



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO



Análise e Síntese de Superfícies Seletivas de Frequência Bioinspiradas usando Redes Neurais para Aplicações em Sistemas de Comunicação sem Fio

SAMUEL BELARMINO DE PAIVA

Orientador: Prof. Dr. Adaildo Gomes D'Assunção

Coorientador: Prof. Dr. Valdemir Praxedes da Silva Neto

Exame de Defesa de Mestrado apresentado ao Programa de Pós-Graduação em Engenharia Elétrica e da Computação da UFRN (área de concentração: Telecomunicações) como parte dos requisitos para obtenção do título de Mestre em Ciências.

Número de Ordem do PPgEEC: M550

Natal, RN, julho de 2019.

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

Paiva, Samuel Belarmino de.

Análise e síntese de superfícies seletivas de frequência bioinspiradas usando redes neurais para aplicações em sistemas de comunicação sem fio / Samuel Belarmino de Paiva. - 2019.
83f.: il.

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

Orientador: Dr. Adaildo Gomes D'Assunção.

Coorientador: Dr. Valdemir Praxedes da Silva Neto.

1. Trevo de quatro folhas - Dissertação. 2. Folha maple - Dissertação. 3. Síntese - Dissertação. 4. Redes neurais artificiais - Dissertação. 5. Regularização bayesiana - Dissertação. I. D'Assunção, Adaildo Gomes. II. Silva Neto, Valdemir Praxedes da. III. Título.


RN/UF/BCZM

CDU 004.8

**Análise e Síntese de Superfícies Seletivas de
Frequência Bioinspiradas Usando Redes Neurais
para Aplicações em Sistemas de Comunicação sem
Fio**


SAMUEL BELARMINO DE PAIVA


Exame de Defesa de Mestrado aprovado em 01 de julho de 2019 pela banca examinadora composta pelos seguintes membros:



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


Prof. Dr. Valdemir Praxedes da Silva Neto (coorientador).....DCO/UFRN


Prof. Dr. Hertz Wilton de Castro Lins.....DCO/UFRN


Prof. Dr. José Alfredo Ferreira Costa.....DEE/UFRN


Prof. Dr. Adaildo Gomes D'Assunção Junior.....IFPB


Prof. Dr. Glaucio Fontgalland.....UFCG

*“When kids look up to great scientists the way
they to do great musicians and actors, civilization
will jump to the next level”.*

Brian Greene.

Agradecimentos

A Deus, por me dar saúde, sabedoria e força para vencer os desafios enfrentados na minha vida.

Aos meus pais, Edmilson e Gisonete, por sempre me ajudarem e darem o apoio necessário na minha vida.

Ao meu irmão Daniel, pelo companheirismo, e à minha prima Tércia, por sempre me apoiar e aconselhar quando preciso. Aos meus avós: Francisco (*in memoriam*), Heronildas (*in memoriam*), Júlia (*in memoriam*) e Severino. Aos meus tios e tias: Ecielho, Girleno, Iracema, Irenilda, Ivonete e Meire. Aos meus primos e primas: Calebe, Hadassa, Igor, Juliana e Luciane.

Ao meu orientador, o professor Adaildo Gomes D'Assunção, pela confiança em mim depositada, pela amizade, pelas sábias ideias e pela humildade e paciência que possui.

Ao meu coorientador, professor Valdemir Praxedes da Silva Neto, que me orienta desde a época de graduação e me ensinou muito do que sei hoje, e que me fez entrar nessa área de pesquisa.

Ao professor Adaildo Gomes D'Assunção Junior, pela ajuda nas medições dos dispositivos.

À Denise, pelo apoio e motivação que me deu ao longo do mestrado.

Aos colegas e amigos de mestrado: Arimatéia, Deyvid, Kaio e Nayana.

Aos meus amigos Adeilson, Júnior, Rodolfo e Yasmin, e às demais pessoas que me ajudaram nesse trabalho.

À CAPES pelo auxílio financeiro, à UFRN, e ao IFPB por ceder o laboratório para a realização das medições.

Resumo

Este trabalho propõe a análise de Superfícies Seletivas de Frequência Bioinspiradas (*Bioinspired Frequency Selective Surfaces* - BFSS), para aplicações em sistemas de comunicações sem fio, operando na banda C, na banda Ku e em UWB (*ultra-wideband*). São consideradas estruturas de BFSS simples e acopladas. As BFSS possuem os elementos *patches* dos arranjos com os formatos do trevo de quatro folhas e da folha maple, e apresentaram resposta *dual-band*, com as frequências de operação nas bandas C e Ku. Para o desenvolvimento das BFSS com a banda ultra larga, foi desenvolvida uma estrutura em cascata, em que uma FSS com elementos patches com o formato de espiras quadradas foi acoplada às BFSS. Além disso, foi desenvolvida a síntese da BFSS no trevo de quatro folhas, utilizando uma rede neural artificial com arquitetura *feedforward* em cascata e com algoritmo de treinamento regularização Bayesiana, para obtenção das especificações de frequências de ressonância e respectivas larguras de bandas desejadas. Os valores numéricos encontrados por meio de simulações para os protótipos projetados foram obtidos pelo software ANSYS HFSS. Os protótipos foram confeccionados e foi realizada a caracterização experimental, cujos valores obtidos foram comparados aos resultados de simulação, os quais mostraram boa concordância.

PALAVRAS-CHAVE: Superfície seletiva de frequência bioinspirada, trevo de quatro folhas, folha maple, síntese, redes neurais artificiais, regularização bayesiana.

Abstract

This work proposes the analysis of Bioinspired Frequency Selective Surfaces (BFSS) for applications in wireless systems, operating in the C band, Ku band and UWB (ultra-wideband). Simple and coupled BFSS structures are considered. The BFSSs have array elements with the four-leaf clover-shaped and maple leaf-shaped, and presented dual-band response, with the operating frequencies in the C and Ku bands. For the development of BFSSs with the ultra-wideband, a cascade structure was developed, in which a FSS with elements with patches with the shape of square loops was coupled to the BFSSs. In addition, the four-leaf clover BFSS synthesis was developed using an artificial neural network with an architecture cascade feedforward and Bayesian regularization training algorithm to obtain the specifications of resonance frequency and respective desired bandwidths. The numerical values obtained by simulations for the projected prototypes were obtained by the ANSYS HFSS software. The prototypes were manufactured and the experimental characterization was performed, whose values were compared to simulation results, which showed good agreement.

KEY-WORDS: Bioinspired frequency selective surface, four leaf clover, maple leaf, synthesis, artificial neural networks, Bayesian regularization.

Sumário

Sumário	I
Lista de Ilustrações	III
Lista de Tabelas	VI
Lista de Símbolos e Abreviaturas	VII
Capítulo 1 Introdução	1
Capítulo 2 Superfícies Seletivas de Frequência	3
2.1 Principais Características	3
2.2 Tipos de Geometrias dos Elementos <i>Patches</i> das FSS	5
2.3 Técnicas de Análise	6
2.3.1 Método do Circuito Equivalente	7
2.3.2 Método dos Momentos	7
2.3.3 Método dos Elementos Finitos	8
2.3.4 Método das Diferenças Finitas no Domínio do Tempo	8
2.3.5 Método WCIP	9
2.3.6 Softwares Comerciais	9
2.4 Técnicas de Medição	9
Capítulo 3 Projeto das BFSS	11
3.1 BFSS no Trevo de Quatro Folhas	11
3.2 UWB BFSS em Trevo de Quatro Folhas	17
3.3 BFSS na Folha Maple	23
3.4 UWB BFSS na Folha Maple	25
Capítulo 4 Redes Neurais Artificiais e Implementação da Síntese da BFSS no Trevo de Quatro Folhas	27
4.1 Redes Neurais Artificiais	27

4.2 Modelagem de um Neurônio	28
4.3 Funções de Ativação	30
4.3.1 Funções de Ativação Parcialmente Diferenciáveis.....	30
4.3.2 Funções de Ativação Totalmente Diferenciáveis	32
4.4 Arquiteturas de Redes Neurais Artificiais	35
4.4.1 Arquitetura <i>Feedforward</i> de Camada Simples	36
4.4.2 Arquitetura <i>Feedforward</i> de Camadas Múltiplas	36
4.4.3 Arquitetura Recorrente ou Realimentada	37
4.4.4 Arquitetura em Estrutura Reticulada	38
4.5 Aspectos de Treinamento e Aprendizado	38
4.6 Perceptrons de Camada Única e de Múltiplas Camadas	40
4.6.1 Perceptron de Camada Única.....	40
4.6.2 Perceptron de Múltiplas Camadas	40
4.7 Algoritmos de Treinamento	42
4.7.1 Método do Gradiente Conjugado Escalar	43
4.7.2 Método Levenberg-Marquardt.....	43
4.7.3 Regularização Bayesiana	44
4.8 Implementação da Síntese da BFSS no Trevo de Quatro Folhas	48
Capítulo 5 Conclusões	55
Capítulo 6 Trabalhos Futuros	57
Referências Bibliográficas	58
Apêndice A – Banco de Dados com as Amostras	63

Lista de Ilustrações

Figura 2-1 - Representação da estrutura de uma FSS.....	3
Figura 2-2 - Superfícies Seletivas de Frequência: (a) arranjo do tipo <i>patch</i> e (b) do tipo abertura.	4
Figura 2-3 – Em (a) é mostrada a representação de um arranjo excitado pela onda incidente E_i , e em (b) de um arranjo excitado por geradores individuais conectados a cada elemento. Em que Z_L são as impedâncias de carga.....	5
Figura 2-4 – Formas de algumas das geométricas de FSS.	6
Figura 2-5 – Fotografia de uma câmara anecóica para medição dos parâmetros de uma FSS.....	10
Figura 2-6 - Representação de um <i>setup</i> para medição dos parâmetros de uma FSS utilizando lentes gaussianas.....	10
Figura 3-1 – <i>Setup</i> de medição para caracterização experimental das BFSS.....	11
Figura 3-2 – Representação da geometria do elemento <i>patch</i> da BFSS no trevo de quatro folhas.	12
Figura 3-3 – Fotografia do protótipo da BFSS no trevo de quatro folhas.	12
Figura 3-4 - Resultados medidos e simulados para os coeficientes de transmissão da BFSS no trevo de quatro folhas.	13
Figura 3-5 - Resultados de simulação para o coeficiente de transmissão da BFSS no trevo de quatro folhas considerando diferentes ângulos de incidência oblíqua.	14
Figura 3-6 - Resultados medidos e simulados para os coeficientes de transmissão da BFSS no trevo de quatro folhas em diferentes ângulos de incidência oblíqua: a) 10°, b) 20°, c) 30°, d) 40°.....	15
Figura 3-7 - Geometria com a forma Espira Quadrada da FSS proposta. Em a) é mostrada a representação e as dimensões, e em b) é mostrada uma fotografia do protótipo desenvolvido.	19
Figura 3-8 - Ilustração da estrutura em cascata para obter a resposta UWB da BFSS no trevo de quatro folhas.	19
Figura 3-9 - Resultados medidos e simulados para os coeficientes de transmissão da BFSS no trevo de quatro folhas com resposta UWB.....	20

Figura 3-10 - Resultados de simulação para o coeficiente de transmissão da BFSS no trevo de quatro folhas com resposta UWB em diferentes ângulos de incidência oblíqua.....	20
Figura 3-11 - Resultados medidos e simulados para os coeficientes de transmissão da BFSS no trevo de quatro folhas com resposta UWB em diferentes ângulos de incidência oblíqua: a) 10°, b) 20°, c) 30°, d) 40°.....	22
Figura 3-12 - Representação da geometria da BFSS na folha maple.	23
Figura 3-13 – Fotografia do protótipo da BFSS na folha maple.	24
Figura 3-14 - Resultados medidos e simulados para os coeficientes de transmissão da BFSS na folha maple.	24
Figura 3-15 - Ilustração da estrutura em cascata para obter a resposta UWB da BFSS na folha maple.	25
Figura 3-16 - Resultados medidos e simulados para os coeficientes de transmissão da BFSS na folha maple com resposta UWB.	26
Figura 4-1 – Representação do diagrama em blocos de um neurônio.....	29
Figura 4-2 – Representação da função de ativação degrau.	31
Figura 4-3 – Representação da função de ativação degrau bipolar.	31
Figura 4-4 – Representação da função de ativação rampa simétrica.....	32
Figura 4-5 – Representação da função de ativação sigmoide.....	33
Figura 4-6 – Representação da função de ativação tangente hiperbólica.....	33
Figura 4-7 – Representação da influência do parâmetro a função de ativação tangente hiperbólica.	34
Figura 4-8 – Representação da função de ativação gaussiana.....	34
Figura 4-9 – Representação da função de ativação linear.	35
Figura 4-10 – Representação de uma rede <i>feedforward</i> de camada simples.....	36
Figura 4-11 – Representação de uma rede <i>feedforward</i> de camadas múltiplas.....	37
Figura 4-12 – Representação de uma rede recorrente ou realimentada.....	38
Figura 4-13 – Representação de uma rede Perceptron de múltiplas camadas.....	41
Figura 4-14 – Representação da rede neural <i>feedforward</i> em Cascata utilizada para desenvolver a síntese.	48
Figura 4-15 – Representação dos parâmetros analisados na síntese da BFSS no trevo de quatro folhas.	48

Figura 4-16 – Desempenho da rede neural para a BFSS no trevo de quatro folhas.....	49
Figura 4-17 – Resultados de simulação da BFSS no trevo de quatro folhas após a utilização da síntese para encontrar as especificações desejadas para as frequências de ressonância de 4,4 e 14,3 GHz, e larguras de banda de 1,53 GHz e 1,29 GHz, respectivamente..	50
Figura 4-18 – Resultados de simulação da BFSS no trevo de quatro folhas após a utilização da síntese para encontrar as especificações desejadas para as frequências de ressonância de 5,8 e 20 GHz, e larguras de banda de 2 GHz.....	51
Figura 4-19 – Resultados de simulação da BFSS no trevo de quatro folhas após a utilização da síntese para encontrar as especificações desejadas para as frequências de ressonância de 10 e 24 GHz, e larguras de banda de 2 GHz e 1,5 GHz, respectivamente.....	53

Lista de Tabelas

Tabela 3-1 - Resultados medidos e simulados da BFSS no trevo de quatro folhas para a primeira banda de ressonância.....	17
Tabela 3-2 - Resultados medidos e simulados da BFSS no trevo de quatro folhas para a segunda banda de ressonância.	17
Tabela 3-3 - Resultados medidos e simulados da BFSS no trevo de quatro folhas com resposta UWB.....	23
Tabela 3-4 - Resultados medidos e simulados da BFSS na folha maple.....	25
Tabela 4-1 – Variação dos parâmetros da BFSS no trevo de quatro folhas.	49
Tabela 4-2 – Valores desejados comparados aos valores obtidos por simulações, e o erro apresentado entre eles, para as três estruturas simuladas.....	53

Lista de Símbolos e Abreviaturas

ADS	<i>Advanced Design System</i>
BFSS	<i>Bioinspired Frequency Selective Surface</i> (Superfície Seletiva de Frequência Bioinspirada)
BW	<i>Bandwidth</i> (Largura de Banda)
CST	<i>Computer Simulation Technology</i>
E^i	Onda plana incidente
E^r	Onda plana refletida
E^t	Onda plana transmitida
FDTD	<i>Finite-Difference Time Domain</i> (Diferenças Finitas no Domínio do Tempo)
FEM	<i>Finite-Element Method</i> (Método dos Elementos Finitos)
FMT	<i>Fourier Modal Transform</i> (Transformada Modal de Fourier)
f_r	Frequência de ressonância
FSS	<i>Frequency Selective Surface</i> (Superfície Seletiva de Frequência)
h	Altura do substrato
HFSS	<i>High Frequency Structural Simulator</i>
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
IFMT	<i>Inverse Fourier Modal Transform</i>
MEMS	<i>Micro-Electro-Mechanical Systems</i> - sistemas micro-eleto-mecânico
MLP	<i>Multilayer Perceptron</i> (Perceptron Multicamadas)
MoM	<i>Method of Moments</i> (Método dos Momentos)
MSE	<i>Mean Square Error</i> (Erro Médio Quadrático)
RBF	<i>Radial Basis Function</i> (Função de Base Radial)
RNA	Rede Neural Artificial
RF	<i>Radio Frequency</i> (Rádio Frequência)
TE	<i>Transverse Electric</i> (Transversal Elétrico)

TM	<i>Transverse Magnetic</i> (Transversal Magnético)
WCIP	<i>Wave Concept Iterative Procedure</i> (Método Iterativo das Ondas)
WLAN	<i>Wireless Local Area Network</i> (Rede Local sem Fio)
ϵ_r	Constante dielétrica do substrato
λ	Comprimento de onda

Capítulo 1

Introdução

Os sistemas de comunicações sem fio modernos têm exigido cada vez mais dispositivos que possuam diversas frequências de operação e forneçam altas taxas de transmissão de dados. Com isso, é necessário o estudo e desenvolvimento de novos componentes que atendam esta atual demanda nos sistemas de telecomunicações [1].

