

# MODELAGEM DE UMA ANTENA PLANAR QUASE-FRACTAL UTILIZANDO REDE NEURAL ARTIFICIAL

Elder Eldervitch Carneiro de Oliveira<sup>1</sup>

Tales Augusto Carvalho de Barros<sup>2</sup>

Pedro Carlos de Assis Júnior<sup>3</sup>

Rodrigo César Fonseca da Silva<sup>4</sup>

Marcelo da Silva Vieira<sup>5</sup>

## RESUMO

Neste artigo, uma antena patch baseado na curva fractal de Minkowski nível II foi modelada por meio de uma rede neural com três camadas, treinada com o algoritmo *resilient backpropagation* (RPROP). O conjunto de treinamento utilizado na caracterização eletromagnética da antena foi obtido por meio de um estudo paramétrico sobre as dimensões da antena, fazendo uso de simulações no *software* Ansoft Design<sup>TM</sup> que implementa o método dos momentos (MoM). O modelo da rede neural aqui proposto consiste de uma rede do tipo *multilayer perceptron* (MLP) composta de três camadas, sendo uma camada de neurônios ocultos. A rede neural uma vez treinada foi capaz de prever o comportamento da antena dentro de uma região de interesse investigada e com uma boa precisão e baixo custo computacional após o a fase de treinamento, sendo capaz de generalizar o conhecimento adquirido para dados fora do conjunto de treinamento imposto a ela.

**Palavras-chave:** Antena de microfita. Rede Neural. Fractal de Minkowski.

---

<sup>1</sup> Doutor em Engenharia Elétrica. Atualmente é professor adjunto da Universidade Estadual da Paraíba.

<sup>2</sup> Mestrando em Engenharia Elétrica pelo Instituto Federal da Paraíba – IFPB.

<sup>3,4,5</sup> Doutor em Física. Atualmente é professor adjunto da Universidade Estadual da Paraíba – UEPB.

## 1. INTRODUÇÃO

Com o advento cada vez mais acentuado do avanço tecnológico dos sistemas de comunicação sem fio, seja em tecnologias WiMax, Wi-Fi, Bluetooth ou mesmo as gerações 3G a 5G, surge uma grande necessidade por buscar dispositivos que atendam as mais variadas demandas, tais como: baixo peso, baixo perfil, baixo custo, eficiência e facilidade de integração a outros dispositivos e compatibilidade com tecnologias emergentes e demais aplicações. Nesse contexto, os projetos envolvendo tecnologias planares, por exemplo, antenas de microfita, arranjos de antenas, filtros seletivos em frequência, dentre outros (BALANIS, 1997), surgem como uma interessante solução, em virtude das características já mencionadas e por serem de fácil fabricação em pequena ou grande escala, a um custo acessível.

Projetos dessa natureza, aliado a geometria fractal, tornam ainda mais interessantes e atrativas as pesquisas na grande área da eletrodinâmica fractal, na qual é possível se conseguir dispositivos com dimensões reduzidas e com um comportamento multi-frequência, isso em virtude da junção de todas essas características em um único dispositivo compacto. Este artigo consiste em uma investigação numérica por meio de simulações computacionais de uma antena patch quase-fractal de nível II por meio da utilização da curva de fractal de Minkowski (OLIVEIRA, 2008) (MANDELBROT, 1983). Também é realizada uma modelagem neural dos parâmetros eletromagnéticos associados a essa estrutura.

Devido à grande complexidade de análise desse tipo de estrutura, técnicas de onda completa são normalmente utilizadas para modelagem e caracterização dessas antenas por meio de simuladores que implementam esses métodos, tais como o método dos momentos (MoM). Diante dessa dificuldade de análise, as redes neurais artificiais são constituídas de processadores de informação distribuídos paralelamente ao longo da arquitetura rede utilizada (HAYKIN, 2001). Elas surgem como uma técnica alternativa a projeto de circuitos e/ou dispositivos de micro-ondas que não tenham modelos matemáticos capazes de descrevê-los ou mesmo representá-los, onde muitas vezes essa análise é realizada por meio de métodos numéricos que necessitam de um tratamento matemático rigoroso e muito custoso.

