

Utilização de Redes Neurais Artificiais para Determinação de Propriedades Ópticas a partir de Medidas de Refletância Difusa

Clóvis Júnior

Faculdade de Engenharia Elétrica
Universidade Federal de Uberlândia
Uberlândia, Brasil
ORCID: 0000-0002-2551-3684

Renata Costa

Faculdade de Engenharia Elétrica
Universidade Federal de Uberlândia
Uberlândia, Brasil
ORCID: 0000-0002-3254-8562

Ádamo do Monte

Instituto de Física
Universidade Federal de Uberlândia
Uberlândia, Brasil
ORCID: 0000-0003-3438-3735

Diego Cunha

Instituto de Física
Universidade Federal de Uberlândia
Uberlândia, Brasil
ORCID: 0000-0002-5536-0498

Abstract — Skin cancer is the most frequent type of cancer in Brazil, mainly due to the excess of exposure to the Sun radiation. This disease is associated to a uncontrolled cell growth that can invade tissues and organs, and spreading to different body parts. One of the potential tool for skin cancer diagnostics is the Spacial Frequency domain imaging (SFDI), which determinates the optical properties of tissues in image by illuminating them with varying spatial light patterns. Despite its diagnostic potential, the optimization of the signal acquisition and image processing is currently being investigated, such as computation time efficiency and accuracy of the computed data. In this work, we investigated the optimization of the SFDI technique by employing Artificial Neural Networks (RNA) for pattern recognition and determination the optical properties of tissues from diffuse reflectance data. Values of diffuse reflectance for light beams with different spatial frequencies in different tissues were generated from diffusion theory and used as input data for the RNA supervised training. The output data consisted of the corresponding optical properties of the tissues (absorption and scattering coefficients). Feedforward RNAs with different number of neurons were evaluated, employing a backpropagation algorithm and sigmoid activation function. Results showed that the accuracy of the RNA in determining optical properties from diffuse reflectance data increased with the number of neurons, although the mean squared error were smaller than 10^{-8} , for RNA with number of neurons between 5 and 10. Theses results indicated that, due to its processing speed and accuracy, the use of RNA can be a valuable tool for optinization of the SFDI technique for skin cancer diagnostics.

Keywords — *Artificial Neural Network, skin cancer, SFDI, Difuse reflectance.*

I. INTRODUÇÃO

O câncer de pele ocorre devido ao crescimento anormal das células que compõe a pele, e por isso podem originar diversos tipos do mesmo. Com esse crescimento anormal, a ordenação do tecido é alterada pela presença da célula cancerígena, e é com essa nova configuração, comparada ao padrão de estrutura do tecido em questão, que se dá o diagnóstico. É notável, através das informações disponíveis na literatura atual, que existem diversos fatores de risco e sintomas que compõe o câncer de pele que atualmente equivale à 33% de todos os diagnósticos desta doença no Brasil [1].

A Imagem de Domínio de Frequência Espacial (*Spacial Frequency domain imaging* - SFDI) é um método de imagem funcional que é mais sensível à processos biológicos e fisiológicos, capaz de renderizar rapidamente mapas quantitativos bidimensionais a partir das propriedades de absorção e espalhamento de luz pelos tecidos [2]. Um dos seus objetivos é quantificar o contraste de absorção, fluorescência e dispersão em tecidos espessos. Quando essa técnica é aplicada à estrutura de células cancerígenas, a mesma tende a atuar de maneira eficaz na quantificação das propriedades como absorção e dispersão [3].