O estudo e análise de novas configurações de dispositivos e circuitos planares de microfita, como as Superfícies Seletivas de Frequência (*Frequency Selective Surfaces* - FSSs), é fundamental para o avanço dos atuais sistemas de comunicações, cuja demanda exige dispositivos e circuitos que possuam pequenas dimensões, de baixo custo, baixo peso, de fácil construção e integração com outros circuitos e que possam operar em banda larga ou ultra-larga (*ultra-wideband* - UWB) [1].

A natureza, ao longo de milhões de anos de processos evolutivos e de seleção natural, produziu estruturas geométricas bastante otimizadas para absorção da luz solar, para transformá-la em energia química, como as folhas, por exemplo [2]. Diante disso, atualmente, pesquisadores têm aplicado as formas geométricas encontradas na natureza para a produção de *patches* de antenas de microfita, para diversas aplicações [2] - [6], conforme pode-se encontrar na literatura científica. Entretanto, o estudo de Superfícies Seletivas de Frequência Bioinspiradas (*Bioinspired Frequency Selective Surfaces* - BFSSs) é recente na comunidade científica.

Mesmo com as vantagens que as FSS ou BFSS, como veremos, possuem, a aplicação de certas geometrias em um projeto pode tornar a análise muito complexa ao se utilizar os métodos numéricos de análise comumente encontrados na literatura. Com isso, uma das alternativas encontradas por vários pesquisadores para solucionar esse problema é a utilização das Redes Neurais Artificiais (RNA), para o desenvolvimento do projeto da FSS/BFSS com as características desejadas [7] - [12].

Pode-se definir uma RNA como um processador paralelamente distribuído, composto por unidades de processamento simples, que possuem a propensão natural para armazenar conhecimento experimental e disponibilizá-lo para uso [7], [13]. As redes neurais são

multidisciplinares, e são aplicadas em várias áreas do conhecimento, tais como engenharias [14], [15], química [16], biologia [17], física [18], economia e finanças [19], estatística [20] e medicina [21].

O principal objetivo deste trabalho é o estudo e desenvolvimento de superfícies seletivas de frequência bioinspiradas e a síntese de uma das estruturas propostas com a utilização de redes neurais e algoritmo de regularização bayesiana, para aplicações em sistemas de comunicações sem fio.

No capítulo 2 será realizada uma revisão bibliográfica sobre as FSS, mostrando as principais características, os tipos, as técnicas numéricas de análise, as técnicas de medição etc.

O capítulo 3 apresentará o desenvolvimento das BFSS propostas neste trabalho. Serão mostrados os resultados obtidos através de simulações e os valores serão comparados aos resultados encontrados após a caracterização experimental dos protótipos.

No capítulo 4 é realizada uma revisão bibliográfica sobre as redes neurais artificiais, em que são apresentadas as principais arquiteturas, as funções de ativação, os principais algoritmos de treinamento (com enfoque na regularização bayesiana) e a implementação da síntese na BFSS analisada.

O capítulo 5 apresenta as conclusões do trabalho, com ênfase nas contribuições mais relevantes.

No capítulo 6 são apresentados os trabalhos futuros a serem desenvolvidos a partir deste trabalho.

Por fim, são apresentadas as referências bibliográficas e no Apêndice A é mostrado o banco de dados com as amostras obtidas por simulações para a construção do banco de dados para implementação da síntese da BFSS analisada.

Capítulo 2

Superfícies Seletivas de Frequência

Pode-se definir uma Superfície Seletiva de Frequência como um filtro de micro-ondas espacial, composto por patches metálicos periódicos ou uma placa condutora perfurada com elementos em abertura, de modo que possa ser realizada a transmissão ou reflexão das ondas eletromagnéticas em uma determinada frequência, com a função de transferência definida em termos de frequência, ângulo de incidência e polarização de incidência [22] - [26].

Neste capítulo serão analisadas as características das FSS, isto é, os tipos de arranjos, as técnicas de análise e as técnicas de medição.

2.1 Principais Características

A estrutura de uma FSS é caracterizada por ser um arranjo periódico, constituído por *patches* condutores ou aberturas. A configuração com *patches* metálicos sobre um substrato, tem recebido a denominação de FSS capacitiva, enquanto a configuração com aberturas periódicas perfuradas numa superfície condutora, é chamada de FSS indutiva. A estrutura do tipo *patch* é utilizada quando deseja-se obter uma resposta de filtro rejeita-faixa em torno da frequência de ressonância do dispositivo; em contrapartida, a estrutura do tipo abertura funciona como um filtro passa-faixa na frequência de ressonância [22], [27]. A Figura 2-1 apresenta a representação de uma FSS, e a Figura 2-2 mostra as representações de um arranjo do tipo *patch* e um arranjo do tipo abertura.




Figura 2-1 - Representação da estrutura de uma FSS.




Figura 2-2 - Superfícies Seletivas de Frequência: (a) arranjo do tipo *patch* e (b) do tipo abertura.

Além disso, os arranjos periódicos podem ser ativos ou passivos. Uma FSS passiva é caracterizada poder ser um dispositivo em que alguns elementos geométricos são projetados numa camada dielétrica para a operação em uma determinada frequência, cujo sinal pode ser transmitido ou rejeitado, e suas propriedades não podem ser alteradas. Em contrapartida, uma FSS ativa é composta pelos mesmos elementos geométricos do tipo passiva, mas com a implementação de alguns dispositivos eletrônicos ativos, como diodos, varactores ou capacitores [23], [27], aumentando as suas possibilidades de aplicações em sistemas de comunicações sem fio, por exemplo.

De maneira geral, um arranjo periódico pode ser excitado de duas maneiras, são elas: por uma onda incidente E^i , conforme representação na Figura 2-3 - a) (arranjo passivo), ou por geradores individuais conectados a cada elemento (arranjo ativo), cuja representação é mostrada na Figura 2-3 - b). Vale ressaltar que nesse último caso, os geradores de tensão devem possuir a mesma amplitude e uma variação de fase linear ao longo do arranjo ativo, de modo que haja a caracterização como uma superfície periódica [22].




Figura 2-3 – Em (a) é mostrada a representação de um arranjo excitado pela onda incidente E^i , e em (b) de um arranjo excitado por geradores individuais conectados a cada elemento. Em que Z_L são as impedâncias de carga.

Em arranjos passivos, a onda plana incidente será parcialmente transmitida na direção E^t , e parcialmente refletida na direção especular E^r . Considerando condições ressonantes e nenhum *grating lobes*, a amplitude do sinal refletido pode ser igual a E^i enquanto $E^t = 0$. Portanto, é comum definir o coeficiente de reflexão especular como [22]:

$$\Gamma = \frac{E^r}{E^i} \quad (1.1)$$

Em que, E^r e E^i são em geral referenciados ao plano do arranjo. Analogamente, o coeficiente de transmissão é definido como [22]:

$$\tau = \frac{E^t}{E^i} \quad (1.2)$$

2.2 Tipos de Geometrias dos Elementos *Patches* das FSS

A geometria do *patch* da FSS influencia diretamente a distribuição de corrente na estrutura e, conseqüentemente, está relacionada com a resposta em frequência. De forma geral, as geometrias mais comuns encontradas na literatura científica são: polígonos regulares, como o retângulo, o quadrado e o círculo e outras que são derivadas destas, como dipolos, espiras, entre outras [27].

Em [22], o autor divide as formas dos elementos em quatro grupos:

- Grupo 1: os centros conectados ou *N-polos*, cujas formas mais comuns são: dipolos finos, tripolos, dipolos cruzados, cruz de Jerusalém e espiral quadrada. A representação das geometrias do grupo 1 são mostradas na Figura 2-4 - a);
- Grupo 2: este grupo é composto por elementos do tipo espira, cujas formas mais conhecidas são: espiras quadradas, quadradas duplas, e anéis concêntricos. A representação das geometrias do grupo 2 são mostradas na Figura 2-4 - b);
- Grupo 3: elementos com o interior sólido ou de diversas formas. Algumas das geometrias mais conhecidas são: retangulares, hexagonais e circulares. A representação das geometrias do grupo 3 são mostradas na Figura 2-4 - c);
- Grupo 4: Combinações obtidas a partir de modificações ou combinações de elementos típicos. A representação das geometrias do grupo 4 são mostradas na Figura 2-4 - d);




Figura 2-4 – Formas de algumas das geométricas de FSS.

2.3 Técnicas de Análise

Na literatura podem ser encontradas equações aproximadas para a análise das FSS, para a determinação das características de transmissão e reflexão, tanto para as estruturas do tipo *patch* quanto abertura. Na modelagem, são levadas em consideração as seguintes características dos dispositivos: dimensão, geometria do *patch*, tipo de substrato etc. A desvantagem é que esses métodos perdem a precisão da predição do desempenho da estrutura analisada à medida que a frequência considerada aumenta [27], [28].

Com os avanços dos recursos computacionais, foram desenvolvidos os métodos conhecidos como Métodos de Onda Completa, os quais possuem rigorosas formulações matemáticas, exigindo assim maior esforço computacional e analítico, mas com a vantagem

de fornecerem resultados precisos, quando comparados aos métodos aproximados, mesmo em frequências elevadas [27]. A seguir, são citados os principais métodos:

- Método dos Momentos (*Method of Moments* - MoM);
- Método dos Elementos Finitos (*Finite-Element Method* - FEM);
- Método das Diferenças Finitas no Domínio do Tempo (*Finite-Difference Time Domain* - FDTD);
- Método Iterativo das ondas (*Wave Concept Iterative Procedure* - WCIP).

A seguir, cada um desses métodos será descrito, e também o método do Circuito Equivalente.

2.3.1 Método do Circuito Equivalente

O método do circuito equivalente, o qual também é conhecido como método da linha de transmissão, é uma técnica aproximada de análise de circuitos planares, que se mostra simples, eficiente e produz resultados satisfatórios. Neste método, os segmentos condutores que constituem a estrutura são modelados por seu circuito equivalente como componentes indutivos ou capacitivos. Este método tem a vantagem de não necessitar de recursos computacionais avançados, quando comparado a outros métodos, além de permitir uma análise rápida das estruturas. Entretanto, a desvantagem é a sua precisão limitada, embora seja eficiente computacionalmente [29], [30], [31].

2.3.2 Método dos Momentos

Esse método tem sido bastante utilizado na análise de circuitos planares [29], [32], [33], [34], [35]. Essa técnica é utilizada para discretizar equações integrais, convertendo-as em equações matriciais, em que a corrente superficial do circuito pode ser determinada pela solução de tais equações matriciais. De forma geral, expande-se a distribuição de corrente em uma combinação linear de um conjunto de funções de base com coeficientes desconhecidos [27], [29].

Este método possui como desvantagem necessitar, em determinados casos, de um grande poder de processamento para a construção das funções de Green, pois esta depende da geometria que está sendo analisada. Com isso, a determinação e a escolha das funções de base são as etapas mais fundamentais para a aplicação do método dos momentos [27], [29].

Vale ressaltar que utilizando um caso particular do método dos momentos, o qual é conhecido como método de Garlekin, a escolha das funções de base e teste pode ser facilitada. Para esse caso, as funções de base e teste são idênticas e as soluções resultantes são da forma variacional [27], [29].

2.3.3 Método dos Elementos Finitos

Esse método consiste em discretizar o domínio de integração da estrutura em análise, que pode ser planar ou volumétrica, a ser avaliada em um conjunto de regiões infinitesimais (elementos finitos), realizando a conversão do domínio de resolução em um domínio discreto. A divisão do domínio é conhecida como malha ou *mesh*, a qual é o conjunto de elementos finitos resultantes da discretização [27], [36].

As unidades discretizadas podem apresentar qualquer forma geométrica bem definida, como elementos triangulares para configurações planares ou tetraédicas e elementos prismáticos para configurações tridimensionais, satisfatórios para geometrias curvadas [29]. O método envolve a integração de funções de base em cima do *patch* condutor, o qual é dividido em várias subseções. A dificuldade da resolução das equações de onda com condições de limite não-homogêneas pode ser solucionada pela decomposição destas equações em dois problemas de valor limite: um através da equação de Laplace com um limite não-homogêneo e o outro através de uma equação de onda não-homogênea com uma condição de limite homogênea [27], [29], [36], [37].

Esse método tem se mostrado uma técnica computacional poderosa e bastante útil para modelagens de ondas eletromagnéticas que se propagam e interagem com seus contornos. Através dele se pode determinar características de propagação, tais como perdas e dispersão e distribuições do campo eletromagnético como uma função da localização espacial, frequência ou tempo. Vários softwares comerciais utilizam o FEM e tem sido bastante utilizado para análise da propagação de ondas até em frequências de terahertz [38], [39].

2.3.4 Método das Diferenças Finitas no Domínio do Tempo

As equações do FDTD se baseiam na discretização das equações de Maxwell no domínio do tempo e do espaço, dividindo a estrutura em análise em células unitárias. Com

esse método pode-se analisar estruturas não homogêneas e circuitos com quaisquer geometrias [24], [35].