Características atrativas, tais como: fácil adaptabilidade, generalização e rápida convergência são características que elevam o interesse dessa técnica na análise dos mais diversos dispositivos de micro-ondas, a exemplo das antenas patches em microfita.

## 2. GERAÇÃO DA CURVA FRACTAL DE MINKOWSKI

Benoit Mandelbrot, na década de 70, estudou uma maneira de representar formas exóticas que muitas vezes se faziam presentes na natureza, cujas formas não podiam ser explicadas pela geometria euclidiana em virtude de sua forma diferenciada e inexistência de uma equação matemática para explicá-la, na qual um pequeno pedaço dessa forma é uma réplica idêntica ao todo, dando dessa forma, a ideia de recursividade matemática, diante disso ele denominou essas novas estruturas de fractais (MANDELBROT, 1983).

Uma figura ou forma fractal remete a um objeto irregular, cuja dimensão é fracionária e com duas características muito particulares no que diz respeito a projeto de antenas e demais dispositivos de micro-ondas, são elas: i) a propriedade de preenchimento do espaço, o qual é requisito fundamental para a redução das dimensões da antena, e ii) a propriedade de auto similaridade, a qual é responsável pelo comportamento multibanda do dispositivo (OLIVEIRA, 2008).

A denominação quase-fractal se deu em virtude de a estrutura modelada não apresentar simetria em sua forma como um todo. Os trabalhos de Puente et al. (1998) e Cohen (1997) foram os primeiros a relacionarem a geometria fractal a dispositivos tais como antenas planares. A dimensão,  $d$ , dessa geometria é dada por:

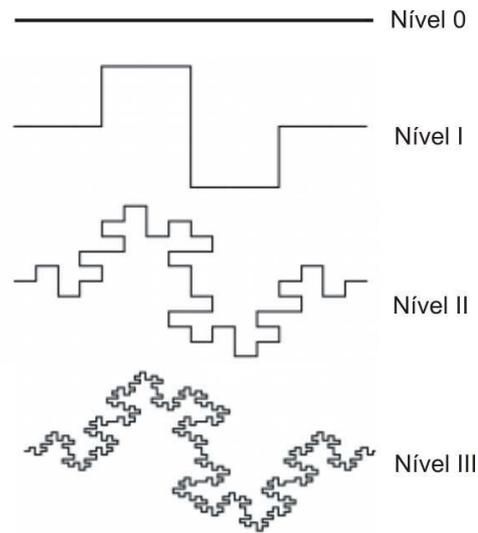
$$d = \frac{\log n}{\log r} \quad (1)$$

Onde,  $d$  é a dimensão fractal,  $n$  é o número de cópias do elemento, e  $r$  é o fator de escala de iteração considerado na geometria fractal. Para a geração da curva fractal de Minkowski, partiu-se inicialmente de um seguimento de reta que é dividido em quatro seguimentos menores que são cópias idênticas de si mesmo, obedecendo a um fator de escala de redução ( $r$ ), que neste caso foi considerado  $\frac{1}{4}$  do comprimento do segmento de reta inicial, conforme ilustra a Figura 1.

A obtenção da curva de Minkowski se dá pelo método IFS (*iterative function system*) a partir de 8 (oito) transformações afins  $q_i : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ , entre rotação e translação, determinado pela equação (2) (Oliveira et al., 2009) (MANDELBROT, 1991).

$$q_i(x, y) = \frac{1}{4} \begin{pmatrix} \cos \theta_i & -\sin \theta_i \\ \sin \theta_i & \cos \theta_i \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} \begin{pmatrix} e_i \\ f_i \end{pmatrix} \quad (2)$$

**Figura 1 – Geração da Curva Fractal de Minkowski.**



### 3. REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais ganharam bastante destaque na década de 80 quando aplicadas a modelagem de circuitos/dispositivos de micro-ondas, muito se deve ao fato de que uma boa parte desses dispositivos não possuem ou apresentam um modelo matemático fechado que os representam (HAYKIN, 2001). Nesse contexto, uma rede neural artificial (RNA) pode ser definida com uma máquina, que é projetada para modelar o mais fiel possível à maneira como o neurônio biológico realiza uma determinada tarefa ou executa uma função de interesse. Para alcançarem bom desempenho, as redes neurais empregam uma interligação robusta de processadores naturais, denominado de neurônios.

