

APLICAÇÃO DE UMA REDE NEURAL ARTIFICIAL PARA CLASSIFICAÇÃO DE NÓDULOS A PARTIR DE DESCRITORES DE IMAGENS EXTRAÍDOS DE MAMOGRAFIAS DIGITAIS

V. M. de Oliveira*, S. T. Faceroli*, S. R. Fernandes*, R. C. P. e Santos*

*IF Sudeste MG Campus, Juiz de Fora, Brasil

e-mail: vinicius.if09@gmail.com

Resumo: Segundo o Instituto Nacional de Câncer (INCA), o câncer de mama é o segundo tipo mais frequente no mundo e o mais comum entre as mulheres, respondendo por 22% dos novos casos a cada ano. A principal ferramenta de diagnóstico do câncer de mama é o exame de mamografia, realizado por aparelhos especiais de raios-X. Este trabalho visa realizar um estudo a respeito da classificação de nódulos a partir da análise de mamografias digitais. Foi desenvolvida uma rede neural artificial para reconhecimento de padrões em descritores de imagens que são extraídos de mamografias digitais que contém nódulos. A rede divide os dados de entrada em duas classes, maligno e benigno. A avaliação do processo de treinamento é realizada através da matriz de confusão gerada. A partir da aplicação da rede, podem-se observar resultados superiores a 90% de acerto na classificação dos nódulos com as configurações de rede testadas. Ao adicionar os descritores de forma e localização ao conjunto de treinamento, observou-se que o resultado foi ainda melhor, alcançando 96% de acerto na classificação dos nódulos. Isso indica que os descritores de imagem apresentam uma boa descrição do problema para classificação de nódulos como maligno ou benigno.

Palavras-chave: Câncer de mama, descritores de imagem, nódulos, classificação, maligno, benigno.

Abstract: As the national Institute of Cancer (INCA), breast cancer is the second most common kind of cancer in the world and the most common among women, answering by 22% of new cases each year. The main tool to diagnostic breast cancer is mammography exam, made by special devices of X-rays. This work aims to conduct a study regarding the classification of nodules from the analysis of digital mammograms. An artificial neural network was developed to recognize patterns in images descriptors that are extracted from digital mammograms containing nodules. The network divides the input data into two classes, benign and malignant. The evaluation of the training process is accomplished through the confusion matrix generated. From the application of the network can be observed superior results at 90% accuracy in the classification of nodes in network configurations tested, reaching 96% when added to the training set descriptors of shape and

location. This indicates that the image descriptors have a good description of the problem to classify nodules as malignant or benign.

Keywords: Breast cancer, image descriptors, nodules, classification, malign, benign.

Introdução

O câncer de mama é o segundo tipo de câncer mais comum no mundo e é o de maior incidência sobre as mulheres, respondendo por 22% dos casos novos a cada ano. Se diagnosticado e tratado oportunamente, o prognóstico é relativamente bom. No Brasil, as taxas de mortalidade por câncer de mama continuam altas, muito provavelmente porque a doença ainda é diagnosticada em estágios avançados [1].

Diversos trabalhos [2,3,4,5,6] utilizando técnicas de inteligência artificial (IA), como as Redes Neurais Artificiais (RNA), têm sido feitos com o intuito de auxiliar o diagnóstico do câncer de mama. As RNAs possuem como característica um aprendizado supervisionado. Assim, a vantagem de usá-las como classificador de padrões é que elas podem, a partir de padrões previamente apresentados à rede durante o treinamento, encontrar soluções não lineares para novas entradas do problema em questão. O bom desempenho de uma Rede Neural para classificação de padrões depende de alguns estágios anteriores à classificação, como por exemplo, a segmentação e seleção de atributos que melhor representam cada classe [2].