Em cada elemento de discretização, as informações referentes ao material são encontradas de maneira que a equação diferencial seja discretizada e convertida em uma equação de diferenças. Quanto maior for o refinamento da malha de discretização, maior será a precisão dos resultados, entretanto, haverá maior esforço computacional [29].

2.3.5 Método WCIP

O método WCIP foi desenvolvido na década de 90. É um método simples e que pode ser utilizado em diversas aplicações. A modelagem é realizada através da relação entre onda refletida e onda incidente sobre o circuito em análise, para descrever o comportamento das estruturas, considerando dois domínios de definição: o espacial e modal. A resolução é iterativa com uma malha de superfície uniforme, de modo que as ondas espaciais e espectrais são diretamente deduzidas da outra com uma Transformada Modal de Fourier (FMT) e da Transformada Modal de Fourier Inversa (IFMT ou FMT^{-1}). Portanto, há uma redução no tempo de cálculo, fornece versatilidade e representação confiável da estrutura do circuito [29].

2.3.6 Softwares Comerciais

Existem vários softwares comerciais disponíveis que podem ser utilizados para a análise dos circuitos planares e, conseqüentemente, de superfícies seletivas de frequência. Estes softwares implementam alguns dos métodos citados anteriormente. Dentre os mais famosos, pode-se citar o ANSYS HFSS (utiliza o método dos elementos finitos), o Ansoft Design e o ADS (que utilizam o método dos momentos) e o CST (que implementa o método das diferenças finitas no domínio do tempo) [29].

2.4 Técnicas de Medição

Algumas técnicas de medição têm sido aplicadas para a medição do coeficiente de reflexão e do coeficiente de transmissão das FSS. Um dos métodos consiste no *setup* de medição composto por duas antenas direcionais, geralmente antenas do tipo corneta,

utilizadas como elementos de transmissão e recepção, em uma câmara anecóica [29], conforme mostrado na Figura 2-5. A câmara anecóica tem a função de reduzir as reflexões e os ruídos causados por sinais de radiofrequência durante as medições. Geralmente a FSS é colocada em um anteparo que é revestido nas bordas com material absorvedor, o qual tem a função de eliminar as reflexões, e fica na linha de visagem entre as duas antenas [23], [29], [41].




Figura 2-5 – Fotografia de uma câmara anecóica para medição dos parâmetros de uma FSS [42].

Outra técnica bastante conhecida para a medição de FSS, é através da aplicação de antenas cornetas associadas a lentes, cuja representação é mostrada na Figura 2-6. Com esse método, pode ser realizada a medição dos coeficientes de reflexão e transmissão em ambas as polarizações. Considerando que a FSS é iluminada pelo feixe gaussiano estreito das lentes, a difração nas bordas é reduzida consideravelmente e testes com vários ângulos de incidência podem ser executados [23], [27].




Figura 2-6 - Representação de um *setup* para medição dos parâmetros de uma FSS utilizando lentes gaussianas

Capítulo 3

Projeto das BFSS

As BFSS desenvolvidas foram simuladas no software ANSYS HFSS, o qual utiliza o método dos elementos finitos. Além disso, vale ressaltar que foi utilizado um *setup* composto por duas antenas cornetas e um analisador de rede N5230A da *Agilent Technologies* para caracterização experimental dos protótipos desenvolvidos, conforme mostrado na Figura 3-1. Os resultados obtidos pelas medições para os coeficientes de transmissão realizadas são comparados com os valores numéricos obtidos das simulações.



Figura 3-1 – *Setup* de medição para caracterização experimental das BFSS.

Nas simulações e confecção das BFSS propostas, foram utilizados substratos de fibra de vidro (FR-4), cuja constante dielétrica é $\epsilon_r = 4,4$, a altura (h) é de 1,57 mm e a tangente de perdas de 0,02.

3.1 BFSS no Trevo de Quatro Folhas

O trevo, cujo nome científico é *Trifolium repens*, é encontrado na maioria das regiões temperadas e subtropicais do planeta. Geralmente, possui três folhas – sua forma com quatro folhas é um fenômeno bastante raro [40], [43].

A superfície seletiva de frequência bioinspirada no Trevo de Quatro Folhas desenvolvida neste trabalho possui resposta *dual-band*, e pode ser utilizada para aplicações na banda C (4 a 8 GHz), e na banda Ku (12 a 18 GHz)

A representação do elemento *patch* da BFSS no trevo de quatro folhas é mostrada na Figura 3-2. As dimensões de T_x e T_y são de 20 mm.




Figura 3-2 – Representação da geometria do elemento *patch* da BFSS no trevo de quatro folhas.

Uma fotografia do protótipo fabricado é mostrada na Figura 3-3. As dimensões do protótipo foram 20 cm de comprimento por 20 cm de largura.




Figura 3-3 – Fotografia do protótipo da BFSS no trevo de quatro folhas.

Na Figura 3-4 pode ser observado o coeficiente de transmissão da BFSS no trevo de quatro folhas, comparado aos valores numéricos das simulações.




Figura 3-4 - Resultados medidos e simulados para os coeficientes de transmissão da BFSS no trevo de quatro folhas.

Conforme mostrado na Figura 3-4, a BFSS no trevo de quatro folhas apresenta duas bandas de ressonância. A primeira banda apresentou no resultado medido uma frequência de ressonância de 4,64 GHz, com uma largura de banda de 1,37 GHz e perda de inserção de -31,03 dB. No resultado correspondente obtido por simulação, a frequência de ressonância foi de 4,4 GHz, a largura de banda chegou a 1,4 GHz e a perda de inserção de -31,59 dB. Na segunda banda, a mediação mostrou largura de banda de 1,2 GHz. O resultado correspondente simulado apresentou uma frequência de ressonância de 14,3 GHz, a largura de banda foi de 1,22 GHz e perda de inserção de -29,38 dB.

Além disso, foi verificada a estabilidade angular da estrutura. Através de simulações e medições, foram analisados os coeficientes de transmissão da BFSS em relação aos ângulos incidentes oblíquos de 0°, 10°, 20°, 30° e 40°. Na Figura 3-5, podem ser observados os valores obtidos nas simulações, os quais apresentaram uma boa estabilidade angular nas duas bandas de ressonância.






Figura 3-5 - Resultados de simulação para o coeficiente de transmissão da BFSS no trevo de quatro folhas considerando diferentes ângulos de incidência oblíqua.


Na Figura 3-6, são mostrados os coeficientes de transmissão obtidos nas medições com ângulos de incidência oblíquos cujos valores foram 10° , 20° , 30° e 40° , os quais são comparados aos valores encontrados nas simulações.




(a)



(b)



(c)



(d)

Figura 3-6 - Resultados medidos e simulados para os coeficientes de transmissão da BFSS no trevo de quatro folhas em diferentes ângulos de incidência oblíqua: a) 10°, b) 20°, c) 30°, d) 40°.

Como mostrado na Figura 3-6 - a), para um ângulo de incidência de 10°, a primeira banda apresentou no resultado medido uma frequência de ressonância de 4,64 GHz, com uma largura de banda de 1,26 GHz e perda de inserção de -25,9 dB. No resultado correspondente obtido por simulação, a frequência de ressonância foi de 4,4 GHz, a largura de banda chegou a 1,4 GHz e a perda de inserção de -31,59 dB. Na segunda banda, a mediação mostrou uma frequência de ressonância em torno de 14,3 GHz, com uma largura de banda de 1,35 GHz e uma perda de inserção de cerca de -16 dB. O resultado correspondente simulado apresentou uma frequência de ressonância de 14,3 GHz, a largura de banda foi de 1,1 GHz e perda de inserção de -29,38 dB.

De acordo com o que pode ser observado na Figura 3-6 - b), para um ângulo de incidência de 20° , a primeira banda apresentou no resultado medido uma frequência de ressonância de 4,57 GHz, com uma largura de banda de 1,14 GHz e perda de inserção de -27,21 dB. No resultado correspondente obtido por simulação, a frequência de ressonância foi de 4,4 GHz, a largura de banda chegou a 1,4 GHz e a perda de inserção de -31,59 dB. Na segunda banda, a mediação mostrou uma frequência de ressonância em torno de 14 GHz, com uma largura de banda de 1,45 GHz e perda de inserção de cerca de -16,5 dB. O resultado correspondente simulado apresentou uma frequência de ressonância de 14,3 GHz, a largura de banda foi de 1,22 GHz e perda de inserção de -29,38 dB.

Na Figura 3-6 - c), pode ser observado que para um ângulo de incidência de 30° , a primeira banda apresentou no resultado medido uma frequência de ressonância de 4,64 GHz, com uma largura de banda de 1,51 GHz e perda de inserção de -27,52 dB. No resultado correspondente obtido por simulação, a frequência de ressonância foi de 4,4 GHz, a largura de banda chegou a 1,4 GHz e a perda de inserção de -31,59 dB. Na segunda banda, a mediação mostrou que a frequência de ressonância é em torno de 13,8 GHz, com uma largura de banda acima de 1,5 GHz e uma perda de inserção de cerca de -19,06 dB. O resultado correspondente simulado apresentou uma frequência de ressonância de 14,3 GHz, a largura de banda foi de 1,22 GHz e perda de inserção de -29,38 dB.

Conforme mostrado na Figura 3-6 - d), para um ângulo de incidência de 40° , a primeira banda apresentou no resultado medido uma frequência de ressonância de 4,43 GHz, com uma largura de banda de 1,47 GHz e perda de inserção de -25,16 dB. No resultado correspondente obtido por simulação, a frequência de ressonância foi de 4,4 GHz, a largura de banda chegou a 1,4 GHz e a perda de inserção de -31,59 dB. Na segunda banda, a mediação mostrou que a frequência de ressonância é em torno de 13,8 GHz, com uma largura de banda de 0,8 GHz e a perda de inserção de cerca de -19,25 dB. O resultado correspondente simulado apresentou uma frequência de ressonância de 14,3 GHz, a largura de banda foi de 1,22 GHz e perda de inserção de -29,38 dB.

Na Tabela 3-1 e na Tabela 3-2 são resumidos os valores relacionados aos gráficos plotados na Figura 3-4 e Figura 3-6, para a primeira e segunda banda de operação, respectivamente.

Tabela 3-1 - Resultados medidos e simulados da BFSS no trevo de quatro folhas para a primeira banda de ressonância.

θ	Valores medidos			Valores simulados		
	f_r (GHz)	BW (GHz)	S_{21} (dB)	f_r (GHz)	BW (GHz)	S_{21} (dB)
0°	4,64	1,37	-31,03	4,4	1,4	-31,59
10°	4,64	1,26	-25,90	4,4	1,4	-31,59
20°	4,57	1,14	-27,21	4,4	1,4	-31,59
30°	4,64	1,51	-27,52	4,4	1,4	-31,59
40°	4,43	1,47	-27,52	4,4	1,4	-31,59

Tabela 3-2 - Resultados medidos e simulados da BFSS no trevo de quatro folhas para a segunda banda de ressonância.


θ	Valores medidos			Valores simulados		
	f_r (GHz)	BW (GHz)	S_{21} (dB)	f_r (GHz)	BW (GHz)	S_{21} (dB)
0°	14,3	1,13	-16,01	14,3	1,22	-29,38
10°	14,3	1,35	-16	14,3	1,22	-29,38
20°	14	1,45	-16,5	14,3	1,22	-29,38
30°	13,8	Acima de 1,5	-19,06	14,3	1,22	-29,38
40°	13,8	0,8	-19,05	14,3	1,1	-29,38

3.2 UWB BFSS em Trevo de Quatro Folhas


A tecnologia UWB compreende a banda de frequência entre 3,1 e 10,6 GHz. Os sistemas UWB possuem várias vantagens, dentre as quais, pode-se citar: maior imunidade a ruído, baixo custo e baixa potência do equipamento, entre outras. Diante disso, essa tecnologia se destaca entre as alternativas de sistemas de comunicações sem fio *short-range*,

principalmente na quarta geração (4G) e aplicações na banda de operação mais baixa da quinta geração (5G) [2].


Para a BFSS exibir a resposta UWB, foi construído um protótipo com a estrutura em cascata, em que uma FSS com *patches* do tipo espira quadrada (a qual é ilustrada, mostrando o protótipo fabricado e apresentados os resultados correspondentes na Figura 3-7), cujas dimensões de T_x e T_y possuem dimensão de 20 mm, foi acoplada sobre a BFSS no trevo de quatro folhas, conforme a representação do protótipo que pode ser observada na Figura 3-8. A distância entre as estruturas foi de 1,57 mm.



(a)



(b)



(c)

Figura 3-7 - Geometria com a forma Espira Quadrada da FSS proposta. Em a) é mostrada a representação e as dimensões, e em b) é mostrada uma fotografia do protótipo desenvolvido.




Figura 3-8 - Ilustração da estrutura em cascata para obter a resposta UWB da BFSS no trevo de quatro folhas.

O coeficiente de transmissão desse dispositivo foi medido e comparado aos valores obtidos com as simulações, conforme pode ser observado na Figura 3-9.




Figura 3-9 - Resultados medidos e simulados para os coeficientes de transmissão da BFSS no trevo de quatro folhas com resposta UWB.

Conforme mostrado na Figura 3-9, a BFSS com resposta UWB apresentou no resultado medido uma banda que vai de 3,66 a 9,16 GHz, constituindo uma largura de banda de 5,56 GHz. No resultado correspondente obtido por simulação, a banda de ressonância vai de 3,55 a 9,9 GHz, com uma largura de banda de 6,35 GHz.

Além disso, foi verificada a estabilidade angular do protótipo em relação ao ângulo de incidência das ondas eletromagnéticas para os ângulos oblíquos de 10°, 20°, 30° e 40°, e seus valores comparados aos resultados numéricos das simulações. Na Figura 3-10 pode ser observado o comportamento dos coeficientes de transmissão, cujos resultados foram calculados nas simulações.






Figura 3-10 - Resultados de simulação para o coeficiente de transmissão da BFSS no trevo de quatro folhas com resposta UWB em diferentes ângulos de incidência oblíqua.


Na Figura 3-11 são apresentados os valores dos coeficientes de transmissão obtidos através da caracterização experimental da UWB BFSS, para os ângulos de incidência da radiação eletromagnética de 10° , 20° , 30° e 40° , e os resultados são comparados aos valores simulados.




(a)



(b)



(c)



(d)

Figura 3-11 - Resultados medidos e simulados para os coeficientes de transmissão da BFSS no trevo de quatro folhas com resposta UWB em diferentes ângulos de incidência oblíqua: a) 10°, b) 20°, c) 30°, d) 40°.

Conforme mostrado na Figura 3-11 - a), para um ângulo de incidência de 10°, a BFSS em cascata apresentou no resultado medido uma largura de banda de 5,56 GHz (de 3,67 a 9,23 GHz). No resultado correspondente obtido por simulação, a largura de banda foi de 6,35 GHz (de 3,55 a 9,9 GHz).