A Figura 2 ilustra o modelo teórico de um neurônio artificial (HAYKIN, 2001). Matematicamente um neurônio  $j$  de uma rede neural com  $N_i$  entradas é expresso por:

$$Net_j = \sum_{i=1}^{N_i} x_i w_{ji} + b \quad (3)$$

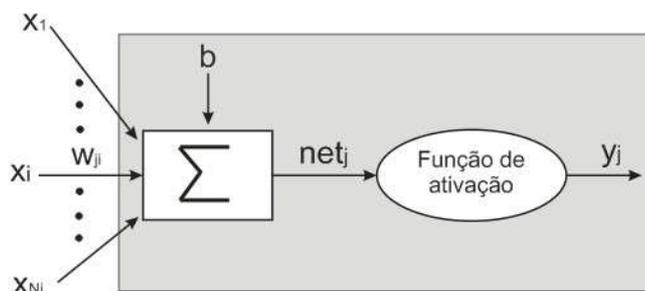
$$y_j = \phi(Net_j) \quad (4)$$

Em que,  $x_1, x_2, \dots, x_{n_i}$  são os sinais de entrada;  $w_1, w_2, \dots, w_{j_i}$  são os pesos sinápticos entre o neurônio  $i$  e neurônio  $j$ ;  $b$  é a polarização, também chamado de bias;  $net_j$  é o potencial de ativação;  $\phi(\cdot)$  é a função de ativação, e  $y_j$  é o sinal de saída do neurônio. Existem algumas funções de ativação que podem ser empregadas na formulação de um

neurônio. De uma maneira geral a função de ativação mais comumente utilizada é a função sigmóide, dado pela equação (5) (HAYKIN, 2001):

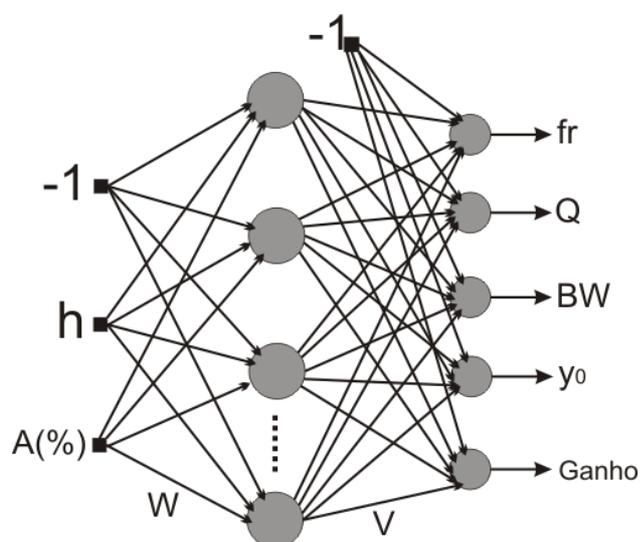
$$\phi Net_j = \frac{1}{1 + \exp(-Net_j)} \quad (5)$$

**Figura 2 – Modelo Teórico de um Neurônio Artificial.**



A arquitetura de rede neural utilizada neste trabalho foi do tipo MLP (*multilayer perceptron*), consistindo de três camadas, sendo uma camada de neurônios escondidos (HAYKIN, 2001). A Figura 3 ilustra o modelo de rede neural utilizado nesse artigo, onde a estrutura consiste de uma rede com três camadas, sendo uma camada escondida.

