

CLASSIFICAÇÃO DE MAMOGRAFIAS UTILIZANDO EXTRAÇÃO DE ATRIBUTOS DE TEXTURA E REDES NEURAIS ARTIFICIAIS

I. M. M. Fernandes e W. P. dos Santos

Departamento de Engenharia Biomédica, Universidade Federal de Pernambuco, Brasil
e-mail: bella.mfernandes@gmail.com

Resumo: O câncer de mama continua sendo um problema significativo de saúde pública. O exame de mamografia tem aumentado o prognóstico desta neoplasia. No entanto, as imagens de mamografia são de difícil interpretação, de forma que os sistemas CAD podem auxiliar o radiologista na sua leitura, aumentando a sensibilidade e a precisão do diagnóstico. Visamos desenvolver um sistema CAD para a detecção e classificação de lesões em mamografias. Utilizamos a base de dados IRMA, separada em quatro grupos organizados segundo a constituição do tecido mamário, obtendo-se classificadores específicos por tipo de tecido. Essa abordagem se justifica, pois os quatro tipos de mama estão comumente relacionados à faixa etária da paciente, uma informação facilmente disponível na prática clínica. Analisamos o poder de classificação de diversos classificadores baseados em redes neurais artificiais a fim de identificar a estrutura que melhor detecta e classifica lesões suspeitas em imagens de mamografia por tipo de mama, obtendo mais de 80% de instâncias corretamente classificadas.

Palavras-chave: Mamografia, sistema CAD, redes neurais artificiais.

Abstract: *The breast cancer continues to be a significant public health problem. Mammography has increased the prognosis of this neoplasia. However, the mammographic images are difficult to be read, so the CAD systems would help the radiologist to interpret those images, increasing the sensibility and accuracy of the diagnosis. The aim of this article is to develop a CAD system to detect and classify lesions in mammograms. We used the IRMA database, separated in four groups organized according to the mammary tissue composition, drawing specific classifiers by tissue type. This approach is justified because those four groups of breasts are usually attached to the age of the patient, an easily obtained information. We analyzed the classification strength of different classifiers based on artificial neural networks to help identifying the best structure to detect and classify suspicious lesion on mammograms, achieving more than 80% of instances well classified.*

Keywords: *Mammogram, CAD system, artificial neural networks.*

Introdução

De acordo com o Instituto Nacional do Câncer (INCA), o câncer de mama é o segundo mais frequente no mundo e o mais comum entre as mulheres [1]. Apesar de não haver formas preconizadas de prevenção do câncer de mama, quanto mais cedo detectado e diagnosticado, maiores as chances de cura do paciente. No Brasil, a mamografia e o exame clínico das mamas (ECM) são os métodos indicados para o rastreamento na rotina da atenção integral à saúde da mulher.

De acordo com a literatura, a mamografia tem sensibilidade e especificidade variáveis entre 88% e 93,1%, e entre 85% e 94,2%, respectivamente [1]. A sensibilidade depende de fatores como tamanho e localização da lesão, densidade do tecido mamário, qualidade dos recursos técnicos e habilidade de interpretação do radiologista, sendo a especificidade igualmente dependente da qualidade da imagem [2]. De forma geral, a leitura e interpretação de imagens de mamografia são tarefas que exigem experiência do radiologista, e seu julgamento depende de treinamento, experiência e critérios subjetivos. Mesmo experts bem treinados apresentam uma taxa acertos de classificação de 65 à 75% entre observadores [3]. No entanto, a utilização desse exame como método de rastreamento reduz a mortalidade em 25% [1].

Dessa forma, sistemas Computacionais de Apoio ao Diagnóstico (*Computer Aided Diagnosis – CAD*) podem auxiliar os radiologistas na difícil tarefa de leitura e interpretação de imagens de mamografia, de forma a automatizar o processo de interpretação de imagens médicas. De 65 a 90% das biopsias de tecidos com suspeita de câncer mostram-se benignas. Desta forma, é importante o desenvolvimento de sistemas CADs que permitam a distinção entre lesões malignas e benignas [2, 4].

Propomos neste artigo um sistema automatizado para a classificação de lesões a partir de imagens de mamografia, aplicando mapas de Kohonen para a segmentação da imagem, extração de atributos a partir dos momentos de Haralick e de Zernike e classificação utilizando redes neurais artificiais. A base de dados foi separada em quatro grupos de imagens, organizadas segundo o tipo de tecido mamário, visto que mamas de composições diferentes não são comparáveis e que a divisão por tipo de mama reduz a carga de processamento no classificador. O artigo é organizado de forma que é apresentada, na seção seguinte, uma

breve descrição das etapas de um sistema CAD. Em seguida, exporemos os resultados encontrados e a conclusão.