De acordo com o gráfico mostrado na Figura 3-11 - b), para um ângulo de incidência de 20°, a BFSS em cascata apresentou no resultado medido uma largura de banda de 5,79 GHz (de 3,66 a 9,45 GHz). No resultado correspondente obtido por simulação, a largura de banda foi de 6,35 GHz (de 3,55 a 9,9 GHz).

Como mostrado na Figura 3-11 - c), para um ângulo de incidência de 30°, a BFSS em cascata apresentou no resultado medido duas bandas de ressonâncias. A primeira banda de ressonância ocorre de 3,66 a 6 GHz, com uma largura de banda de 2,34 GHz, e a segunda banda de ressonância ocorre entre 6,48 e 10,39 GHz, com uma largura de banda de 3,91 GHz. No resultado correspondente obtido por simulação, a largura de banda foi de 6,35 GHz (de 3,55 a 9,9 GHz).

Conforme mostrado na Figura 3-11 - d), para um ângulo de incidência de 40°, a BFSS em cascata apresentou no resultado medido duas bandas de ressonâncias. A primeira banda de ressonância ocorre de 3,65 a 5,9 GHz, com uma largura de banda de 2,25 GHz, e a segunda banda de ressonância ocorre entre 6,77 e 11,1 GHz, com uma largura de banda de 4,33 GHz. No resultado correspondente obtido por simulação, a largura de banda foi de 6,35 GHz (de 3,55 a 9,9 GHz).

Na Tabela 3-3 são resumidos os valores mostrados nos gráficos apresentados na Figura 3-9 e na Figura 3-11.

Tabela 3-3 - Resultados medidos e simulados da BFSS no trevo de quatro folhas com resposta UWB.

θ	Valores medidos			Valores simulados		
	f_r (GHz)	BW (GHz)	S_{21} (dB)	f_r (GHz)	BW (GHz)	S_{21} (dB)
0°	-	5,50	-	-	6,35	-
10°	-	5,56	-	-	6,35	-
20°	-	5,79	-	-	6,35	-
30°	-	2,34 e 3,91	-	-	6,35	-
40°	-	2,25 e 4,44	-	-	6,35	-

3.3 BFSS na Folha Maple

A folha Maple, a qual possui o nome científico *Acer*, é bastante comum no Canadá, inclusive fazendo parte da sua bandeira e é um símbolo deste país. Nesta seção é apresentada uma superfície seletiva de frequência bioinspirada na folha maple. A estrutura desenvolvida apresentou resposta *dual-band* e pode ser utilizada para aplicações nas bandas C e Ku. A representação do elemento *patch* da BFSS na folha maple é mostrada na Figura 3-12. As dimensões de T_x e T_y são de 20 mm.




Figura 3-12 - Representação da geometria da BFSS na folha maple.

Uma fotografia do protótipo fabricado é mostrada na Figura 3-13. As dimensões do protótipo foram 20 cm de comprimento por 20 cm de largura.




Figura 3-13 – Fotografia do protótipo da BFSS na folha maple.

Na Figura 3-14 pode ser observado o coeficiente de transmissão da BFSS na folha maple, comparado aos valores numéricos das simulações.




Figura 3-14 - Resultados medidos e simulados para os coeficientes de transmissão da BFSS na folha maple.

Conforme mostrado na Figura 3-14, a BFSS com o elemento bioinspirado na geometria da folha maple apresenta duas bandas de ressonância. A primeira banda apresentou no resultado medido uma frequência de ressonância de 6,32 GHz, com uma largura de banda de 2,27 GHz e perda de inserção de -23,23 dB. No resultado correspondente obtido por simulação, a frequência de ressonância foi de 6,4 GHz, a largura de banda chegou a 2,36 GHz e a perda de inserção de -33,05 dB. Na segunda banda, a mediação apresentou frequência de

ressonância de 13,25 GHz, com largura de banda de 0,46 GHz e perda de inserção de -19,61 dB. O resultado correspondente simulado apresentou uma frequência de ressonância de 13,09 GHz, com largura de banda foi de 0,77 GHz e perda de inserção de -20,59 dB.

Na Tabela 3-4 são resumidos os valores relacionados aos gráficos plotados na Figura 3-14, para a primeira e segunda banda de operação, respectivamente.

Tabela 3-4 - Resultados medidos e simulados da BFSS na folha maple.

Banda de operação	Valores medidos			Valores simulados		
	f_r (GHz)	BW (GHz)	S_{21} (dB)	f_r (GHz)	BW (GHz)	S_{21} (dB)
Primeira banda	6,32	2,27	-23,23	6,40	2,36	-33,05
Segunda banda	13,25	0,46	-19,61	13,09	0,77	-20,59

3.4 UWB BFSS na folha Maple

Para a BFSS na folha maple exibir a resposta UWB, foi construído um protótipo com a estrutura em cascata, em que uma FSS com *patches* do tipo espira quadrada, conforme apresentada na Seção 3.2, foi acoplada sobre a BFSS na folha Maple, conforme a representação do protótipo que pode ser observada na Figura 3-15. A distância entre as estruturas foi de 1,57 mm.




Figura 3-15 - Ilustração da estrutura em cascata para obter a resposta UWB da BFSS na folha maple.

O coeficiente de transmissão desse dispositivo foi medido e comparado aos valores obtidos com as simulações, conforme pode ser observado na Figura 3-16.




Figura 3-16 - Resultados medidos e simulados para os coeficientes de transmissão da BFSS na folha maple com resposta UWB.

Conforme mostrado na Figura 3-15, a BFSS com resposta UWB apresentou no resultado medido uma banda que vai de 4,13 a 9,61 GHz, constituindo uma largura de banda de 5,48 GHz. No resultado correspondente obtido por simulação, a banda de ressonância vai de 4,23 a 9,59 GHz, com uma largura de banda de 5,36 GHz.

Capítulo 4

Redes Neurais Artificiais e Implementação da Síntese da BFSS no Trevo de Quatro Folhas

As Redes Neurais Artificiais têm seus fundamentos em áreas como neurociência, matemática, estatística, física, ciência da computação e engenharia. Elas têm sido aplicadas em diferentes campos do conhecimento, como em modelagem, análise de séries temporais, reconhecimento de padrões, processamentos sinais, controle etc. [13]. Além disso, as RNA's têm sido aplicadas recentemente em antenas de microfita e em superfícies seletivas de frequência [7] - [12].

Neste trabalho, uma rede neural artificial foi implementada para realizar a síntese da FSS bioinspirada no trevo de quatro folhas. Os aspectos e detalhes da RNA desenvolvida serão apresentados mais à frente. Primeiro será apresentada uma revisão bibliográfica das redes neurais, a qual começa na seção a seguir.

4.1 Redes Neurais Artificiais

O trabalho em redes neurais, tem tomado como base desde o início das pesquisas o reconhecimento que a forma que o cérebro humano processa informações é totalmente diferente de um computador digital convencional. O cérebro é um sistema processador de informações altamente complexo, não-linear e paralelo, cuja sua estrutura, constituída por neurônios, tem a capacidade de se organizar e executar processamentos como, por exemplo, reconhecimento de padrões, percepção e controle motor, muito mais rápido que os convencionais computadores digitais [13].

O neurônio quando está em “desenvolvimento” é sinônimo de um cérebro plástico, isto é, devido a plasticidade, o sistema nervoso que está em desenvolvimento se adapta ao meio no qual está inserido. Analogamente, a plasticidade é fundamental para as RNA's, já que

a rede neural é uma máquina projetada para modelar a maneira como o cérebro executa uma determinada tarefa ou ação [13].

Portanto, uma rede neural é definida como [13]: *um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:*

1. *O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;*
2. *Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.*

O procedimento usado para realizar o processo de aprendizagem é conhecido como *algoritmo de aprendizagem*, cuja função é alterar os pesos sinápticos da rede de uma forma ordenada para alcançar um objetivo de projeto desejado [13].

Algumas das características mais relevantes relacionadas com aplicações das RNA's são [39]:

1. Adaptação por experiência;
2. Capacidade de aprendizado;
3. Habilidade de generalização;
4. Organização de dados;
5. Tolerância a falhas;
6. Armazenamento distribuído;
7. Facilidade de prototipagem.

4.2 Modelagem de um Neurônio

O neurônio é uma unidade de processamento de informação que é fundamental para o funcionamento de uma rede neural [13]. Na Figura 4-1, pode ser observada a representação do diagrama em blocos de um neurônio.




Figura 4-1 – Representação do diagrama em blocos de um neurônio.

Podem ser identificados três elementos básicos do modelo neuronal [13]:

1. Conjunto de *sinapses* ou *elos de conexão*, em que cada uma se caracteriza por um peso ou força própria. Um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} . O índice k se refere ao neurônio em questão e o índice j refere-se ao terminal de entrada da sinapse ao qual o peso se refere;
2. Um somador para realizar a adição dos sinais de entrada, ponderados pelas respectivas sinapses do neurônio. Estas operações constituem um combinador linear;
3. Uma *função de ativação* para restringir a amplitude da saída de um neurônio. A função de ativação é também conhecida como *função restritiva* já que restringe (limita) o intervalo aceitável de amplitude do sinal de saída a um valor infinito. Comumente, o intervalo normalizado da amplitude de saída de um neurônio é escrito como o intervalo unitário fechado $[0,1]$ ou alternativamente $[-1,1]$.

Além disso, neste modelo neuronal é acrescentado também um *bias*, o qual é aplicado externamente e representado por b_k . O *bias* tem a função de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente [8].

Um neurônio k pode ser representado matematicamente pelas seguintes equações [8]:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (4.1)$$

$$y_k = \varphi(u_k + b_k) \quad (4.2)$$

Em que $x_1, x_2, \dots, x_m$ são os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ; u_k é a saída do combinador linear devido aos sinais de entrada; b_k é o bias; $\varphi(.)$ é a função de ativação; e y_k é o sinal de saída do neurônio. O bias b_k tem a função de aplicar uma transformação afim à saída u_k do combinador linear, conforme a Equação 4.3 [13]:

$$v_k = u_k + b_k \quad (4.3)$$

As funções de ativação são divididas em dois grupos principais: funções parcialmente diferenciáveis e funções totalmente diferenciáveis [44]. Na seção a seguir, será apresentada uma breve discussão sobre esse assunto.

4.3 Funções de Ativação

4.3.1 Funções de Ativação Parcialmente Diferenciáveis

As funções de ativação parcialmente diferenciáveis são caracterizadas por possuírem pontos cujas derivadas de primeira ordem são inexistentes. As três funções principais desse grupo são: função degrau, função degrau bipolar e função rampa simétrica [44].

a) Função degrau (*heavyside / hard limiter*)

Com a aplicação da função degrau, o resultado produzido assumirá valores unitários positivos quando o potencial de ativação do neurônio for maior ou igual a zero; senão, o resultado assumirá valores nulos, conforme descrito na Equação 4.4:

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (4.4)$$

A representação da função apresentada na Equação 4.4 pode ser vista na Figura 4-2.




Figura 4-2 – Representação da função de ativação degrau.

b) Função degrau bipolar ou função sinal (*symmetric hard limiter*)

A aplicação dessa função produzirá um resultado que assumirá valores unitários positivos quando o potencial de ativação do neurônio for maior que zero, valor nulo quando o potencial também for nulo e valores unitários negativos quando o potencial for menor do que zero [44]. Matematicamente, pode-se escrever:

$$\varphi(v) = \begin{cases} 1, & \text{se } v > 0 \\ 0, & \text{se } v = 0 \\ -1, & \text{se } v < 0 \end{cases} \quad (4.5)$$

Graficamente, a Equação 4.5 pode ser representada conforme a Figura 4-3.




Figura 4-3 – Representação da função de ativação degrau bipolar.

c) Função rampa simétrica

Os valores produzidos são iguais aos próprios valores dos potenciais de ativação quando estes estão definidos no intervalo $[-a, a]$, senão, restringe-se aos valores limites [44]. Matematicamente, tem-se:

$$\varphi(v) = \begin{cases} a, & \text{se } v > a \\ v, & \text{se } -a \leq v \leq a \\ -a, & \text{se } v < -a \end{cases} \quad (4.6)$$

A ilustração do gráfico referente a Equação 4.6 pode é apresentada na Figura 4-4.




Figura 4-4 – Representação da função de ativação rampa simétrica.

4.3.2 Funções de Ativação Totalmente Diferenciáveis

As funções de ativação totalmente diferenciáveis são aquelas em que há derivadas de primeira ordem e são conhecidas em todos os pontos de seu domínio de definição. As quatro principais funções que fazem parte desse grupo e que podem ser empregadas em RNA's são: sigmóide (logística), tangente hiperbólica, gaussiana e a função linear [44].

a) Função sigmóide

Segundo [13], a função sigmóide é de longe a função de ativação mais aplicada nas redes neurais artificiais. O resultado da saída dessa função será sempre valores reais entre zero e um, exibindo um balanceamento adequado entre comportamento linear e não-linear [13], [44]. Matematicamente, ela é descrita como:

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (4.7)$$

Em que a é o *parâmetro de inclinação* da função sigmóide, a qual está associada ao nível de inclinação da função em relação ao seu ponto de inflexão [13], [44]. A representação da função sigmóide pode ser observada na Figura 4-5.




Figura 4-5 – Representação da função de ativação sigmóide.

Na Figura 4-5 pode ser analisado o comportamento da sigmóide em relação à variação do parâmetro de inclinação a .

b) Função tangente hiperbólica

Ao contrário da função sigmóide, o resultado da saída sempre assumirá valores reais entre -1 e 1, e pode ser definida matematicamente como [44]:

$$\varphi(v) = \frac{1 - e^{-av}}{1 + e^{-av}} \quad (4.8)$$

Uma ilustração referente a essa função é apresentada na Figura 4-6.




Figura 4-6 – Representação da função de ativação tangente hiperbólica.

Na Figura 4-7 pode ser analisado o comportamento da função tangente hiperbólica em relação à variação do parâmetro de inclinação a .




Figura 4-7 – Representação da influência do parâmetro a função de ativação tangente hiperbólica.

c) Função gaussiana

Com a aplicação da função de ativação gaussiana, a saída do neurônio irá produzir resultados iguais para aqueles valores de potencial de ativação v que estejam posicionados a uma mesma distância de seu centro (média), em que a curva é simétrica em relação a este [44]. A expressão matemática é escrita como:

$$\varphi(v) = e^{-\frac{(v-c)^2}{2\sigma^2}} \quad (4.9)$$

Em que c é um parâmetro que denota o centro da função gaussiana e σ representa o desvio padrão dela [44]. A representação dessa função pode ser observada na Figura 4-8.




Figura 4-8 – Representação da função de ativação gaussiana.

d) Função linear

A função de ativação linear produz os resultados da saída análogos aos valores do potencial de ativação v , a qual pode ser escrita matematicamente como [44]:

$$\varphi(v) = v \quad (4.10)$$

A ilustração referente a essa função é mostrada na Figura 4-9.




Figura 4-9 – Representação da função de ativação linear.