A extração de características de imagens tem se mostrado uma importante etapa para o desempenho adequado de um classificador e se destina a extrair informações pictóricas da imagem como um todo ou de uma região de interesse da imagem. Características de textura podem ser representadas por descritores de imagem que evidenciam informações sobre a distribuição espacial, variação de luminosidade, suavidade, rugosidade, regularidade e descreve o arranjo estrutural das superfícies e as relações entre os diversos níveis de cinza existentes na imagem [7,8]. A extração de características é realizada a partir de cálculos estatísticos através da matriz de coocorrência da imagem ou região de interesse [9].

O objetivo deste trabalho é avaliar o funcionamento de uma rede neural para classificação de imagens de mamografias que contenham nódulos usando descritores de imagem como entrada da rede. A rede deve classificar os casos como maligno ou benigno de acordo com características de textura extraídas da região da imagem que contém o nódulo. A base de dados com as imagens de mamografias com nódulos e os descritores de cada caso foram extraídos de um consórcio formado pelo Instituto de Engenharia Mecânica e Gestão Industrial da Universidade do Porto, Portugal e um centro de Tecnologia Avançado ligado ao Ministério Espanhol da Economia e Competitividade [10].

Materiais e métodos

O banco de dados utilizado é formado por 79 lesões comprovadas por biópsia de 64 mulheres, tornando 143 segmentações, incluindo ainda dados clínicos das pacientes e descritores baseados em imagens. Todas as lesões são nódulos ou combinações destes com outras anormalidades. Para este trabalho, considerou-se apenas o conjunto de dados relativo aos descritores. Utilizaram-se tanto os descritores calculados diretamente dos valores de cinza quanto os calculados a partir da matriz de coocorrência, ambos utilizando apenas a região delimitada pelo contorno do espaço onde está o nódulo nas imagens. A Figura 1 traz um exemplo de como está demarcada essa região nas imagens.



Figura 1 - Imagem de mamografia com nódulo circundado.

Os descritores utilizados para treinamento da RNA são calculados a partir dos valores de cinza da imagem, como por exemplo, média e desvio padrão, e ainda da matriz de coocorrência calculada, como energia, contraste, variância e entropia. Acrescentaram-se, posteriormente, descritores de forma e localização ao treinamento de uma nova rede, como por exemplo, área, perímetro e circularidade. Todos os descritores utilizados podem ser encontrados em [10].

O valor desses descritores foi agrupado em uma matriz com 19 colunas (19 características) e 132 linhas (132 amostras). O número de amostras é menor em relação ao total de segmentações, pois alguns casos foram desconsiderados quando algum dos descritores

não apresentava valor. Utilizou-se essa matriz como entrada para treinamento da rede do tipo *patternet* do Matlab e que faz parte do *toolbox* de redes neurais.

Considerando os descritores de forma e localização, tem-se a matriz de treinamento da rede com 28 colunas (28 características). A avaliação da rede neural é feita inicialmente considerando o conjunto de dados sem os descritores de forma e localização. Posteriormente, eles serão levados em conta e o resultado será comparado. Este procedimento visa avaliar o quanto esses descritores contribuem para o resultado final. Em uma aplicação de identificação automática da região da imagem que contém o nódulo, a não identificação da forma exata da massa pode interferir substancialmente nos valores desses descritores.

A simulação da rede neural foi feita considerando-se os descritores de 70% das imagens em um conjunto de treinamento. Para validação dos resultados tem-se 15% das amostras e os 15% restantes são para teste. Assim, têm-se 92 conjuntos de descritores para treinamento e os outros dois conjuntos de dados com 20 amostras cada.

A rede *patternet* que foi utilizada tem por característica apresentar apenas três camadas. A primeira camada é composta pelos neurônios de entrada e o número de neurônios é igual ao número de características presentes na matriz de entrada da rede. A camada intermediária, ou camada oculta, apresenta número variável de neurônios e é o parâmetro que se altera na estrutura da rede visando melhorar os resultados. Para esta camada foram realizados testes a fim de encontrar a melhor arquitetura para a rede. A camada de saída, por sua vez, apresenta um neurônio que classifica os dados como maligno ou benigno. A Figura 2 mostra o modelo da rede neural aplicada.