Materiais e métodos

A combinação sistemas CAD com o conhecimento e expertise do radiologista pode melhorar significativamente a acurácia da detecção e classificação de lesões suspeitas em imagens de mamografia. De forma geral, a elaboração de sistemas CAD envolvem quatro grandes etapas: pré-processamento da imagem digitalizada, segmentação, extração e seleção de atributos, e classificação do tipo de lesão [4].

Utilizamos a base de dados IRMA (*Image Retrieval in Medical Applications*) [5, 6], elaborada a partir de um projeto desenvolvido pela Universidade de Aachen (RWTH Aachen), na Alemanha, que reúne imagens de diversas outras bases de dados, disponíveis para consulta na internet. Esta base de dados é formada pelas Regiões de Interesse (*Region of Interest*, ROI) de imagens de radiografias digitalizadas da mama, que foram classificadas por radiologistas e redimensionadas para imagens de tamanho 128 x 128 pixel. Ao todo, são 2.796 imagens, organizadas em 12 classes, sendo 2.576 provenientes da base DDSM (*Digital Database for Screening Mammography*), 1 da base LLNL (*Lawrence Livermore National Laboratory*), 69 da base RWTH e 150 proveniente da base MIAS (*Mammographic Image Analysis Society*).

Pré-processamento – Sabemos que as imagens de mamografia possuem baixo contraste, devido principalmente à composição do tecido mamário, isto é, mamografias não possuem bom contraste entre tecido glandular normal e tecidos com características de malignidade, devido à similaridade da atenuação dos raios-x desses dois tipos de tecido, principalmente em mulheres jovens com mamas densas. Do ponto de vista clínico, a constituição do tecido mamário está relacionado à idade do paciente, uma vez que a substituição do tecido glandular por tecido adiposo ocorre de forma gradativa com a idade, sendo esta informação acessível ao especialista. Desta forma, a base de dados IRMA foi separada em quatro subgrupos, levando em consideração a constituição do tecido mamário: adiposo (I), fibroglandular (II), denso (III) e extremamente denso (IV) [7], obtendo-se assim classificadores específicos por tipo de mama.

Das 2.796 imagens disponíveis na base IRMA, utilizamos 1.416 amostras, separadas em imagens sem lesão e com lesão do tipo massa espiculada e massa circunscrita, por serem mais representativas em caráter de benignidade (massas circunscritas) e malignidade (massas espiculadas) [8]. Das imagens utilizadas, 355 são amostras de mamas adiposas, 414 são de mamas com tecido fibroglandular, 341 de mamas densas e 306 de mamas extremamente densas.

Segmentação – A segunda etapa da detecção de lesões utilizando sistemas CAD é separar as regiões suspeitas do tecido mamário, músculo e demais

estruturas presentes na imagem mamográfica, para então extrair as regiões de interesse (ROI) e localizar as lesões. As regiões de suspeita de lesão são aquelas que são mais claras e brilhantes que seus arredores, com densidade uniforme, forma regular (variando em tamanho) e bordas difusas [3].

A segmentação de imagem pode ser realizada por diferentes técnicas, em sua maioria baseadas em descontinuidades e similaridades dos níveis de cinza da imagem.

Nesse artigo propomos a abordagem de segmentação utilizando mapas auto organizáveis de Kohonen (*Self-Organizing Maps*, SOM), que são redes de treinamento não supervisionadas e que, por isto, utilizam apenas os dados de entrada, sem necessidade de conhecimento prévio sobre os padrões, natureza e quantidades das regiões a serem segmentadas. O mapa SOM projeta espaços de alta dimensionalidade em espaços de baixa dimensionalidade, preservando a relação de vizinhança entre padrões. Após a segmentação usando SOM, redimensionamos a imagem para que a mesma enquadre a região lesionada, de forma que as bordas da lesão venham a se tornar a própria borda da imagem.

Extração de atributos – A terceira etapa da detecção de lesões é a extração e seleção de atributos, que podem ser calculados a partir de algumas características da ROI, como tamanho, forma, densidade e suavidade das bordas. Visto que o espaço de atributos é grande e complexo, devido à diversidade dos tecidos normais e das anormalidades, é necessário selecionar quais dos atributos extraídos são significantes para a detecção de lesões. Os atributos redundantes precisam ser eliminados para melhorar o desempenho do classificador, uma vez que o uso excessivo de atributos pode aumentar a complexidade do classificador e reduzir sua performance [3].