**Figura 3 – Modelo de uma rede neural com três camadas.**

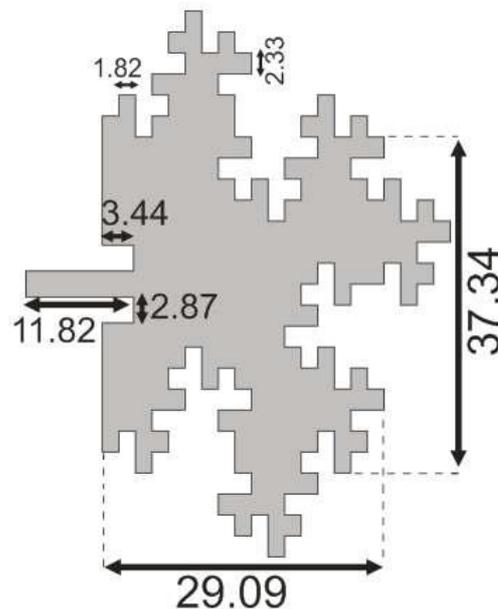


No modelo utilizado nesse trabalho, a rede neural consiste de cinco neurônios de saída, os quais dão ênfase aos parâmetros a serem modelados, tais como: frequência de ressonância ( $fr$ ), fator de qualidade ( $Q$ ), largura de banda percentual ( $BW\%$ ), ganho ( $dB$ ) e o parâmetro *inset-fed* ( $y_0$ ).

#### 4. ESTRUTURA DA ANTENA QUASE-FRACTAL MODELADA

Uma curva fractal é gerada recursivamente a partir de uma forma geradora inicial, conforme mostrado na Figura 1, porém para situações práticas, costuma-se utilizar até o nível II isso em virtude da dificuldade de se trabalhar e/ou mesmo construir dispositivos com um nível mais elevado. Neste trabalho a modelagem neural foi realizada para uma antena fractal de Minkowski nível II. Como dito anteriormente, o termo quase-fractal atribuído a antena modelada, consiste no projeto de uma antena fazendo uso da curva fractal de Minkowski, onde é possível observar que a mesma não apresenta simetria em sua estrutura. A geometria da antena modelada é mostrada na Figura 4, com suas dimensões em milímetros.

**Figura 4 – Estrutura da antena quase-fractal Minkowski nível II modelada.**



Observa-se que a curva fractal de Minkowski de nível II foi aplicada às margens radiante e não radiante de uma antena patch retangular convencional projetada para a frequência de 2,45 GHz, conforme mostrado em Oliveira et al. (2008). A antena consiste de um elemento irradiante (denominado patch), desenhado em conformidade com a curva fractal de Minkowski e depositado sobre uma camada dielétrica isotrópica acima de um plano de terra. A estrutura foi toda ela alimentada pela técnica de linha de microfita, fazendo uso de um conector SMA de 50  $\Omega$  de impedância. A técnica de *inset-fed* ( $y_0$ ) foi utilizada nessa estrutura para melhorar as características de impedância da antena (BALANIS, 1997). O substrato utilizado foi uma placa de fibra de vidro (FR4) com 1,5 mm de espessura ( $h$ ) e uma permissividade elétrica relativa ( $\epsilon_r$ ) igual a 4,4.

## 5. RESULTADOS DA MODELAGEM NEURAL DA ANTENA QUASE-FRACTAL PROPOSTA

Para a modelagem da antena quase-fractal proposta, nós fizemos uso do modelo de rede neural MLP mostrado na Figura 3, apresentando 3 (três) neurônios de entrada, sendo eles: o polarizador (bias, com valor igual a -1), a espessura do substrato ( $h$ ) e a dimensão da antena ( $A\%$ ), na qual para cada variável de entrada dessas foi associado um neurônio. Na camada escondida foi utilizado 12 (doze) neurônios e mais 5 (cinco) neurônios de saída correspondente aos parâmetros de antenas a serem modelados.

