo uma antena capaz de

Tabela 2.2: Propriedades elétricas dos elementos de chaveamento

Propriedade Elétrica	RF MEMS	Diodo PIN	Chave óptica (Si)
Tensão [V]	20 - 100	1 - 5	1.8 - 1.9
Corrente [mA]	0	3 - 20	0 - 87
Consumo [mW]	0.05 - 0.1	5 - 100	0 - 50
Velocidade de Chaveamento	1 - 200 μ sec	1 - 100 nsec	3-9 μ sec
Isolação [1 - 10 GHz]	Muito Alta	Alta	Alta
Perdas [1-10 GHz] dB	0.05 - 0.2	0.3 - 1.2	0.5 - 1.5

alterar sua frequência de ressonância e ao mesmo tempo controlar o diagrama de radiação. As antenas com essa característica podem ser complicadas de se obter, uma vez que ao mudar a configuração da antena para obter a resposta desejada de um parâmetro pode comprometer o comportamento do segundo parâmetro.

Uma possível solução pode ser alcançada usando a abordagem feita em (Mahmood & Denidni 2014), onde o autor utiliza uma estrutura separada da antena para controlar o diagrama de radiação.

O uso de superfícies seletivas de frequência (FSS - *Frequency Selective Surface*) têm sido explorado em diversas aplicações de comunicação devido ao seu efeito sobre campos eletromagnéticos (Mahmood & Denidni 2014) (da Silva et al. 2007) (Abdelghani et al. 2016). As FSS são estruturas periódicas que atuam como filtros de ondas eletromagnéticas, que são projetados para permitir ou rejeitar a passagem de ondas eletromagnéticas através da sua estrutura.

Devido às suas características as FSS podem ser incorporadas ao projeto de antenas de forma a controlar a direção de radiação da antena. Uma possível estrutura é apresentada em (Mahmood & Denidni 2014). O dispositivo é composto por vários painéis de FSS em volta de uma antena, onde cada painel é ativado de acordo com a direção que se deseja que a antena irradie. A Figura 2.2(Mahmood & Denidni 2014) ilustra a configuração

projetada pelo autor.




Figura 2.2: Exemplo do protótipo de uma antena diretiva utilizando FSS

A ativação de cada painel é feita através da polarização de diodos PIN que compõem cada célula da FSS. Quando ativados os diodos PIN criam uma continuidade na estrutura gerando o efeito de rejeição em uma determinada frequência, quando desativados a célula se torna transparente para a mesma frequência. A Figura 2.3(Habib et al. 2009) ilustra uma célula de uma FSS ativa e o seu funcionamento.

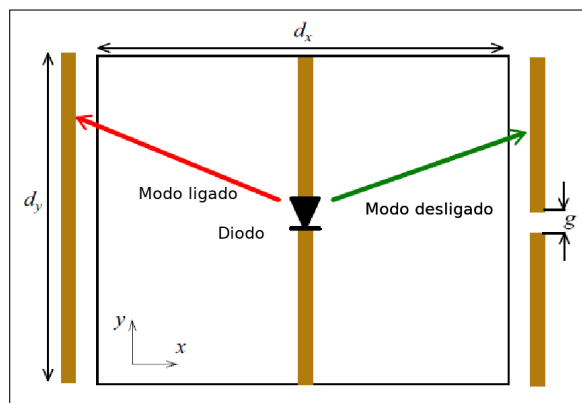


Figura 2.3: Exemplo da célula de uma FSS ativa

O desafio de usar FSS em aplicações de rádios cognitivos está em projetar uma estrutura que atue nas frequências específicas da antena que será utilizada no sistema.

2.5 Modelos iniciais

2.5.1 Proposta de antena multibanda

De acordo com que foi apresentado na Seção 2.2 para implementação de sistemas de rádios cognitivos, especialmente para atuar no modo de entrelaçamento de espectro, são necessárias duas antenas: uma antena de detecção e uma antena de comunicação. A antena de detecção deve ser projetada para monitorar as frequências de interesse do sistema e a partir dessas informações o rádio cognitivo deve tomar a decisão de qual a melhor frequência para a comunicação. Por isso a antena de detecção deve ser uma antena multibanda capaz de cobrir as faixas de interesse. Neste trabalho, a proposta de projeto de uma antena multibanda é inicialmente apresentada através da Figura 2.4.




Figura 2.4: Exemplo do modelo de antena multibanda proposto

Como a frequência de ressonância de cada modo depende principalmente da geometria da antena, o *patch* principal foi subdividido em outros *patches* menores. Dessa forma o algoritmo de otimização pode escolher quais desses *patches* são necessários para criar o casamento de impedância necessário para obter a resposta desejada.

2.5.2 Proposta de antena reconfigurável

A antena de transmissão, para o mesmo modo de operação da Seção 2.5.1 deve ser uma antena reconfigurável, não necessariamente banda larga, para possibilitar a comunicação apenas nas frequências livres descobertas pela antena de detecção. Para o projeto das antena de transmissão uma série de técnicas têm sido empregadas para obter o efeito desejado, como o uso de RF-MEMS, RF *switches*, técnicas de reconfiguração mecânica e diodos PIN (Christodoulou et al. 2012).

De forma a obter uma antena com frequência reconfigurável, a proposta inicial apresentada neste trabalho utiliza uma antena de microfita composta por três *patches* quadrados sobre um substrato de FR4 Epoxy, com $\epsilon_r = 4.4$, separados por quatro diodos PIN com apenas uma alimentação de RF ligada ao *patch* interno, duas linhas de alimentação **Vdc** e uma linha para **GND**, como mostra a 2.5.

Com essa configuração é possível obter dois modos de operação. Um modo **OFF** com os diodos PIN desativados onde a antena ressoa em uma frequência específica f_1 e um segundo modo, denominado de **ON** quando os *patches* externos são alimentados com uma tensão DC maior que 0.8 V através da linha de alimentação **Vdc** e os diodos PIN são ativados e toda a estrutura passa a ressoar em uma nova frequência f_2 .

Seguindo o mesmo conceito de otimização cada um dos *patches* principais foi subdividido em outros *patches* menores para que o algoritmo de otimização decida quais desses *patches* são necessários e quais podem ser descartados de forma a obter a geometria necessária para a antena operar nas frequências desejadas. Em cada um dos três *patches* maiores foi mantido com uma borda fixa para que independente da geometria obtida fosse possível manter a continuidade das trilhas que ativam os diodos PIN.




Figura 2.5: Exemplo do modelo de antena reconfigurável proposto

2.5.3 Proposta de FSS reconfigurável

Para o projeto de superfícies seletivas de frequência reconfiguráveis o modelo da Figura 2.3 foi expandido de forma que seja possível determinar uma geometria dentro da célula básica que cause os efeitos desejados. O modelo para essa estrutura é ilustrado através da Figura 2.6. No modelo proposto a célula básica é dividida em dois *patches* que se conectam quando o diodo PIN é ativado e se separam quando o diodo não é polarizado, gerando assim a possibilidade de reconfiguração.

Para que o algoritmo de otimização seja capaz de determinar a melhor geometria para as frequências desejadas os *patches* também são subdivididos em *patches* menores. A geometria obtida é repetida no restante da estrutura criando uma simetria com relação aos dois eixos. A trilha de ativação do diodo PIN que cruza toda a célula é sempre preservada independente da geometria obtida pelo algoritmo de otimização.




Figura 2.6: Exemplo da proposta para uma FSS reconfigurável

Capítulo 3

Particle Swarm Optimization

3.1 O processo de otimização

Em termos gerais, a otimização pode ser considerada como uma metodologia que requer dois elementos fundamentais: *adaptação* e *propósito*. Rigorosamente, a otimização pode ser definida como uma mudança sistemática, modificação, adaptação de um processo com o objetivo de alcançar um propósito pré-estabelecido. Esse propósito pode ser o máximo ou mínimo numérico de uma função definida pelo usuário. Em outras palavras, otimização envolve conhecer *qual* é o objetivo (maximizar/minimizar uma função) mas desconhecer *como*, o caminho para o objetivo. A resolução prática dessa situação é a essência da pesquisa científica sobre teoria da otimização (Mikki & Kishk 2008).

Baseado nesse conceito, um algoritmo de otimização pode ser definido como um conjunto de instruções que detalham como proceder, a partir de certas condições iniciais, até se alcançar o objetivo final imposto. Um ponto importante é que na maioria das tentativas o algoritmo falha em obter exatamente o objetivo prescrito, alcançando em vez disso uma aproximação do objetivo.

3.2 O Otimizador

Os algoritmos de otimização como o PSO *Particle Swarm Optimization*, Algoritmos Genéticos e Redes Neurais Artificiais, dentre outros, têm sido largamente utilizados para

o projeto e desenvolvimento de estruturas passivas na faixa de frequência de micro-ondas (Jin & Rahmat-Samii 2007) (da Silva et al. 2007).

O PSO é uma técnica de otimização estocástica baseada em populações desenvolvida por Eberhart e Kennedy em 1995 inspirados pelo comportamento social de pássaros e peixes (Kennedy & Eberhart 1995). O PSO compartilha muitas similaridades com técnicas evolucionárias como Algoritmos Genéticos (GA). O sistema é inicializado com uma população de soluções aleatórias e procura pela solução ótima através da atualização sucessiva de gerações. Contudo, ao contrário do GA, PSO não possui operadores evolucionários como *crossover* e *mutação*.

3.2.1 A linguagem do PSO

A linguagem usada para discutir o PSO resulta da analogia de partículas em um enxame, parecida com a analogia das abelhas apresentada previamente. Uma descrição mais detalhada (Robinson & Rahmat-Samii 2004) dos principais termos utilizados na implementação do PSO é apresentada abaixo.

1. **Partícula ou Agente:** Cada indivíduo dentro do enxame (abelhas na analogia anterior) é referenciado como partícula ou agente. Todas as partículas no enxame atuam individualmente sob o mesmo princípio: acelerar em direção a melhor posição pessoal e a melhor posição geral do enxame enquanto verifica constantemente o valor da sua posição atual.
2. **Posição:** Na analogia das abelhas a posição se refere a um local em um campo. Isso é representado por coordenadas em um plano $x - y$. Contudo, geralmente, podemos estender essa ideia para qualquer espaço N -dimensional de acordo com o problema que se deseja resolver. Esse espaço N -dimensional é o espaço de busca de soluções para o problema a ser otimizado. No caso das abelhas a solução é uma localização física no plano $x - y$, mas isso poderia ser a representação de fase e amplitude da

excitação de um elemento dentro um arranjo de antenas, ou a largura e altura de um *patch* de microfita. De forma geral estes valores podem ser quaisquer parâmetros que se deseje otimizar. Reduzir o problema de otimização para um conjunto de valores que representam uma posição dentro de um espaço de soluções é essencial na utilização do PSO.

3. ***Fitness* ou Aptidão:** Como em qualquer técnica de evolução computacional deve haver uma função ou método de avaliar a qualidade de uma posição. A função *fitness* deve ter como parâmetro de entrada a posição no espaço de buscas e retornar um número que representa o valor daquela posição. No caso das abelhas a função *fitness* seria simplesmente a densidade de flores: quanto maior a densidade de flores, melhor a posição. De maneira geral isso pode ser o ganho da antena, algum parâmetro de espalhamento S , ou uma combinação ponderada de vários parâmetros. A função *fitness* provê uma interface entre o problema físico e o algoritmo de otimização.
4. ***Personal Best* (p_{best}):** Na busca do campo de flores, cada abelha se lembra da localização onde ela própria encontrou a maior densidade de flores. Essa localização com o maior valor de aptidão pessoal descoberta por uma partícula é conhecida como *Personal Best* ou p_{best} . Para as abelhas, cada uma delas possuía seu próprio p_{best} determinado pelo caminho que ela percorreu. A cada posição do seu trajeto a abelha compara o valor de aptidão da localização atual com o seu p_{best} . Se a localização atual tiver um valor superior na avaliação da função *fitness* o seu p_{best} é substituído com a posição atual.
5. ***Global Best* (g_{best}):** Cada abelha também tem alguma forma de saber a maior concentração de flores descoberta pelo enxame. Essa localização com o maior valor *fitness* encontrado é denominada como *Global Best* ou g_{best} . Para todo o enxame existe apenas um g_{best} ao qual todos os indivíduos são atraídos. A cada nova posição cada agente compara o valor *fitness* da sua localização com o valor do g_{best} . Se

algum agente estiver em uma localização com um valor de aptidão maior que o do g_{best} , o g_{best} é substituído.

3.2.2 PSO versus AG

O Algoritmo Genético tem encontrado grande sucesso e aceitação dentro da comunidade de eletromagnetismo (da Silva et al. 2007)(Cruz et al. 2009)(Cheng et al. 2016). Por isso é útil comparar os vários aspectos em comum das duas técnicas de otimização.