O SFDI usa iluminação espacial modulada para geração de imagens constituintes dos tecidos. Padrões de iluminação senoidal de múltiplas frequências espaciais são projetados sobre uma área grande de tecido. A imagem refletida é modificada a partir do padrão de iluminação devido às propriedades ópticas do tecido em questão. Essas ondas moduladas espacialmente são desmoduladas para calcular a função de transferência de modulação do tecido (MTF). Usando uma análise baseada em modelo de comparação com as tabelas de pesquisa de refletância, a MTF pode ser analisada para determinar a refletância difusa, e subsequentemente, as propriedades ópticas do tecido, em específico, os parâmetros de absorção e espalhamento reduzido [4]. As tabelas de pesquisa de refletância são criadas de duas maneiras diferentes: medições experimentais de *phantoms* (instrumentos utilizados para simulação de tecidos do corpo humano) com propriedades ópticas conhecidas, ou teoricamente, a partir de métodos analíticos ou simulação Monte Carlo. Ambas têm seus defeitos: no caso da primeira, essa é demorada e a precisão depende das habilidades e experiências do investigador. Na segunda, é necessária uma computação intensiva para obter resultados com a variância desejável, o que pode tornar extremamente demorada o processo de formação da imagem [2].

Desta forma, é evidente a necessidade de um novo método para resolver tais problemas de forma a gerar resultados mais rápidos, porém mantendo a alta precisão. Este trabalho apresenta para a solução da adversidade, o desenvolvimento de uma Rede Neural Artificial (RNA) com intento de reconhecimento de padrões objetivando o processamento de coeficientes de absorção e espalhamento de luz de uma maneira mais ágil. As RNAs se aplicam

basicamente a problemas em que existem dados, experimentais ou gerados por meio de modelos dos quais a rede se adaptará visando à execução de uma determinada tarefa [5].

Portanto, este trabalho tem como objetivo determinar os coeficientes de absorção e espalhamento de tecidos a partir dos valores de refletância difusa obtidos para estes coeficientes, empregando para isso uma RNA.

II. FUNDAMENTAÇÃO TEÓRICA

O SFDI é uma abordagem de imagem que permite a determinação quantitativa rápida das propriedades ópticas dos tecidos através de padrões de iluminação senoidal de múltiplas frequências espaciais que são projetados sobre os mesmos [4]. A equação de difusão da luz para um meio homogêneo tem sua forma independente do tempo dada por:

$$\nabla^2 \phi \mu_{eff}'^2 = -3\mu_{tr} q \quad (1)$$

onde ϕ é a taxa de influência, q é função de intensidade da fonte, μ_{tr} é o coeficiente de transporte e μ_{eff}' é o coeficiente de atenuação escalar, que se relaciona com o coeficiente de absorção (μ_a) por meio da equação $\mu_{eff}' = (3\mu_a \mu_{tr})^{1/2}$. O coeficiente de transporte tem relação direta com o coeficiente de espalhamento reduzido (μ_s') – sendo $\mu_s' = \mu_s(1-g)$, na qual μ_s é o coeficiente de espalhamento e g o fator de anisotropia do meio (cosseno do ângulo de espalhamento médio) – encontrado por $\mu_{tr} = (\mu_a + \mu_s')$.

III. METODOLOGIA

A.. Cálculo da Refletância

Para a técnica do SFDI, temos um esquema de fonte de iluminação modulada: normalmente, é imposta uma fonte de onda plana incidente que varia periodicamente com uma dada frequência espacial, sendo assim, as frequências e fases espaciais se estendem nas dimensões espaciais ortogonais, x e y , com alguma dependência arbitrária da profundidade z . Em particular, neste trabalho, consideramos uma fonte de luz de frequência espacial diferente de zero ao longo da dimensão x apenas, sendo a iluminação constante ao longo de y . Neste caso, essa onda plana dará origem a uma onda que se propaga com um efeito coeficiente de atenuação escalar (μ_{eff}') [6], dado por:

$$\mu_{eff}' = (\mu_{eff}^2 + 4\pi^2 f^2)^{1/2} \quad (2)$$

sendo f a frequência espacial da fonte de luz. Para o cálculo da refletância difusa, $R_d(f)$, é utilizado um dado conjunto de propriedades ópticas. Nestas condições, a solução da eq. 1 para refletância difusa será [6]:

$$R_d(f) = \frac{3Aa'}{(\frac{\mu_{eff}'}{\mu_{tr}} + 1)(\frac{\mu_{eff}'}{\mu_{tr}} + 3A)} \quad (3)$$