Para o conjunto de treinamento fornecido ao algoritmo *resiliente backpropagation* (RPROP) (Riedmiller et al., 1993), os dados foram obtidos de uma análise paramétrica, onde se variou a espessura do substrato ( $h$ ) utilizado em  $h=[1,5; 3,0; 4,5; 6,0; 7,5; 9,0; 10,5]$  mm para cada dimensão da antena analisada,  $A\%=[50; 60; 75; 90; 100]$ , consistindo de 7 (sete) pontos por curva, totalizando 28 (vinte e oito) amostras como pontos que compuseram o conjunto de treinamento dessa rede. Em que, a curva referente a 75% das dimensões da antena foi retirada (não utilizada no treinamento) para teste e validação do modelo de rede neural proposto.

O primeiro resultado obtido consiste de uma análise paramétrica realizada no simulador, onde foi observado o comportamento do parâmetro *inset-fed* ( $y_0$ ) quando aumentamos a espessura do dielétrico e variamos o tamanho da antena quase-fractal de nível II. Observa-se também a resposta da saída da rede neural após a fase de treinamento, conforme é mostrada na Figura 5, onde a modelagem neural mostra que a rede aprendeu perfeitamente ao conjunto de treinamento (curvas sólidas) imposto a ela e foi capaz de generalizar todo o conhecimento adquirido para dados não treinados pela rede neural proposta (curva referente a 75%), bem como para qualquer curva dentro da região de interesse analisada.

O resultado da Figura 6 mostra o comportamento da largura de banda percentual da antena com diferentes dimensões ao se submeter à variação da espessura do dielétrico. Observa-se um comportamento de curva exponencial, com tendência crescente à medida que se eleva a espessura do substrato utilizado, sendo o maior valor obtido para a curva de  $A\%=50$ , para um  $h=10,5$  mm. A saída da rede mostrou um perfeito aprendizado para dados treinados e uma ótima generalização (para dados não utilizados no treinamento) da largura de banda percentual para outras dimensões da antena dentro da região analisada.

Figura 5 - Saída da rede neural para a modelagem do parâmetro *inset-fed* (dimensões em milímetros).

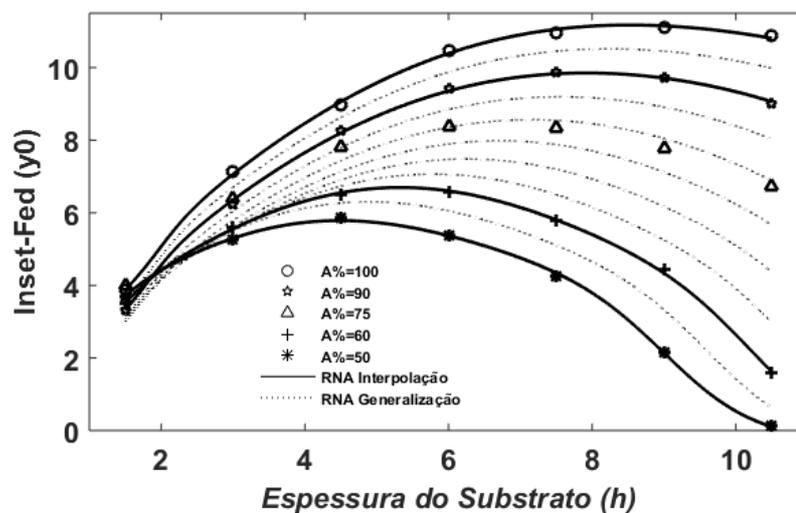
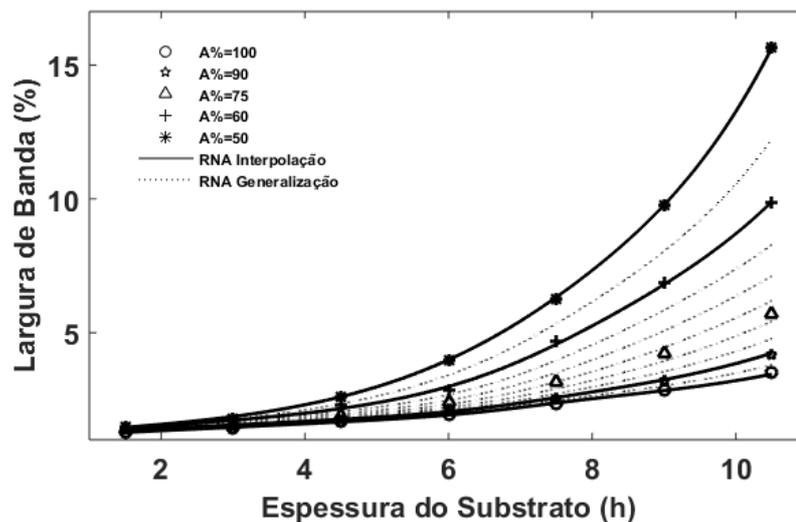