Uma das vantagens do PSO sobre o AG é a sua simplicidade algorítmica. O AG consiste de três principais operadores: seleção, cruzamento e mutação. Dentro de cada um desses operadores existem diversas opções de implementações. Por exemplo, pode-se escolher entre a seleção por torneio ou roleta (Back et al. 1997). É necessário decidir entre o cruzamento de ponto único ou de ponto duplo. Contudo no PSO existe apenas um único operador: o cálculo da velocidade. A vantagem de possuir menos operadores é a redução do tempo computacional e a eliminação da necessidade de selecionar a variação apropriada para cada operador de acordo com uma determinada otimização.

Cada otimização possui vários parâmetros numéricos que precisam ser cuidadosamente selecionados. No caso do AG simples o tamanho da população e as taxas de cruzamento e mutação precisam ser determinadas. No algoritmo PSO, o tamanho da população, o peso inercial e os valores de c_1 e c_2 são os parâmetros fundamentais que precisam ser determinados ao início da otimização, contudo, é mais simples ajustar esses valores do que reescrever parte do código para verificar mudanças no comportamento do otimizador.

Outra diferença entre AG e PSO é a habilidade de controlar a convergência do algoritmo. As taxas de cruzamento e mutação podem sutilmente afetar a convergência do AG, mas não pode se comparar ao nível de controle alcançado através da manipulação do peso inercial no PSO. Em (Robinson & Rahmat-Samii 2004) os autores mostram que o decréscimo do peso inercial ao longo das gerações dramaticamente melhora a convergência do

enxame. Esse tipo de controle permite que o usuário determine a taxa de convergência e o nível de estagnação do algoritmo. A estagnação ocorre no AG quando eventualmente todos os indivíduos possuem basicamente o mesmo material genético que o melhor indivíduo. Nesses casos o conjunto de genes é tão homogêneo que o operador de cruzamento tem pouco ou nenhum efeito e cada nova geração é basicamente igual a anterior. Entretanto, no PSO esse efeito pode ser controlado ou impedido. Com um peso inercial grande as partículas continuam a voar em volta do g_{best} o que permite que elas ainda busquem novos locais com melhores condições (Jin & Rahmat-Samii 2007).

Por fim, os princípios conceituais das duas técnicas de otimização se baseiam em dois paradigmas completamente diferentes. O PSO, se baseia no comportamento social de um enxame, e o AG é baseado na codificação genética e na seleção natural, o que deixa em aberto a possibilidade de integração entre as duas técnicas (Robinson & Rahmat-Samii 2004). Alguns autores já testaram esse conceito. Em 2002, foi mostrado que PSO e AG podem ser utilizados em série, através do uso de populações otimizadas com PSO como população inicial do AG e vice-versa (Robinson et al. 2002). Uma outra abordagem envolve integrar os dois paradigmas em um único algoritmo, utilizando estratégias evolucionárias e a inteligência do enxame (Miranda & Fonseca 2002). Essa técnica mostrou em vários casos um desempenho melhor do que o PSO e o AG aplicados individualmente.

3.2.3 O algoritmo

O PSO é baseado no princípio de que cada solução pode ser representada como uma partícula, ou agente, dentro de um enxame. Cada agente possui um vetor posição e de velocidade e cada coordenada representa o valor de um parâmetro a ser otimizado. Então para uma otimização N-dimensional, cada agente terá uma posição em um espaço N-dimensional que representa uma possível solução do problema.

Da mesma forma que GA, PSO também requer uma função de aptidão que a partir da posição do partícula atribui um valor de aptidão a cada agente. Cada partícula é inicia-

lizada com posição e velocidade aleatórias. A velocidade e a posição das partículas são atualizadas de acordo com as seguintes equações matriciais (Rahmat-Samii 2007):

$$\mathbf{V}_t = w\mathbf{V}_{t-1} + c_1\eta_1(\mathbf{P}_{t-1} - \mathbf{X}_{t-1}) + c_2\eta_2(\mathbf{G}_{t-1} - \mathbf{X}_{t-1}) \quad (3.1)$$

$$\mathbf{X}_t = \mathbf{X}_{t-1} + \mathbf{V}_t \quad (3.2)$$

onde c_1 e c_2 são valores constantes que servem para balancear as influências do *gbest* e do *pbest*, sendo w o peso inercial. Os valores de *pbest* e *gbest* de todos os agentes são armazenados nas matrizes \mathbf{P} e \mathbf{G} , e são atualizados a cada iteração. Para inserir aleatoriedade ao comportamento das partículas, as constantes c_1 e c_2 são multiplicadas por coeficientes aleatórios η_1 e η_2 , respectivamente. Em cada dimensão, tanto η_1 e η_2 são gerados a partir de uma distribuição uniforme entre (0,1), com $c_1 = c_2 = 2.0$ como sugerido em (Jin & Rahmat-Samii 2007)(Mikki & Kishk 2008).

A Figura 3.1 mostra uma ilustração do mecanismo de atualização das partículas dentro do PSO. A cada iteração, cada partícula irá combinar informação da sua atual velocidade \mathbf{V}_{t-1} , com a correção individual que está relacionada ao melhor resultado da partícula ($\mathbf{P}_{t-1} - \mathbf{X}_{t-1}$) e com a correção social que relaciona a partícula com o melhor resultado global ($\mathbf{G}_{t-1} - \mathbf{X}_{t-1}$). A contribuição desses três componentes irá resultar na posição \mathbf{X}_t da partícula na próxima geração.

Uma vez definido a forma como cada agente será atualizado torna-se necessário especificar como eles serão avaliados. Para isso uma função *fitness* que indica o quão próximo do objetivo cada partícula se encontra tem que ser definida. De uma forma geral, para a maioria dos problemas que envolvem otimização de estruturas eletromagnéticas, um dos principais objetivos é obter um bom casamento de impedância ($S_{11} < -10dB$) na frequência de interesse. Por isso uma forma de avaliar as partículas pode ser descrita por:

$$f(\vec{x}) = S_{11,f} \quad (3.3)$$

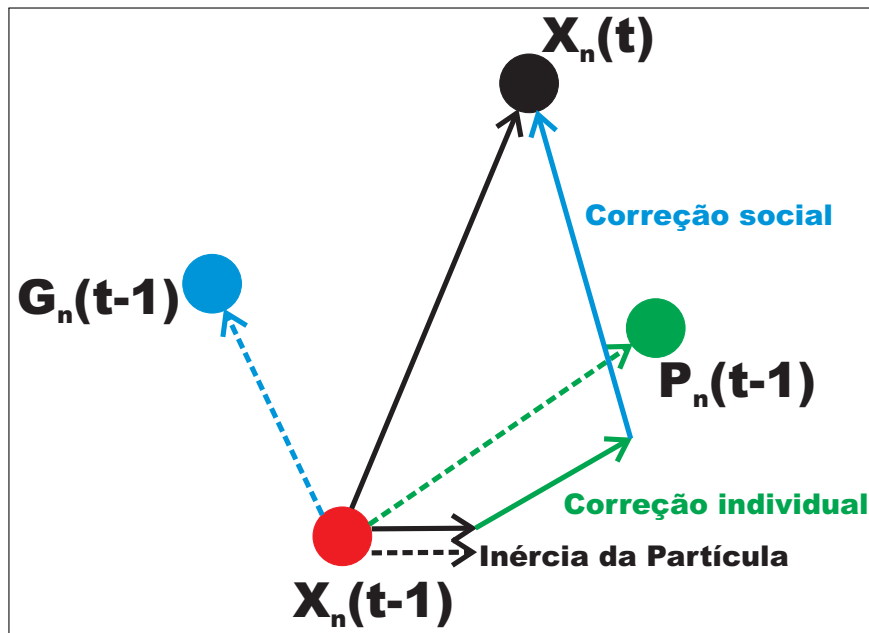


Figura 3.1: Ilustração gráfica do mecanismo de atualização da partícula

onde $S_{11,f}$ é o valor simulado de S_{11} na frequência de interesse.

Utilizando a Equação 3.3 para avaliar as partículas torna a otimização um problema de minimização, ou seja, o algoritmo deve encontrar o menor valor possível para $f(\vec{x})$.

3.2.4 Descrição do algoritmo PSO

Inicialização da população

Para cada partícula:

- Escolha uma posição aleatória dentro do espaço de buscas.
- Avalie a partícula usando a função *fitness*.
- Inicialize a melhor posição pessoal (*personal best*) como sendo a posição atual.
- Inicialize a velocidade com um valor aleatório.

Para toda a população

- Inicialize a melhor posição da população (*global best*) com o valor da partícula que tiver obtido melhor avaliação.

Iterações

- Calcule a nova velocidade através da Equação 3.1, combinando os seguintes elementos:
 - A posição atual.
 - A velocidade atual.
 - A melhor posição pessoal (*personal best*).
 - A melhor posição geral (*global best*).
- Mova a partícula aplicando a nova velocidade através do uso da Equação 3.2.
- Aplique um método de confinamento, caso necessário, para assegurar que a nova posição está dentro do espaço de busca.
- Se a nova avaliação (*fitness*) for melhor do que a melhor posição anterior (*personal best*), substitua a anterior pela atual.
- Se dentro das novas avaliações houver um valor melhor do que o valor anterior da melhor posição geral (*global best*), substitua a melhor posição da população por esse novo valor.

Como critério de parada pode-se escolher:

- Quando o valor de avaliação ótimo é conhecido, o algoritmo pode parar apenas quando encontrar esse valor ou quando estiver suficientemente próximo, com um valor de tolerância definido previamente
- Quando o problema trata de buscar o menor/maior valor possível o algoritmo pode ser interrompido quando:
 - Uma quantidade máxima de iterações é atingida.
 - Quando a melhor avaliação da população está estagnada.

3.3 PSO - Binário

A partir das analogias físicas feitas até então é possível compreender a aplicação do PSO para problemas que precisam da otimização de parâmetros que são representados através de valores reais. A técnica tende a não funcionar caso o PSO, como apresentado, seja aplicado para casos onde as partículas precisam voar entre valores zero e um, e só podem utilizar valores inteiros. Uma solução para esse problema foi proposta em (Kennedy & Eberhart 1997) em 1997. Os autores introduziram o conceito de velocidade e probabilidade que um bit pode assumir sendo zero ou um. Apesar dessa adaptação não intuitiva os autores mostraram em (Kennedy & Spears 1998) que de um forma geral o algoritmo binário do PSO supera a implementação binária do AG em uma vasta variedade de casos. Por causas desses resultados e da necessidade criada neste trabalho, o algoritmo Binário do PSO (*BPSO*) é utilizado ao decorrer de todas as otimizações apresentadas.

As próximas seções apresentam a implementação utilizada do BPSO aplicada aos problemas de otimização mencionados anteriormente.

3.3.1 BPSO - Implementação

Para as estruturas propostas no Capítulo 2 (Figuras 2.4, 2.5,2.6), o objetivo é determinar uma nova geometria para obter a resposta desejada, por isso as estruturas são subdivididas de forma que o algoritmo deve tomar a decisão sobre quais subdivisões são necessárias e quais pode ser descartadas, configurando assim uma otimização binária. Por isso o algoritmo deve ser adaptado para tratar do caso onde a posição das partículas é dada através de valores binários.

Considerando a Equação 3.2 em um espaço de soluções binário, na $(t-1)$ -ésima iteração a posição do m -ésimo agente pode ser expressa por um vetor binário N -dimensional:

$$\begin{aligned} \{x_{mn,t-1}\} &= \{x_{m1,t-1}, x_{m2,t-1}, \dots, x_{mn,t-1}\} \\ \{x_{mn,t-1}\} &\in \{0, 1\} \end{aligned} \quad (3.4)$$

Uma vez que cada elemento $x_{mn,t-1}$ é um valor binário, a distância de Hamming entre a posição atual de um agente e o seu *personal best* (ou *global best*) pode assumir apenas três possíveis valores:

$$p_{mn,t-1} - x_{mn,t-1} = \begin{cases} 1; & p_{mn,t-1} = 1, x_{mn,t-1} = 0 \\ 0; & p_{mn,t-1} = x_{mn,t-1} = 0 \\ -1; & p_{mn,t-1} = 0, x_{mn,t-1} = 1 \end{cases} \quad (3.5)$$

Multiplicando a Equação 3.5 pelas constantes $(c_1\eta_1, c_2\eta_2)$ e somando com a velocidade anterior $v_{mn,t-1}$, a velocidade atual da partícula $v_{mn,t}$ é ainda um número real. Como $x_{mn,t-1}$ precisa ser um valor binário a posição dos agentes precisa ser atualizada de uma forma diferente da apresentada na Equação 3.2.