Sendo A dado por:

$$A = \frac{1 - R_{eff}}{2(1 + R_{eff})} \quad (4)$$

e

$$R_{eff} \approx 0.0636n + 0.668 + \frac{0.710}{n} - \frac{1.440}{n^2} \quad (5)$$

sendo R_{eff} o coeficiente de reflexão efetiva e n o índice de refração do meio. Observa-se então por meio das equações (2) e (5), que por intermédio de valores para os coeficientes das propriedades ópticas de um determinado tecido, é possível determinar os seus valores de refletância difusa para diferentes frequências espaciais de modulação da fonte de luz incidente.

Neste trabalho, os valores de R_d foram calculados para o intervalo de valores de μ_a entre 0.0396 e 1.9396 mm^{-1} , e de μ_s' entre 3.9604 e 5.8604 mm^{-1} , para as frequências espaciais 0.1, 0.2, 0.3, 0.4 e 0.5 mm^{-1} . Os valores de n e g foram mantidos fixos em 1.33 e 0.71, respectivamente [6].

B. Criação da Rede Neural Artificial

As Redes Neurais Artificiais (RNA) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutural neural do cérebro humano e que obtém conhecimento através de treinamento. As RNAs são compostas por várias unidades de processamento que são conectadas por canais de comunicação e associadas a determinado peso. As unidades realizam operações apenas sobre seus dados locais que são entradas recebidas pelas suas conexões. Em virtude das interações entre as unidades de processamento da rede se dá o comportamento inteligente de uma Rede Neural Artificial. De forma resumida, a operação de uma RNA se baseia em características estruturais principais de um neurônio biológico como: recepção de informação pelos dendritos, soma de ponderação de sinais dendritais no corpo neural e finalmente a entrega do sinal aos neurônios. Análogo ao um neurônio biológico, a unidade de processamento segue as seguintes etapas abaixo [5]:

- Sinais apresentados a entrada;
- A multiplicação de cada sinal por um peso, que indicará a sua influência na saída da unidade;
- A soma ponderada dos sinais visando produzir um nível de atividade;
- Ao exceder este nível a unidade produzirá uma determinada resposta de saída.

Todos os modelos de redes neurais necessitam de uma arquitetura e de um algoritmo de aprendizado, onde os pesos e suas conexões são ajustados de acordo com os padrões apresentados. A arquitetura de RNA estudada neste trabalho foi a de multicamadas, onde os neurônios são organizados em duas ou mais camadas de processamento. Os neurônios da camada de entrada têm o papel exclusivo de distribuir cada uma das entradas da rede a todos os neurônios da camada seguinte, por se tratar de uma rede com camadas ocultas, não é possível prever a saída desejada nas camadas intermediárias. Além desta arquitetura, foi empregado como paradigma de aprendizado, o aprendizado supervisionado, baseado em um conjunto de exemplos de estímulo-resposta, ou em algum outro tipo de informação que represente o comportamento que deve ser apresentado pela rede neural.

Para criar a rede neural artificial de multicamadas foi utilizada a função *Neural Network Start* do Matlab, a qual oferece 4 ferramentas de ajuda para resolver diferentes tipos de problema. O assistente usado para criar a rede neural foi o *Fitting tool*, descrita como “*Input-output and Curve Fitting*”,

cujo objetivo é mapear um conjunto de dados de entradas numéricas, estimar seus resultados e auxiliar na seleção de dados. A avaliação e o desempenho da rede foram calculados a partir do erro quadrático médio e análise de regressão. Para um treinamento mais rápido e eficiente, empregou-se o algoritmo *backpropagation levenberg-marquardt*, visando encontrar iterativamente a mínima diferença entre as saídas desejadas e as saídas obtidas pela rede neural com o mínimo de erro. Para chegar nesse resultado, um padrão de entrada é aplicado como um estímulo aos elementos da primeira camada da rede, que é propagado por cada uma das outras camadas até que a saída μ_a e μ_s seja gerada. Logo após, ela é comparada com a saída esperada, que irá gerar um sinal de erro e para cada elemento de saída, esse sinal será retropropagado contribuindo diretamente para a formação da saída.