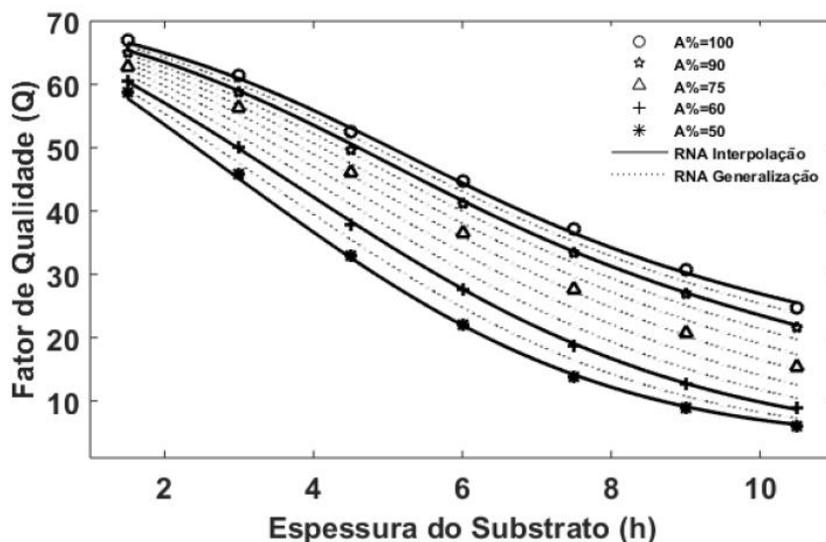
Figura 6 - Saída da rede neural para a modelagem do parâmetro largura de banda percentual (dimensões dos parâmetros da antena em milímetros).



O fator de qualidade ( $Q$ ) é um parâmetro que projeta a máxima eficiência da antena, e que também relaciona a frequência de ressonância e a largura de banda dessa antena. A Figura 7 mostra o comportamento desse fator  $Q$  à medida que aumentamos a espessura do substrato utilizado em função das dimensões da antena. Desse resultado podemos observar que o maior valor de  $Q$  obtido foi para uma antena com 100% de sua dimensão física ( $A\%=100$ ), com um valor de 68, para um valor de  $h=1,5$  mm. Novamente, após a fase de treinamento, pode-se observar que a rede neural aprendeu ao conjunto de

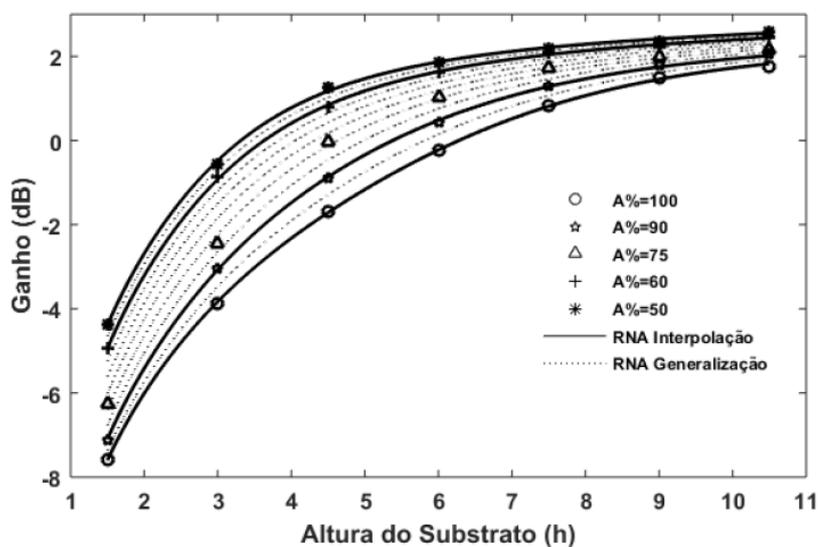
treinamento imposto e foi capaz de interpolar e generalizar todo o conhecimento adquirido dentro da faixa de interesse com boa precisão e baixo custo computacional.