Uma das possíveis soluções para esse problema é descrita em (Jin & Rahmat-Samii 2007). Na otimização binária, a velocidade da partícula $v_{mn,t}$ está relacionada com o fato de que a posição do agente $x_{mn,t}$ assume valores 0 ou 1. A atualização da posição é feita então utilizando uma função intermediária $S(v_{mn,t})$ definida como:

$$S(v_{mn,t}) = \frac{1}{1 + e^{-v_{mn,t}}} \quad (3.6)$$

A Figura 3.2 mostra o comportamento da função $S(v_{mn,t})$ no domínio $[-V_{max}, V_{max}]$. A função da Equação 3.6 é uma função sigmoide com as seguintes características:

$$S(v_{mn,t}) = \begin{cases} \frac{1}{1+e^{V_{max}}} \rightarrow 0, & v_{mn,t} = -V_{max} \rightarrow -\infty \\ \frac{1}{2}; & v_{mn,t} = 0 \\ \frac{1}{1+e^{-V_{max}}} \rightarrow 0, & v_{mn,t} = V_{max} \rightarrow \infty \end{cases} \quad (3.7)$$




Figura 3.2: A Função Sigmoid $S(v_{mn,t})$ representa a probabilidade de um bit assumir o valor 0 ou 1

A função intermediária $S(x)$ mapeia o seu domínio de $[-V_{max}, V_{max}]$ no intervalo $[1/(1+e^{V_{max}}), 1/(1+e^{-V_{max}})]$, que é um subconjunto de $(0,1)$. O valor de $S(v_{mn,t})$ pode ser interpretado como um limiar de probabilidade para decidir se posição da partícula deve ser invertida. Um valor aleatório com distribuição uniforme, $r_{mn,t}$, é então gerado e comparado a $S(v_{mn,t})$. O n -ésimo bit da m -ésima partícula, $x_{mn,t}$, é atualizado por:

$$x_{mn,t} = \begin{cases} 1; & r_{mn,t} < S(v_{mn,t}) \\ 0; & r_{mn,t} \geq S(v_{mn,t}) \end{cases} \quad (3.8)$$

Em (Kennedy & Eberhart 1997) valor sugerido como máximo/mínimo da função $S(v)mn,t$ é $V_{max} = 6.0$. Esse valor será usado como padrão para todas as otimizações implementadas.

3.4 A função *fitness*

Parte importante do processo de otimização a função *fitness* ou função de avaliação deve ser definida de acordo com o objetivo a ser alcançado e tem que representar sem ambiguidade as partículas do enxame.

No processo de otimização de estruturas eletromagnéticas é comum que a referência seja o parâmetro de espalhamento, S (da Silva et al. 2007)(Rajagopalan et al. 2014), especialmente para a otimização de antenas onde o S_{11} é uma relação direta entre a impedância da fonte e da antena.

Por exemplo, para a otimização de uma antena onde se deseja obter o melhor casamento de impedâncias possível em uma única frequência, a Equação 3.9 é uma boa candidata para servir de função avaliação.

$$f(\vec{x}) = S_{11,f} \quad (3.9)$$

onde $S_{11,f}$ representa o valor do S_{11} para uma frequência, f , específica.

Para esse caso cada partícula, que representa uma possível configuração da antena, é simulada e tem o valor do S_{11} usado diretamente como função de avaliação sendo o algoritmo responsável por minimizar a Equação 3.9 e assim obter a melhor configuração possível.

Como discutido no Capítulo 2 o desenvolvimento de sistemas de rádios cognitivos depende do projeto de dispositivos multibanda. Sendo assim é necessário utilizar uma função *fitness* que considere o comportamento multibanda das estruturas. Na Figura 2.4 é apresentada a proposta de uma possível antena multibanda. Para o caso de uma otimização que tem como objetivo obter uma antena que tenha simultaneamente duas ressonâncias, uma na frequência f_1 e outra na frequência f_2 , a Equação a seguir serve como função *fitness*:

$$f(\vec{x}) = \max(S_{11,f_1}, S_{11,f_2}) \quad (3.10)$$

Mantendo o algoritmo com o objetivo de obter o $\min(f(\vec{x}))$, a otimização passa a seguir uma estratégia minimax (Rajagopalan et al. 2014). O uso do pior valor de S_{11} evita que ocorra uma convergência prematura do algoritmo em apenas uma das frequências simuladas.

Nos dois casos apresentados anteriormente a função de avaliação foi construída para obter uma estrutura com um comportamento específico, representado por apenas um parâmetro, o valor de S_{11} . Na Figura 2.5 a proposta da estrutura é possuir dois estados de operação, um modo *ON* onde os diodos PIN estão ativados e a estrutura deve ressoar apenas frequência f_{on} e rejeitar uma segunda frequência f_{off} e ter o comportamento contrário quando estiver no modo *OFF* que representa a desativação dos diodos PIN. Sendo assim a função *fitness* deve considerar dois parâmetros o $S_{11,on}$ que representa o modo *ON* e o $S_{11,off}$ que representa o segundo modo de operação.

Em (Rajagopalan et al. 2014) e (Jin & Rahmat-Samii 2007) a seguinte função avaliação é proposta:

$$f(\vec{x}) = \max(S_{11,on}) + \max(S_{11,off}) + |\max(S_{11,on}) - \max(S_{11,off})| \quad (3.11)$$

Os dois primeiros termos da Equação 3.11 representam um problema de otimização minimax, onde o pior valor do S_{11} (dB) nas regiões de interesse dos modos *ON* e *OFF* são minimizados. Os termos seguintes da Equação são incluídos para assegurar a convergência nas duas bandas de operação.

3.5 Otimização Multiobjetivo

Em alguns problemas para se obter um resultado ideal é necessário trabalhar com mais de um parâmetro de otimização. Por exemplo no projeto de antenas não se pode levar em consideração apenas os resultados dos parâmetros de espalhamento, S , mas é necessário considerar valores de ganho, de eficiência e outros parâmetros fundamentais (Balanis 2005). Existem várias estratégias para tratar um problema de otimização com múltiplos objetivos.

3.5.1 Estratégia da soma ponderada

Uma das formas mais simples de se trabalhar com múltiplos objetivos é transformando os vários objetivos em um único objetivo, isso pode ser obtido através da estratégia da soma ponderada.

Considere que os K fatores considerados em um projeto são representados por K funções de avaliação, $f_i(\vec{x})$ ($i = 1, 2, \dots, K$), sendo \vec{x} a posição da partícula no espaço de busca. Intuitivamente, esses fatores pode ser ponderados e somados para formular um objetivo único:

$$f(\vec{x}) = \sum_{i=1}^K w_i f_i(\vec{x}) \quad (3.12)$$

Contudo, determinar qual o melhor equilíbrio entre todos os fatores requer conhecimento da importância relativa de cada fator com relação aos outros. Apesar de simples, essa estratégia frequentemente requer um extenso ajuste dos pesos, w_i , particularmente em problemas onde os objetivos não estão relacionados.

3.5.2 Estratégia dos múltiplos enxames

Com múltiplos objetivos um dos desafios no uso do PSO é como determinar quais são os melhores valores individuais e sociais (*personal best* e *global best*) de cada partícula. Uma forma de resolver isso é através do uso de múltiplos enxames. Essa estratégia é denominada na literatura como VEPSO (*Vector Evaluated Particle Swarm*) (Greeff & Engelbrecht 2008)(Gies & Rahmat-Samii 2004).

O algoritmo do VEPSO é conceitualmente simples: dois enxames de partículas diferentes operam de forma simultânea cada um em busca de um objetivo diferente. Ao final de cada iteração, o valor da melhor partícula (*global best*) de cada população são trocados, logo as equações de atualização de cada enxame passam a ser:

$$\mathbf{V}_t^{(1)} = w\mathbf{V}_{t-1}^{(1)} + c_1\eta_1(\mathbf{P}_{t-1}^{(1)} - \mathbf{X}_{t-1}^{(1)}) + c_2\eta_2(\mathbf{G}_{t-1}^{(2)} - \mathbf{X}_{t-1}^{(1)}) \quad (3.13)$$

$$\mathbf{V}_t^{(2)} = w\mathbf{V}_{t-1}^{(2)} + c_1\eta_1(\mathbf{P}_{t-1}^{(2)} - \mathbf{X}_{t-1}^{(2)}) + c_2\eta_2(\mathbf{G}_{t-1}^{(1)} - \mathbf{X}_{t-1}^{(2)}) \quad (3.14)$$

Nas Equações 3.13 e 3.14 t indica a iteração e os sobrescritos (1) e (2) denotam a qual exame a informação pertence.

Ao final da execução do algoritmo é comum obter-se duas partículas vencedoras semelhantes entre si mas cada uma com uma tendência maior a um dos objetivos.

A utilização do VEPSO tem sido limitada a problemas com dois objetivos, pois no caso de mais objetivos não é claro qual estratégia adotar na troca de informação entre os enxames (Gies & Rahmat-Samii 2004)(Jin & Rahmat-Samii 2007).

3.5.3 A fronteira de Pareto

O algoritmo do PSO pode ser desenvolvido para considerar a fronteira de Pareto para os casos de otimizações com múltiplos objetivos. O conceito da dominância de Pareto

consiste em considerar que para valores arbitrários de \vec{x}_1 e \vec{x}_2 , \vec{x}_1 domina \vec{x}_2 se e apenas se todas as funções de avaliação satisfizerem $f_i(\vec{x}_1) \leq f_i(\vec{x}_2)$ para todo i e ao menos um i deve ser $f_i(\vec{x}_1) < f_i(\vec{x}_2)$. O conjunto de todas as soluções não-dominadas é definido como a fronteira de Pareto. No PSO, o algoritmo usa como *global best* a solução da fronteira Pareto mais próxima a cada agente. O *personal best* é selecionado como a primeira solução não-dominada obtida pela partícula (Jin & Rahmat-Samii 2007).

O uso da dominância de Pareto oferece a possibilidade de operar com a otimização de mais de dois objetivos de uma forma simples e eficiente (Coello et al. 2004).

3.6 O otimizador híbrido

O uso de PSO para solução de problemas híbridos, com parâmetros reais e binários simultaneamente, é mais eficiente do que outras abordagens clássicas como GA pois diferente das técnicas evolutivas as operações relacionadas a cada dimensão não dependem da informação de outras dimensões tanto para as soluções locais ou globais. Essa independência permite que diferentes dimensões de um mesmo problema possam ser representadas por valores reais ou binários e submetidas ao mesmo esquema de atualização do PSO.

A utilização de um otimizador híbrido para o desenvolvimento de circuitos de micro-ondas é uma abordagem interessante pois permite que se utilize a capacidade do modelo binário de criar estruturas completamente novas em conjunto com a poder de adaptação de estruturas já conhecidas que o modelo real proporciona. Em (Jin & Rahmat-Samii 2010) os autores apresentam comparações entre o modelo híbrido de otimização e outros algoritmos clássicos como AG e variações do PSO juntamente com um série de aplicações na área de dispositivos de micro-ondas.

A implementação do algoritmo HPSO é descrita de forma resumida na Tabela 3.1, uma vez que essa forma de otimização segue os mesmos princípios do algoritmo PSO

clássico já descrito.

Tabela 3.1: Principais parâmetros de implementação do HPSO

	PARTE REAL	PARTE BINÁRIA
$\vec{x} = [\vec{r}, \vec{b}]$	$\vec{r} = [R_1, R_2]$	$\vec{b} = [B_1, B_2, B_3, \dots, B_n]$
p_{best} g_{best}	Ambas as partes compartilham os mesmos p_{best} e g_{best}	
Velocidade	$\mathbf{V}_t = w\mathbf{V}_{t-1} + c_1\eta_1(\mathbf{P}_{t-1} - \mathbf{X}_{t-1}) + c_2\eta_2(\mathbf{G}_{t-1} - \mathbf{X}_{t-1})$	
Inércia	Varável entre 0.9 - 0.4	Constante 1.0
V_{max}	$0.1 \times (R_{max} - R_{min})$	6.0
Atualização	$\vec{r} = \vec{r}_{t-1} + \vec{v}_{r,t}$	$S(v_{mn,t}) = \frac{1}{1+e^{-v_{mn,t}}}, x_{mn,t} = \begin{cases} 1; & r_{mn,t} < S(v_{mn,t}) \\ 0; & r_{mn,t} \geq S(v_{mn,t}) \end{cases}$

Capítulo 4

O PSO e Antenas

Com as informações apresentadas no Capítulo 2 e no Capítulo 3 foi desenvolvido um processo automático de projeto de dispositivos como antenas planares e superfícies seletivas de frequência. A abordagem utilizada é baseada na capacidade de otimização do algoritmo PSO apresentado no Capítulo 3. No processo de otimização de dispositivos eletromagnéticos um dos maiores desafios é obter uma caracterização da estrutura que seja fiel aos modelos reais e seja capaz de simular com precisão os parâmetros requisitados pelas funções de avaliação.

A implementação do PSO foi totalmente desenvolvida no ambiente de programação *MATLAB*[®] e para a avaliação das estruturas foi utilizado o *Ansys HFSS*[®]. O uso do *MATLAB*[®], como ambiente de programação, se deve a disponibilidade de ferramentas para interagir com outros *softwares* através de uma interface COM (*Component Object Model*). Uma vez que a interface COM é inicializada entre o *MATLAB*[®] e o *Ansys HFSS*[®] é possível controlar todos elementos necessários para simular uma estrutura eletromagnética com os parâmetros desejados.

