



Prova de conceito de algoritmo com rede neural artificial para tratamento de imagem para tomografia de câncer cerebral infantil por micro-ondas

João Gabriel de Souza Bitencourt

Bacharelado de Engenharia de Controle e Automação
Laboratório Maxwell de Micro-Ondas e Eletromagnetismo Aplicado (LABMAX)
Instituto Federal de Educação, Ciência e Tecnologia de São Paulo (IFSP) – Campus
Cubatão, SP, Brasil.

Raimundo Eider Figueiredo Sobrinho

Bacharelado de Engenharia de Controle e Automação
Laboratório Maxwell de Micro-Ondas e Eletromagnetismo Aplicado (LABMAX)
Instituto Federal de Educação, Ciência e Tecnologia de São Paulo (IFSP) – Campus
Cubatão, SP, Brasil.

Dr. Alexandre Maniçoba de Oliveira

Laboratório Maxwell de Micro-Ondas e Eletromagnetismo Aplicado (LABMAX)
Instituto Federal de Educação, Ciência e Tecnologia de São Paulo (IFSP) – Campus
Cubatão, SP, Brasil.

Dr. Arnaldo de Carvalho Junior

Laboratório Maxwell de Micro-Ondas e Eletromagnetismo Aplicado (LABMAX)
Instituto Federal de Educação, Ciência e Tecnologia de São Paulo (IFSP) – Campus
Cubatão, SP, Brasil.

Resumo: Os tumores cerebrais são o resultado do crescimento descontrolado de células anormais. Tumores cerebrais e do sistema nervoso central representam 26% dos cânceres infantis. Assim como os demais tipos de câncer, o diagnóstico precoce é fundamental para o processo de cura e de sobrevida do paciente infantil. Ferramentas de diagnóstico de câncer, sobretudo de forma não invasiva, de baixo custo, são altamente desejáveis. Entre as diferentes tecnologias utilizadas para o diagnóstico de câncer infantil, estão os sistemas de tomografia por ondas eletromagnéticas de micro-ondas de campo próximo e baixa intensidade. As medições coletadas com esta técnica precisam ser processadas e tratadas para formar as imagens que serão interpretadas por um profissional de medicina. Algoritmos de inteligência artificial (IA) têm sido utilizados para o processamento de imagens. Esse artigo trata de uma prova de conceito de algoritmo utilizando rede

neural artificial (RNA) para identificação e classificação de diferentes materiais, para elaboração de imagem de tomografia por micro-ondas de campo próximo para diagnóstico de câncer cerebral infantil.

Palavras-chave: Imagem de Micro-ondas de Campo Próximo. Imagem Médica. Rede Neural Artificial. Lógica Paraconsistente.

Abstract: Brain Tumors are the result of the uncontrolled growth of abnormal cells. Brain and central nervous system tumors account for 26% of childhood cancers. As with other types of cancer, early diagnosis is essential for the healing process and survival of the child patient. Cancer diagnostic tools, especially in a non-invasive, low-cost way, are highly desirable. Among the different technologies used for diagnosing childhood cancer are low-intensity, near-field microwave electromagnetic wave tomography systems. Measurements collected with this technique need to be processed to form the images that will be interpreted by a medical professional. Artificial intelligence (AI) algorithms have been used for image processing. This article deals with a proof-of-concept algorithm using an artificial neural network (ANN) for the identification and classification of different materials, for the elaboration of a microwave tomography image for the diagnosis of childhood brain cancer.

Keywords: Near-field microwave image. Medical Image. Artificial Neural Network. Paraconsistent Logic.

1 INTRODUÇÃO

O câncer é uma doença caracterizada por uma má formação celular, estando presente em todo o reino animal, principalmente nos seres humanos. Há uma relação entre países de baixa e média renda e o número de casos que afetam esses lugares [1], em que o Brasil se encaixa nesse parâmetro. De acordo com o Instituto Nacional de Câncer (INCA), o câncer, no Brasil, fica abaixo apenas das doenças cardiovasculares [1].

O câncer cerebral infantil é um dos grandes problemas de saúde pública na contemporaneidade, sobretudo quando se observa o aumento no número de casos. Observa-se a necessidade de redução do tempo entre o início da patologia e o seu diagnóstico a fim de se obter a melhoria na sobrevivência das crianças pacientes [2], [3].

Observa-se aumento na ocorrência dos casos de câncer cerebral infantil, apesar da redução da mortalidade, graças aos avanços no diagnóstico precoce e de seu tratamento [4], [5].

O diagnóstico precoce é uma ação a ser implementada como forma de prevenção ao câncer cerebral infantil. No entanto, esse tipo de diagnóstico requer exames realizados por equipamentos grandes, de alta tecnologia e de alto custo [2]. Assim, pode-se qualificar como principal problema para o diagnóstico precoce do câncer cerebral infantil a necessidade de um equipamento de fácil acesso, baixo custo e de precisão. Para tanto, intensos esforços da comunidade acadêmica de eletromagnetismo têm sido aplicados à bioengenharia. Destaque-se a aplicação de micro-ondas para o diagnóstico do câncer cerebral infantil por imagens [6],[7],[8].

A técnica de imagens por micro-ondas consiste em se utilizar basicamente de um sistema de radar de pulsos, que podem estar entre 1 e 10,6 GHz, formado pelo sistema eletrônico e pelas antenas (receptoras e transmissoras), dispostas na forma de arranjo no entorno da cabeça da criança e, a partir da interação das micro-ondas de baixa potência e de seus tecidos, realiza-se a análise [8]. Estes sinais eletromagnéticos sofrem mudanças em função das diferentes densidades dos tecidos e, após atravessá-los, são recebidos pela antena e processados por algoritmos específicos que, por sua vez, apresentam uma espécie de representação dielétrica (condutividade e permissividade) dos tecidos do cérebro na forma de imagens de alta resolução [8]. Estas imagens permitem ao médico diagnosticar precocemente o câncer cerebral infantil, conforme resultados dos trabalhos publicados sobre diagnóstico por imagens por micro-ondas [8],[9],[10].