**Figura 7 - Saída da rede neural para a modelagem do parâmetro fator de qualidade (dimensões dos parâmetros da antena em milímetros).**



Outro parâmetro modelado pela rede neural foi o ganho (dB) da antena quase-fractal de Minkowski nível II. O resultado da Figura 8 mostra o comportamento do ganho dessa antena ao se varia a sua dimensão e sua espessura do substrato ( $h$ ).

**Figura 8 - Saída da rede neural para a modelagem do parâmetro ganho em dB para a antena proposta (dimensões dos parâmetros da antena em milímetros).**

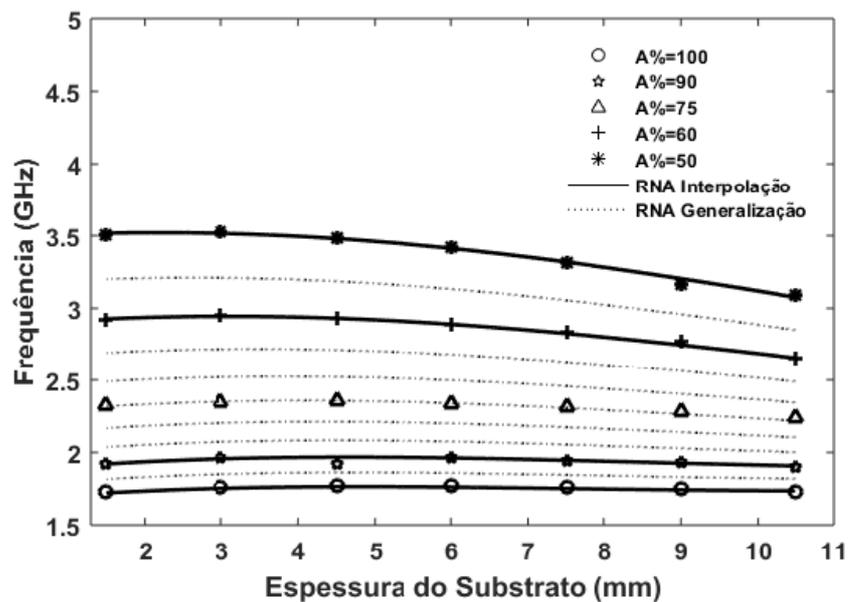


Podemos observar que a antena apresentou o maior ganho para a curva correspondente a 50% de suas dimensões físicas e para um  $h$  igual a 10,5 mm de

espessura. A resposta da rede ao conjunto de treinamento imposto é mostrada na Figura 9, onde novamente podemos observar que o modelo de rede neural proposto aprendeu perfeitamente ao conjunto de treinamento imposto a ela e foi capaz de generalizar todo o conhecimento adquirido dentro da região de interesse investigada.

Observa-se da Figura 9 um comportamento com tendências linear da frequência de ressonância para todas as dimensões da antena quando se varia a espessura do substrato. Já era esperado que a curva referente à dimensão da antena de 50% seria a que apresentaria as maiores frequências de ressonâncias, isso em virtude da redução considerável de suas dimensões. Para essa situação a resposta da rede foi muito boa e com grande precisão tanto na fase de treinamento quanto na fase de teste e generalização para dados não treinados pela rede neural. O modelo neural aprendeu ao conjunto de treinamento imposto e generalizou perfeitamente a todo o conhecimento adquirido dentro da região analisada.

