

SISTEMA NEURO-FUZZY PARA DETECÇÃO E CLASSIFICAÇÃO DE MICROCALCIFICAÇÕES EM MAMOGRAMAS

FABIANO C. FERNANDES, LOURDES M. BRASIL

Universidade Católica de Brasília, Programa de Pós-Graduação Stricto Sensu em Gestão do Conhecimento e da Tecnologia da Informação, SGAN 916, Brasília - DF, Brasil, CEP: 70790-160

E-mails: fabiano_fernandes@yahoo.ca, lmb@ucb.br

JANICE M. LAMAS

Clinica de Mamografia de Brasília, Centro Clínico Oswaldo Cruz, SHL Sul, Q. 716, Bloco F, Sala 510, Brasília - DF, Brasil, CEP: 70390-700

E-mail: janicelamas@terra.com.br

Abstract— Breast cancer is the second cancer in the world and the most common cancer among women. Since the causes are unknown, it cannot be prevented. The presence of microcalcification clusters is an important sign for detection of breast carcinoma. Mammography is one of the most reliable exams for breast cancer detection. Early detection is the key issue for breast cancer control and computer-aided diagnosis system can help radiologists in detection and diagnosing breast abnormalities. This paper presents a fuzzy-neural system that classifies the mammogram region of interest as benign or malign. The Mini Mammographic Image Analysis Society Digital Mammogram Database (Mini-MIAS) was used to assess the system. The system accuracy achieved was in the order of 87%.

Keywords— Breast cancer, microcalcification, computer-aided diagnosis, Neural Networks, ANFIS.

Resumo— O câncer de mama é o segundo câncer mais freqüente no mundo e o tipo mais comum de câncer entre as mulheres. Como suas causas são desconhecidas, o mesmo não pode ser prevenido. A presença de microcalcificações é um sinal importante para a detecção do carcinoma mamário. A detecção precoce é um aspecto chave para o controle do câncer de mama e a mamografia é um dos exames mais confiáveis para a detecção do câncer de mama. Um sistema de diagnóstico auxiliado por computador pode ajudar os radiologistas na detecção e diagnóstico do câncer de mama, aumentando sua eficiência em até 30%. O presente estudo propõe um sistema neuro-fuzzy para a classificação da região de interesse do mamograma como maligna ou benigna. A base de dados Mini-MIAS do *Mammographic Image Analysis Society Digital Mammogram Database* foi utilizada para validar o modelo proposto e o mesmo atingiu uma precisão de 87%.

Palavras-chave— Câncer de mama, microcalcificação, sistema de diagnóstico auxiliado por computador, Redes Neurais Artificiais, ANFIS.

1 Introdução

O câncer de mama é o segundo tipo de câncer mais freqüente no mundo, o primeiro entre as mulheres e o número de novos casos esperados para o Brasil em 2006 é de 48.930, com um risco estimado de 52 casos a cada 100 mil mulheres (INCA, 2006). A prevenção do câncer de mama, até o momento, é impossível, pois as causas da doença permanecem desconhecidas. Portanto, a detecção precoce é a chave para melhorar o prognóstico da doença. O mamograma tem sido um dos métodos mais confiáveis para a detecção precoce de carcinomas mamários. A análise de um grande volume de mamogramas é uma atividade intensa, ineficiente e com baixa precisão. Recentemente, a análise de mamogramas auxiliada por computador tem recebido grande atenção devido a sua velocidade, consistência e capacidade de oferecer uma solução promissora ao problema (Cheng, Wang & Shi, 2003).

A presença de microcalcificações é um sinal importante para a detecção do carcinoma mamário e apesar da mamografia auxiliada por computador ter

sido estudada nos últimos vinte anos, a interpretação automatizada de microcalcificações permanece ainda uma tarefa difícil, pois os objetos de interesse podem ser muito pequenos, levando a equívocos, bem como possuir tamanhos diferentes, formas variadas e distribuições diversas, tornando difícil a identificação de padrões. Outra razão é que as Regiões de Interesse (ROI – *Region Of Interest*) podem ter contraste baixo e a diferença de intensidade entre uma área suspeita e as circunvizinhanças podem ser muito estreitas. Tecidos densos ou epidermes grossas, especialmente em mulheres jovens, tornam as áreas suspeitas quase invisíveis. Finalmente, os tecidos densos podem ser facilmente mal interpretados como calcificações, gerando uma taxa maior de Falso Positivo (FP), maior problema da maioria dos algoritmos existentes (Cheng, Wang & Shi, 2003).