A camada de entrada da RNA consistia de cinco valores de refletância difusa, $R_d(f)$, calculado cada um para um valor diferente de frequência espacial f . A camada de saída consistia no par de valores de coeficientes de absorção e espalhamento, μ_a e μ_s , referentes aos valores de $R_d(f)$. Foram avaliadas RNAs com diferentes números de neurônios entre 1 a 10, em uma única camada oculta. Por se tratar de uma rede *feed-forward* de neurônios sigmóides ocultos e neurônios de saída linear, pode-se ajustar arbitrariamente os problemas de mapeamento multidimensional, dados consistentes e neurônios suficientes em sua camada oculta. A fig. 1 mostra uma representação esquemática da RNA utilizada.

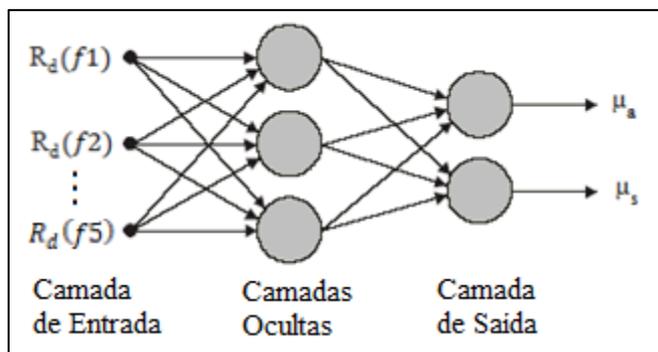


Fig.1 Representação esquemática da Rede Neural. Adaptado de [7].

Definidas as matrizes de dados de treinamento a serem utilizadas, procedeu-se determinando as porcentagens de validação, teste e treinamento.

- Bloco de Treinamento: ajusta a rede iterativamente a fim de minimizar o gradiente de erro entre suas inferências e os resultados reais fornecidos pelos dados do bloco;
- Bloco de validação: verifica o poder de generalização da rede neural, como também, interrompe o treinamento quando não se verifica mais uma progressão nas duas iterações consecutivas;
- Bloco de Teste: realiza um teste de desempenho da rede já treinada, com o propósito de averiguar se o resultado atingido é desejável ou se há necessidade de alterações no treinamento e/ou estrutura neural.

As proporções escolhidas para treinamento, validação e teste da rede neural em questão estudada, foram de 70% 15% 15%, respectivamente. É importante destinar algumas

amostras à validação, visto que não se pode comprometer o poder de generalização da Rede Neural Artificial por apresentação dos dados em iterações excessivas, logo, a finalidade é interromper o treinamento e apresentar o erro associado às amostras de validação. Como medidas de desempenho da RNA, foram calculadas o Erro Médio Quadrático (MSE – *Mean Square Error*) e a Correlação de Regressão (R), estes sempre apresentarão os menores valores dentre os blocos de dados, uma vez que foram descritos diretamente à Rede Neural Artificial durante seu treinamento [5]. Logo, a RNA será ajustada pelo algoritmo de treinamento para acertar estes valores com a precisão mais alta possível.

IV. RESULTADOS E DISCUSSÃO

A Fig. 2 mostra as curvas de refletância difusa, $R_d(f)$, em função da frequência espacial, para diferentes valores de coeficientes de absorção e espalhamento.