**Figura 9 – Saída da rede neural para a modelagem da frequência de ressonância para a antena proposta (dimensões dos parâmetros da antena em milímetros).**



## 6. CONCLUSÃO

Nesse artigo, foi projetado uma antena patch quase-fractal para a faixa de frequência das micro-ondas, onde foi utilizada a curva fractal de Minkowski de nível II para o projeto da antena. Também foi realizado um estudo paramétrico sobre essa antena,

onde levantamos dados de parâmetros fundamentais de antenas, tais como: frequência de ressonância, largura de banda, fator de qualidade, ganho e o parâmetro inset-fed, sendo este último muito utilizado para casamento de impedância de antenas. Esses dados foram obtidos com o auxílio do simulador de onda completa Ansoft designer<sup>TM</sup>, onde foi criada uma base de dados que posteriormente foi utilizada no algoritmo de treinamento *resiliente backpropagation*, com a finalidade de treinar o modelo de rede neural aqui proposto para a modelagem dos parâmetros da antena quase-fractal de Minkowski de nível II.

No estudo paramétrico realizado, variou-se a espessura do substrato ( $h$ ) e as dimensões da antena ( $A\%$ ). Foi observado que a rede MLP não teve dificuldade de aprender ao conjunto de treinamento imposta a ela, na qual a rede neural foi capaz de interpolar os pontos ainda na fase de treinamento e extrapolar de forma eficiente todo o aprendizado adquirido para dados não utilizados na fase de treinamento dentro da região de interesse investigada, mostrando-se tão precisa quanto os modelos analíticos e eficientes computacionalmente, apresentando assim um baixo custo computacional, em que o erro médio quadrático obtido na fase de treinamento para 8 mil épocas foi da ordem de  $2,93 \times 10^{-5}$ .

## AGRADECIMENTOS

Os autores do trabalho agradecem ao Grupo de Eletromagnetismo e Matemática Computacional Aplicada (GEMCA) e a Universidade Estadual da Paraíba - UEPB.

## REFERÊNCIAS

- BALANIS, C. A. **Antenna theory-analysis and design**. 2nd ed. USA: John Wiley & Sons, 1997.
- MANDELBROT, B. B. **The Fractal Geometry of Nature**. USA: W. H. Freeman, 1983.
- OLIVEIRA, E. E. C. **Antenas de Microfita com Patch Quase-Fractal para Aplicações em Redes WPAN/WLAN**. Dissertação (Mestrado em Engenharia Elétrica)– Universidade Federal do Rio Grande do Norte - UFRN, 2008.
- HAYKIN, S. **Redes Neurais – Princípios e Práticas**. Bookman, 2001.
- PUENTE et al. **On the Behavior of the Sierpinski Multibanda Fractal Antenna**. IEEE Transactions on Antennas and Propagation, vol. 67, pp. 517-524, 2013.
- COHEN, N. **Fractal antenna applications in wireless telecommunications**, Proceedings of Electronics Industries Forum of New England, pp. 43-49, 1997.

CRUZ, J. N.; SERRES, A. J.; MOURA, L. C. M.; COSTA, A. P.; SILVA, P. H. F.; Antena Monopolo Impressa Bioinspirada na Folha de Inga Marginata para Aplicações UWB. In: 12º CBMag - Congresso Brasileiro de Eletromagnetismo e 17º SBMO - Simpósio Brasileiro de Micro-ondas e Optoeletrônica, 2014, Curitiba. Anais.

OLIVEIRA, E. E. C.; SILVA, P. H. F.; CAMPOS, A. L. P. S.; **Overall Size Antenna Reduction Using Fractal Elements**, Microwave and Optical Technology Letters, vol. 51, pp. 671-675, 2009.

MANDELBROT, B. B. **Objectos Fractais: forma, acaso e dimensão**, Gradiva Publicações, Lisboa, 1991.

RIEDMILLER, M.; BRAUN, H.; **A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm**, In Proceedings of the IEEE International Conference on Neural Networks, vol. 1, pp. 586- 591, 1993.

MORETTI, Isabella. “Regras da ABNT para TCC: conheça as principais normas”. 2017. Disponível em: <<https://viacarreira.com/regras-da-abnt-para-tcc-conheca-principais-normas>>. Acesso em: 09/07/2018.