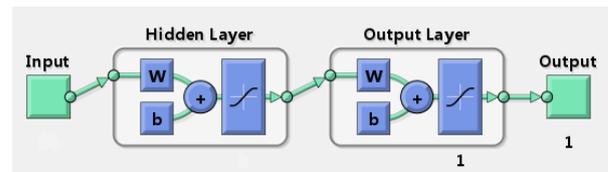


Figura 2 – Arquitetura da rede neural aplicada

A rede *patternet* apresenta como função padrão para o treinamento a função *trainscg*. Essa função atualiza os pesos (w) e *bias* (b) da rede seguindo um algoritmo de retropropagação, de acordo com o método do gradiente conjugado dimensionado.

Resultados

A avaliação da rede neural foi feita a partir das matrizes de confusão gerada pelo Matlab após a execução do treinamento de cada rede. Essas matrizes são de treinamento, validação, teste e uma matriz final que considera o comportamento global da rede. A análise dos resultados foi feita considerando a matriz de confusão final e observando os valores encontrados para falso-positivos e falso-negativos, bem como o acerto final da rede na classificação dos nódulos. A classe 1

corresponde aos casos malignos e, a classe 2, aos casos benignos.

Foram testadas algumas arquiteturas de rede variando o número de neurônios na camada escondida. A arquitetura que apresentou melhor resultado durante as simulações foi a que continha 8 neurônios na camada escondida. Os resultados mostrados neste trabalho são referentes a essa disposição dos neurônios na camada oculta.

A Figura 3 mostra a matriz de confusão com os resultados da rede testada sem o conjunto de descritores de forma e localização do nódulo.

Output Class	1	48 36.4%	3 2.3%	94.1% 5.9%
	2	4 3.0%	77 58.3%	95.1% 4.9%
		92.3% 7.7%	96.3% 3.7%	94.7% 5.3%
		1	2	
		Target Class		

Figura 3 – Matriz de confusão para a rede sem os descritores de forma e localização

A Figura 4 traz a matriz de confusão com os resultados da rede simulada considerando-se as 28 características, onde se inclui os descritores de forma e localização do tumor.

Output Class	1	49 37.1%	2 1.5%	96.1% 3.9%
	2	3 2.3%	78 59.1%	96.3% 3.7%
		94.2% 5.8%	97.5% 2.5%	96.2% 3.8%
		1	2	
		Target Class		

Figura 4 – Matriz de confusão para a rede com os descritores de forma e localização

Discussão

Os resultados obtidos apresentaram percentagem satisfatória. Nota-se uma ligeira melhora quando se utiliza os descritores de forma e localização. Isso pode ser explicado pelo aumento do número de características fornecidas como entrada para a rede. Quanto maior o

número de amostras ou a quantidade de características que descrevem o problema, maior a chance de a rede encontrar um padrão correto.

Considerando que os casos malignos são os que apresentam importância maior para o início de um tratamento, nota-se a partir da matriz de confusão que houve um acerto de 94,1% na classificação dos casos malignos na primeira rede testada. A segunda rede apresentou, para esse caso, 96,1% de acerto. A percentagem de erro, 5,9% e 3,9% para a primeira e segunda rede respectivamente, representa os casos de falso-negativos para casos malignos que, em um resultado ideal, deveria ser reduzida a zero.

A partir das matrizes de confusão apresentadas, pode-se observar também que para os casos classificados como maligno, a primeira rede apresentou acerto de 92,3%. Já a segunda rede, a qual considera os descritores de forma e localização, apresentou 94,2%. O erro, 7,7% e 5,8% para a primeira e segunda rede respectivamente, neste caso, é referente aos casos de falso-positivos para a classe que representa os casos malignos.

Ambas as redes apresentaram acerto significativo na distinção entre as duas classes, sendo que, como citada anteriormente, a segunda rede foi melhor. Os acertos foram de 94,7% e 96,2% para a rede sem os descritores de forma e localização e para a rede com esses descritores, respectivamente.