A Figura 4.1 apresenta o fluxograma de implementação da interação entre o *MATLAB*[®] e o *Ansoft HFSS*[®].

Como apresentado nas Figuras 2.4, 2.5, 2.6 as estruturas propostas para otimização são subdivididas de forma a permitir que o algoritmo de otimização tenha um maior grau de liberdade e seja capaz de obter dispositivos completamente novos.

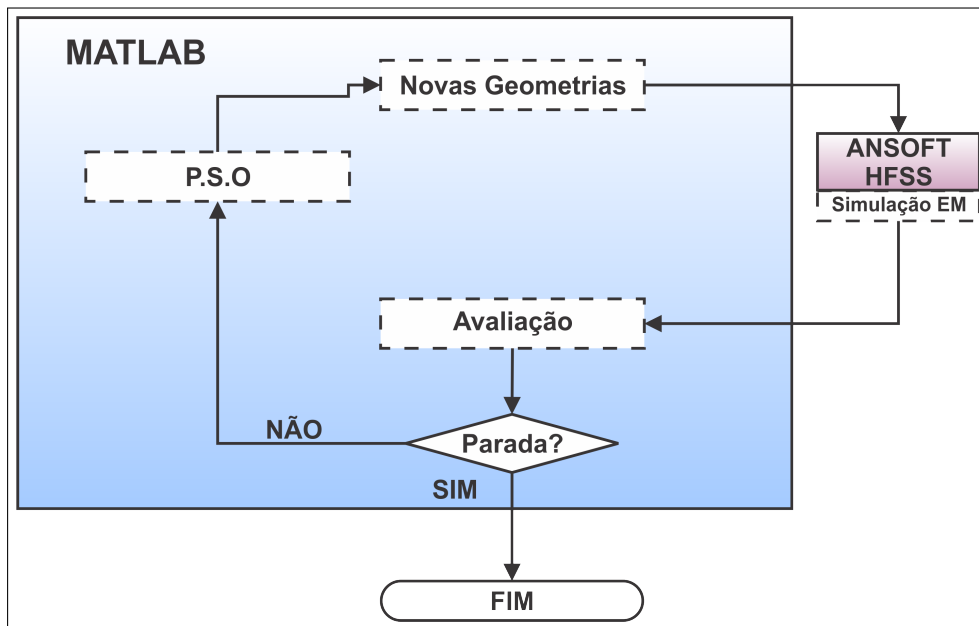


Figura 4.1: Fluxograma de implementação do algoritmo de otimização

A geração de estruturas baseadas nesse tipo de otimização binária pode levar a criação de conexões puramente diagonais entre as subdivisões que não são corretamente representadas durante o processo de simulação. Para evitar tais conexões durante a otimização todas as estruturas são submetidas a uma sub-rotina que impede a criação de conexões diagonais. A sub-rotina pesquisa em toda a estrutura a possibilidade de uma conexão diagonal, quando encontrada tal conexão é gerado um valor aleatório, r , entre 0 e 1, e de acordo com o valor obtido ativa uma das subdivisões vizinhas, evitando assim a conexão inválida. O processo da sub-rotina é ilustrado na Figura 4.2.

4.1 Projeto de uma antena multibanda

Uma antena multibanda é um componente importante dentro do projeto de um sistema de rádio cognitivo, pois é a partir das frequências que antena for capaz de detectar que o sistema é capaz de decidir qual o melhor canal de comunicação. Por exemplo, um sistema pode ser projetado para trabalhar na faixa ISM de 2,4 GHz mas com a capacidade




Figura 4.2: Ilustração do mecanismo de identificação e correção de conexões diagonais

de alterar para a banda de 1,8 GHz quando julgar necessário. Dessa forma uma antena que opere nessas duas banda é necessária para atuar como antena de detecção.

Para desenvolver uma antena com a característica de multibanda em 1,8 GHz e 2,4 GHz foi utilizada uma antena de microfita de uma camada com um *patch* simples. A configuração proposta na Figura 4.3, o *patch* principal possui 56mm de largura e 28 mm de comprimento. Para permitir a otimização o *patch* principal foi subdividido em 98 *patches* de 4mm x 4mm.

Para o algoritmo de otimização a presença de 98 *patches* gera um espaço de busca com 2^{98} combinações, de forma a reduzir o espaço de busca e evitar a criação de uma estrutura completamente assimétrica, o que afetaria negativamente diagrama de irradiação da antena, foi imposto a estrutura um plano de simetria ao longo do comprimento do *patch* principal. O uso do plano de simetria reduz o espaço de busca para 2^{49} combinações.

4.1.1 Otimização das frequências de ressonância

Inicialmente a otimização foi desenvolvida para buscar uma antena com ressonância nas frequências de 1,8 GHz e 2,4 GHz. Como função de avaliação foi utilizada a Equação 3.10.

O BPSO foi iniciado com um enxame de 10 partículas e como critério de parada o máximo de 200 iterações ou quando o valor de *global best* não sofresse alteração por




Figura 4.3: Antena base para a otimização

mais de 20 iterações. A Figura 4.4 mostra a evolução do algoritmo e que o processo foi terminado com 60 iterações.

A Figura 4.5 mostra a geometria obtida ao final da otimização, a Figura 4.6 mostra o resultado da simulação da perda de retorno, S_{11} , da antena final, mostrando que o algoritmo foi bem sucedido na tarefa de obter um bom casamento de impedâncias ($S_{11} \leq -10dB$) nas duas frequências de interesse.

Nesta otimização não houve qualquer preocupação com os possíveis valores do ganho da antena nas frequências de interesse. O ganho máximo em 2.4 GHz foi de $G = 1.5dB$ e de $G = -12.6$ para 1.8 GHz, o que caracteriza uma antena com ganho muito baixo especialmente para a segunda faixa de frequência. As Figuras 4.7 e 4.8 apresentam a distribuição de ganho da antena para os planos $\phi = 0$ e $\phi = 90$ simulados nas frequências de 2.4 GHz e 1.8 GHz, respectivamente.

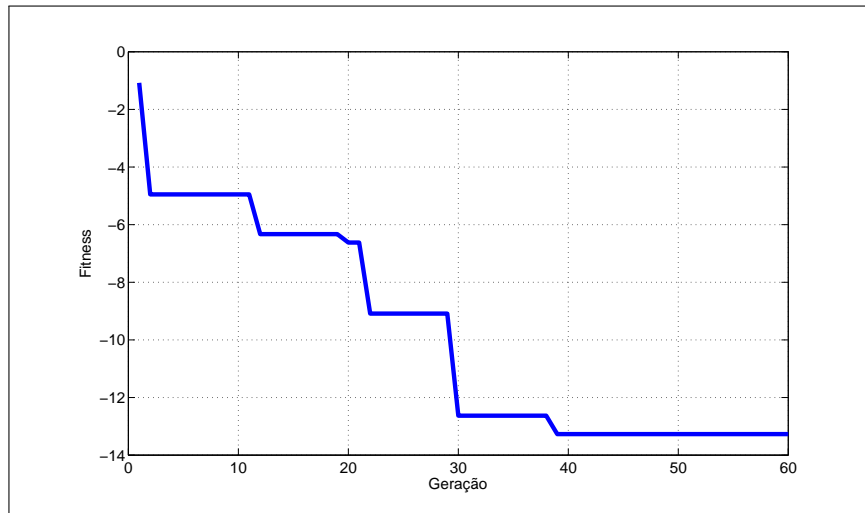


Figura 4.4: Evolução do BPSO ao longo das iterações.

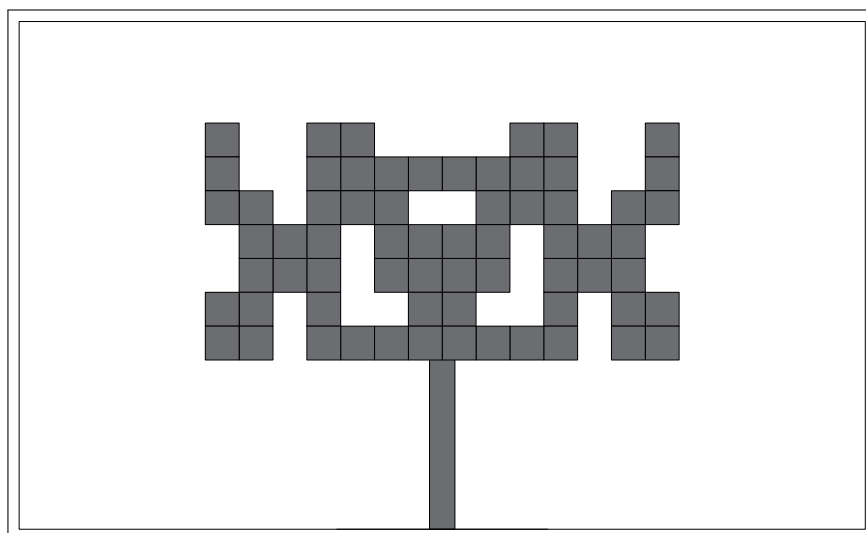


Figura 4.5: Geometria obtida pelo algoritmo.




Figura 4.6: Resultado simulado do S_{11} para a geometria apresenta na Figura 4.5.

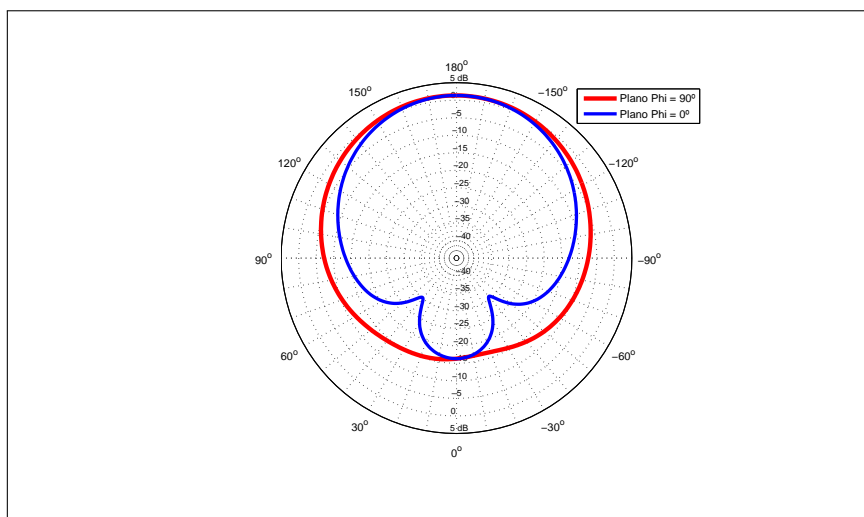


Figura 4.7: Ganho simulado para a antena da Figura 4.5 na frequência de 2,4GHz .




Figura 4.8: Ganho simulado para a antena da Figura 4.5 na frequência de 1,8GHz .

4.2 Projeto de antena reconfigurável

Para um sistema de rádio cognitivo é essencial projetar um antena reconfigurável, pois essa antena será responsável por criar o canal de comunicação de acordo com as informações obtidas pela antena detectora. A antena de comunicação deve operar nas mesmas frequências que a antena de detecção, mas deve ativar a comunicação apenas na frequência que for identificada como livre, por isso a necessidade de reconfigurabilidade.

Para a proposta de antena reconfigurável, a antena apresentada na Figura 4.9. A antena é composta por um *patch* central, identificado pelo número 2, conectado através de um diodo PIN a outros dois *patches*, 1 e 3. Cada um dos três *patches* principais foi subdividido em outros 64 *patches* menores. Para manter a simetria e evitar estruturas complexas de serem construídas apenas 32 *patches* internos são otimizados e então espelhados dentro do *patch* principal criando uma simetria axial. Ainda preocupado com a simetria os dois *patches* externos são otimizados de forma a sempre possuírem a mesma geometria. Por fim com todas as restrições determinadas o espaço de busca do algoritmo possui 2^{64}

soluções possíveis.




Figura 4.9: Exemplo do modelo de antena reconfigurável proposto

Foi utilizado o diodo PIN Infineon BAR64-03W para conectar os *patches*. Na simulação para representar a ação do diodo no estado *OFF*, cada conexão é substituída por uma capacitância de $0,17\text{pF}$, enquanto que para o estado *ON* o diodo é simulado como uma resistência com $2,1\Omega$. Para polarizar os diodos foram incluídas na simulação três trilhas de alimentação DC com 1 mm de espessura cada, as linhas estão presentes em todas as simulações para que o seu efeito sobre a impedância da antena seja considerado durante o processo de otimização.

Utilizando o BPSO, descrito no Capítulo anterior, com um enxame de tamanho 10, com o objetivo de obter uma estrutura com ressonância apenas em $f_{off} = 2,4\text{ GHz}$ quando os diodos estiverem desativados e com ressonância em $f_{on} = 1,8\text{ GHz}$ quando toda a antena estiver conectada. O algoritmo foi iniciado e após 200 iterações apresentou como solução a geometria ilustrada pela Figura 4.10.