A extração e seleção de atributos que serão utilizados para a classificação é um passo fundamental, visto que o bom desempenho do sistema CAD depende mais da otimização desta etapa do que do método de classificação [3]. De acordo com as características escolhidas, o espaço de atributos pode ser baseado em intensidade, na geometria ou na textura. Atributos extraídos das características dos níveis de cinza, forma e textura da lesão e de seus arredores podem ser expressos como descritores matemáticos e utilizados pelo classificador para distinção de lesões benignas e malignas [4, 3].

Os extratores de atributos baseados em textura são amplamente utilizados, permitindo o cálculo de entropia, correlação, variância, energia e outros [3]. Utilizamos a extração de características de textura de Haralick (HA), baseada na matriz de Co-Ocorrência de níveis de cinza (*Grey Level Co-Occurrence Matrix*, GLCM), e os momentos de Zernike para extração de 32 atributos. Este último forma um mapeamento em um conjunto complexo de polinômios de Zernike, e estes são ortogonais entre si, de forma que os momentos de Zernike (ZE) possibilitam representar as propriedades

da imagem sem redundância ou sobreposição de informação entre os momentos [8].

Ao final da etapa de extração dos atributos, realizamos um balanceamento linear das imagens, uma vez que a base IRMA possui quantidades diferentes de imagens sem lesão, com lesão benigna e lesão maligna. Desta forma, equilibramos o conjunto das imagens de forma que todos contenham 233 amostras para cada tipo de classe.

Classificação e avaliação dos resultados – Uma vez que os atributos relacionados às lesões são extraídos, eles são utilizados como entrada para um classificador que deverá realizar a tarefa de classificação dos dados em três tipos de classes (normal, benigno e maligno). Classificadores como discriminantes lineares e redes neurais artificiais (*Artificial Neural Networks*, ANN) possuem boa performance em classificação de massas [3]. As ANNs utilizadas possuem uma camada de entrada com 32 nodos, que são referentes à quantidade de atributos extraídos da imagem, a camada de saída com os 3 nodos possíveis de classificação e uma ou mais camadas escondidas entre elas. Utilizamos amostras da base de dados para realizar o treinamento da rede, com informações de entrada e saída conhecidas, necessitando determinar os pesos dos nodos da camada escondida. Utilizamos para o treinamento o método de validação cruzada por *k-folds*, com *k* igual a 10. Uma vez determinado os pesos dos neurônios e treinada a rede, a mesma está pronta para realizar a classificação. De acordo com a literatura, os três tipos de classificadores ANN mais utilizados em aplicações de processamento de imagens de mamografia são redes neurais de três camadas com *back propagation*, redes de função de base radial (*Radial Basis Function*, RBF) e perceptrons de múltiplas camadas (*MultiLayer Perceptron*, MLP) [3, 9].

Realizamos neste artigo um comparativo entre três classificadores a fim de verificar o poder de classificação dos mesmos. Além dos classificadores RBF e MLP citados anteriormente, ensaiamos também com o classificador de Otimização Sequencial Mínima (*Sequential Minimal Optimization*, SMO), utilizado principalmente em treinamentos de Máquinas de Vetores de Suporte (*Support Vector Machine*, SVM). A etapa de classificação foi realizada com a ferramenta Weka 3.6, disponível gratuitamente. Utilizamos a configuração da rede RBF conforme disponível na biblioteca do Weka 3.6. Para o classificador SMO, testamos duas variações do kernel, o polinomial e o RBF (SMO-KPM e SMO-KRBF). Para o classificador MLP, testamos seu poder de classificação com 1, 2 e 3 camadas escondidas, cada uma com a quantidade de neurônios definida como a metade da soma do número de classes e atributos, neste caso 18 neurônios em cada camada escondida.

Resultados e Discussão

A partir dos gráficos de 1 a 4, verificamos que a classificação, para os quatro subgrupos da base IRMA,

baseados na composição do tecido mamário, apresentou melhores resultados com o classificador MLP. Uma vez que o aumento do número de camadas aumenta a complexidade da rede, o tempo de processamento e custo computacional, podemos considerar que o classificador com melhor custo é a rede MLP com apenas uma camada escondida (MLP-1), que obteve uma média de acertos de 84,62% para a segmentação da base utilizando os extratores de atributos de Haralick e Zernike e 81,37% para segmentação realizada unicamente com Zernike. Notamos também que a divisão da base IRMA em 4 subgrupos, organizados segundo o tipo de mama, reduziu a carga sobre o classificador, o que mostrou-se favorável à classificação.