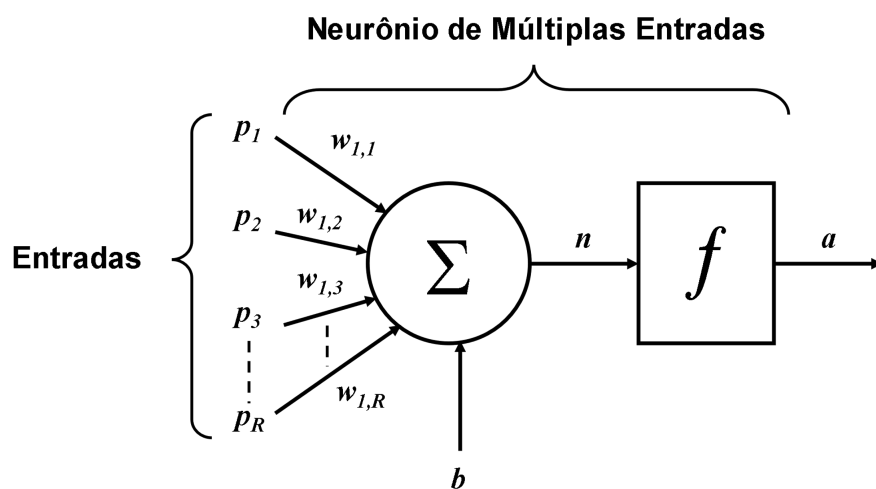
O sistema de diagnóstico precoce de câncer por imagens de micro-ondas precisa de ambientes propícios de teste e calibração para serem desenvolvidos. Para isso, trabalhos de pesquisa para detecção de tumores por imagens por micro-ondas utilizaram, sobretudo em sua fase inicial, *phantoms* como alternativa ao uso em humanos [11]. Os *phantoms* são modelos físicos feitos a partir de materiais sintetizados de forma a imitar as características eletromagnéticas dos tecidos e órgãos, para aplicação em análise por imagens, além de poderem ser utilizados em procedimentos de calibração [12], [13].

As micro-ondas têm sido investigadas para a detecção de tumores, com destaque para o emprego de técnicas de inteligência artificial (IA), aprendizado de

máquina (*machine learning* - ML) e redes neurais artificiais (RNAs) (*artificial neural network* – ANN) [14],[15],[16].

RNAs são algoritmos capazes de aprender uma determinada função ou reconhecer padrões. Apesar de não terem a mesma complexidade de um cérebro biológico, as RNAs apresentam duas similaridades básicas com o neurônio biológico: a possibilidade de descrição de seus blocos de construção por dispositivos computacionais simples e as conexões entre os neurônios determinam a função da rede [17]. A Fig. 1 apresenta a concepção de um neurônio artificial.

Figura 1 - Estrutura simplificada de um neurônio Artificial



Fonte: Adaptado de [17].

Onde $p_1 \dots p_n$ são as entradas, $w_{1,1} \dots w_{1,R}$ são os pesos aplicados sobre o valor da entrada, b ou “bias” é um valor de ajuste, n é o resultado da soma. O bloco f é a função de ativação que será aplicada ao neurônio artificial, enquanto a é valor de saída deste neurônio. O neurônio artificial pode ser descrito pelas equações (1) e (2), sendo que esta última equação está na forma de matriz.

Diversas funções matemáticas podem ser utilizadas como função de ativação de neurônios artificiais [18]. De modo a permitir o treinamento do neurônio e das redes neurais, é desejável que a função seja não linear e derivável [17]. A interligação de neurônios e a organização em camadas formam as RNAs.

$$n = w_{1,1}p_1 + w_{1,2}p_2 + w_{1,3}p_3 + \dots + w_{1,R}p_R \quad (1)$$

$$a = f(Wp + b) \quad (2)$$

Uma função de ativação bastante utilizada é a tangente hiperbólica, com curva tipo sigmoide, cuja equação e sua derivada são apresentadas em (3) e (4) [17],[18].

$$a = \tanh \tanh (n) = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (3)$$

$$(n) = 1 - (n) \quad (4)$$

O algoritmo proposto também faz uso da lógica paraconsistente anotada com anotação de dois valores (LPA2v) para a extração de média. A LPA2v pertence à família de lógicas paraconsistentes, cuja principal característica é a revogação da não contradição, intrínseca da lógica clássica [17]. A LPA2v é uma lógica robusta, com matemática simples e que permite o tratamento de sinais e informações contraditórias. Entre os diversos algoritmos e baseadas nas equações da LPA2v, está o paraextrator. Este algoritmo permite o cálculo de média, em um grupo de evidências, pela extração dos efeitos da contradição, como ruídos e incertezas, com respeito a uma determinada proposição [19].

O algoritmo do paraextrator funciona da seguinte forma:

- a) Em uma base de dados ou vetor, selecione os valores máximo e mínimo.
- b) O valor máximo será a evidência μ_1 , enquanto o valor mínimo será a evidência μ_2 .
- c) Aplique a LPA2v, equações (5)-(7), para calcular o grau de evidência resultante (μ_{ER}).

$$d = \sqrt{(1 - |\mu_1 + \mu_2 - 1|)^2 + (\mu_1 - \mu_2)^2} \quad (5)$$

$$D = \begin{cases} 1 & d > 1 \\ d & d \leq 1 \end{cases} \quad (6)$$

$$\mu_{ER} = \begin{cases} \frac{2-D}{2} (\mu_1 + \mu_2 - 1) & > 0 \\ \frac{D}{2} (\mu_1 + \mu_2 - 1) & < 0 \\ 0.5 (\mu_1 + \mu_2 - 1) & = 0 \end{cases} \quad (7)$$

- d) Adicione o μ_{ER} na base de dados e retire os valores máximo e mínimo utilizados.
- e) Retorne ao passo a) e refaça os cálculos até restar apenas um valor final possível para μ_{ER} .