4.4 Arquiteturas de Redes Neurais Artificiais

As redes neurais artificiais podem ser divididas em três partes, conhecidas como camadas, as quais recebem as seguintes denominações [44]:

a) Camada de entrada:

É a camada que recebe as informações (dados), sinais, características ou medições obtidas.

b) Camadas escondidas, intermediárias, ocultas ou invisíveis:

São constituídas de neurônios que possuem a função de extrair as características relacionadas ao processo ou sistema a ser inferido. Basicamente quase todo processamento interno da RNA é realizado nessas camadas.

c) Camada de saída:

É também composta por neurônios, tendo a função de produzir e apresentar os resultados finais da rede, os quais são derivados dos processamentos executados pelos neurônios das camadas anteriores.

As principais arquiteturas das RNA's, levando em consideração a disposição dos seus neurônios, as formas de interligação entre eles e a constituição de suas camadas, são nomeadas como: redes *feedforward* (alimentação à frente) de camada simples, redes *feedforward* de camadas múltiplas, redes recorrentes e redes reticuladas [44].

4.4.1 Arquitetura *Feedforward* de Camada Simples

Essa arquitetura de RNA's é caracterizada por possuir apenas uma camada de entrada e uma única camada de neurônios, a qual é a própria camada de saída [44]. A Figura 4-10 apresenta uma representação gráfica de uma rede *feedforward* de camada simples composta de n entradas e m saídas.




Figura 4-10 – Representação de uma rede *feedforward* de camada simples.

O fluxo das informações é unidirecional, isto é, segue da camada de entrada em direção à camada de saída. A quantidade de saídas será igual ao número de neurônios. Essas RNA's são geralmente utilizadas em problemas relacionados à classificação de padrões e filtragem linear [44].

Dentre os principais tipos de redes com arquitetura *feedforward* de camada simples, pode-se citar: *Perceptron* e *Adaline* [44].

4.4.2 Arquitetura *Feedforward* de Camadas Múltiplas

As redes *feedforward* de camadas múltiplas são compostas por uma ou mais camadas ocultas de neurônios [40], conforme representação apresentadas na Figura 4-11. São aplicadas na solução de diversos tipos de problemas, dentre os quais pode citar: aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica, controle de processos etc. [44].




Figura 4-11 – Representação de uma rede *feedforward* de camadas múltiplas.

Na representação mostrada na Figura 4-11, é ilustrada uma rede *feedforward* de camadas múltiplas formada por uma camada de entrada constituída por n sinais, duas camadas neurais ocultas compostas de n_1 e n_2 neurônios, respectivamente, e uma camada neural de saída constituída por m neurônios representando os valores correspondentes a saída da aplicação [44].

Pode-se citar como os principais tipos de redes com arquitetura *feedforward* de camadas múltiplas, o Perceptron Multicamadas (*Multilayer Perceptron – MLP*) e as Redes de Base Radial (*Radial Basis Function – RBF*) [44].

Vale destacar também as redes em cascatas. Elas são uma rede neural *feedforward* de múltiplas camadas, em que todas as unidades de entrada são conectadas diretamente com todas as unidades ocultas e com todas as unidades de saída. Além disso, as unidades ocultas estão dispostas em cascata, isto é, a saída de cada unidade oculta serve como uma entrada para todas unidades ocultas posteriores e todas as unidades de saída [45].

4.4.3 Arquitetura Recorrente ou Realimentada

Essas redes são caracterizadas por as saídas dos neurônios serem realimentadas como sinais de entrada para outros neurônios. Esse aspecto da realimentação habilita tais redes para a implementação de processamento dinâmico de informações, isto é, podem ser aplicadas em sistemas variantes em relação ao tempo, como previsão de séries temporais, otimização e identificação de sistemas, controle de processos etc. [44].

Dentre os principais tipos de redes que possuem realimentação, pode-se citar a rede de Hopfield e a rede Perceptron multicamadas com realimentação entre neurônios situados em camadas distintas [44]. Na Figura 4-12 pode ser vista uma ilustração da rede perceptron com

realimentação, em que um dos sinais da camada de saída é retroalimentado à camada intermediária.




Figura 4-12 – Representação de uma rede recorrente ou realimentada.

Portanto, através do processo de realimentação, as redes com tal arquitetura produzem as saídas atuais considerando-se também os valores das saídas anteriores [44].

4.4.4 Arquitetura em Estrutura Reticulada

As redes com arquiteturas reticuladas possuem como principais características a consideração da disposição espacial dos neurônios com o propósito da extração de características, isto é, a localização espacial dos neurônios tem relação direta com o processo de ajuste de seus pesos e limiares. Essas redes podem ser aplicadas em problemas de agrupamento (*clustering*), reconhecimento de padrões, otimização de sistemas, grafos etc. [44]. Segundo [44], a principal representante desta arquitetura é a rede de Kohonen.

4.5 Aspectos de Treinamento e Aprendizado

As redes neurais têm a capacidade de aprender através de um conjunto de dados (amostras) que representem o comportamento do sistema, em que, após a rede aprender a relação entre as entradas e saídas, ela é capaz de generalizar soluções. Assim, a rede produzirá uma resposta próxima daquela esperada, a partir dos sinais inseridos nas suas entradas [44].

O processo de treinamento de uma RNA é implementado pela aplicação de passos ordenados que sejam necessários para a sintonização dos pesos sinápticos e limiares de seus neurônios, cujo objetivo é a generalização de soluções produzidas pelas suas saídas. Ao

conjunto de passos ordenados visando o treinamento da rede, dá-se a nomeação de algoritmo de aprendizagem [44].

Geralmente, divide-se o conjunto total das amostras disponíveis do sistema em duas partes, isto é: subconjunto de treinamento e subconjunto de teste. O subconjunto de treinamento, o qual é constituído aleatoriamente por cerca de 60 a 90% das amostras do conjunto total, será usado essencialmente no processo de aprendizado da rede. Já o subconjunto de teste, que é composto por cerca de 10 a 40% do conjunto total de amostras, será aplicado para checar se os aspectos relacionados à generalização de soluções por parte da rede já estão em níveis aceitáveis, possibilitando assim a validação da topologia assumida. Entretanto, o dimensionamento desses conjuntos também deve considerar a caracterização estatística dos dados [44].

No processo de treinamento das RNA's, cada apresentação completa das amostras pertencentes ao subconjunto de treinamento, com o objetivo principal de ajustar os pesos sinápticos e limiares de seus neurônios será denominada de época de treinamento [44].

Existem três tipos principais de aprendizado, são eles [45]:

- a) **Aprendizado supervisionado:** há a necessidade de utilizar um conjunto de dados consistindo em vetores de entrada e um *target* (saída desejada) relacionada com cada vetor de entrada. O conjunto de dados é denominado de conjunto de treinamento. Portanto, o objetivo do treinamento supervisionado é ajustar os valores dos pesos de modo que o erro entre a saída real e a saída desejada do neurônio seja minimizado [45].
- b) **Aprendizado não-supervisionado:** diferentemente do treinamento supervisionado, durante a execução do algoritmo de aprendizado em treinamento não-supervisionado não existem as saídas desejadas, isto é, o objetivo é a descoberta de padrões ou de características no conjunto de dados de entrada sem nenhuma assistência de uma fonte externa. Portanto, a rede deve se auto-organizar em relação às características dos elementos que compõem o conjunto total de amostras, identificando os *clusters* (subconjuntos) que possuam similaridades. Assim, os pesos sinápticos e limiares dos neurônios da rede são ajustados pela aplicação do algoritmo de aprendizagem [44], [45].
- c) **Aprendizado por reforço:** neste método, o objetivo é recompensar o neurônio (ou partes da rede neural) que apresentar boa performance, e penalizar o neurônio por uma má performance. Portanto, o treinamento é executado por tentativa e erro, pois a única resposta disponível para uma determinada entrada é se esta é satisfatória ou não. Caso

seja considerada satisfatória, incrementos aos pesos sinápticos e limiares são gradualmente efetuados com visando recompensar essa condição comportamental relacionada ao sistema [44], [45].

4.6 Perceptrons de Camada Única e de Múltiplas Camadas

4.6.1 Perceptron de Camada Única

O perceptron, o qual foi idealizado por Rosenblatt em 1958, é a forma mais simples de configuração de uma RNA [44]. A Figura 4-1 apresenta uma ilustração de uma rede perceptron composta por n sinais de entrada, relacionados ao problema a ser mapeado, e apenas uma saída.

Analisando a Figura 4-1, pode-se perceber que cada uma das entradas $x_1, x_2, \dots, x_m$, as quais contêm as informações referentes ao comportamento do processo analisado, será primeiramente ponderada pelos pesos sinápticos $w_{k1}, w_{k2}, \dots, w_{km}$, quantificando a importância de cada um em relação aos objetivos funcionais atribuídos ao neurônio, cuja função será assim mapear o comportamento de entrada/saída do processo [44].

Após essa primeira etapa, o valor resultante constituído por todas as entradas já ponderadas pelos seus respectivos pesos, com o acréscimo do *bias* b , é repassado como argumento da função de ativação, cujo resultado será a saída v , a qual é dada por [44]:

$$v = \sum_{i=1}^m w_i x_i + b \quad (4.11)$$

Normalmente, as funções de ativação utilizadas no perceptron são a função degrau ou degrau bipolar. Para a implementação do ajuste de pesos e limiar do perceptron, é utilizado o processo de treinamento supervisionado, isto é, para cada amostra referente aos sinais de entrada, se tem a respectiva saída (resposta) desejada [44].

4.6.2 Perceptron de Múltiplas Camadas

As redes perceptron de múltiplas camadas possuem pelo menos uma camada intermediária (oculta) de neurônios, localizada entre a camada de entrada e a respectiva saída

da rede neural. Portanto, uma rede MLP tem pelo menos duas camadas de neurônios, os quais são distribuídos entre as camadas intermediárias e a camada de saída [44].

Essas redes têm aplicações na solução de problemas relacionados às mais diversas áreas da ciência. Dentre as áreas, pode-se ressaltar [44]:

- Aproximação universal de funções;
- Reconhecimento de padrões;
- Identificação e controle de processos;
- Previsão de séries temporais;
- Otimização de sistemas.

Na Figura 4-13, é apresentada uma ilustração de rede perceptron de múltiplas camadas. O fluxo das informações na estrutura da rede começa na camada de entrada, passa pelas camadas intermediárias, e termina na camada neural de saída [44].




Figura 4-13 – Representação de uma rede perceptron de múltiplas camadas.

Nas redes perceptron de múltiplas camadas, a propagação dos sinais das entradas, independentemente do número de camadas intermediárias, é sempre realizada no sentido da camada de entrada em direção à camada de saída. Os sinais são apresentados à rede na sua camada de entrada. As camadas intermediárias têm a função de extrair a maioria das informações referentes ao seu comportamento e as codificam por meio dos pesos sinápticos e limiares de seus neurônios, criando assim a representação do ambiente em que está inserido o sistema analisado. E, por fim, os neurônios da camada de saída recebem os estímulos vindos dos neurônios da última camada intermediária, produzindo a resposta que será a saída da rede [44].

O ajuste dos pesos e do limiar de cada um dos neurônios é executado com a implementação do processo de treinamento supervisionado, em que para cada amostra dos dados de entrada obtém-se a saída relacionada (desejada) [44].

4.7 Algoritmos de Treinamento

As redes neurais aprendem sobre o seu ambiente por meio de um processo iterativo de ajustes aos seus parâmetros livres, isto é, os pesos sinápticos. Um conjunto pré-estabelecido de regras bem definidas com o objetivo de solucionar um problema de aprendizagem recebe a nomeação de *algoritmo de treinamento*. Não há apenas um algoritmo de aprendizagem para as redes neurais, mas existe um “conjunto de ferramentas” composto por vários algoritmos de treinamento, em que cada um possui suas vantagens específicas [9].

Após a inicialização dos pesos e dos *biases* de uma rede neural, a etapa de treinamento é iniciada. O processo de treinamento necessita de um conjunto de exemplos que refletem o comportamento da própria rede, isto é, os elementos de entrada e saída. No período de treinamento, os pesos e os *biases* são ajustados iterativamente, com o objetivo de minimizar a função custo ou erro, a qual é geralmente representada pelo Erro Médio Quadrático (*Mean Square Error – MSE*), entre a entrada da rede e a saída desejada [9].

Boa parte dos algoritmos de treinamento de redes neurais artificiais consistem em obter o gradiente da função de desempenho da rede, para ajustar os pesos sinápticos e minimizar a função erro/custo [9]. O algoritmo de treinamento de redes neurais mais famoso para a determinação do gradiente é o *backpropagation* [9], [7]. Entretanto, esse método é comumente lento para aplicações em problemas práticos; portanto, foram desenvolvidas variações do algoritmo *backpropagation* baseadas em outras técnicas de otimização, os quais são algoritmos de alta performance que podem convergir de dez a cem vezes mais rápido do que o algoritmo *backpropagation* convencional [9], [46].

Esses algoritmos mais rápidos são divididos em duas categorias. A primeira categoria é caracterizada por utilizar técnicas heurísticas desenvolvidas a partir de algoritmos *backpropagation* tradicionais (método do gradiente descendente), como é o caso do algoritmo *resilient backpropagation*. A segunda categoria utiliza técnicas de otimização numéricas padrões, tais como os seguintes algoritmos: *gradiente conjugado* (*Fletcher-Reeves update*, *Polak-Ribière update*, *Powell-Beale restarts* - reinicialização *Powell-Beale*, *scaled conjugate*

gradient – gradiente conjugado escalar), *Quasi-Newton (BFGS algorithm – algoritmo BFGS, one step secant algorithm)* e *Levenberg-Marquardt* [9], [46].

Além disso, pode-se citar também os métodos de *regularização*. A regularização busca aperfeiçoar a capacidade de generalização dos algoritmos de aprendizado com a utilização de alguma restrição durante a fase de treinamento [47]. Nesta dissertação, será dada ênfase para a regularização Bayesiana.

Na seção a seguir, serão vistos com mais detalhes alguns dos principais métodos de algoritmos de treinamento.

4.7.1 Método do Gradiente Conjugado Escalar

A maioria dos algoritmos de gradiente conjugado exigem um espaço de busca que demanda um alto custo computacional, já que a resposta da rede é computada várias vezes para cada elemento de entrada. O algoritmo do gradiente conjugado escalar, desenvolvido por [48], foi projetado para diminuir o custo computacional na obtenção do espaço de busca. Esse algoritmo combina a aproximação *model-trust region*, a qual é utilizada no algoritmo Levenberg-Marquardt com a eficiência da técnica do gradiente conjugado [9], [46].