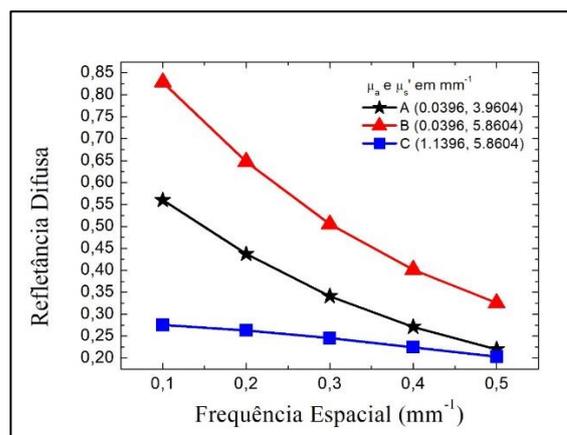


Fig.2 Refletância Difusa em função da Frequência Espacial.

Os dados da experiência demonstram que a frequência crescente causa uma diminuição na refletância. Nota-se que para um valor do μ_s maior apresentado pela curva B, a refletância difusa apresenta um valor superior ao observado pela curva A. Logo, o μ_s é diretamente proporcional à R_d . Conclui-se também que, para um valor maior do μ_a exibido por meio da curva C, a R_d pouco variou em relação às demais quando se trata do aumento da f , além do mais o valor para a refletância é bem menor quando comparado com a curva B. Portanto, μ_a é inversamente proporcional à R_d .

A fig. 3 mostra o erro quadrático médio (MSE) da rede neural, considerando diferentes números de neurônios na camada oculta.

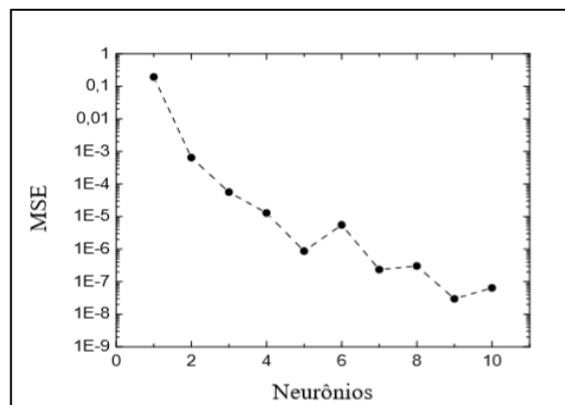


Fig.3 Erro Médio Quadrático em função do número de neurônios

Analisando o gráfico da fig. 3, é evidente, mesmo com algumas variações, uma queda do MSE com o aumento do número de neurônios. Com isso, pode-se afirmar que quanto maior o número de neurônios, mais próximo de zero será o MSE. Logo, tanto o MSE quanto a correlação do bloco, ajustarão a RNA pelo algoritmo de treinamento para acertar os valores apresentados diretamente à rede com a máxima precisão. Porém, quanto mais neurônios utilizados, maior o período de processamento de informações da rede. Para as análises posteriores foram consideradas RNAs com cinco e dez neurônios em sua camada oculta.

Tabela I. Erro Médio Quadrático (MSE) e Correlação (R) para as RNAs

Nº de Neurônios	Treinamento		Validação		Teste	
	MSE (10^{-8})	R	MSE (10^{-8})	R	MSE (10^{-8})	R
5	21.40	0.99	40.80	0.99	25.80	0.99
10	0.29	0.99	0.37	0.99	0.60	0.99

Na tabela I, percebe-se um valor de MSE bem menor para a RNA com 10 neurônios quando comparado com a de 5. Em relação à regressão, as de ambas as Redes foram eficientes e apresentaram o mesmo valor. Porém, a RNA com 5 neurônios realizou 442 iterações para realizar seu processo, apresentando um gradiente de 5.30×10^{-6} , enquanto a RNA com 10 neurônios efetuou 745 iterações, o que denota um tempo maior de processamento quando comparado com a de 5, apresentando um gradiente de 9.92×10^{-8} ; melhores indicadores de precisão são àqueles com menor gradiente, logo, é confirmado a tese anterior que quanto maior o número de neurônios na camada oculta, melhor a precisão e menor o MSE. As figuras 4 e 5 mostram respectivamente os histogramas de erro nas RNAs com 5 e 10 neurônios.