Esse artigo dá continuidade aos estudos desenvolvidos em [8], apresentando os resultados de uma prova de conceito de algoritmo, utilizando algoritmo para extrator da LPA2v para extração de média e rede neural artificial (RNA) para identificação e classificação de diferentes padrões de reflexão de sinais. O objetivo é a elaboração de imagem de tomografia por micro-ondas de campo próximo para diagnóstico de câncer cerebral infantil. A seção 2 apresenta a metodologia utilizada pelo algoritmo proposto. A seção 3 apresenta os resultados alcançados por esta pesquisa, com uma breve discussão. O artigo é finalizado com as considerações finais, apresentadas na seção 4.


2 MATERIAIS E MÉTODOS

Esta sessão apresenta os conceitos básicos utilizados para a elaboração do algoritmo de tratamento de imagem de medição de micro-ondas de baixa intensidade de campo próximo, para o câncer cerebral infantil.

2.1. Medição e Base de Dados

Para as medições, utiliza-se um posicionador de antena e um equipamento refletômetro no domínio do tempo (*time domain reflectometer* - TDR), conforme descrito em [16]. O TDR gera um pulso em uma frequência de micro-ondas que propagará até o alvo e retornará ao instrumento. O TDR mede, então, o sinal recebido, que dependerá das características dielétricas do alvo. A Fig. 2 apresenta uma fotografia da antena Vivaldi Palm Tree, do *phantom*, do posicionador utilizados.


Figura 2 - Sistema de geração de micro-ondas utilizando *phantom* e antena Palm Tree



Fonte: Adaptado de [16].

Para o desenvolvimento do algoritmo, foram utilizadas as bases de dados geradas pelas medições realizadas em [8]. O *phantom* utilizado é um modelo de cabeça infantil semirrealista e homogêneo, feito de poliestireno expandido (isopor) da Daiso Industries Company, Ltd., Modelo YM-18-P6 C028 600 - EPS n.º 4, lote n.º 2009BJ. Dentro deste *Phantom*, é posicionado, na parte frontal, um modelo de tumor, modelado com uma bolsa de silicone, com paredes de 30 µm de espessura, preenchida com água mineral. A antena se desloca a passos de 1 mm, alguns centímetros antes e depois do alvo. Dois conjuntos de medições foram realizadas. Com e sem tumor simulado. O resultado foram duas planilhas, de 101 colunas (medições), com 1001 pontos. A Fig. 3 apresenta uma parte da planilha com as medições obtidas com tumor simulado.


Figura 3 – Medições do TDR *phantom* com tumor



Fonte: Elaborado pelos autores (2022).

A Fig. 4 apresenta um exemplo de medições (colunas), do arquivo de medições com tumor, identificadas como medição em vazio (sem alvo, ar), corpo (*phantom*) e tumor. Observa-se que há uma pequena diferença nos valores de amplitude de cada uma das medições dos três obstáculos, dificultando a distinção e análise dos dados comparativos.

Figura 4 - Sistema de geração de micro-ondas utilizando *phantom* e antena Palm Tree



Fonte: Adaptado de [16].

2.2. Identificação de Padrões e RNA resultante

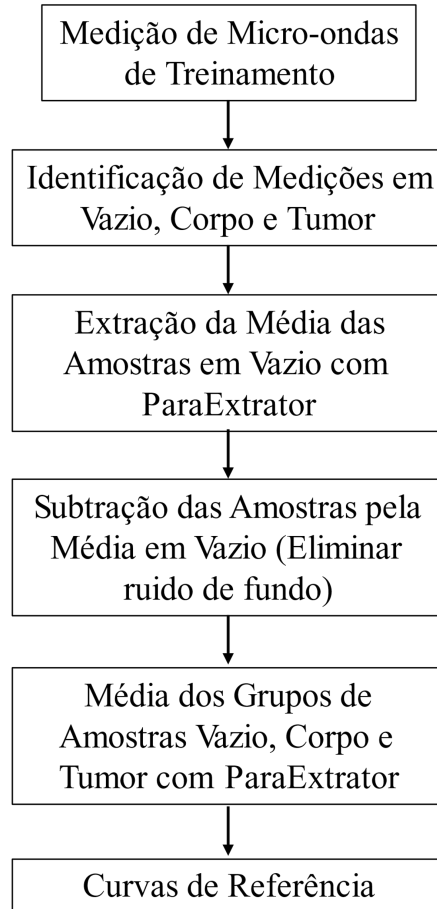
A metodologia proposta neste artigo considera duas etapas. A primeira consiste no treinamento da rede neural. A segunda consiste em utilizar um algoritmo de preparação de dados com a rede neural treinada para a confecção da imagem da tomografia. A imagem proposta é em 2D, considerando-se duas direções de medidas coletadas, frontal e lateral.

A Fig. 5 apresenta o algoritmo proposto para o treinamento da RNA. Os blocos são explicados a seguir:

- O primeiro passo é selecionar a base de dados. A primeira metade da base de dados com câncer foi utilizada para o treinamento da RNA (colunas 1 a 50), enquanto a segunda metade foi utilizada para validação (51 a 101).
- Amostras 1 a 10 são usadas para caracterizar o vazio. Amostras 25 a 35 para caracterizar o corpo e amostras 46 a 50 para caracterizar o tumor.
- É calculada a média das amostras em vazio, linha a linha (média de 10 valores em cada uma das 1001 linhas), com o algoritmo do paraextrator.
- Subtração das 101 amostras (colunas) pela média do vazio. Isso é feito para retirar o ruído de fundo das medições.

- e) Com a nova base de dados resultante, calcular a média das amostras em vazio (1 a 10), corpo (25 a 35) e tumor (46 a 50), com o algoritmo paraextrator.
- f) Aplicar a transformada rápida de Fourier (*fast Fourier transform* – FFT) nas três médias obtidas no bloco anterior.

