

## REDES NEURAIIS ARTIFICIAIS APLICADAS NA CLASSIFICAÇÃO DE TUMORES PULMONARES

M. L. N. Franco\*, L. M. Nunes\*, A. P. P. Froner\*\*, A. M. M. Silva\*\* e A. C. Patrocínio\*.

\*Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, Brasil.

\*\* Faculdade de Física, Pontifícia Universidade Católica do RS, Porto Alegre, Brasil.

e-mail: marceloInfranco@gmail.com

**Resumo:** O diagnóstico precoce de tumores malignos é fundamental para determinar as possibilidades de recuperação e sobrevida dos pacientes. Em alguns casos, como o câncer pulmonar, as diferenças entre tecidos, malignos e benignos, podem ser imperceptíveis aos olhos humanos não treinados, dependendo então, da aptidão do radiologista para um melhor diagnóstico. Sendo assim, a aplicação de ferramentas computacionais pode auxiliar na detecção precoce de neoplasias. Neste trabalho é apresentada uma proposta de classificação entre dois tipos de neoplasia pulmonar. Para isso foram testadas e analisadas várias configurações de redes neurais artificiais utilizando descritores geométricos e atributos de Haralick extraídos de imagens tomográficas, como entradas das RNA. A classificação obteve taxa de acerto superior a 98%.

**Palavras-chave:** Redes Neurais Artificiais, Nódulos Pulmonares, Classificação.

**Abstract:** *Early diagnosis of malignant tumors is critical in determining the chances of recovery and survival of patients. In some cases, such as lung cancer, differences between tissues, malignant and benign can be imperceptible to not trained human eyes, then, it depends on ability of the radiologist to better diagnosis. Thus, the application of computational tools can assist in early detection of cancers. In this work, a proposal for classification of two types of lung cancer is presented. For that were tested and analyzed several configurations of artificial neural networks using geometric descriptors and Haralick attributes extracted from tomographic images as inputs of ANN. The obtained classification with correct response rate of over 98% accuracy.*

**Keywords:** *Artificial Neural Networks, Lung Nodules, Rating.*

### Introdução

Segundo o Instituto Nacional do Câncer, de 1920 até os dias atuais, o câncer pulmonar é o tipo de tumor maligno com maior incidência no mundo, apresentando aumento de 2% ao ano. Em 2011 [1], foram detectadas 22.424 mortes devido à neoplasia pulmonar no Brasil.

Dados do American Cancer Society apontam que, se o diagnóstico for tardio as chances de sobrevida em cinco anos ficam abaixo de 14% para os pacientes com

essa patologia, no entanto com o diagnóstico precoce essa taxa pode chegar a 49% dos casos [2].

Estudos apontam a existência de altas taxas de falso-positivo em biopsias [3, 4, 5 e 6]. Em alguns casos, as alterações dos tecidos pulmonares são imperceptíveis aos olhos humanos, dificultando o processo de diferenciação entre nódulos malignos e benignos [7].

Além disso, a interpretação das imagens depende exclusivamente da habilidade dos radiologistas [8]. Diante deste cenário, vários sistemas baseados em técnicas de processamento de imagens digitais e outras ferramentas computacionais estão sendo desenvolvidos para auxiliar no diagnóstico de câncer de pulmão [9, 10, 11 e 12].

Uma estratégia interessante para esse problema é o uso de Redes Neurais Artificiais (RNA) na classificação e seleção de atributos relevantes. Neste trabalho foi testada a eficácia de uma série de atributos extraídos na caracterização dos nódulos encontrados, em Adenocarcinoma e Carcinoma, mediante o uso de técnicas de classificação por RNA.

### Materiais e métodos

As imagens de tomografia computadorizada utilizadas nesta análise foram obtidas no Hospital São Lucas da Pontifícia Universidade Católica do Rio Grande do Sul (PUC-RS). O tomógrafo utilizado é da marca Siemens, modelo *Emotion, multislice* de 16 canais, com janela de -600 a 1200 HU.

Dos exames coletados foram selecionadas 233 Regiões de Interesse (RI), sendo 80 com lesões do tipo Carcinoma (classe 1) e 153 de Adenocarcinoma (classe 2), todas as lesões com comprovação histopatológica.

De cada amostra foram extraídos 17 atributos, dos quais apenas 16 foram utilizados, sendo eles, sete momentos invariantes de Hu [13], área, perímetro, compacidade, irregularidade, intensidade média da lesão, média dos pixels em unidades de Hounsfield [14], homogeneidade, entropia e variância [15]. O atributo volume foi considerado redundante por ser diretamente proporcional à área.