Figura 4.10: Geometria obtida para uma antena reconfigurável




Figura 4.11: Comparação entre o resultado simulado e medido da antena reconfigurável

A Figura 4.12 mostra o protótipo construído da antena utilizado na medição. A comparação apresentada na Figura 4.11 entre o resultado medido e as simulações mostrou uma boa concordância mesmo na faixa de 1,8 GHz onde os diodos PIN estão polarizados e existe uma tensão DC na superfície da antena. A medição foi feita utilizando o Analisador de Redes PNA5232A que suporta até uma tensão direta de 35 V na porta de RF, minimizando a interferência causada pela tensão usada para polarizar os diodos PIN.




Figura 4.12: Protótipo da antena reconfigurável

4.3 Otimização da frequência de ressonância e do ganho

4.3.1 O Algoritmo VEPSO

Na tentativa de melhorar o ganho da antena da seção anterior o algoritmo VEPSO citado no Capítulo 3 foi implementado. O algoritmo consiste em criar dois enxames de partículas e determinar que o primeiro enxame se encarregue de otimizar as frequências de ressonância e o segundo enxame fique responsável por obter o melhor ganho possível nas duas frequências, sendo que a cada iteração as velocidades são atualizadas de acordo com as Equações 3.13 e 3.14. As funções avaliação utilizadas no primeiro e no segundo enxame são:

$$f_1(\vec{x}) = \max(S_{11,f_1}, S_{11,f_2}) \quad (4.1)$$

$$f_2(\vec{x}) = \min(\max(G_{f_1}), \max(G_{f_2})) \quad (4.2)$$

onde G_{f_1} e G_{f_2} representam o ganho da antena nas frequências de 1,8GHz e 2,4GHz respectivamente.

Utilizando dois enxames de 10 agentes cada, ao final de 200 iterações o algoritmo apresentou a antena representada na Figura 4.13

O resultado da simulação da perda de retorno, S_{11} é mostrado na Figura 4.14. No gráfico do parâmetro S_{11} é importante notar que os valores das ressonâncias ficaram abaixo do esperado $-10dB$ mas não foram melhores do que o resultado obtido na primeira otimização.

Apesar do algoritmo ter como objetivos a obtenção dos melhores valores de S_{11} e Ganho nas duas frequências de interesse. O ganho máximo em 2,4 GHz foi de $G = -0,34$ dB e de $G = -0,39$ dB para 1,8 GHz, apesar dos valores ainda muito baixos para o ganho houve um maior equilíbrio entre as duas frequências. Provavelmente o resultado do ganho




Figura 4.13: Geometria Obtida pelo Algoritmo para a segunda otimização.




Figura 4.14: Resultado simulado do S_{11} para a geometria apresentada na Figura 4.13.

possa ser explicado pela parada prematura do algoritmo ou pelo tamanho dos enxames. As Figuras 4.15 e 4.8 apresentam a distribuição do ganho nas frequências 2,4 GHz e 1,8 GHz, respectivamente.




Figura 4.15: Ganho Simulado para a antena da Figura 4.13 na frequência de 2,4 GHz .




Figura 4.16: Ganho Simulado para a antena da Figura 4.13 na frequência de 1,8 GHz .

4.3.2 Antena de microfita suspensa

A tangente de perdas do FR4 ($\tan \delta = 0.02$) se torna um grande obstáculo para o projeto de antenas com ganhos mais elevados. Por isso uma das alternativas adotadas

para minimizar o efeito do substrato, mas ao mesmo tempo manter o projeto baseado em uma antena de baixo custo, foi a utilização da configuração apresentada por (Gardelli et al. 2004) e mostrada na 4.17. Com essa configuração é possível obter uma baixa constante dielétrica efetiva ($\epsilon_{eff} \approx 1.4 - 1.8$) que é adequada para aumentar a largura de banda da antena, mantendo uma tangente de perdas ($\tan\delta \approx 3 - 5 \times 10^{-3}$) permitindo a obtenção de um ganho mais elevado.




Figura 4.17: *Layout* da estrutura de uma antena suspensa.

Para o projeto da antena suspensa, optou-se por utilizar um algoritmo de objetivo único. Mas para manter o ganho como sendo um parâmetro importante na otimização, foi utilizado como variável de otimização o ganho intrínseco da antena, calculado como:

$$G_r = 4\pi \frac{U}{P_{inc}} \quad (4.3)$$

$$G_i = \frac{G_r}{1 - |S_{11}|^2} \quad (4.4)$$

onde G_r é o ganho real da antena, U é a intensidade de radiação em watts e P_{inc} é a potência incidente em watts.

Utilizando a 4.4 permite que o projeto considere simultaneamente as perdas devido ao descasamento de impedância e as perdas de radiação evitando a necessidade de utilizar um algoritmo multiobjetivo.

No entanto ao utilizar 4.4 o otimizador passa atuar com o objetivo de maximizar os




Figura 4.18: Geometria final obtida pelo BPSO.

resultados da função *fitness* ao invés de minimizador como nos casos anteriores.

Utilizando como estrutura base o modelo apresentado na Figura 4.17 com um *patch* retangular de 50 x 45 mm, dividido em 400 “pixels”, o algoritmo BPSO foi iniciado com um enxame de 14 partículas em busca de uma geometria do *patch* que apresentasse uma dupla ressonância nas frequências de 1.8 GHz e 2.4 GHz, com valores de ganho viáveis.

Após 600 iterações o algoritmo encontrou como melhor solução para o problema a configuração que é ilustrada na Figura 4.18.

A Figura 4.19 mostra o protótipo construído com as configurações sugeridas pelo algoritmo.

Na Figura 4.20 mostra a comparação entre o resultado medido e simulado do parâmetro S_{11} da antena suspensa. Os valores medidos e simulados apresentam um excelente concordância.




Figura 4.19: Protótipo com a configuração obtida






Figura 4.20: Comparação entre os valores medido e simulados para a antena suspensa.

Com relação ao ganho a simulação mostrou que para a frequência de 1.8 GHz a antena apresenta o valor máximo de 5 dB e de 6.4 dB na frequência de 2.4 GHz. As Figuras 4.21a e 4.21b mostram a distribuição do ganho da antena para as frequências de 1.8 GHz e 2.4 GHz, respectivamente.



(a)



(b)

Figura 4.21: (a) Simulação do ganho em 1.8 GHz e (b) Simulação do ganho em 2.4 GHz.

Esses resultados mostram que a utilização do ganho intrínseco como variável de otimização foi bem sucedido, uma vez que o algoritmo foi capaz de encontrar uma geometria

com excelente casamento de impedância ao mesmo tempo que manteve ótimos valores do ganho nas frequências de interesse.

Capítulo 5

Contribuição para o *Particle Swarm Optimization*

5.1 HPSO com zona negativa

O extenso estudo sobre aplicação do PSO e HPSO desenvolvido em (Jin & Rahmat-Samii 2010) e (Jin & Rahmat-Samii 2007), foi fator motivador para apresentar uma contribuição para o desenvolvimento de algoritmos híbridos.

Uma das vantagens comumente apontadas do PSO sobre outros algoritmos de otimização é o compartilhamento de informação entre as partículas (Eberhart & Shi 2001), (Robinson & Rahmat-Samii 2004). De uma forma simples isso significa que a partícula que encontrou a melhor solução do problema compartilha essa posição com todas as demais partículas, fazendo que todos comecem a se deslocar através de caminhos diferentes para aquela posição. Apesar de criarem uma forte tendência em direção as melhores posições do espaço de busca, não existe nenhum mecanismo que impeça que as partículas percorram caminhos que já tenham sido traçados por outras partículas, e definidos como soluções ruins para o problema, causando um desperdício de recurso computacional.

Uma forma já explorada de minimizar esse comportamento pode ser encontrada em (Wang 2009) que utiliza a posição da pior solução encontrada pelo exame como um termo na equação do cálculo da atualização de cada partícula. Apesar de ser uma abordagem

de acordo com os princípios do PSO ela apenas cria uma tendência da partícula de evitar uma determinada área do espaço de soluções.

Para criar um comportamento mais explícito neste trabalho é apresentado o conceito de zonas negativas. As zonas negativas são regiões dentro do espaço de busca onde as partículas do enxame são impedidas de percorrer. Para determinar essas zonas o algoritmo utiliza a cada geração a posição da partícula com pior *ranking* e com um valor de raio, r , com esses valores é especificada uma região onde nenhuma partícula pode entrar. Caso alguma partícula caia em alguma dessas regiões a sua velocidade e posição são recalculadas da seguinte forma:

$$\mathbf{V}_t = (-1 + \eta_3)(V)_t \quad (5.1)$$

$$\mathbf{X}_t = (X)_t + (V)_t \quad (5.2)$$

sendo η_3 uma valor aleatório entre 0 e 1.

Dessa forma a partícula é repelida pela zona negativa e ganha velocidade em uma nova direção proporcional a sua velocidade anterior. A Figura 5.1 ilustra o efeito das zonas negativas no caminho que cada partícula traça na busca da solução desejada.

A eficiência do algoritmo do HSPO-NZ é verificada por uma função clássica para testes de otimização proposta por (Kennedy & Eberhart 2001) conhecida como a função Rastrigin:

$$f = \sum_{i=1}^3 [a_i^2 - 10 \cos(2\pi a_i) + 10] \quad (5.3)$$

Na Figura 5.2 é ilustrado um exemplo da função Rastrigin com $N=2$, sendo o seu mínimo global localizado em $x_1 = x_2 = 0$

Para efeito de comparação todas as simulações foram realizadas utilizando os mesmos parâmetros apresentados em (Jin & Rahmat-Samii 2010) uma vez que os autores apresen-




Figura 5.1: Representação de um enxame em busca da melhor solução em um espaço bidimensional. Os círculos cinzas ilustram as possíveis zonas negativas onde as partículas são repelidas. O X simboliza o objetivo da otimização.




Figura 5.2: Topologia bidimensional da função Rastrigin

tam uma variação do algoritmo PSO para soluções de problemas de otimizações similares aos discutidos neste trabalho.

Em cada um dos testes o otimizador é um minimizador por padrão que busca encontrar o mínimo global da função sendo a otimização executada em um espaço de buscas de 18 dimensões consistindo de duas variáveis reais $R_1, R_2 \in [-5, 5]$ e dezesseis *bits* binários ($M = 2, N = 16$). Sendo $a_1 = R_1, a_2 = R_2$ e a_3 é relacionado com a parte binária através do seguinte mapeamento:

$$a_3 = \frac{10}{2^{16} - 1} \sum_{N=1}^{16} 2^{N-1} B_N - 5 \quad (5.4)$$

A implementação do algoritmo impõem uma condição de contorno para a parte real que impede que as variáveis reais assumam valores fora do espaço de busca.

Um enxame com 10 indivíduos é utilizado na otimização da função por 200 iterações. Devido à natureza estocástica dos algoritmos, o mesmo teste é repetido por 200 ensaios independentes.

Para comparação o mesmo problema foi resolvido através do algoritmo HPSO clássico. De acordo com (Jin & Rahmat-Samii 2010) um valor final menor que 0.5 é considerado como um resultado ótimo para a otimização.

Os histogramas das Figuras 5.3 e 5.4 apresentam os resultados das 200 otimizações independentes realizadas sobre a função Rastrigin. Utilizando o HPSO-NZ em 166 dos testes foram obtidos o resultado ótimo, enquanto que usando o HPSO apenas 135 testes retornaram um valor ótimo, uma diferença de aproximadamente 23% entre os dois algoritmos.

A Figura 5.5 apresenta a média, em 200 testes, dos melhores valores de aptidão em cada iteração para cada um dos algoritmos analisados.