4.7.2 Método Levenberg-Marquardt

Assim como os métodos quasi-Newton, o algoritmo de Levenberg-Marquardt foi desenvolvido para melhorar a velocidade de treinamento de algoritmos de segunda ordem sem a necessidade de calcular a matriz Hessiana. Quando a função de desempenho da rede tem a forma de uma soma de quadrados, a qual é comumente utilizada em redes *feedforward*), a matriz Hessiana pode ser escrita como [9], [46]:

$$H = J^T J \quad (4.12)$$

E o gradiente pode ser computado como [25]:

$$g = J^T e \quad (4.13)$$

Em que J é a matriz Jacobiana, a qual armazena as derivadas de primeira ordem dos erros da rede em relação aos pesos e *biases*, e a variável e é o vetor que armazena os erros da rede [9], [46]. A matriz Jacobiana pode ser computada por meio de uma da técnica de *backpropagation* tradicional, que representa muito menos complexidade quando comparada à implementação da matriz Hessiana [9], [46].

O algoritmo Levenberg-Marquardt utiliza a matriz Jacobiana ao invés da matriz Hessiana, na atualização dos pesos, de acordo com a equação [9], [46]:

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (4.14)$$

Quando a variável escalar μ é igual a zero, é o método de Newton, utilizando a matriz Hessiana aproximada. Em contrapartida, quando μ é um valor grande, o método se torna o gradiente descendente com pequeno passo de atualização. Como método de Newton é mais rápido e preciso na detecção de erros, o objetivo do algoritmo Levenberg-Marquardt é, deste modo, se tornar tão eficiente quanto ele, isto é, ser o mais rápido possível durante a implementação. Portanto, μ é decrescido após cada iteração bem-sucedida, e tem o valor acrescido somente quando uma determinada atualização for responsável por maximizar a função de desempenho da rede. Com isso, a função de desempenho será sempre reduzida em cada iteração do algoritmo [9], [46].

4.7.3 Regularização Bayesiana

A regularização é uma denominação para métodos que envolvem a modificação da função de desempenho das redes neurais. A função de desempenho tradicional utilizada para o treinamento de redes neurais *feedforward* é a soma dos quadrados dos erros de treinamento [47]. O objetivo inicial do processo de treinamento é a minimização da soma dos erros quadrados:

$$E_D = \sum_{i=1}^n (t_i - a_i)^2 \quad (4.15)$$

Em que t_i é saída desejada e a_i representa a resposta da rede neural.

Comumente, o treinamento tem como objetivo a minimização da soma dos erros quadrados $F = E_D$. A regularização adiciona um termo adicional, e a função objetivo se torna $F = \beta E_D + \alpha E_w$, em que E_w representa a soma dos quadrados dos pesos da rede, e α e β são parâmetros da função. O tamanho relativo dos parâmetros da função objetivo dita a ênfase do treinamento, isto é, para $\alpha \ll \beta$, o algoritmo de treinamento minimizará os erros, enquanto que para $\alpha \gg \beta$, o treinamento irá priorizar a redução no tamanho dos pesos em detrimento dos erros da rede, produzindo assim uma resposta da rede mais suave [47].

O principal desafio na implementação da regularização é estimar os valores corretos de α e β para a função objetivo, de forma a obter uma aprendizagem eficiente, evitar o ajuste excessivo no treinamento (*overtraining*) e ainda garantir a capacidade de generalização da rede [47], [14].

Na conjuntura bayesiana, os pesos da rede são considerados como variáveis aleatórias. Após a aquisição dos dados, a função densidade para os pesos pode ser atualizada de acordo com a regra de Bayes, a qual pode ser escrita matematicamente como [47]:

$$P(w|D, \alpha, \beta, M) = \frac{P(D|w, \beta, M)P(w|\alpha, M)}{P(D|\alpha, \beta, M)} \quad (4.16)$$

Em que D representa o conjunto de dados, M é o modelo de rede neural utilizado, e w é o vetor de pesos da rede. $P(w|\alpha, M)$ é a densidade *a priori*, a qual representa o nosso conhecimento dos pesos antes da obtenção dos dados. $P(D|w, \beta, M)$ é a função de verossimilhança, a qual representa a probabilidade dos dados ocorrerem para os pesos w . $P(D|\alpha, \beta, M)$ é um fator de normalização para garantir que a probabilidade total é igual a 1 [47].

Considerando que o ruído nos dados do conjunto de treinamento é gaussiano e a distribuição *a priori* dos pesos é gaussiana, a densidade de probabilidade é dada por [47]:

$$\begin{aligned} P(D|W, \beta, M) &= \frac{1}{Z_D(\beta)} \exp(-\beta E_D) \\ &\text{e} \\ P(w|\alpha, M) &= \frac{1}{Z_w(\alpha)} \exp(-\alpha E_w) \end{aligned} \quad (4.17)$$

Em que, $Z_D(\beta) = \left(\frac{\pi}{\beta}\right)^{\frac{n}{2}}$ e $Z_W(\alpha) = \left(\frac{\pi}{\alpha}\right)^{\frac{N}{2}}$. Fazendo a substituição destas probabilidades na Equação 4.16, tem-se:

$$P(w|D, \alpha, \beta, M) = \frac{\frac{1}{Z_W(\alpha)} \frac{1}{Z_D(\beta)} \exp(-(\beta E_D + \alpha E_W))}{\text{fator de normalização}} = \frac{1}{Z_F(\alpha, \beta)} \exp(-F(w)) \quad (4.18)$$

Na Equação 4.18, os pesos ótimos devem maximizar a probabilidade *a posteriori* $P(w|D, \alpha, \beta, M)$. Esse processo, por sua vez, é equivalente a minimização da função objetivo $F = \beta E_D + \alpha E_W$ [47].

Considerando a aplicação da regra de Bayes para otimização dos parâmetros α e β da função objetivo, tem-se que [43]:

$$P(\alpha, \beta|D, M) = \frac{P(D|\alpha, \beta, M)P(\alpha, \beta|M)}{P(D|M)} \quad (4.19)$$

Considerando uma densidade *a priori* uniforme $P(\alpha, \beta|M)$ para α e β , a maximização da probabilidade *a posteriori* é alcançada maximizando a função de verossimilhança $P(D|\alpha, \beta, M)$. Essa função de verossimilhança é o fator de normalização para a Equação 4.16. Visto que todas as probabilidades têm uma distribuição gaussiana, pode-se resolver a Equação 4.16 para o fator de normalização, da seguinte forma [47]:

$$\begin{aligned} P(D|\alpha, \beta, M) &= \frac{P(D|w, \beta, M)P(w|\alpha, M)}{P(w|D, \alpha, \beta, M)} \\ &= \frac{\left[\frac{1}{Z_D(\beta)} \exp(-\beta E_D) \right] \left[\frac{1}{Z_W(\alpha)} \exp(-\alpha E_W) \right]}{\frac{1}{Z_F(\alpha, \beta)} \exp(-F(w))} \\ &= \frac{Z_F(\alpha, \beta)}{Z_D(\beta)Z_W(\alpha)} \cdot \frac{\exp(-\beta E_D - \alpha E_W)}{\exp(-F(w))} = \frac{Z_F(\alpha, \beta)}{Z_D(\beta)Z_W(\alpha)} \end{aligned} \quad (4.20)$$

Em que, $Z_D(\beta)$ e $Z_W(\alpha)$ são constantes conhecidas, entretanto, $Z_F(\alpha, \beta)$ não é conhecida, e pode ser estimada pela expansão da série de Taylor. Visto que a função objetivo tem a forma quadrática em uma pequena área em torno do ponto mínimo, $F(w)$ pode ser expandida em torno do ponto mínimo, da densidade *a posteriori* w^{MP} , cujo gradiente é zero. Assim, a constante de normalização Z_F pode ser escrita como [47]:

$$Z_F \approx (2\pi)^{N/2} (\det((H^{MP})^{-1}))^{1/2} \exp(-F(H^{MP})) \quad (4.21)$$

Em que $H = \beta \nabla^2 E_D + \alpha \nabla^2 E_W$ é a matriz Hessiana da função objetivo. Substituindo a Equação 4.21 na Equação 4.20, é possível encontrar os valores ótimos para α e β no ponto mínimo. Para isso, são realizadas algumas manipulações na Equação 4.20, e encontra-se [47]:

$$\begin{aligned} \alpha^{MP} &= \frac{\gamma}{2E_W(w^{MP})} \\ &\text{e} \\ \beta^{MP} &= \frac{n - \gamma}{2E_D(w^{MP})} \end{aligned} \quad (4.22)$$

Em que $\gamma = N - 2\alpha^{MP} \text{tr}(H^{MP})^{-1}$ representa o número de parâmetros efetivos, e N é o número total de parâmetros da rede.

A otimização bayesiana dos parâmetros de regulação precisa da computação da matriz Hessiana de $F(w)$ no ponto mínimo w^{MP} . Com isso, é proposta a aproximação de Gauss-Newton para a matriz Hessiana, a qual é utilizada se o algoritmo de otimização Levenberg-Marquardt for aplicado para localizar o ponto mínimo. Assim, a computação adicional para a otimização da regulação é mínima, e os passos são [47]:

0. Inicializa com $\alpha = 0$ e $\beta = 1$, e é utilizado o método de Nguyen-Widrow para inicializar os pesos;
1. Processa um passo do algoritmo de Levenberg-Marquardt para minimizar a função objetivo $F(w) = \beta E_D + \alpha E_W$;
2. Calcula o número efetivo de parâmetro $\gamma = N - 2\alpha^{MP} \text{tr}(H^{MP})^{-1}$, utilizando a aproximação de Gauss-Newton para a matriz Hessiana disponível no algoritmo de treinamento de Levenberg-Marquardt, isto é, $H = \nabla^2 F(w) \approx 2\beta J^T J + 2\alpha I_N$, em que J é a matriz jacobiana dos erros do conjunto de treinamento;
3. Calcula novas estimativas para os parâmetros da função objetivo $\alpha = \frac{\gamma}{2E_W(w)}$ e $\beta = \frac{n - \gamma}{2E_D(w)}$;
4. Repete as iterações 1 a 3, até o algoritmo convergir.

4.8 Implementação da Síntese da BFSS no Trevó de Quatro Folhas

Folhas

A síntese da BFSS no trevo de quatro folhas foi desenvolvida no software MATLAB, com o uso da biblioteca “nnstart”. Para implementação da síntese, foi utilizada uma rede neural *Feedforward* em Cascata, com quatro neurônios na camada de entrada, dez neurônios na camada oculta e três neurônios da camada de saída. A representação da estrutura da RNA é ilustrada na Figura 4-14.




Figura 4-14 – Representação da rede neural *feedforward* em cascata utilizada para desenvolver a síntese.

Os quatro neurônios na camada de entrada correspondem as duas frequências de ressonâncias e suas respectivas larguras de banda, e os três neurônios na camada de saída correspondem aos parâmetros construtivos da geometria desenvolvida, isto é, a altura do substrato (h), a periodicidade (p) e as dimensões do elemento *patch* (d), em que foi considerada, em todas as simulações, o mesmo valor para o comprimento e para largura do *patch*. Para uma melhor visualização dessas variáveis da geometria proposta, observe a Figura 4-15.




Figura 4-15 – Representação dos parâmetros analisados na síntese da BFSS no trevo de quatro folhas.

Para o treinamento da rede, foram utilizadas 179 amostras, no total, em que 70% destas foram utilizadas para treinamento e 30% para teste. Em todas as simulações, para a construção do banco de dados das amostras, o substrato dielétrico utilizado foi a fibra de vidro (FR-4). Na Tabela 4-1, são mostrados os valores dos parâmetros que foram variados para a geração do banco de dados.

Tabela 4-1 – Variação dos parâmetros da BFSS no trevo de quatro folhas.

Parâmetros	Valores em (mm)
Periodicidade	5, 10, 12,5, 15, 17,5 e 20
Dimensões	1, 1,5, 2, 2,5, 3, 3,5 4, 4,5 5, 5,5 6, 6,5 7, 7,5, 8, 8,5, 9, 9,5, 10, 10,5, 11, 11,5, 12, 12,5, 13, 13,5, 14, 14,5, 15, 15,5, 16, 16,5, 17, 17,5 18, 18,5 19 e 19,5
Espessura do dielétrico	0,8, 1,2 e 1,57

Todas as amostras obtidas com as simulações executadas podem ser vistas no Apêndice A.

O algoritmo de treinamento da rede neural artificial utilizado para a implementação da síntese foi a regularização bayesiana, o qual foi descrito na Seção 4.7.3. No projeto, os dados inseridos referentes as duas frequências de ressonâncias e suas respectivas larguras de banda foram os mesmos encontrados para a BFSS no trevo de quatro folhas apresentada na Seção 3.1, isto é: frequências de ressonâncias de 4,4 e 14,3 GHz, e larguras de banda de 1,4 e 1,22 GHz, respectivamente. Na Figura 4-16, são mostrados os desempenhos da rede na fase de treinamento e teste.




Figura 4-16 – Desempenho da rede neural para a BFSS no trevo de quatro folhas.

Conforme se pode observar, a rede neural tem a melhor performance na 192 época, com erro de 0,045046. O erro médio quadrático diminuiu com o número de épocas. A rede apresenta um erro quadrático médio muito pequeno no final da fase de treinamento, o que significa que a RNA foi bem treinada e que as saídas desejadas e as saídas da rede para o conjunto de treinamento ficaram bastante próximos.

Os resultados gerados pela RNA foram: espessura do dielétrico (h) de 1,5766 mm, periodicidade (p) de 19,9835 mm e dimensões do elemento *patch* (d) de 18,8628 mm x 18,8628 mm. Então, a estrutura foi implementada no software ANSYS HFSS com esses valores encontrados, e o gráfico obtido com a simulação é apresentado na Figura 4-17.




Figura 4-17 – Resultados de simulação da BFSS no trevo de quatro folhas após a utilização da síntese para encontrar as especificações desejadas para as frequências de ressonância de 4,4 e 14,3 GHz, e larguras de banda de 1,53 GHz e 1,29 GHz, respectivamente.

Os resultados mostrados na Figura 4-17 são:

- Primeira frequência de ressonância: 4,4 GHz;
- Largura de banda da primeira banda de operação: 1,53 GHz;
- Segunda frequência de ressonância: 14,3 GHz;
- Largura de banda da segunda banda de operação: 1,29 GHz.

Com isso, os valores dos erros correspondentes aos valores desejados e obtidos após a simulação no software ANSYS HFSS é:

- Erro relacionado à primeira frequência de ressonância: 0;
- Erro relacionado à largura de banda da primeira banda de operação: 0,093 ou 9,3%;

- Erro relacionado à segunda frequência de ressonância: 0;
- Erro relacionado à largura de banda da segunda banda de operação: 0,057 ou 5,7%.

Não se achou necessária a fabricação do protótipo da geometria desenvolvida após a síntese com a rede neural, pois as dimensões obtidas são bastante próximas daquelas apresentadas na Seção 3.1.

Além disso, foram testados outros valores para as frequências de ressonâncias e respectivas larguras de banda, para dar uma maior confiabilidade à síntese. Primeiro foram testados os valores das frequências de ressonância de 5,8 e 20 GHz, com larguras de banda de 2 GHz, para aplicações nas bandas C e K (18 a 27 GHz). Os resultados gerados pela RNA foram: espessura do dielétrico (h) de 0,8648 mm, periodicidade (p) de 14,8576 mm e dimensões do elemento *patch* (d) de 14,5271 mm x 14,5271 mm. Na Figura 4-18, é mostrado o gráfico obtido com a simulação executada no software ANSYS HFSS.