As amostras foram inseridas em uma RNA do tipo *Backpropagation* que foi implementada utilizando o *toolbox* do *MatLab* [16]. Para seu treinamento, 56 pares de amostras (entradas e saídas desejadas) de cada classe foram escolhidos aleatoriamente.

O algoritmo de treinamento do *MatLab* subdivide as amostras em três grupos, onde 70% das amostras compõem o treinamento de fato, 15% a validação e os 15% restantes promovem os testes durante o treinamento.

A RNA foi implementada com diversas configurações, alterando-se o número de neurônios na camada intermediária e a função de ativação. O critério utilizado para a conclusão do treinamento foi o gradiente do erro, sendo estabelecido o término quando o mesmo fica abaixo de 0,0001.

Foram realizados vários treinamentos onde o número de neurônios na camada escondida variou de 15 a 35 e foram testadas as funções de ativação hiperbólica (*tansig*) e sigmoide (*logsig*) [16].

As 121 amostras remanescentes compõem o conjunto de testes, independentes dos previstos durante o treinamento. O teste final consiste em inserir as amostras na rede já treinada e comparar suas respostas aos valores esperados.

A Figura 1 mostra a janela do *toolbox* que foi utilizada durante o treinamento das RNAs.

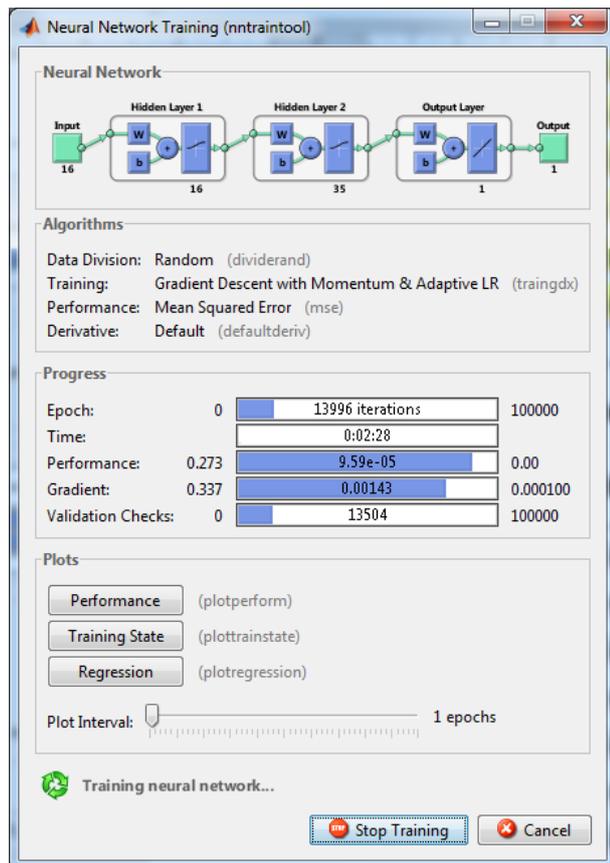


Figura 1: Janela de treinamento da RNA [16].

Já a Figura 2 denota a evolução dos erros (treinamento em azul, teste em vermelho e validação em verde) ao longo das épocas na fase de aprendizagem.

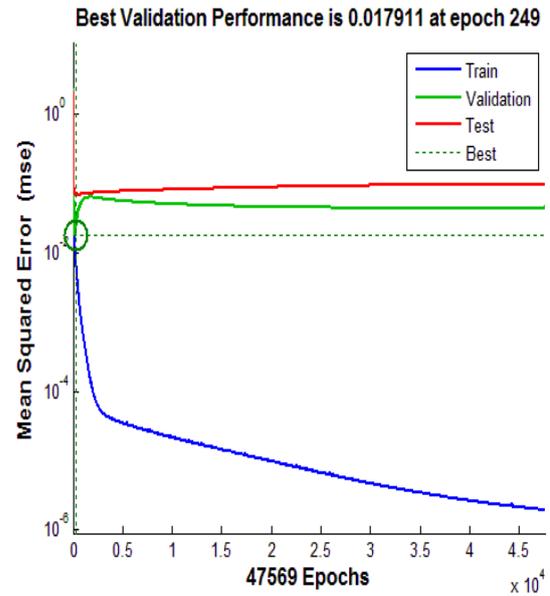


Figura 2: Gráfico dos erros (MSE) ao longo das épocas.