A Tabela 2 apresenta a comparação do algoritmo HPSO-NZ com mais 4 diferentes algoritmos implementados em (Jin & Rahmat-Samii 2010) para a solução do mesmo

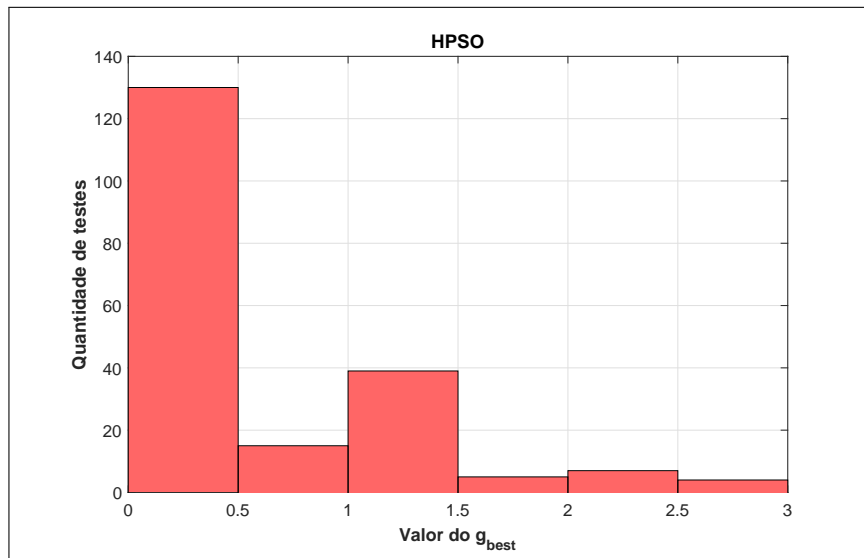


Figura 5.3: Histograma das soluções encontradas pelo HPSO em 200 testes independentes

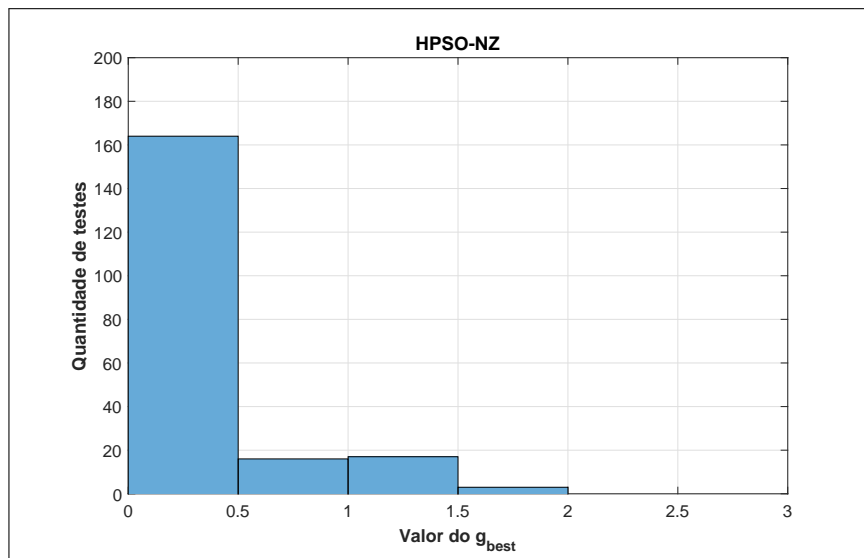


Figura 5.4: Histograma das soluções encontradas pelo HPSO-NZ em 200 testes independentes




Figura 5.5: Comparação entre as médias das melhores partículas em 200 testes independentes para HPSO-NZ, HPSO, BPSO, BGA e RPSO para a solução da função Rastrigin

problema. Esses resultados numéricos implicam que o algoritmo HPSO-NZ é computacionalmente eficiente na solução de problemas de otimização híbridos (real/binário) por oferecer uma maior possibilidade de convergência com os mesmos números de agentes e iterações que os demais algoritmos clássicos.

Tabela 5.1: Comparação entre 6 algoritmos para otimização da Função Rastrigin - (10 agentes, 200 iterações, 200 testes)

Algoritmo	$g_{best} < 0.5$
HPSO-NZ	166
HPSO	135
HPSO (Jin & Rahmat-Samii 2010)	137
BPSO (Jin & Rahmat-Samii 2010)	80
BGA (Jin & Rahmat-Samii 2010)	12
Round-Off RPSO (Jin & Rahmat-Samii 2010)	6

Como forma de melhorar o desempenho do algoritmo HPSO os autores em (Jin & Rahmat-Samii 2010) refazem os testes apresentados na Tabela 5.1 aumentando a quantidade de agentes e de iterações antes de terminar o processo. A Tabela 5.2 apresenta os resultados obtidos em (Jin & Rahmat-Samii 2010) em conjunto com os resultados obtidos

nas simulações do HPSO-NZ com os mesmos parâmetros.

Tabela 5.2: Comparação entre 6 algoritmos para otimização da Função Rastrigin - (20 agentes, 500 iterações, 200 testes)

Algoritmo	$g_{best} < 0.5$
HPSO-NZ	199
HPSO	199
HPSO (Jin & Rahmat-Samii 2010)	198
BPSO (Jin & Rahmat-Samii 2010)	199
BGA (Jin & Rahmat-Samii 2010)	105
Round-Off RPSO (Jin & Rahmat-Samii 2010)	11

Com o acréscimo de agentes e de iterações do algoritmo, foi possível obter uma taxa de acerto de aproximadamente 100% mas implicando no aumento do custo computacional total do algoritmo uma vez que com 20 agentes e 500 iterações são necessários 10000 cálculos da função *fitness* durante todo o processo. Para casos, como a otimização de estruturas eletromagnéticas, que necessitam de simulações complexas para o cálculo da função *fitness* a execução de tantos cálculos pode tornar o processo inviável.

Para compreender melhor o comportamento do algoritmo em situações com menos agentes e menos iterações as Tabelas 5.3 e 5.4 apresentam os resultados da solução da função Rastrigin para diferentes condições. Nos resultados apresentados foram efetuados 1000 testes independentes como forma de minimizar as variações estatísticas do resultados. As Tabelas mostram apenas a quantidade de testes que terminaram com a solução considerada ótima para o problema ($g_{best} < 0.5$).

Tabela 5.3: Comparação entre os algoritmos HPSO e HPSO-NZ para otimização da Função Rastrigin - (10 agentes, 1000 testes)

	200 iterações	300 iterações
HPSO	680	882
HPSO-NZ	817	920

Através dos resultados apresentados pelas Tabelas 5.3 e 5.4 pode-se verificar que o HPSO-NZ é capaz de atingir taxas de acerto maiores que 90% com menos agentes e

Tabela 5.4: Comparação entre os algoritmos HPSO e HPSO-NZ para otimização da Função Rastrigin - (15 agentes, 1000 testes)

	200 iterações	300 iterações
HPSO	829	953
HPSO-NZ	920	979

menos iterações o que pode significar um menor esforço computacional em casos específicos.

5.2 Aplicação do algoritmo HPSO-NZ

5.2.1 Antena *Dual-Band*

Para demonstrar os conceitos apresentados nas seções anteriores uma antena de microfita suspensa (Gardelli et al. 2004), como ilustra a Figura 5.6, foi utilizada para otimização. Neste modelo a geometria da antena é definida a partir de uma variável binária com 100 elementos e a posição da alimentação a partir de dois valores reais. A Tabela 3 apresenta os principais parâmetros da antena.




Figura 5.6: Geometria da antena suspensa

Como apresentado nos capítulos anteriores o parâmetro de otimização adotado é o ganho intrínseco, G_i , da antena, calculado como:

Tabela 5.5: Parâmetros da Antenna

Parâmetro	Valor
Largura Máxima, W	50mm
Comprimento Máximo, L	50mm
Frequência de ressonância 1	1.8 GHz
Frequência de ressonância 2	2.4 GHz
ϵ_{r1}	1
h_1	6 mm
h_2	1.6 mm
ϵ_{r2}	4.4
$\tan\gamma_2$	0.02
Quantidade de <i>pixels</i> internos	400

$$G_i = \frac{G_r}{1 - |S_{11}|^2} \quad (5.5)$$

onde G_r é o ganho real da antena definido na Equação 4.3, U é a intensidade de radiação em watts e P_{inc} é a potência incidente em watts.

O uso do ganho intrínseco assegura que o projeto é capaz de simultaneamente considerar as perdas devido o descasamento de impedâncias e as perdas de radiação, evitando a necessidade de um algoritmo multiobjetivo para tratar os dois problemas.

O objetivo da otimização é obter a configuração geométrica de uma antena com duas frequências de ressonância, para isso utiliza-se a seguinte função *fitness* para avaliar cada agente:

$$f(\vec{x}) = \min(G_{i,f_1}, G_{i,f_2}) \quad (5.6)$$

A Equação 5.6 representa uma forma de otimização minimax (Rajagopalan et al. 2014), onde o menor ganho entre as duas frequências de otimização é escolhido para ser maximizado.

Utilizando os parâmetros da Tabela 5.5 na implementação dos algoritmos HPSO e o HPSO-NZ para a otimização de uma antena foram obtidos resultados com as configura-

ções apresentada através das Figuras 5.7 e 5.8.




Figura 5.7: Configuração interna de *patches* obtida pelo HPSO para uma antena multi-banda (1.8 GHz/2.4 GHz)

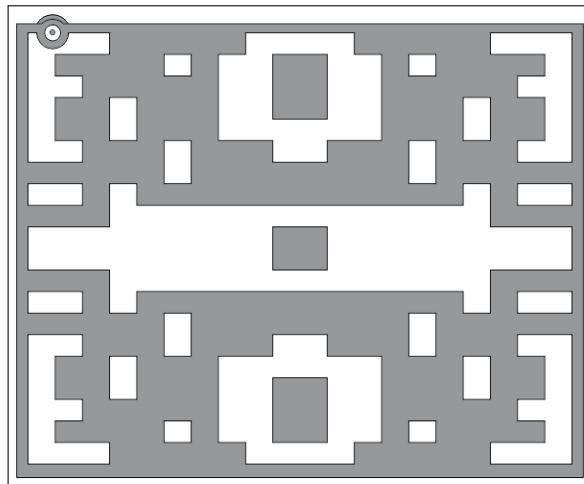


Figura 5.8: Configuração interna de *patches* obtida pelo HPSO-NZ para uma antena multi-banda (1.8 GHz/2.4 GHz)

A Figura 5.9 compara a evolução do g_{best} nos dois algoritmos. O HPSO-NZ teve como condição de parada o máximo de 100 iterações enquanto que o HPSO teve a condição de parada estendida para 200 iterações para obter um resultado similar.

A Figura 5.10 apresenta os resultados simulados da perda de retorno, S_{11} , para as duas geometrias.




Figura 5.9: Comparação entre a evolução do g_{best} ao longo da otimização para os algoritmos HPSO e HPSO-NZ




Figura 5.10: Resultado simulado do parâmetro S_{11} para as configurações obtidas pelos algoritmos HPSO e HPSO-NZ

5.2.2 Antena Tri-Band

Um projeto de antena compacta pode ser ainda mais desafiador quando existe a necessidade de expandir um projeto anterior através da inclusão de novas características. Para analisar a capacidade do algoritmo HPSO-NZ foram utilizados os mesmo parâmetros da Tabela 5.5 mas incluindo um terceiro objetivo, a busca por uma ressonância na frequência de 3.5 GHz, caracterizando assim um projeto de uma antena multibanda (1.8 GHz/2.4 GHz/3.5 GHz). Dessa forma o algoritmo deve descobrir qual configuração geométrica e qual posição da ponta de alimentação são ideais para obter o resultado desejado dentro do mesmo espaço restrito do problema anterior.

A Figura 5.11 apresenta a configuração obtida pelo algoritmo ao final de 100 iterações de otimização.




Figura 5.11: Configuração interna de *patches* obtida pelo HPSO-NZ para antena multibanda (1.8 GHz/2.4 GHz/3.5 GHz)

A Figura 5.12 ilustra a simulação do parâmetro S11 para a geometria final apresentada na Figura 5.11. Os resultados mostrados na Figura 5.12 confirmam a obtenção do objetivo esperado.




Figura 5.12: Resultado simulado para antena multibanda (1.8 GHz/2.4 GHz/3.5 GHz) obtida pelo HPSO-NZ

5.2.3 Antena reconfigurável

Estendendo a aplicação do algoritmo, foi implementado o HPSO-NZ para o desenvolvimento de uma antena com capacidade de reconfiguração de frequência similar ao projeto do Capítulo 4 mas utilizando o conceito de *patch* suspenso da Figura 4.9 que utiliza uma alimentação que permite um maior grau de liberdade de projeto e que automaticamente melhora os valores de ganho da antena. Para essa otimização o algoritmo foi configurado para obter uma geometria com respostas em 1.8 GHz e 2.45 GHz. O algoritmo obteve a geometria apresentada na Figura 5.14.

Considerando os mesmos diodos PIN utilizados na otimização da antena da Figura 4.9 e com uma camada de ar de 6 mm entre o *patch* e o plano terra. Na Figura 5.14 o ponto de alimentação pelo cabo coaxial é representada pelo círculo branco dentro do *patch* central. A Figura 5.14 mostra os resultados simulados da antena obtida para os modos *ON* e *OFF* da geometria obtida pelo algoritmo.

Este Capítulo apresentou uma nova variação do algoritmo clássico do PSO que é ainda mais robusta e capaz de obter resultados utilizando um conjunto menor de variáveis impli-




Figura 5.13: Configuração interna de *patches* obtida pelo HPSO-NZ para antena reconfigurável (1.8 GHz/2.4 GHz)




Figura 5.14: Simulação do parâmetro S_{11} da geometria da Figura 5.14

cando em uma redução do custo computacional do processo de otimização, o que é muito bem vindo em um campo de desenvolvimento que possui uma demanda alta relacionada a simulações computacionais de protótipos.

Foram apresentadas as comparações dos resultados de otimizações de problemas conhecidos de forma a validar as mudanças propostas e evidenciar os benefícios do novo algoritmo. Usando o HSPO-NZ duas antenas com as mesmas restrições, mas com características diferentes foram desenvolvidas pelo algoritmo, resultado em uma antena com comportamento *dual band* e uma antena *tri band*.