Figura 4-18 – Resultados de simulação da BFSS no trevo de quatro folhas após a utilização da síntese para encontrar as especificações desejadas para as frequências de ressonância de 5,8 e 20 GHz, e larguras de banda de 2 GHz.

Os resultados mostrados na Figura 4-18 são:

- Primeira frequência de ressonância: 5,8 GHz;
- Largura de banda da primeira banda de operação: 2,28 GHz;
- Segunda frequência de ressonância: 19,8 GHz;
- Largura de banda da segunda banda de operação: 1,57 GHz.

Com isso, os valores dos erros correspondentes aos valores desejados e obtidos após a simulação no software ANSYS HFSS é:

- Erro relacionado à primeira frequência de ressonância: 0;
- Erro relacionado à largura de banda da primeira banda de operação: 0,14 ou 14%;
- Erro relacionado à segunda frequência de ressonância: 0,01 ou 1%;
- Erro relacionado à largura de banda da segunda banda de operação: 0,22 ou 22%.

Depois foram testados os valores das frequências de ressonância de 10 e 24 GHz, com larguras de banda de 2 GHz e 1,5 GHz, respectivamente, para aplicações nas bandas X (8 a 12 GHz) e K. Os resultados gerados pela RNA foram: espessura do dielétrico (h) de 1,4684 mm, periodicidade (p) de 10,6622 mm e dimensões do elemento *patch* (d) de 8,2334 mm x 8,2334 mm. Na Figura 4-19, é mostrado o gráfico obtido com a simulação executada no software ANSYS HFSS.




Figura 4-19 – Resultados de simulação da BFSS no trevo de quatro folhas após a utilização da síntese para encontrar as especificações desejadas para as frequências de ressonância de 10 e 24 GHz, e larguras de banda de 2 GHz e 1,5 GHz, respectivamente.

Os resultados mostrados na Figura 4-19 são:

- Primeira frequência de ressonância: 9,6 GHz;
- Largura de banda da primeira banda de operação: 2,07 GHz;
- Segunda frequência de ressonância: 23,7 GHz;
- Largura de banda da segunda banda de operação: 1,2 GHz.

Com isso, os valores dos erros correspondentes aos valores desejados e obtidos após a simulação no software ANSYS HFSS é:

- Erro relacionado à primeira frequência de ressonância: 0,04 ou 4%;
- Erro relacionado à largura de banda da primeira banda de operação: 0,035 ou 3,5%;
- Erro relacionado à segunda frequência de ressonância: 0,013 ou 1,3%;
- Erro relacionado à largura de banda da segunda banda de operação: 0,2 ou 20%.

Na Tabela 4-2, são resumidos os valores desejados comparados aos valores obtidos por simulações, para as três estruturas testadas, e o erro apresentado entre eles.

Tabela 4-2 – Valores desejados comparados aos valores obtidos por simulações, e o erro apresentado entre eles, para as três estruturas simuladas.

Primeira estrutura			
Parâmetros	Valores desejados	Valores simulados	Erro (%)
f_{r1} (GHz)	4,4	4,4	0
BW ₁ (GHz)	1,4	1,53	9,3
f_{r2} (GHz)	14,3	14,3	0
BW ₂ (GHz)	1,22	1,29	5,7
Segunda estrutura			
Parâmetros	Valores desejados	Valores simulados	Erro (%)
f_{r1} (GHz)	5,8	5,8	0
BW ₁ (GHz)	2	2,28	14
f_{r2} (GHz)	20	19,8	1
BW ₂ (GHz)	2	1,57	22
Terceira estrutura			
Parâmetros	Valores desejados	Valores simulados	Erro (%)
f_{r1} (GHz)	10	9,6	4
BW ₁ (GHz)	2	2,07	3,5
f_{r2} (GHz)	24	23,7	1,3
BW ₂ (GHz)	1,5	1,2	20

Portanto, conforme apresentado, pode ser observado que a síntese da BFSS no trevo de quatro folhas com redes neurais e algoritmo de treinamento regularização bayesiana se mostrou bastante satisfatória, e uma boa concordância entre os valores desejados e obtidos é apresentada.

Capítulo 5

Conclusões

Neste trabalho foram apresentadas superfícies seletivas de frequências bioinspiradas para aplicações em sistemas de comunicação sem fio. As estruturas utilizadas podem ser utilizadas em aplicações nas bandas C, Ku e em UWB.

As estruturas analisadas foram bioinspiradas nas geometrias do trevo de quatro folhas e da folha maple. Ambas as estruturas apresentaram resposta *dual-band*, nas bandas C e Ku. Para as BFSSs desenvolvidas alcançarem a resposta UWB, foram construídos dispositivos em cascata, em que uma FSS com elementos *patches* espira quadrada foi acoplada sobre as superfícies seletivas de frequência bioinspiradas.

A estabilidade angular dos protótipos da BFSS no trevo de quatro folhas e da UWB BFSS no trevo de quatro folhas foi testada. Embora nas simulações elas tenham permanecido completamente estáveis até quarenta graus, os valores obtidos nas medições apresentaram uma diferença a partir do ângulo de 30° em relação aos valores simulados.

Além disso, foi realizada a síntese da superfície seletiva de frequência bioinspirada no trevo de quatro folhas. A síntese foi desenvolvida com a utilização do software comercial MATLAB. A aplicação da inteligência artificial na BFSS representa a vantagem de o usuário poder escolher as frequências de operação e as respectivas larguras de banda desejadas.

No desenvolvimento da síntese foi utilizada uma rede neural *feedforward* em cascata, com quatro neurônios na camada de entrada, dez neurônios na camada oculta e três neurônios da camada de saída. O algoritmo de treinamento foi a regularização bayesiana. Para o treinamento foi construído um banco de dados com 179 amostras, com os valores referentes as frequências de operação e as respectivas larguras de banda, obtidos de acordo com a variação da altura do substrato, da periodicidade e das dimensões do elemento *patch* da BFSS. Essas simulações foram executadas no software ANSYS HFSS, e todos os valores são apresentados no Apêndice A.

A síntese apresentou resultados satisfatórios, com valores baixos para os erros, quando comparados os valores desejados e simulados, em relação as frequências de ressonância e respectivas larguras de banda, representando boa confiabilidade do algoritmo utilizado.

Com isso, pode-se citar como principais contribuições desta dissertação:

- Desenvolvimento de novas geometrias para os elementos *patches* de superfícies seletivas de frequência, as quais são bioinspiradas e apresentam resposta *dual-band*, as quais podem ser utilizadas nas bandas C e Ku, além da aplicabilidade na tecnologia UWB. Além disso, pelo design elegante dos elementos *patches*, as BFSS desenvolvidas podem ser utilizadas em aplicações *indoor*. Também vale ressaltar que embora os elementos geométricos bioinspirados já tenham sido bastante estudados em aplicações em antenas, em FSS eles são um campo de estudo novo, e os resultados se mostraram bastante satisfatórios;
- O desenvolvimento da síntese utilizando redes neurais e o algoritmo de treinamento de regularização bayesiana representa a aplicação de um algoritmo novo para a síntese desses dispositivos, pois é de desconhecimento do autor este algoritmo já ter sido aplicado para a síntese de superfícies seletivas de frequência.

Capítulo 6

Trabalhos Futuros

Em trabalhos futuros, pretende-se:

- Desenvolver superfícies seletivas de frequência bioinspiradas com *closely spaced resonances* (bandas de ressonâncias próximas);
- Utilizar algoritmos bioinspirados e/ou outras técnicas de inteligência artificial, como *deep learning*, por exemplo, para a implementação da síntese de novas BFSS a serem construídas;
- Implementar reconfiguração eletrônica de BFSS com diodos PIN e/ou MEMS;
- Pesquisar novos elementos *patches* de BFSS para aplicações na tecnologia 5G.

Referências Bibliográficas

- [1] A. G. D. Jr, Análise de Circuitos Integrados e de Superfícies Seletivas de Frequência pelo Método Iterativo das Ondas para Aplicações nas Faixas de Micro-ondas e de Terahertz, Campina Grande, Brasil: Tese de Doutorado, Universidade Federal de Campina Grande, 2012.
- [2] J. N. Cruz, R. C. S. Freire, A. J. R. Serres, L. C. M. Moura e P. H. Fonseca Silva, “Parametric Study of Printed Monopole Antenna Bioinspired on the Inga Marginata Leaves for UWB Applications,” *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, pp. 312-322, 2017.
- [3] H. A. Medeiros Silva, Análise de Antenas de Microfita Bioinspiradas e Fractais, Natal, Brasil: Dissertação de Mestrado, Universidade Federal do Rio Grande do Norte, 2017.
- [4] L. C. M. Moura, J. N. Cruz, A. P. Costa, P. H. F. Silva e J. C. Silva, “UWB Cotton Leaf Design Microstrip-Fed Printed Monopole Antenna,” em *Proceedings of SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference*, Porto de Galinhas, 2015.
- [5] T. C. Albuquerque, Antenas Bioinspiradas em Plantas para Recuperação de Energia Eletromagnética do Ambiente, Campina Grande, Brasil: Dissertação de Mestrado, Universidade Federal de Campina Grande, 2016.
- [6] P. F. S. Jr, Arranjos de Antenas Bioinspiradas Desenvolvidos pela Expressão de Gielis, Campina Grande, Brasil: Tese de Doutorado, Universidade Federal de Campina Grande, 2017.
- [7] F. C. G. S. Segundo, Aplicação de Inteligência Computacional em Projetos de Superfície Seletiva de Frequência Multibanda e/ou Banda Larga para Aplicações Comerciais, Natal, Brasil: Tese de Doutorado, Universidade Federal do Rio Grande do Norte, 2018.
- [8] H. W. C. Lins, Análise e Síntese de Antenas e Superfícies Seletivas de Frequência Utilizando Computação Evolucionária e Inteligência de Enxames, Natal: Tese de Doutorado, Universidade Federal do Rio Grande do Norte, 2012.
- [9] R. M. S. Cruz, Análise e Otimização de Superfícies Seletivas de Frequência Utilizando

- Redes Neurais Artificiais e Algoritmos de Otimização Natural, Natal, Brasil: Tese de Doutorado, Universidade Federal do Rio Grande do Norte, 2009.
- [10] M. R. Silva, Otimização de Superfícies Seletivas de Frequência com Elementos Pré-Fractais Utilizando Rede Neural MLP e Algoritmos de Busca Populacional, Natal: Tese de Doutorado, Universidade Federal do Rio Grande do Norte, 2014.
- [11] E. J. B. Rodrigues, Antenas Planares Eletronicamente Reconfiguráveis em Frequência para Sistemas de Rádios Cognitivos, Natal: Tese de Doutorado, Universidade Federal do Rio Grande do Norte, 2016.
- [12] P. S. Oliveira, Desenvolvimento de uma Nova Técnica para Otimização de Circuitos Planares Inspirada no Comportamento Social das Aranhas, Natal: Tese de Doutorado, Universidade Federal do Rio Grande do Norte, 2017.
- [13] S. Haykin, Redes Neurais: princípios e Prática, Porto Alegre: Bookman, 2001.
- [14] E. C. Cintra, Aplicações de Redes Neurais no Controle de Teores de Cobre e Ouro do Depósito de Chapada (GO), Rio Claro: Tese de Doutorado, Universidade Estadual Paulista, 2003.
- [15] L. O. Werle, Analisadores Virtuais Baseados em Modelo Neural para Monitoramento e Controle de Colunas de Destilação com Aquecimento Distribuído, Florianópolis, Brasil: Tese de Doutorado, Universidade Federal de Santa Catarina, 2012.
- [16] L. L. C. Franke, A. K. Chatzopoulos e S. Rigopoulos, "Tabulation of combustion chemistry via Artificial Neural Networks (ANNs): Methodology and application to LES-PDF simulation of Sydney flame L," *Combustion and Flame*, vol. 185, pp. 245-260, 2017.
- [17] D. W. Armitage e H. K. Ober, "A comparison of supervised learning techniques in the classification of bat echolocation calls," *Ecological Informatics*, vol. 5, nº 6, pp. 465-473, 2010.
- [18] N. Perraudin, M. Defferrard, T. Kacprzak e R. Sgier, "DeepSphere: Efficient spherical convolutional neural network with HEALPix sampling for cosmological applications," *Astronomy and Computation*, vol. 27, pp. 130-146, 2019.
- [19] L. Falat e L. Pancikova, "Quantitative Modelling in Economics with Advanced Artificial Neural Networks," *Procedia Economics and Finance*, vol. 34, pp. 194-201, 2015.
- [20] M. E. Benalcázar, M. Brun e V. L. Ballarin, "Artificial neural networks applied to statistical design of window operators," *Pattern Recognition Letters*, vol. 34, nº 9, pp.

- 970-979, 2013.
- [21] D. C. Cirean, A. Giusti, L. M. Gambardella e L. M. Schmidhuber, “Mitosis detection in breast cancer histology images with deep neural networks,” *Lecture Notes in Computer Science*, vol. 8150, pp. 441-418, 2013.
- [22] B. A. Munk, *Frequency Selective Surfaces: Theory and Design*, New York: Wiley-Interscience, 2000.
- [23] T. K. Wu, *Frequency Selective Surfaces and Grid Array*, New York: John Wiley, 1995.
- [24] R. Mittra, C. H. Chan e T. Cwik, “Techniques for analyzing frequency selective surfaces – A review,” *Proceedings of the IEEE*, vol. 76, pp. 1593-1615, 1998.
- [25] S. B. Paiva, V. P. Silva Neto, A. G. D'Assunção, “A New Compact Dual-band FSS with Angular and Polarization Stability for Wireless Applications,” em *SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference*, Águas de Lindóia, Brasil, 2017.
- [26] V. P. Silva Neto, S. B. Paiva e A. G. D'Assunção, “A New Compact, Stable and Dual-band Active Frequency Selective Surface with Closely Spaced Resonances for Wireless Applications at 2.4 and 2.9 GHz,” *IEEE Transactions on Electromagnetic Compatibility*, artigo aceito para publicação, 2019.
- [27] C. L. Nóbrega, *Análise de Superfícies Seletivas de Frequência com Elementos Pré-fractais para Aplicações em Comunicações Indoor*, Natal: Tese, Universidade Federal do Rio Grande do Norte, 2013.
- [28] S. W. Lee e C. L. Law, “Simple formulas for transmission through periodic metal grids or plates,” *IEEE Transactions on Antennas and Propagation*, vol. 30, nº 5, pp. 904-909, 1982.
- [29] V. P. Silva Neto, *Caracterização de Circuitos Planares de Micro-ondas pelo Método Iterativo das Ondas*, Natal: Dissertação de Mestrado, Universidade Federal do Rio Grande do Norte, 2013.
- [30] H. Prues e V. D. Capelle, “Accurate transmission line model for the rectangular microstrip antenna,” *IEEE Proceeding in Microwave, Optics and Antennas*, vol. 134, pp. 334-340, 1984.
- [31] R. W. Dearnley e A. R. F. Barel, “A broad-band transmission line model for a rectangular microstrip antenna,” *IEEE Transactions on Antennas and Propagation*, vol. 37, pp. 6-15, 1989.