## Resultados

Na fase de treinamento foram computados o número de épocas e dois tipos de erros, o erro de treinamento e o erro de teste na fase de aprendizagem. A Tabela 1 demonstra a eficiência no treinamento de cada rede.

Tabela 1: Eficiência das RNAs durante o treinamento.

Rede	Neurônios na Camada Interm.	Função de Ativação	Erro no Treino	Erro no Teste	Nº de Épocas
1	15	Tansig	3,62E-05	5,94E-02	12969
2	15	Logsig	9,34E-05	1,90E-01	6757
3	20	Tansig	2,24E-05	2,07E-02	8182
4	20	Logsig	8,91E-05	1,26E-01	9858
5	25	Tansig	2,40E-05	2,77E-02	15596
6	25	Logsig	8,44E-05	2,28E-02	17249
7	30	Tansig	4,04E-05	1,28E-01	13065
8	30	Logsig	6,89E-05	7,15E-02	15431
<b>9</b>	<b>35</b>	<b>Tansig</b>	<b>2,23E-05</b>	<b>9,03E-03</b>	<b>6072</b>
10	35	Logsig	6,01E-05	5,65E-02	11432

Conforme apresentado na Tabela 1, os menores erros de treinamento e de testes durante a aprendizagem ocorreu na rede nove. O tempo médio de treinamento para cada rede foi de dois minutos e 29 segundos.

Na fase de testes, foram utilizadas 24 amostras de Carcinoma (classe 1) e 98 amostras de Adenocarcinoma (classe 2). A Tabela 2 mostra os resultados dos testes.

Tabela 2: Taxas de acertos das RNAs nos testes.

Rede	%Acertos Aden.	%Acertos Carci.	%Acertos Total
1	94,90%	100,00%	95,87%
2	94,90%	100,00%	95,87%
3	94,90%	95,65%	95,04%
4	92,86%	95,65%	93,39%
<b>5</b>	<b>97,96%</b>	<b>100,00%</b>	<b>98,35%</b>
<b>6</b>	<b>100,00%</b>	<b>95,65%</b>	<b>99,17%</b>
7	93,88%	100,00%	95,04%
8	95,92%	95,65%	95,87%
9	93,88%	100,00%	95,04%
10	92,86%	95,65%	93,39%

Na Tabela 2 é possível verificar maior eficiência nas redes cinco e seis, sendo ligeiramente maior na rede seis.

### Discussão

Com a interface de treinamento do *toolbox* do *MatLab*, é possível acompanhar o decaimento dos erros da RNA durante o processo de aprendizagem, conforme Figura 1.

As configurações das RNAs treinadas que apresentaram menores MSEs de treinamento e teste ocorreram quando utilizado a função tangente hiperbólica como função de ativação, conforme apresentado na Tabela 1.

Na fase de testes independentes, as RNAs que apresentaram melhor desempenho não foram as que apresentaram os menores MSEs da fase de treinamento.

A RNA com 25 neurônios na camada escondida foi a que obteve o maior acerto total para as duas classes, conforme apresentado na Tabela 2.

O uso de poucas amostras pode acarretar uma série de vieses. Para uma melhor caracterização da eficiência da RNA seria necessário aumentar o número de casos, no entanto uma alternativa a essa limitação pode ser o uso da técnica *leave-one-out* [17] como metodologia de treinamento.

Outra consideração é o fato de que a pesquisa utilizou apenas duas classes de tumores, sendo que um maior número de classes pode ocasionar uma diminuição da eficiência total do sistema. Contudo, o uso de técnicas como a citada no parágrafo anterior, ou um número maior de amostras pode melhorar tal perspectiva.

As duas classes correspondem a lesões malignas e, portanto, com algumas características semelhantes, assim a classificação destas lesões é algo complexo e exige experiência profissional.

Mesmo com as semelhanças e a complexidade apresentadas nesta classificação, as RNAs alcançaram uma alta taxa de acerto, atingindo valores acima de 98% de acerto total e chegando a obter 100% de acerto em uma das classes.

Observa-se na Tabela 2 que a porcentagem de acertos totais tende a se aproximar da porcentagem de acertos em Adenocarcinoma. Isso ocorre pelo fato de que na fase de testes, há um número desigual de amostras das classes.