Capítulo 6

O HPSO-NZ e Superfícies Seletivas de Frequência

6.1 Superfícies Seletivas de Frequência

As superfícies seletivas de frequências são estruturas periódicas que interagem com ondas eletromagnéticas de forma seletiva de acordo com a frequência de operação (Wu 1995). Essas superfícies têm sido introduzidas com sucesso no projeto de antenas para diversos propósitos, como a supressão de ondas de superfície, antenas com maior largura de banda e antenas com controle de feixe (Habib et al. 2009). Mais recentemente, estruturas FSS têm sido aplicadas para o desenvolvimento de cavidades de Fabry-Pérot (Abdelghani et al. 2016)

Um dos passos mais importante no processo de desenvolvimento de uma FSS é a correta escolha dos elementos para o arranjo. O tipo do elemento, a geometria, os substratos, a presença ou não de superstratos, o espaçamento entre os elementos e diversos outros parâmetros determinam a resposta em frequência da estrutura, a largura de banda e a dependência do ângulo de incidência e polarização (Sarabandi & Behdad 2007). Uma revisão ampla de FSS tradicionais pode ser encontrada em (Wu 1995).

Contudo para enfrentar os desafios e exigências apresentadas pelos sistemas de comunicação atuais existe a necessidade de desenvolver novas soluções e estratégias para o

desenvolvimento de dispositivos de RF.

6.1.1 Estruturas Reconfiguráveis

Uma FSS reconfigurável é uma estrutura que é capaz de permitir ou bloquear a propagação de ondas eletromagnéticas pela ativação ou desativação de elementos ativos como diodos.

A unidade básica de uma FSS reconfigurável é apresentada na Figura 6.1. Os diodos são inseridos entre a linha descontínua. Essa unidade básica é reproduzida infinitamente ao longo do plano XY. Uma onda eletromagnética com o campo elétrico polarizado paralelamente a linha que incidir sobre essa estrutura irá apresentar o comportamento ilustrado na Figura 6.1. Em (Wu 1995) os autores avaliaram que um arranjo de fios paralelos contínuos age como um filtro passa-alta principalmente devido ao comportamento indutivo dos fios. Por outro lado, um arranjo similar de fios descontínuos se comporta como um filtro rejeita-faixa devido aos efeitos capacitivos apresentados pelos elementos descontínuos em série com seus efeitos indutivos. Com relação ao uso dos diodos PIN os autores em (Ribeiro 2004) e (Habib et al. 2009) fazem uma vasta investigação dos efeitos capacitivos causados em dispositivos de micro-ondas como antenas e FSS.

A Figura 6.1 é uma simulação de uma FSS ativa com uma célula de 20mm x 20mm, com uma linha de 1mm de espessura e uma descontinuidade de 1mm. O comportamento da estrutura é representado para os casos da linha contínua e para o caso da linha descontínua.

Seguindo o modelo de projeto binário estabelecido nos capítulos anteriores para a otimização de antenas, neste Capítulo o mesmo conceito é aplicado para a otimização de FSS. A Figura 6.2 apresenta um exemplo de célula binária de otimização, no centro da célula é incorporado uma linha metálica, de tamanho fixo, que serve para ativar o diodo PIN da célula.

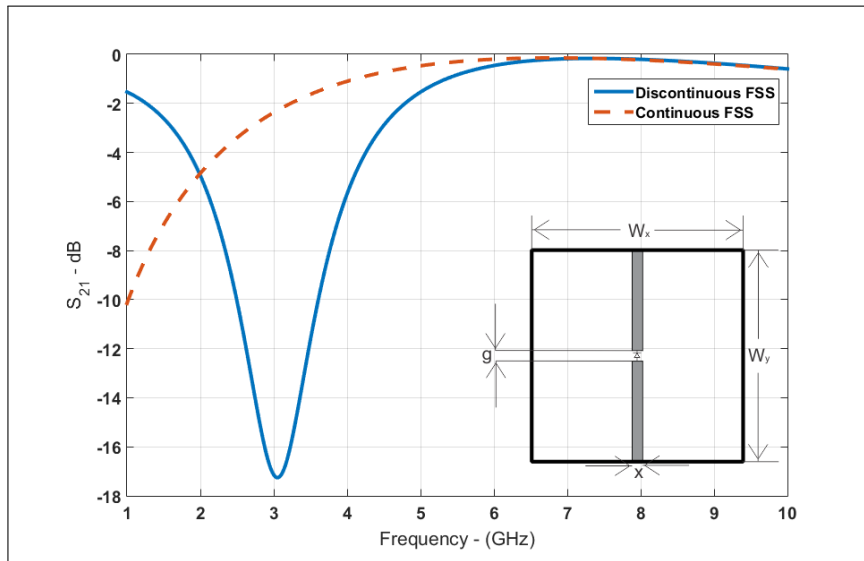


Figura 6.1: Célula básica de uma FSS reconfigurável e as respostas simuladas




Figura 6.2: Conceito de um *patch* binário de FSS

6.1.2 Projeto de uma FSS reconfigurável

O Projeto na Faixa de 7GHz

Utilizando o HPSO-NZ apresentado nos Capítulos anteriores e com os parâmetros estruturais sumarizados na Tabela 6.1 um processo de otimização iniciado para obter uma estrutura com resposta na faixa de 7 GHz. O tamanho da célula (W_x e W_y) foi tratado como o parâmetro real e a geometria interna da célula como o parâmetro binário do algoritmo HPSO-NZ.

Foi utilizando o diodo PIN da Infineon BAR64-03W para conectar as linhas entre as células.

Tabela 6.1: Principais parâmetros de implementação do HPSO-NZ

Parâmetros de Otimização	Valores
Largura máxima da célula (mm), W_x	100
Comprimento máximo da célula (mm), W_y	100
Frequência de atuação (GHz), f	7.0
Permissividade relativa do substrato (FR4), ϵ_r	4.4
Tangente de perdas do substrato, $\tan\delta$	0.02
Altura do substrato (mm), h_1	1.57
Quantidade de (patches) internos	400
Quantidade de (patches) utilizados no HPSO-NZ	100
Quantidade de soluções possíveis	2^{100}
Tamanho do enxame de partículas	20
Máximo de iterações do algoritmo	600

Nesta otimização o tamanho do *patch* metálico interno da célula foi condicionado para ser obrigatoriamente menor que o tamanho da célula, evitando que o *patch* preencha a célula por completo.

Ao final das 600 iterações o algoritmo apresentou como melhor resultado uma estrutura com célula de 20mm x 20mm e com a configuração de *patch* apresentada através da Figura 6.3.

A Figura 6.4 apresenta os resultados simulados e medidos da configuração obtida pelo algoritmo. As linhas sólidas são os resultados simulados e as linhas pontilhadas os valores




Figura 6.3: Configuração de *patches* internos para a otimização em 7 GHz.

medidos. O protótipo foi construído em uma lamina de FR4 de 20cm x 20cm resultando em uma FSS com 100 células que pode ser vista na Figura 6.5

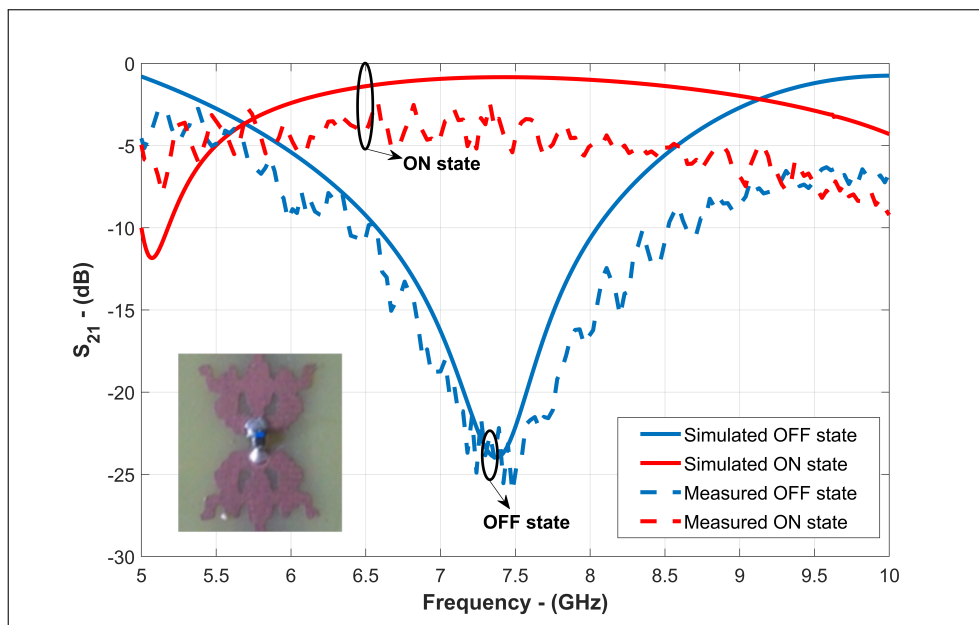


Figura 6.4: Resultados simulados e medidos do coeficiente de transmissão para a FSS otimizada em 7 GHz

A Figura 6.4 mostra que de acordo com o esperado a FSS atua como um filtro rejeita-

faixa próximo de 7 GHz quando os diodos PIN estão desativados e como um passa-faixa no momento em que os diodos são alimentados.

Os diodos PIN foram ativados usando uma fonte de corrente controlada para evitar qualquer dano aos circuitos. Em cada protótipo foram adicionadas duas linhas metálicas horizontais para servirem de barramento de alimentação como pode ser visto na Figura 6.5.




Figura 6.5: Foto do protótipo da FSS otimizada em 7GHz

O Projeto na Faixa de 3 GHz

Para testar o algoritmo de otimização em uma condição diferente da anterior, uma nova otimização foi realizada com algumas novas restrições e um novo objetivo.

O objetivo estabelecido visa a faixa de frequência de 3 GHz, que é o início da faixa de operação de sistemas UWB (3.1 GHz - 10.6 GHz), utilizando os mesmo parâmetros da otimização anterior, mas utilizando apenas 100 *pixels* interno. Essa alteração tem como objetivo testar a capacidade do algoritmo de obter soluções em casos diversos e diminuir a complexidade de construção do protótipo.

Ao final das 600 iterações o algoritmo apresentou como melhor resultado uma estrutura com célula de 60mm x 60mm e com a configuração de *patch* apresentada através da Figura 6.6.




Figura 6.6: Configuração de *patches* internos para a otimização em 3 GHz.

A Figura 6.7 apresenta os resultado medidos e simulados para a configuração de célula encontrada pelo algoritmo ao fim das 600 iterações.

Os resultados da Figura 6.7 mostram que a FSS é capaz de operar em dois estados diferentes na faixa de 3 GHz. Foram utilizados na construção do protótipo os didos PIN Infineon BAR64-03W(Technologies 2015) para a conexão das células.

Todos os resultados experimentais foram obtidos no laboratório de medidas de micro-ondas do IFPB (GTEMA), utilizando um analisador de redes de duas portas Agilent N5230A e duas antenas cornetas padrões de 20 dB. A Figura 6.8 mostra uma foto do

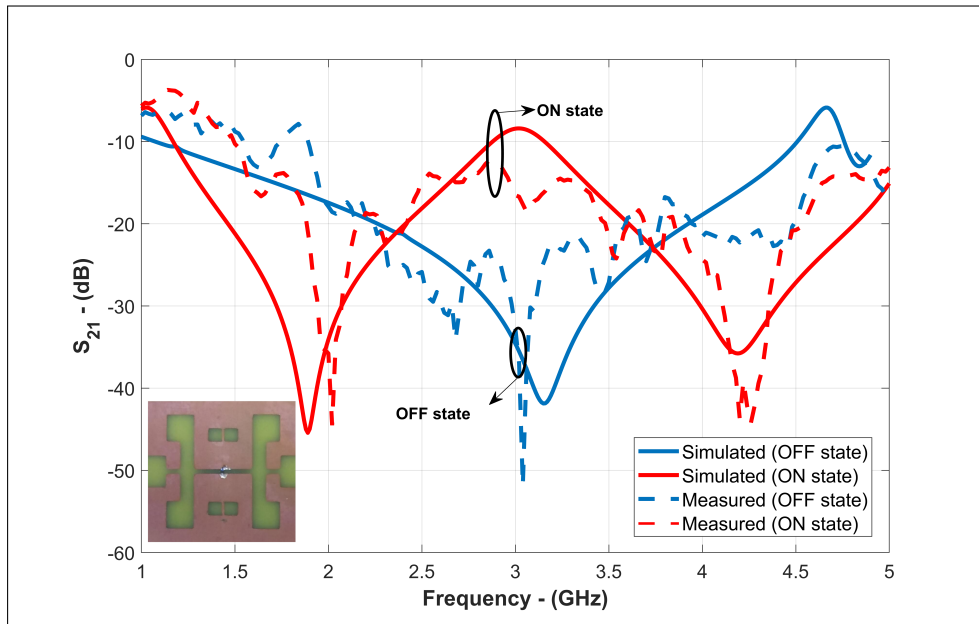


Figura 6.7: Resultados simulados e medidos do coeficiente de transmissão para a FSS otimizada em 3 GHz

setup de medição utilizado no laboratório.