No entanto, é importante levar em consideração o custo computacional envolvido para obtenção dos resultados. Conforme visto na tabela 1, a classificação do grupo no qual foi utilizado conjuntamente os momentos de Haralick e de Zernike para extração de atributos resultou num tempo de construção do classificador maior que no caso em que usamos apenas os atributos extraídos pelos momentos de Zernike. Vimos ainda que ambos os métodos realizam uma boa segmentação, permitindo à rede MLP classificar bem as imagens de entrada. Desta forma, notamos que os momentos de Zernike são bastante promissores para a extração de características de imagens de mamografia, reduzindo o tempo de processamento e custo computacional necessário para sua implementação.

Tabela 1: Tempo médio, em segundos, para a construção do classificador pelo Weka 3.6.

Classificador	HA-ZE	ZE
RBF	1,11	0,81
SMO-KPM	0,49	0,37
SMO-KRBF	1,07	1,01
MLP-1	266,52	36,71
MLP-2	406,58	59,26
MLP-3	547,38	82,38

Conclusão

Verificamos que, para aplicações em detecção de lesões em imagens de mamografia, realizada de forma independente para cada subgrupo da base de dados, o método apresentado, com determinação de ROIs e segmentação por mapas SOM e extração de atributos pelos momentos de Zernike e classificação por redes MLP, aplicado a cada tipo de mama separadamente resultou numa taxa de classificação superior à 80%. Esse estudo permitiu verificar o potencial de redes MLP para classificação de massas em mamografia e a vantagem na aplicação no classificador de forma específica por tipo de mama. Acreditamos que essas redes podem ser otimizadas para melhorar seu poder de classificação e acurácia. Pretendemos alcançar, em estudos futuros, uma taxa de classificação de 90%.




Gráfico 1: Instâncias corretamente classificadas para subgrupo de mamas adiposas (I).




Gráfico 3: Instâncias corretamente classificadas para subgrupo de mamas densas (III).




Gráfico 2: Instâncias corretamente classificadas para subgrupo de mamas fibroglandulares (II).




Gráfico 4: Instâncias corretamente classificadas para subgrupo de mamas extremamente densas.

Referências

- [1] Ministério da Saúde. Instituto Nacional de Câncer. "Mamografia: da prática ao controle". Rio de Janeiro: INCA, 2007.
- [2] Ganesan K, Acharya UR, Chua CK, Min LC, Abraham KT, e Kwan-Hoong Ng. Computer-Aided Breast Cancer Detection Using Mammograms: A Review. IEEE Reviews in Biomedical Engineering, vol. 6, 2013
- [3] Cheng HD, Shi XJ, Min R, Hu LM, Cai XP e Du HN. Approaches for automated detection and classification of masses in mammograms. Pattern Recognition, vol. 39, 2006.
- [4] Shanthu S, Bhaskaran AV. A Novel Approach for detecting and Classifying Breast Cancer. In: International Journal of Intelligent Information Technologies (IJIT) 2013; 9(1), 21-39.
- [5] de Oliveira JE, Machado AM, Chavez GC, Lopes AP, Deserno TM, Araújo A de A. MammoSys: A content-based image retrieval system using breast density patterns. Comput Methods Programs Biomed 2010; 99(3): 289-97.
- [6] de Oliveira JEE, Soiron M, Deserno TM. Texture patterns extracted from digitized mammograms of different BI-RADS classes. Proc Spie 2012; 8315: 217-9.
- [7] Vález N, Bueno G, Déniz O, Esteve P, Rienda MA, Pastor C. Automatic Breast Tissue Classification Based on BIRADS Categories. Digital Mammography/ IWDM, volume 6136 of Lecture Notes in Computer Science, page 259-266. Springer, (2010).
- [8] Tahmasbi A, Saki F, Shokouhi SB. Classification of benign and malignant masses based on Zernike moments. Computer in Biology and Medicine, vol 41, 2011.
- [9] Mustra M., Grgic M., Delac, K. Breast Density Classification Using Multiple Feature Selection. Automatika, vol. 53, N°4, 2012.