### Conclusão

Com a extração de 12 atributos geométricos foi possível caracterizar as lesões quanto ao formato, visto que na prática clínica as caracterizações tanto de forma quanto de contorno são importantes para que o especialista classifique a lesão. Já os demais atributos, um de intensidade e três de textura, auxiliaram na diferenciação entre as patologias.

Mesmo com poucas amostras da classe 1 e um número desigual de amostras entre as classes, as RNAs apresentaram altas taxas de acerto, demonstrando que a ferramenta é robusta e pode ser trabalhada para que se atinja taxas de acerto ainda mais altas.

A próxima etapa deste trabalho é a utilização de uma técnica de seleção de atributos a fim de utilizar os atributos mais significativos para a classificação das lesões. Além disso, será incluída mais uma classe de lesão pulmonar de patologia benigna.

### Agradecimentos

Agradecimentos ao Hospital São Lucas pelo fornecimento dos materiais necessários para a pesquisa e à FAPEMIG pelo apoio financeiro.

### Referências

- [1] Tipos de Câncer: Pulmão at. <http://www2.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/pulmao>. Acesso em: 22 Ago. 2014.
- [2] American Cancer Society - Non-small cell lung cancer survival rates by stage at. <http://www.cancer.org/cancer/lungcancer-non-smallcell/detailedguide/non-small-cell-lung-cancer-survival-rates>. Acesso em: 22 Ago. 2014.
- [3] Sun Mi C et al. Characteristics of Benign Solitary Pulmonary Nodules Confirmed by Diagnostic Video-Assisted Thoracoscopic Surgery. 2014.
- [4] Aberle D R et al. Reduced Lung-Cancer Mortality with Low-Dose Computed Tomographic Screening. *The New England Journal of Medicine*; 2011; 395 – 409.
- [5] Moloney F. et al. Increasing the accuracy of 18F-FDG PET/CT interpretation of “mildly positive” mediastinal nodes in the staging of non-small cell lung cancer. *European Journal of Radiology*; 2014.
- [6] Swensen S J et al. Lung nodule enhancement at CT: multicenter study. *Radiology*; 2000; 214: 73 – 80.
- [7] Silva A C, Carvalho P C P, Gattass M. Diagnosis of Lung Nodule Using Semivariogram and Geometric Measures in Computerized Tomography Images. *Computer Methods and Programs in Biomedicine*; 2005; 79: 31-38.

- [8] Kamiya H, Murayama S, Kakinohana Y, Miyara T. Pulmonary Nodules: A Quantitative Method of Diagnosis by Evaluating Nodule Perimeter Difference to Approximate Oval Using Three-Dimensional CT Images. *Clinical Imaging*; 2011; 35:123-126.
- [9] Hosseini R, Dehmeshki J, Barman S, Mazinani M. A Fuzzy Logic System for Classification of the Lung Nodule in Digital Images in Computer Aided Detection. *Fourth International Conference on Digital Society*; 2010; 255 – 259.
- [10] Li Y, Yu Q. Lung Nodule Classification Using Supervised Manifold Learning Based on All-Class and Pairwise-Class Feature Extraction. *International Conference on Computer Science and Service System*; 2012; 2269 – 2272.
- [11] Zhang J, Cao M, Gai W, Li B. Performance Comparison of ESVM and CSVM for Classifying the Lung Nodules on CT Scans. *Seventh International Conference on Image and Graphics*; 2013; 409 – 413.
- [12] Lee S L A, Kouzani A Z, Nasierding G, Hu E J. Pulmonary Nodule Classification Aided by Clustering. *International Conference on Systems, Man, and Cybernetics: San Antonio, TX, USA*; 2009; 906 – 911.
- [13] Hu M K. Visual Pattern Recognition by Moments Invariants. *IRE Trans. Inf. Theory*; 1962; 8:179-187.
- [14] Martí J, Cufí X, Regincós J, Español J, Barceló C. Shapebased Feature Selection for Microcalcification Evaluation. *Proc. SPIE: Image Processing*; 1998; 3338:1215-1224.
- [15] Gonzales R C, Woods R E. (2009) *Processamento Digital de Imagens*, São Paulo.
- [16] Matlab: The Language of Technical Computing at. <http://www.mathworks.com/products/matlab/>. Acesso em: 23 Ago. 2014.
- [17] Hertz J, Krogh A, Palmer R G. (1991) *Introduction to the Theory of Neural Computation*, Studies in the Sciences of Complexity. Santa Fe Institute, Santa Fe.