Figura 6.8: Setup de medição utilizado para a medição das FSS

Capítulo 7

Conclusões

Neste trabalho são apresentados os conceitos básicos de rádios definidos por *software* e rádios cognitivos mostrando como essas tecnologias podem ser relevantes para a solução de problemas relacionados ao congestionamento do espectro eletromagnético.

Como ponto importante para o desenvolvimento dessas tecnologias também são estudados e desenvolvidos modelos de projetos de estruturas como antenas multibanda, antenas reconfiguráveis e superfícies seletivas de frequência.

Para os projetos das estruturas é utilizado como principal ferramenta o algoritmo *Particle Swarm Optimization* implementado e estudado para a aplicação específica do desenvolvimento das estruturas citadas. A implementação básica do algoritmo possibilitou a obtenção das estruturas iniciais e também mostrou os desafios com relação aos custos computacionais a serem enfrentados. Além dos desafios computacionais as primeiras implementações mostraram as dificuldades para os projetos de estruturas que atendessem as especificações desejadas e mantivessem um baixo custo de prototipação.

Para manter o baixo custo de prototipação o modelo base das antenas foi modificado passando a adotar um projeto com múltiplas camadas. Com uma camada dielétrica suspenso para diminuir os efeitos da alta tangente de perdas do material foi possível obter valores de perda de retorno e ganhos condizentes com as necessidades práticas. Com essa configuração foi possível verificar a robustez da metodologia de otimização que obteve os resultados esperados mesmo com uma estrutura mais complexa

Com o domínio da implementação do *PSO* foi possível propor uma modificação no algoritmo de forma que mesmo com o aumento da complexidade de implementação, é possível obter os resultados com uma menor quantidade de iterações diminuindo consequentemente a quantidade de simulações necessárias. Para validar essa contribuição o algoritmo desenvolvido, *HPSO-NZ*, foi comparado com algoritmos similares na solução de um mesmo problema de minimização tendo o algoritmo proposto apresentado resultados superiores a todos os algoritmos da comparação.

Como desenvolvimento natural dentro do grupo de pesquisa GEMA-UFRN o algoritmo desenvolvido foi aplicado ao desenvolvimento de Superfícies Seletivas de Frequência. Mantendo o escopo conceitual do trabalho e como contribuição para o desenvolvimento de FSS, as otimizações foram desenvolvidas para estruturas eletronicamente ativas e de geometria binária. As estruturas foram desenvolvidas para serem responsivas dentro da faixa de frequência de sistemas *UWB* que varia entre 3.1GHz e 10GHz. Os resultados obtidos mostraram que é possível desenvolver novas geometrias com as funcionalidades propostas dentro da faixa de frequência determinada.

Com os desenvolvimentos de três pontos principais dentro deste projeto: a otimização de antenas reconfiguráveis, contribuição para desenvolvimento de um algoritmo de otimização focado em estruturas eletromagnéticas e o desenvolvimento de FSSs reconfiguráveis. Os possíveis trabalhos que podem ser desenvolvidos a partir do conhecimento acumulado incluem:

1. O estudo da otimização de estruturas de *Fabry-Pérot*, que são basicamente antenas integradas com FSSs de forma terem um aumento do ganho de irradiação.
2. O aprofundamento no desenvolvimento do *HPSO-NZ*, estudando o maior efeito da escolha dos limites das zonas negativas, alternativas a zona negativa de acordo com o tipo de parâmetro, influência da quantidade de zonas negativas e novas formas de repelir os indivíduos que estão em uma zona negativa.
3. O desenvolvimento de antenas e FSS reconfiguráveis com mais de dois estados.

4. O estudo da reconfiguração de outros parâmetros como ganho e diagrama de radiação.
5. Aplicação do *HPSO-NZ* para FSS de múltiplas camadas.
6. O estudo da otimização de FSS de acordo com o ângulo de incidência.

Referências Bibliográficas

- Abdelghani, M., H. Attia & T. A. Denidni (2016), ‘Dual- and wide-band fabry-perot resonator antenna for wlan applications’, *IEEE Antennas and Wireless Propagation Letters* **PP**(99), 1–1.
- Axell, E., G. Leus, E.G. Larsson & H.V. Poor (2012), ‘Spectrum sensing for cognitive radio : State-of-the-art and recent advances’, *Signal Processing Magazine, IEEE* **29**(3), 101–116.
- Back, T., U. Hammel & H. P. Schwefel (1997), ‘Evolutionary computation: comments on the history and current state’, *IEEE Transactions on Evolutionary Computation* **1**(1), 3–17.
- Balanis, Constantine A. (2005), *Antenna Theory*, Wiley.
- Buracchini, E. (2000), ‘The software radio concept’, *Communications Magazine, IEEE* **38**(9), 138–143.
- Cheng, Y. F., W. Shao, S. J. Zhang & Y. P. Li (2016), ‘An improved multi-objective genetic algorithm for large planar array thinning’, *IEEE Transactions on Magnetics* **52**(3), 1–4.
- Christodoulou, C.G., Y. Tawk, S.A. Lane & S.R. Erwin (2012), ‘Reconfigurable antennas for wireless and space applications’, *Proceedings of the IEEE* **100**(7), 2250–2261.
- Coello, C.A.C., G.T. Pulido & M.S. Lechuga (2004), ‘Handling multiple objectives with particle swarm optimization’, *Evolutionary Computation, IEEE Transactions on* **8**(3), 256–279.

- Cruz, R. M. S., P. H. da F. Silva & A. G. D'Assuncao (2009), Synthesis of crossed dipole frequency selective surfaces using genetic algorithms and artificial neural networks, *em* '2009 International Joint Conference on Neural Networks', pp. 627–633.
- da Silva, P.H.F., P. Lacouth, G. Fontgalland, A.L.P. Campos & A.G. d'Assuncao (2007), Design of frequency selective surfaces using a novel mom-ann-ga technique, *em* 'Microwave and Optoelectronics Conference, 2007. IMOC 2007. SBMO/IEEE MTT-S International', pp. 275–279.
- Eberhart & Yuhui Shi (2001), Particle swarm optimization: developments, applications and resources, *em* 'Evolutionary Computation, 2001. Proceedings of the 2001 Congress on', Vol. 1, pp. 81–86 vol. 1.
- Gardelli, R., G. La Cono & M. Albani (2004), 'A low-cost suspended patch antenna for wlan access points and point-to-point links', *Antennas and Wireless Propagation Letters, IEEE* **3**(1), 90–93.
- Gies, D. & Y. Rahmat-Samii (2004), Vector evaluated particle swarm optimization (vepsa): optimization of a radiometer array antenna, *em* 'Antennas and Propagation Society International Symposium, 2004. IEEE', Vol. 3, pp. 2297–2300 Vol.3.
- Greff, M. & A.P. Engelbrecht (2008), Solving dynamic multi-objective problems with vector evaluated particle swarm optimisation, *em* 'Evolutionary Computation, 2008. CEC 2008. (IEEE World Congress on Computational Intelligence). IEEE Congress on', pp. 2917–2924.
- Habib, M.A., M.N. Jazi, A. Djaiz, M. Nedil & T.A. Denidni (2009), Switched-beam antenna based on ebg periodic structures, *em* 'Microwave Symposium Digest, 2009. MTT '09. IEEE MTT-S International', pp. 813–816.
- Hall, P.S., P. Gardner & A. Faraone (2012), 'Antenna requirements for software defined and cognitive radios', *Proceedings of the IEEE* **100**(7), 2262–2270.

- Haykin, Simon (2005), 'Cognitive radio: brain-empowered wireless communications', *Selected Areas in Communications, IEEE Journal on* **23**(2), 201–220.
- Jin, N. & Y. Rahmat-Samii (2010), 'Hybrid real-binary particle swarm optimization (hps) in engineering electromagnetics', *IEEE Transactions on Antennas and Propagation* **58**(12), 3786–3794.
- Jin, Nanbo & Y. Rahmat-Samii (2007), 'Advances in particle swarm optimization for antenna designs: Real-number, binary, single-objective and multiobjective implementations', *Antennas and Propagation, IEEE Transactions on* **55**(3), 556–567.
- Kennedy, J. & R. Eberhart (1995), Particle swarm optimization, *em 'Neural Networks, 1995. Proceedings., IEEE International Conference on'*, Vol. 4, pp. 1942–1948 vol.4.
- Kennedy, J. & R.C. Eberhart (1997), A discrete binary version of the particle swarm algorithm, *em 'Systems, Man, and Cybernetics, 1997. Computational Cybernetics and Simulation., 1997 IEEE International Conference on'*, Vol. 5, pp. 4104–4108 vol.5.
- Kennedy, J. & W. M. Spears (1998), Matching algorithms to problems: an experimental test of the particle swarm and some genetic algorithms on the multimodal problem generator, *em 'Evolutionary Computation Proceedings, 1998. IEEE World Congress on Computational Intelligence., The 1998 IEEE International Conference on'*, pp. 78–83.
- Kennedy, James & Russell C. Eberhart (2001), *Swarm Intelligence*, Morgan Kaufmann Publishers Inc., San Francisco, CA, USA.
- Lou, S. & H.C. Luong (2008), A 0.81 ghz to 10.6 ghz sdr low-noise amplifier in 0.13 micron cmos, *em 'Custom Integrated Circuits Conference, 2008. CICC 2008. IEEE'*, pp. 65–68.

- Mahmood, S.M. & T.A. Denidni (2014), Reconfigurable antenna using novel active frequency selective surface, *em* 'Antennas and Propagation Society International Symposium (APSURSI), 2014 IEEE', pp. 1236–1237.
- Mikki, S. & A. Kishk (2008), *Particle Swarm Optimizaton:A Physics-Based Approach*, Morgan and Claypool.
- Miranda, V. & N. Fonseca (2002), Epso - best-of-two-worlds meta-heuristic applied to power system problems, *em* 'Evolutionary Computation, 2002. CEC '02. Proceedings of the 2002 Congress on', Vol. 2, pp. 1080–1085.
- Rahmat-Samii, Y. (2007), Modern antenna designs using nature inspired optimization techniques: Let darwin and the bees help designing your multi band mimo antennas, *em* 'Radio and Wireless Symposium, 2007 IEEE', pp. 463–466.
- Rahmat-Samii, Y., J.M. Kovitz & H. Rajagopalan (2012), 'Nature-inspired optimization techniques in communication antenna designs', *Proceedings of the IEEE* **100**(7), 2132–2144.
- Rajagopalan, H., J.M. Kovitz & Y. Rahmat-Samii (2014), 'Mems reconfigurable optimized e-shaped patch antenna design for cognitive radio', *Antennas and Propagation, IEEE Transactions on* **62**(3), 1056–1064.
- Ribeiro, Alex Sandro (2004), Projeto de circuitos chaveadores com diodos pin para antenas quasi-yagi ativas aplicado às comunicações móveis, Dissertação de mestrado, Unicamp.
- Robinson, J., S. Sinton & Y. Rahmat-Samii (2002), Particle swarm, genetic algorithm, and their hybrids: optimization of a profiled corrugated horn antenna, *em* 'Antennas and Propagation Society International Symposium, 2002. IEEE', Vol. 1, pp. 314–317 vol.1.

- Robinson, J. & Y. Rahmat-Samii (2004), ‘Particle swarm optimization in electromagnetics’, *IEEE Transactions on Antennas and Propagation* **52**(2), 397–407.
- Sarabandi, K. & N. Behdad (2007), ‘A frequency selective surface with miniaturized elements’, *IEEE Transactions on Antennas and Propagation* **55**(5), 1239–1245.
- Tawk, Y., J. Costantine & C.G. Christodoulou (2014a), ‘Cognitive-radio and antenna functionalities: A tutorial [wireless corner]’, *Antennas and Propagation Magazine, IEEE* **56**(1), 231–243.
- Tawk, Y., J. Costantine & C.G. Christodoulou (2014b), ‘Reconfigurable filtennas and mimo in cognitive radio applications’, *Antennas and Propagation, IEEE Transactions on* **62**(3), 1074–1083.
- Technologies, Infineon (2015), ‘Infineon datasheet’.
- URL:** http://www.infineon.com/dgdl/Infineon-BAR64SERIES-DS-v01_01-en.pdf?fileId=db3a304314dca3890114fef8f4ca0aca
- Wang, Hui (2009), An improved particle swarm optimization using best neighbor with worst particle and its application in soft-sensor of gasoline endpoint, *em* ‘2009 International Conference on Apperceiving Computing and Intelligence Analysis’, pp. 387–390.
- Wu, T. K. (1995), *Frequency Selective Surface and Grid Array*, John Wiley and Sons.