Conclusão

A extração de descritores de imagem apresentou uma boa base de dados para se encontrar um padrão para classificação de nódulos em mamografias como maligno ou benigno. A rede neural mostrou-se eficaz para a aplicação, embora não se tenha conseguido reduzir os falso-negativos a zero para nenhuma das arquiteturas de rede testadas.

As características presentes no banco de dados foram extraídas a partir de um processamento local das imagens, ou seja, sabia-se onde estava o nódulo na imagem e a técnica foi aplicada apenas no local do tumor. Assim, este trabalho não substitui a avaliação das imagens por um médico, mas representa um apoio à decisão trazendo um avanço importante dado a dificuldade do diagnóstico do câncer de mama. A percentagem de falso-negativos para a classe maligno foi pequena, especialmente na segunda rede, representando 3,9% dos casos. A redução desta taxa é importante, pois ela representa os casos malignos que foram classificados como benigno. Essa classificação incorreta pode prejudicar o início de um tratamento mais adequado destinado a casos malignos.

Agradecimentos

Agradecimentos ao IF Sudeste MG *Campus* Juiz de Fora, à FAPEMIG pelo fomento e aos orientadores do trabalho.

Referências

- [1] INCA, Tipos de Câncer: Mama. Disponível em: <http://www2.inca.gov.br/wps/wcm/connect/tiposde-cancer/site/home/mama/cacer_mama++> Acesso em 12 de novembro de 2013.
- [2] Bilska-Wolak, A. O.; Floyd, C.E.; Lo, J. Y.; Baker, J. A., Computer Aid for Decision to Biopsy Breast Masses on Mammography: Validation on New Cases. *Academic Radiology*, June, v.12, no. 6, pp. 671-680. 2005.
- [3] Andrioni, V.; Guingo, B. C.; Pereira, W. C. A.; Infantsi, A. F. C. (2010) “Rede neural artificial para redução de falso-positivos em mamografia detectados por diferença de gaussiana”. *Anais do XII Congresso Brasileiro de Engenharia Biomédica*. Tiradentes: v.1.
- [4] Belloti, R.; De Carlo, F.; Tangaro, N. (2006) “A completely automated CAD system for mass detection in a large mammographic database”, *Medical Physics*, v. 33, n.8, p. 3066-3075.
- [5] S.C. Park, J. Pu and B. Zheng, (2009), Improving performance of computer-aided detection scheme by combining results from two machine learning classifiers, *Acad Radiol* 16, p. 266-274.
- [6] Andrioni, V.; Guingo, B.; Santana, E.; Pereira, W.; Infantsi, A. (28 – 1 Mach – April 2011). Comparison of artificial neural network using texture parameters in the recognition of lesions in mammograms digitized. *Pan American Health Care Exchanges – PAHCE*, pp. 426 – 430.
- [7] Pedrini, H. & Schwartz, W. R., 2008. *Análise de Imagens Digitais, Princípios, Algoritmos e Aplicações*. Editora Thomson Pioneira.
- [8] Nascimento, João Paulo Ribeiro. **Análise e classificação de imagens baseada em características de textura utilizando matrizes de co-ocorrência**. 2003. 116 p. Dissertação (Programa de Pós-Graduação em informática, setor de Ciências Exatas) – Universidade Federal do Paraná, Curitiba.
- [9] Haralick, R. M.; Shanmugam, K.; Dinstein, I., 1973. *Textural Features for Image Classification in IEEE Transactions on Systems, Man and Cybernetics*, v. 3, n. 6, pp. 610-621.
- [10] Daniel C. Moura, Miguel A. Guevara López. **An evaluation of image descriptors combined with clinical data for breast cancer diagnosis**. *International Journal of Computer Assisted Radiology and Surgery*, 2013 (in press).
Doi: 10.1007/s11548-013-0838-2