- [32] T. Itoh, Numerical Techniques for Microwave and Millimeter-microwave Passive Structures, New York: John Wiley & Sons, 1989.
- [33] R. W. Dearnley e A. R. F. Barel, “A Comparasion of Models to Determine the Resonant Frequencies of a Rectangular Microstrip Antenna,” *IEEE Transactions on Antennas and Propagation*, vol. 37, pp. 114-118, 1989.
- [34] E. K. Miller, L. Medgyesi-Mitschang e E. H. Newman, Computational Electromagetics - Frequency Domain in Method of Moments, USA: IEEE Press, 1992.
- [35] R. F. Harrington, Field Computation by Method of Moments, USA: Macmillan Company, 1968.
- [36] M. N. O. Sadiku, “A Simple Introduction to Finite Element Analysis of Electromagnetic Problems,” *IEEE Transactions on Education*, vol. 32, pp. 85-93, 1989.
- [37] H. D. Bruns, C. Schuster e H. Singer, “Numerical Electromagnetic Field Analysis for EMC Problems,” *IEEE Transactions on Electromagnetic Compability*, vol. 49, pp. 253-262, 2007.
- [38] S. B. Paiva, Novas Propostas de Geometrias para Superfícies Seletivas de Frequência para Aplicações Wireless, Caraúbas, Brasil: Monografia, Universidade Federal Rural do Semi-árido, 2016.
- [39] J. A. Deibel, M. Escarra, N. Berndsen, K. Wang e D. M. Mittleman, “Finite-Element Method Simulations of Guided Wave Phenomena at Terahertz Frequencies,” *Proceedings of the IEEE*, vol. 95, nº 8, pp. 1624-1640, 2007.
- [40] A. Taflove, Advances in Computational Electromagnetics - The Finite Difference Time Domain Method, Artech House Publishers, 1998.
- [41] R. H. C. Maniçoba, Estudo do Acoplamento Entre Superfícies Seletivas de Frequência Assimétricas em Estruturas de Multicamadas, Natal, Brasil: Tese de Doutorado, Universidade Federal do Rio Grande do Norte, 2012.
- [42] I. o. E. a. Technology, “Researchers develop cheaper and simpler radar-absorbent material,” [Online]. Available: <https://phys.org/news/2015-01-cheaper-simpler-radar-absorbent-material.html>. [Acesso em 05 Maio 2019].
- [43] D. Redação, “Por que o trevo de quatro folhas é um símbolo de boa sorte?,” [Online]. Available: <https://super.abril.com.br/cultura/por-que-o-trevo-de-quatro-folhas-e-um-simbolo-de-boa-sorte/>. [Acesso em 05 Maio 2019].

- [44] I. N. Silva, D. H. Spatti e R. A. Flauzino, *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas - fundamentos teóricos e aspectos práticos*, São Paulo: Artliber, 2010.
- [45] A. P. Engelbrecht, *Computational Intelligence - An Introduction*. 2nd Edition, Chichester: John Wiley & Sons, 2007.
- [46] H. Demuth, M. Beale e M. Hagan, *Neural Network Toolbox™ 6 - User's Guide*, Natick: Mathworks, 2009.
- [47] F. D. Foresee e M. T. Hagan, "Gauss-Newton approximation to bayesian learning," em *Proceedings of International Conference on Neural Networks*, 1997.
- [48] M. F. Moller, "A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning," *Neural Networks Magazine*, vol. 6, pp. 525-533, 1993.

Apêndice A – Banco de Dados com as Amostras

h	p	d	fr1	BW1	fr2	BW2
0.8	10	6	14.3	1.29	29	0.17
0.8	10	6.5	13.5	1.4	28.84	0.34
0.8	10	7	12.9	1.67	28.5	0.7
0.8	10	7.5	11.9	1.79	28.3	0.99
0.8	10	8	11.3	2.11	28.2	1.48
0.8	10	8.5	10.3	2.22	28.3	1.81
0.8	10	9	9.7	2.69	28.4	2.27
0.8	10	9.5	8.76	3.07	28.55	2.55
0.8	12.5	7	12.39	0.97	23.61	0.03
0.8	12.5	7.5	11.82	1.08	23.56	0.06
0.8	12.5	8	11.7	1.16	23.47	0.19
0.8	12.5	8.5	10.63	1.92	23.39	0.29
0.8	12.5	9	10.13	1.32	21.54	0.09
0.8	12.5	9.5	9.75	1.49	23.18	0.76
0.8	12.5	10	9.13	1.66	23.17	0.96
0.8	12.5	10.5	8.66	1.74	23.2	1.18
0.8	12.5	11	8.2	1.93	23.2	1.38
0.8	12.5	11.5	7.8	2.25	23.3	1.58
0.8	12.5	12	7.25	2.75	19.88	0.16
0.8	15	10	9.13	0.95	19.74	0.04
0.8	15	10.5	8.77	1.01	18.4	0.1
0.8	15	11	8.6	1.17	18.3	0.13
0.8	15	11.5	8.2	1.31	18.2	0.13
0.8	15	12	7.84	1.31	18	0.07
0.8	15	12.5	7.5	1.42	19.6	0.75
0.8	15	13	7.3	1.59	19.6	0.91
0.8	15	13.5	6.8	1.66	19.6	1.02
0.8	15	14	7.2	1.58	19.6	0.9
0.8	15	14.5	6.8	1.65	19.6	1
0.8	17.5	12	7.97	0.88	16.07	0.11

0.8	17.5	12.5	7.51	0.9	16.01	0.13
0.8	17.5	13	7.29	0.97	15.91	0.17
0.8	17.5	13.5	7.16	1.06	15.94	0.13
0.8	17.5	14	6.78	1.11	15.8	0.06
0.8	17.5	14.5	7.10	1.03	15.9	0.11
0.8	17.5	15	6.37	1.27	16.91	0.59
0.8	17.5	15.5	6.10	1.38	16.92	0.65
0.8	17.5	16	5.81	1.54	16.93	0.75
0.8	17.5	16.5	5.45	1.67	14.91	0.1
0.8	17.5	17	5.07	1.81	14.7	0.19
0.8	20	9	4.1	0.1	9.6	0.46
0.8	20	13	7.4	0.71	14.9	0.06
0.8	20	13.5	7.08	0.72	14.26	0.06
0.8	20	14	7	0.79	14.3	0.09
0.8	20	14.5	6.7	0.8	14.2	0.08
0.8	20	15	6.53	0.85	14.2	0.12
0.8	20	15.5	6.27	0.88	14.15	0.09
0.8	20	16	6.13	0.96	14.03	0.05
0.8	20	16.5	5.86	1	14.86	0.31
0.8	20	17	5.69	1.08	14.86	0.37
0.8	20	17.5	5.45	1.12	14.86	0.39
0.8	20	18	5.26	1.23	14.87	0.48
0.8	20	18.5	5.02	1.3	14.87	0.49
0.8	20	19	4.78	1.53	13.19	0.14
0.8	20	19.5	4.45	1.62	13.04	0.2
1.2	10	6	13.6	1.32	27.40	0.25
1.2	10	6.5	12.6	1.38	27	0.46
1.2	10	7	12.1	1.63	26.5	0.7
1.2	10	7.5	11.1	1.77	26.3	0.96
1.2	10	8	10.6	2.01	26.1	1.30
1.2	10	8.5	9.8	2.3	26.1	1.63
1.2	10	9	9.3	2.72	26.4	1.77
1.2	10	9.5	8.3	3.16	26.5	2.2
1.2	12.5	7	11.61	0.93	22.94	0.08
1.2	12.5	7.5	11.13	1.04	22.77	0.18
1.2	12.5	8	10.61	1.15	22.45	0.35
1.2	12.5	8.5	10.1	1.2	22.24	0.51
1.2	12.5	9	9.65	1.35	22	0.73
1.2	12.5	9.5	9.15	1.48	21.88	0.95
1.2	12.5	10	8.7	1.6	21.9	1.13

1.2	12.5	10.5	8.4	1.81	21.9	1.4
1.2	12.5	11	7.86	2.03	22.01	1.59
1.2	12.5	11.5	7.3	2.24	22.1	1.82
1.2	12.5	12	6.76	2.6	22.23	2.14
1.2	15	9	9.5	0.85	19.3	0.06
1.2	15	9.5	9.12	0.93	19.25	0.19
1.2	15	10	8.7	0.98	19.1	0.3
1.2	15	10.5	8.4	1.06	18.93	0.49
1.2	15	11	8.1	1.16	18.8	0.65
1.2	15	11.5	7.73	1.25	18.75	0.84
1.2	15	12	7.53	1.38	18.75	1
1.2	15	12.5	7.10	1.49	18.8	1.18
1.2	15	13	6.74	1.58	18.81	1.38
1.2	15	13.5	6.44	1.75	18.92	1.46
1.2	15	14	6.09	1.93	18.97	1.68
1.2	15	14.5	5.57	2.11	19.04	1.81
1.2	17.5	11	7.93	0.77	16.72	0.1
1.2	17.5	11.5	7.64	0.81	16.67	0.17
1.2	17.5	12	7.47	0.89	16.59	0.27
1.2	17.5	12.5	7.18	0.94	16.53	0.36
1.2	17.5	13	6.95	1.01	16.45	0.52
1.2	17.5	13.5	6.68	1.04	16.39	0.68
1.2	17.5	14	6.51	1.14	16.41	0.78
1.2	17.5	14.5	6.3	1.24	16.4	0.89
1.2	17.5	15	6	1.32	16.4	1.02
1.2	17.5	15.5	5.79	1.44	16.46	1.15
1.2	17.5	16	5.6	1.57	16.5	1.19
1.2	17.5	16.5	5.19	1.63	16.57	1.25
1.2	17.5	17	4.93	1.96	14	0.12
1.2	20	13	7.1	0.76	14.7	0.06
1.2	20	13.5	6.76	0.77	14.68	0.14
1.2	20	14	6.6	0.81	13.55	0.09
1.2	20	14.5	6.34	0.83	13.52	0.09
1.2	20	15	6.14	0.87	13.49	0.09
1.2	20	15.5	5.91	0.91	14.56	0.46
1.2	20	16	5.81	0.98	14.53	0.61
1.2	20	16.5	5.53	0.99	14.47	0.61
1.2	20	17	5.37	1.09	14.56	0.75
1.2	20	17.5	5.2	1.17	14.6	0.81
1.2	20	18	4.97	1.23	14.6	0.87

1.2	20	18.5	4.86	1.4	14.61	0.94
1.2	20	19	4.51	1.48	12.51	0.09
1.2	20	19.5	4.26	1.72	12.35	0.24
1.57	5	4	19.4	2.89	38.8	0.72
1.57	5	4.5	16.90	4.2	37.40	1.32
1.57	10	6	12.9	1.18	26	0.2
1.57	10	6.5	12	1.37	25.3	0.45
1.57	10	7	11.2	1.6	24.9	0.65
1.57	10	7.5	10.6	1.83	24.4	0.88
1.57	10	8	10	2.08	24.3	1.12
1.57	10	8.5	9.4	2.28	24.4	1.22
1.57	10	9	8.8	2.75	24.6	1.29
1.57	10	9.5	7.82	3.25	24.69	1.66
1.57	12.5	7	11.04	0.93	21.84	0.13
1.57	12.5	7.5	10.74	1.06	21.66	0.22
1.57	12.5	8	10.07	1.14	21.25	0.39
1.57	12.5	8.5	9.58	1.26	21.03	0.52
1.57	12.5	9	9.2	1.39	20.8	0.69
1.57	12.5	9.5	8.7	1.5	20.7	0.86
1.57	12.5	10	8.33	1.7	20.66	1.02
1.57	12.5	10.5	7.81	1.84	20.65	1.21
1.57	12.5	11	7.39	2.14	20.72	1.42
1.57	12.5	11.5	6.91	2.4	20.87	1.63
1.57	12.5	12	6.3	2.86	20.9	1.96
1.57	15	9	9.1	0.89	18.6	0.21
1.57	15	9.5	8.6	0.91	18.4	0.32
1.57	15	10	8.4	1.04	18.2	0.44
1.57	15	10.5	7.87	1.06	18.14	0.52
1.57	15	11	7.7	1.2	18	0.7
1.57	15	11.5	7.31	1.27	17.87	0.87
1.57	15	12	7.05	1.37	17.9	1
1.57	15	12.5	6.66	1.5	17.94	1.15
1.57	15	13	6.4	1.61	18	1.25
1.57	15	13.5	6.05	1.79	18.08	1.4
1.57	15	14	5.7	1.99	18.1	1.61
1.57	15	14.5	5.2	2.35	18.2	1.91
1.57	17.5	10	8.1	0.71	16.4	0.07
1.57	17.5	10.5	7.79	0.74	16.35	0.14
1.57	17.5	11	7.5	0.8	16.2	0.24
1.57	17.5	11.5	7.3	0.84	16.1	0.32

1.57	17.5	12	7	0.9	16	0.41
1.57	17.5	12.5	6.8	0.97	15.87	0.53
1.57	17.5	13	6.60	1.03	15.8	0.68
1.57	17.5	13.5	6.35	1.09	15.77	0.78
1.57	17.5	14	6.3	1.14	15.8	0.84
1.57	17.5	14.5	5.95	1.27	15.82	1.01
1.57	17.5	15	5.84	1.3	15.83	1.06
1.57	17.5	15.5	5.56	1.37	15.87	1.18
1.57	17.5	16	5.31	1.47	15.93	1.27
1.57	17.5	16.5	5	1.68	16	1.43
1.57	17.5	17	4.7	1.87	16	1.65
1.57	20	11	7.6	0.58	14.6	0.03
1.57	20	11.5	7.3	0.62	14.56	0.06
1.57	20	12	7.2	0.66	14.5	0.03
1.57	20	12.5	7	0.72	14.4	0.15
1.57	20	13	6.7	0.71	14.4	0.2
1.57	20	13.5	6.53	0.74	14.35	0.25
1.57	20	14	6.4	0.79	14.2	0.35
1.57	20	14.5	6.11	0.84	14.21	0.4
1.57	20	15	5.9	0.86	14.2	0.5
1.57	20	15.5	5.74	0.89	14.14	0.58
1.57	20	16	5.6	1	14.1	0.7
1.57	20	16.5	5.44	1.06	14.10	0.83
1.57	20	17	5.3	1.13	14.1	0.91
1.57	20	17.5	5.09	1.21	14.17	1.02
1.57	20	18	4.8	1.28	14.2	1.08
1.57	20	18.5	4.62	1.37	14.26	1.16
1.57	20	19	4.36	1.4	14.3	1.23
1.57	20	19.5	4.1	1.65	14.3	1.47