Figura 5 – Fluxograma do Algoritmo de Classificação de Padrões vazio, corpo e tumor do *phantom*

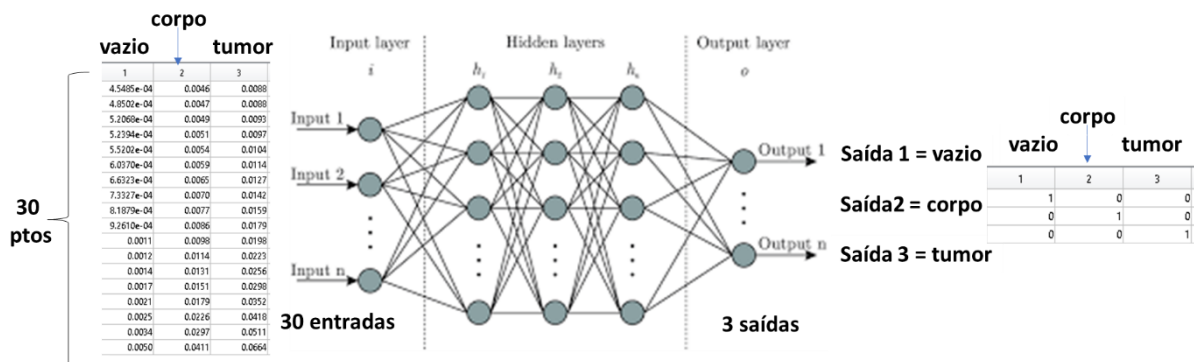


Fonte: Adaptado de [16].

As três curvas obtidas são usadas para o treinamento de uma RNA, com a ferramenta *neural net pattern recognition* (nprtool) do Matlab. A RNA deve apresentar saída 1 quando um determinado padrão é apresentado em sua entrada e zero para os outros dois padrões.

A Fig. 6 apresenta o conceito.

Figura 6 – Diagrama conceitual da RNA, sinais de entrada e saídas resultantes



Fonte: Adaptado de [16].

A ferramenta nprtool gera um bloco do Simulink que pode ser acionado para ser executado via script do Matlab. Este bloco será usado para a classificação de padrões apresentados em sua entrada, pelo algoritmo de tomografia de imagem de câncer cerebral infantil, proposto neste artigo.

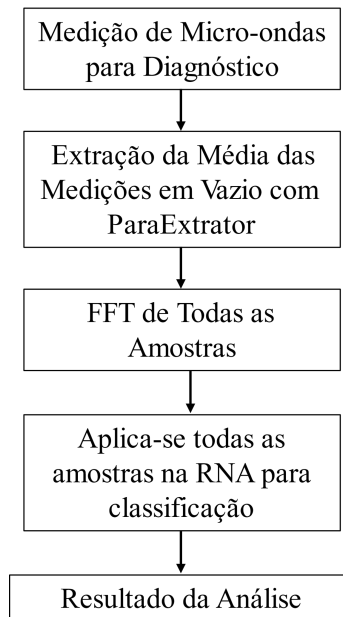
2.3. Identificação de Padrões e RNA

A Fig. 7 apresenta o fluxograma do algoritmo para classificação dos padrões e montagem da imagem de diagnóstico em 2D. Ele pode ser descrito da seguinte forma:

- O primeiro passo é obter os arquivos das medições nas direções frontal e lateral.
- Seleção das amostras em vazio (no início da medição), cálculo da média das medições em vazio com o paraextrator e subtração de todas as medidas por esta média em vazio.
- Cálculo da FFT de todas as amostras.
- Executa a RNA para todas as amostras, em cada direção. O resultado são dois arquivos com 101 pontos cada e três saídas (vazio, corpo e tumor), com valores 0 ou 1. Estes dois arquivos são utilizados para a montagem de uma figura com cores vermelho, verde e azul (*red, green and blue* – RGB) no Matlab.

A próxima seção apresenta os resultados obtidos.

Figura 7 – Fluxograma do algoritmo de tomografia por micro-ondas com classificação de padrões utilizando RNA



Fonte: Adaptado de [16].

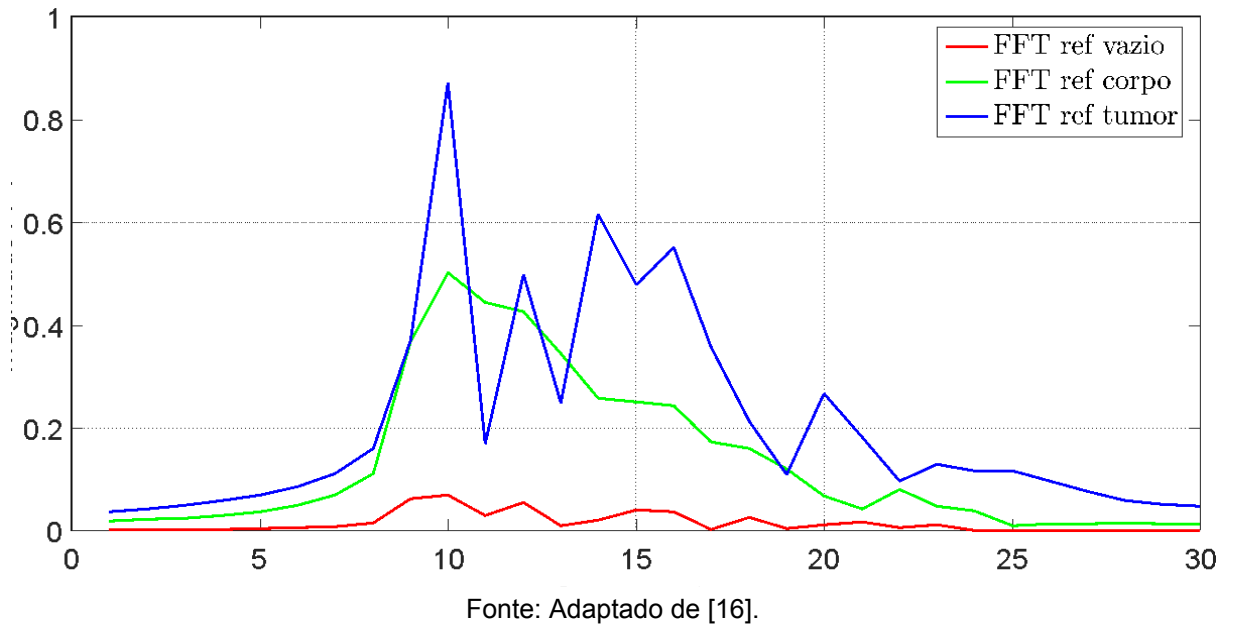
3 RESULTADOS

Nesta seção, são apresentados os resultados obtidos tanto para a identificação de padrões e projeto da RNA, como para a confecção da imagem de tomografia do câncer cerebral infantil.