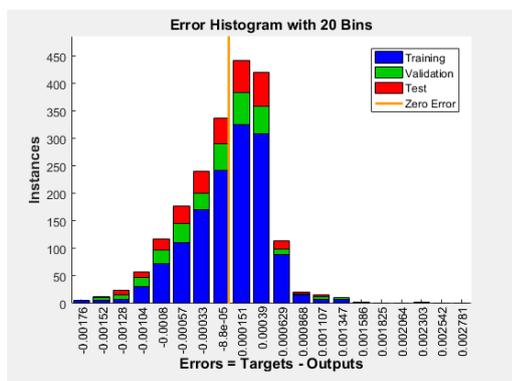


Fig. 4 Histograma de erro da RNA com 5 neurônios

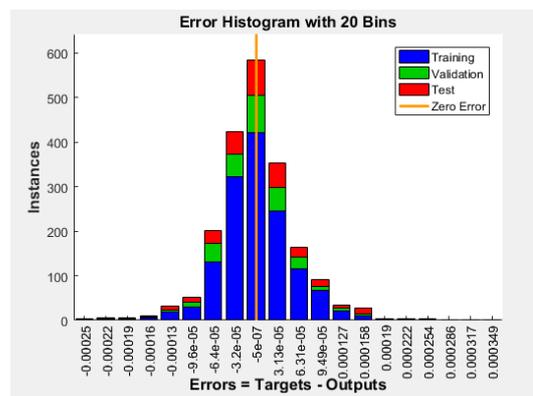


Fig.5 Histograma de erro da RNA com 10 neurônios

Os histogramas exibidos nas fig. 4 e 5, apresentam uma distribuição estatística dos erros de inferência além de permitir visualizar diretamente o erro médio e modal estatístico, bem como, define bem a região de precisão da Rede Neural Artificial treinada. Durante o treinamento da rede com 10 neurônios, notou-se através do histograma um melhor rendimento ao comparar a rede com 5. A curva gaussiana da Fig. 5 se concentrou onde obteve-se o menor erro ao realizar o processamento da RNA.

V. CONCLUSÃO

Os resultados mostram que as RNAs são eficientes em determinar as propriedades ópticas de tecidos a partir dos valores correspondentes de refletância difusa em diferentes frequências espaciais. Observou-se que, como tendência geral, o erro quadrático médio na estimativa destes coeficientes diminui com o aumento do número de neurônios na camada oculta da RNA. Por outro lado, o número de iterações necessárias torna-se maior, comprometendo o tempo computacional.

AGRADECIMENTOS

Ao Programa de Educação Tutorial do curso de Engenharia Biomédica, pela concessão do auxílio financeiro.

REFERÊNCIAS

- [1] Ministério da Saúde - Instituto Nacional de Câncer – Coordenação de Prevenção e Vigilância – Divisão de Vigilância e Análise de Situação, 2015.
- [2] HENNESSY, Ricky et al. Monte Carlo lookup table-based inverse model for extracting optical properties from tissue-simulating phantoms using diffuse reflectance spectroscopy. *Journal of Biomedical Optics*, Vol.18 No.3, Texas, 1 de março, 2013.
- [3] O'SULLIVAN, T. D. et al. Diffuse optical imaging using spatially and temporally modulated light. *Journal of Biomedical Optics*, 2013.
- [4] CUCCIA, David et al. Spatial frequency domain imaging (SFDI): a technology overview and validation of an LED-based clinic friendly device. *Proc. of spie moems-mems*, Vol. 8254, California, 2012.
- [5] BRAGA, A. de.; LUDERMIR, T. B.; CARVALHO, A. C. P. de L. F. *Redes Neurais Artificiais teoria e aplicações*, 2014.
- [6] CUCCIA, David et al. Quantitation and mapping of tissue optical properties using modulated imaging. *Journal of Biomedical Optics*, Vol.14 No.2, California, 3 de abril, 2009.
- [7] MOTTA, C. G. L. Sistema inteligente para Avaliação de Riscos em Vias de Transporte Terrestre. COPPE/UF RJ, 2004.