3.1. Padrões Identificados e RNA Resultante


A execução do algoritmo da primeira etapa, de identificação de padrões, resultou nas curvas de referência (padrões), apresentados na Fig. 8. A FFT resulta em uma redução no número de pontos, de 1001 para 30, permitindo uma simplificação na arquitetura da RNA. Além disso, a subtração das medidas pela média em vazio, além de extrair o ruído de fundo, permite uma melhor distinção entre as envoltórias das curvas de vazio, corpo e tumor.

Figura 8 – Resultado após a FFT das médias das amostras em vazio (vermelho), corpo (verde) e tumor (azul)

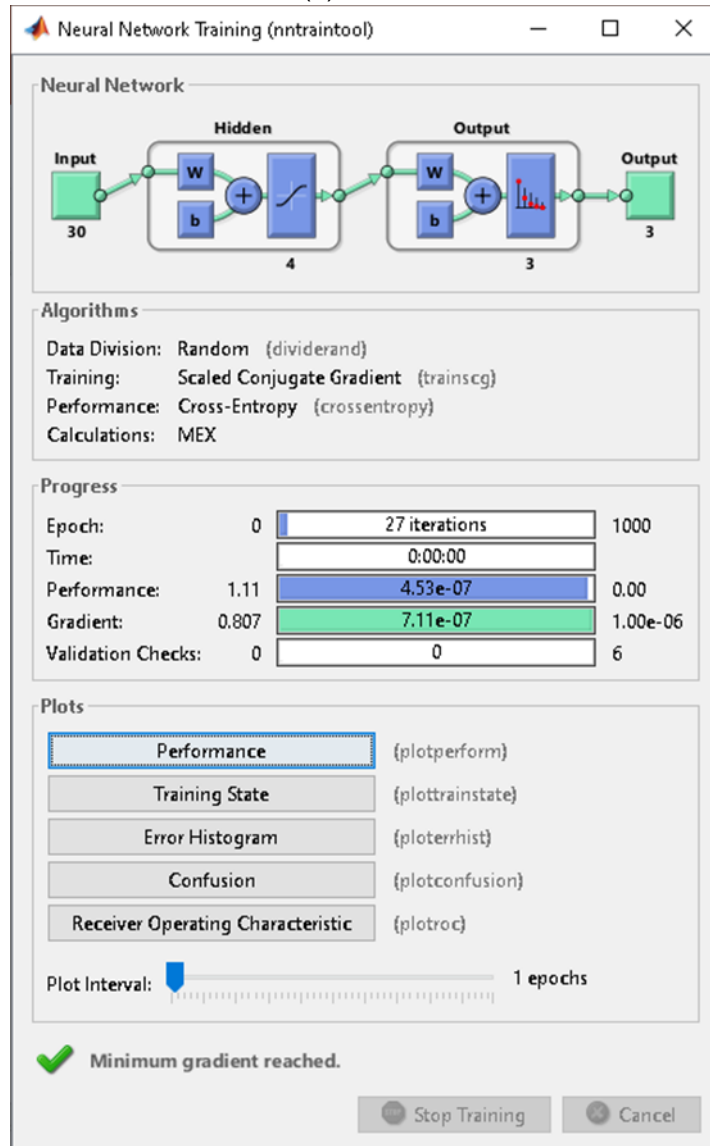


Após algumas tentativas de treinamento da RNA com a ferramenta nprtool do Matlab, foi definida a configuração com 30 entradas, dez neurônios na camada oculta e três saídas. A Fig. 9a apresenta esta configuração, enquanto a Fig. 9b apresenta o resultado da análise do treinamento da RNA. A função de ativação dos neurônios da camada oculta é a \tanh . Os neurônios da camada de saída utilizam função linear simples. A ferramenta do Matlab permite criar um bloco no Simulink, já com os pesos e bias aprendidos e configurados.

Figura 9 – Topologia da RNA (a) e resultado do treinamento (b)



(a)

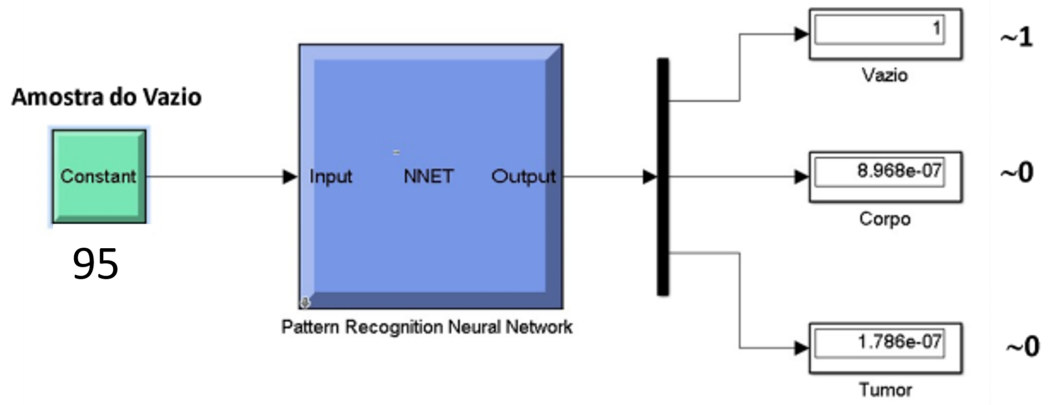


(b)

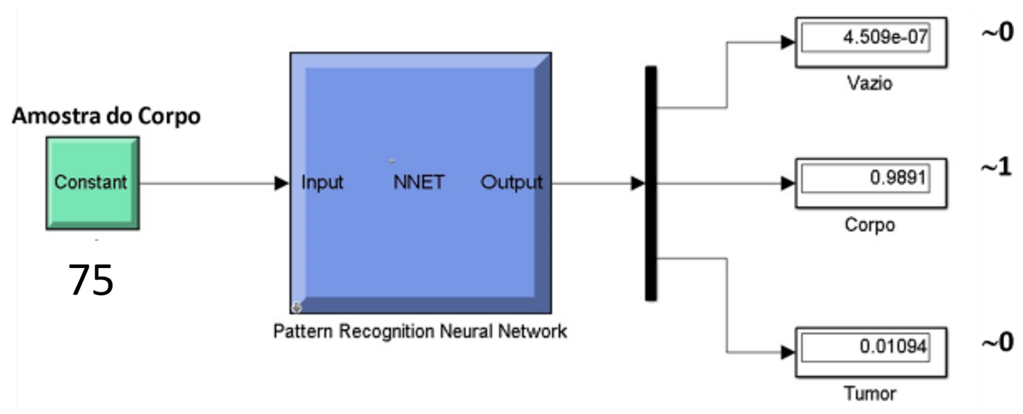
Fonte: Adaptado de [16].

A Fig. 10 apresenta o resultado de teste da RNA, utilizando-se amostras da segunda metade do arquivo de medições com tumor da base de dados. A amostra número 95 foi utilizada para testar a classificação em vazio, a amostra 75 para verificar a classificação do corpo e a amostra 55, do tumor.


Figura 10 – Topologia da RNA (a) e resultado do treinamento (b)



(a)



(b)



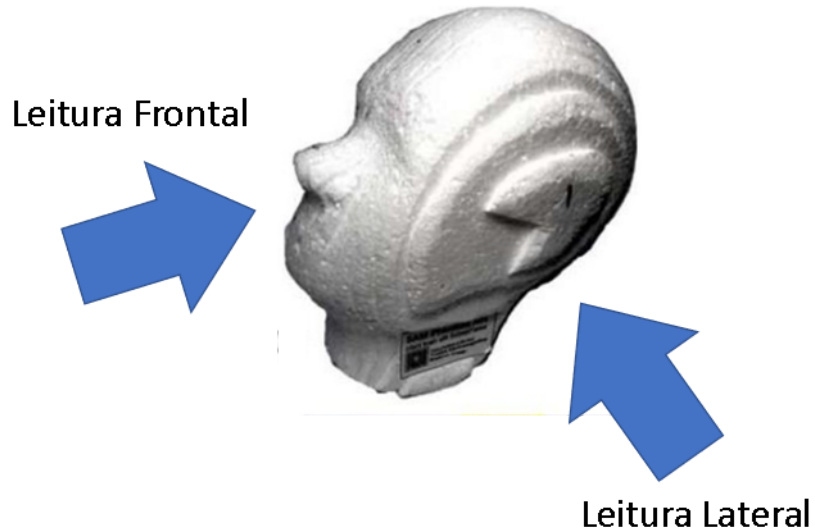
Fonte: Adaptado de [16].

Note-se, que, nos três casos, a saída identificada é de, aproximadamente, 1 e as não identificadas, aproximadamente 0. Os resultados foram considerados aceitáveis para a RNA ser utilizada na identificação e classificação de padrões, para ser usada na prova de conceito proposta.

3.2. Imagem de Tomografia de Micro-ondas por RNA

Para a elaboração da imagem proposta da tomografia por micro-ondas, são necessários duas medições, frontal e lateral, do *Phantom*, conforme Fig. 11.

Figura 11 – Geração da Imagem de Diagnóstico do Tumor



Fonte: Elaborado pelos autores (2022).

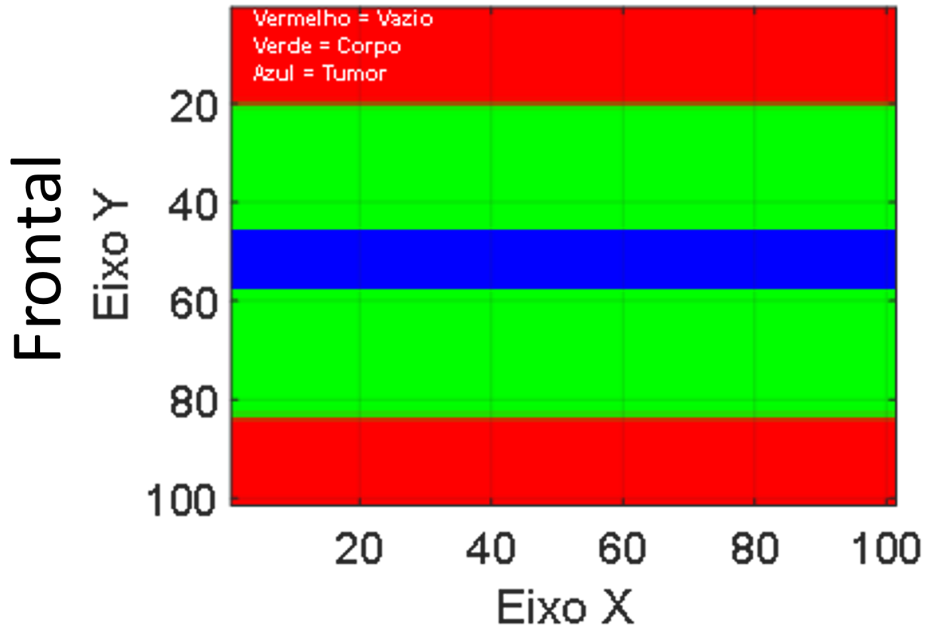
Infelizmente, o método proposto em [8] apenas utilizou medições em uma direção (frontal). Assim sendo, uma base de dados foi montada artificialmente com o arquivo de medições sem tumor, que não foi utilizado para o treinamento ou validação da RNA. Este arquivo sem tumor foi alterado para simular as medições na direção lateral. As alterações consistiram de:

- a) Inserido Medidas com Tumor 47, 48 (início), 51 (meio), 56 e 57 (fim) a partir da posição 20 do arquivo.
- b) Repetido 24 medidas do cérebro sem tumor, da posição 80 – 104.

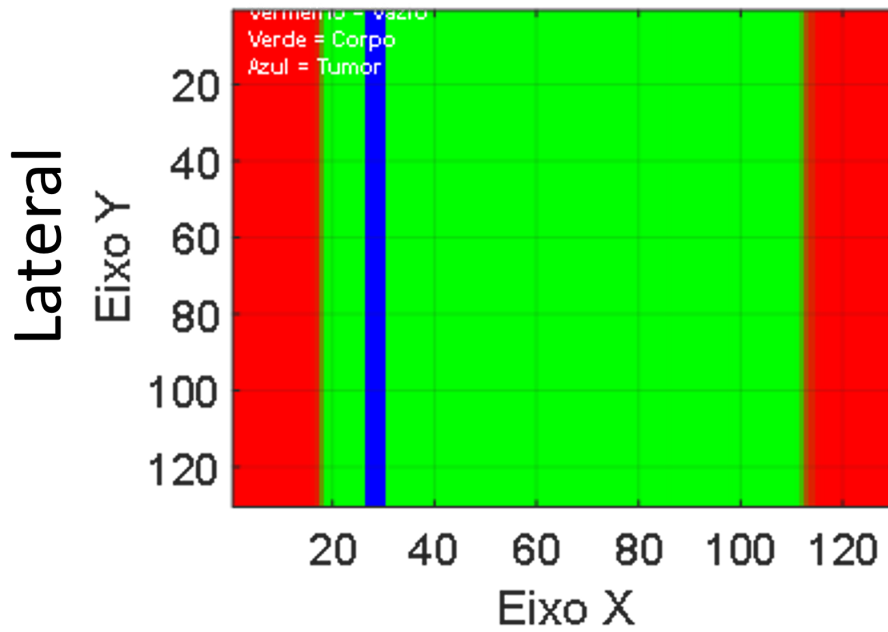
Com as alterações feitas, base de dados lateral resultou em uma planilha com 130 colunas, de 1001 pontos. A base de dados de medições frontal é a mesma com câncer cuja metade das amostras havia sido utilizada para o treinamento da RNA. Os dois arquivos foram utilizados como entrada para o algoritmo de elaboração de imagem. O *script* elaborado em Matlab executa as etapas com o arquivo de medidas frontal, chamando o bloco do simulink a analisar a cada amostra (coluna) sequencialmente e salva uma matriz. Como a RNA possui três saídas, cada uma delas corresponde a uma cor, no padrão RGB. Em seguida, o *script* executa os mesmos passos, porém agora para o arquivo de medidas lateral, salvando uma

segunda matriz. A Fig. 12 mostra uma imagem montada com a classificação da RNA, para a matriz de cada direção de medição, frontal (a) e lateral (b). Vermelho refere-se à medição em vazio, enquanto verde se refere ao corpo e azul ao tumor.

Figura 12 – Padrão de imagem de medição frontal (a) e lateral (b)



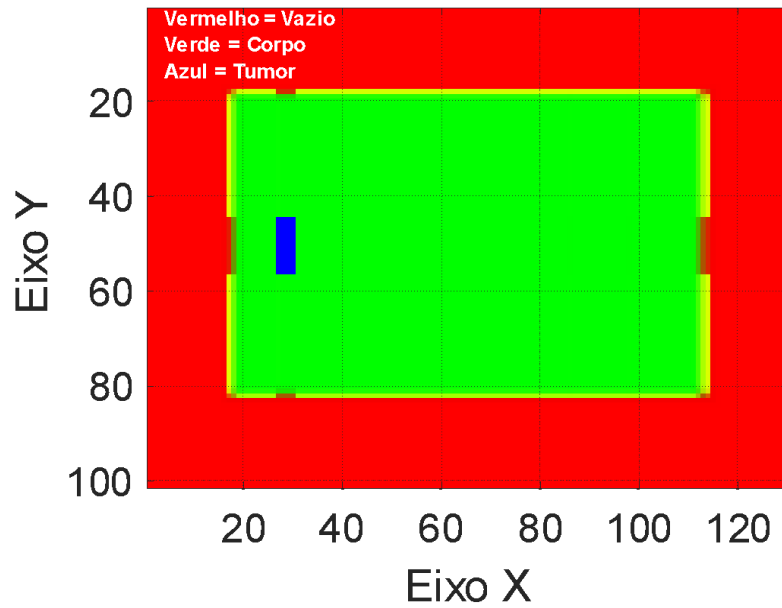
(a)




(b)

Fonte: Elaborado pelos autores (2022).

Figura 13 – Resultado Prova de Conceito de Imagem de Micro-ondas por RNA (a) e Imagem original algoritmo referência [8] (b)



(a)



(b)

Fonte: (a) Elaborado pelos autores (2022) e (b) Adaptado de [8].

O *script* proposto compara então os valores das duas matrizes, ponto a ponto (ou *pixel a pixel*), de modo a montar uma imagem de 101 x 130 pontos. Analisa-se *pixel a pixel* da esquerda para a direita e de cima para baixo. O processo se dá da seguinte forma:

- a) Compara-se um valor RGB frontal, com cada valor RGB lateral.

- b) Se $R_{\text{frontal}} \geq R_{\text{lateral}}$, faça saída $R = R_{\text{frontal}}$. Caso contrário, saída $R = R_{\text{lateral}}$.
- c) Se $G_{\text{frontal}} \geq G_{\text{lateral}}$, faça saída $G = G_{\text{frontal}}$. Caso contrário, saída $G = G_{\text{lateral}}$.
- d) Se saída $R \geq 0.9$, faça saída $G = 0$. Caso contrário, mantém saída G .
- e) Saída $B = B_{\text{frontal}} \times B_{\text{lateral}}$.
- f) Repete-se a etapa b, com o próximo valor RGB frontal, para a próxima linha até concluir a imagem.

O resultado é apresentado na Fig. 13a. Para efeitos de comparação, a imagem obtida pelo método de tratamento de imagem com a equação de energia de Shannon (*Shannon energy*) da referência [8] é apresentado na Fig. 13b.

Note-se que, no método proposto por esta prova de conceito, consegue distinguir entre três diferentes obstáculos: o vazio, o corpo ou cabeça e o tumor. Já o método apresentado em [8], as cores representam a intensidade da reflexão do sinal medido, após o tratamento com aplicação de equações *Shannon energy* e polinomial. Este método é capaz de destacar uma enorme diferença entre os obstáculos, mas não distingue os limites de vazio e corpo, por exemplo. A medição em duas direções permite, ainda, que o método proposto por esta prova de conceito delimite melhor a posição e o formato (*shape*) do tumor.

4 CONCLUSÃO

Neste artigo foi proposto um algoritmo para identificação de padrões de medições de reflexão de micro-ondas de campo próximo, e classificação de padrões, de modo a compor uma imagem de tomografia de reflexões de OEM de micro-ondas de campo próximo, para diagnóstico de câncer cerebral infantil. Os algoritmos de identificação e confecção de imagem fazem uso de equações e regras da LPA2v para o cálculo de média de medições (paraextrator) e de rede neural artificial para classificação de padrões. Em que pese a aplicação proposta, o método pode ser adaptado para outros tipos de diagnósticos, como outros tipos de tumores e doenças, como infecções nos pulmões devido à pneumonia severa ou COVID-19. O método pode também ser ampliado para identificar outros obstáculos, como massa encefálica, nervos, coágulos, acúmulo de líquidos, crânio, tecidos de pele, entre outros.

A prova de conceito proposta neste artigo pode ser considerada como uma segunda geração e uma continuidade nos estudos apresentados em [8]. Os próximos passos da pesquisa incluem a substituição da RNA clássica obtida com o aplicativo do Matlab, por outra com neurônios LPA2v [17], ampliar o número de padrões de identificação de substâncias, aumentar a resolução e melhorar a qualidade da imagem final gerada.

REFERÊNCIAS

- [1] NOGUEIRA, H. S.; LIMA, W. P. Câncer, sistema imunológico e exercício físico: uma revisão narrativa. **Corpoconsciência**, p. 40-52, 2018.
- [2] BARON, M. C. Advances in care of children with brain tumors. **Journal of Neuroscience Nursing, Glenview**, v. 23, n. 1, p. 39-43, fev. 1991.
- [3] KLEIHUES, P. *et al.* The WHO Classification of Tumors of the Nervous System. **Journal of Neuropathology & Experimental Neurology**, v. 61, n. 3, p. 215-225, mar. 2002.
- [4] LANDRIGAN, P. J.; GARG, A. Chronic effects of toxic environmental exposures on children's health. **Journal of Toxicology: Clinical Toxicology**, v. 40, n. 4, p. 449-456, 2002.
- [5] STEUBER, C. P.; NESBIT JR, M. E. Clinical assessment and differential diagnosis of the child with suspected cancer. **Principles and practice of pediatric oncology**. 3rd ed. Philadelphia: Lippincott-Raven, p. 129-39, 1997.
- [6] LANDRIGAN, Philip J.; *et al.* Children's health, and the environment: public health issues and challenges for risk assessment. **Environmental health perspectives**, v. 112, n. 2, p. 257, 2004.
- [7] HUBAL, E. A. C.; *et al.* Children's exposure assessment: a review of factors influencing Children's exposure, and the data available to characterize and assess that exposure. **Environmental health perspectives**, v. 108, n. 6, p. 475, 2000.
- [8] DE OLIVEIRA, A. M.; *et al.*, A Fern Antipodal Vivaldi Antenna for Near-Field Microwave Imaging Medical Applications, in **IEEE Transactions on Antennas and Propagation**, DOI: <https://doi.org/10.1109/TAP.2021.3096942>.
- [9] CHEW, K. M.; *et al.* Human Brain Microwave Imaging Signal Processing: Frequency Domain (S-parameters) to Time Domain Conversion. **Engineering**, v. 5, n. 5, p. 31, 2013.
- [10] RAGHAVAN, S.; RAMARAJ, M. An Overview of Microwave Imaging towards for Breast Cancer Diagnosis. In: **Progress in Electromagnetics Research Symposium Proceedings**, p. 627-630, 2012.
- [11] XU, X. G. Computational phantoms for radiation dosimetry: A 40-year history of evolution. In: XU, X. G.; ECKERMAN, K. F. (Ed.). **Handbook of Anatomical Models for Radiation Dosimetry**. Boca Raton: Taylor & Francis, 2010. p. 3-5.

- [12] AMERICAN ASSOCIATION OF PHYSICISTS IN MEDICINE. A protocol for determination of absorbed dose from high energy photon and electron beam. **Med. Phys.**, v. 10, n. 6, p. 746-747; 758-759, nov.-dez. 1983.
- [13] SILVA, M. P.; MOTA, H. C.; ALMEIDA, C. E. V. Verificação do fator de calibração e indicador da qualidade do feixe de aceleradores lineares. **Radiol. Bra.**, v. 34, n. 5, p. 273-279, jun. 2001.
- [14] ALSHEHRI, S. A.; KHATUN, S. UWB imaging for breast cancer detection using neural network. **Progress In Electromagnetics Research**, v. 7, p. 79-93, 2009.
- [15] VASILAKOS, A. V.; *et al.* Neural networks for computer-aided diagnosis in medicine: a review. **Neurocomputing**, v. 216, p. 700-708, 2016.
- [16] BITENCOURT, J. G. S.; *et al.* Sistema de Rastreamento de Câncer Através de Imagem por Micro-Ondas - Análise e Processamento de Imagem com a Lógica Anotada com Anotação de 2 valores (LPA2v). Anais do **CONICT - Congresso de Inovação, Ciência e Tecnologia do IFSP (2022)**. 23 nov. 2022.
- [17] DE CARVALHO, A; *et al.* Rotary Inverted Pendulum Identification for Control by Paraconsistent Neural Network, in **IEEE Access**, v. 9, p. 74155-74167, 2021, doi: 10.1109/ACCESS.2021.3080176.
- [18] APICELLA, A.; *et al.* A survey on modern trainable activation functions. **Neural Networks**, v. 138, p. 14-32, 2021.
- [19] DA SILVA FILHO, J. I.; LAMBERT-TORRES, G.; FERRARA, L.; MARIO, M. C.; SANTOS, M.; ONUKI, A.; CAMARGO, J.; ROCCO, A., "Paraconsistent Algorithm Extractor of Contradiction Effects - *Paraextrctr_{ctr}*, **Journal of Software Engineering and Applications**, v. 4, n. 10, p. 579-584, 2011. doi: 10.4236/jsea.2011.410067.