Este trabalho propõe um modelo de pré-processamento das ROI que inclui a supressão de ruído, aumento de contraste entre a ROI e o fundo da imagem, para a fase de detecção a equalização de histograma e extração de descritores texturais como entropia, energia, contraste e homogeneidade e para a fase de classificação a utilização de uma implementação do modelo ANFIS (*Adaptive-Network-based*

Fuzzy Inference System) para verificar a aderência do mesmo aos aspectos difusos característicos das imagens dos mamogramas.

2 O Câncer de Mama

Em todo o mundo cerca de um milhão de mulheres descobre que está com câncer de mama a cada ano (OMS, 2006).

A formação do câncer se dá no corpo humano, pois as células estão constantemente se reproduzindo através do processo chamado de mitose, onde uma célula adulta divide-se em duas. A mitose é realizada de forma controlada dentro do organismo, porém em determinadas ocasiões e por motivos ainda desconhecidos, determinadas células reproduzem-se com uma velocidade maior, resultando em massas celulares chamadas neoplasias. As neoplasias malignas apresentam um crescimento rápido desordenado e infiltrativo, onde as células não guardam semelhanças com as que lhes deram origem e se desenvolvem em outras partes do corpo, fenômeno denominado metástase, característica mais marcante dos tumores (Santos, 2002).

O câncer de mama mínimo é definido como um câncer de menos de 0,5 cm de diâmetro e pode se referir a um carcinoma lobular *in situ*, câncer intraductal e cânceres invasivos. A maioria dos cânceres clinicamente palpáveis mede acima de 1 cm. Mesmo os cânceres mamários mínimos de 0,5 cm de diâmetro, tidos como clinicamente iniciais, representam um tumor biologicamente tardio. O tamanho médio dos cânceres detectados por auto-exame é maior do que 2 cm. O câncer de mama comporta-se de forma menos previsível do que outros cânceres e pacientes com câncer de mama podem sucumbir muito rapidamente. A sobrevivência das pacientes depende do tamanho do tumor no diagnóstico inicial e da presença ou ausência de linfonodos auxiliares positivos. O diagnóstico precoce, portanto, não apenas influencia o prognóstico, mas propicia uma cirurgia cosmeticamente mais aceitável que pode fornecer índices livres de recidiva e de sobrevivência comparáveis às intervenções cirúrgicas mais dramáticas e agressivas. O diagnóstico precoce do câncer de mama seria melhorado se as técnicas utilizadas pelos radiologistas pudessem detectar com precisão e de forma não invasiva as alterações pré-cancerosas hiperplásicas (Santos, 2002).

3 Textura

Não existe um consenso ou uma definição formal para textura, porém sua maior característica é a repetição de um padrão ou de vários padrões em uma região (Parker, 1996). O padrão pode se repetir com exatidão ou com pequenas variações de tema, possivelmente em função da posição. Existe também um aspecto aleatório da textura que não pode ser ignorado, o tamanho, a forma, a cor e a orientação de ele-

mentos do padrão, também chamados de *textons*, podem variar na região. Algumas vezes, a diferença entre duas texturas está apenas no grau de variação ou na distribuição estatística entre os *textons*.

Textura é a propriedade possuída por uma região que seja suficientemente grande para demonstrar sua natureza recorrente. A mesma textura exibida em diferentes escalas será percebida como diferentes texturas. É improvável que qualquer operação de medida simples possa permitir a segmentação de regiões de textura em uma imagem digital. As linhas de divisão são frequentemente arbitrárias e são definidas mais em função da percepção humana. Por outro lado, é possível que alguma combinação de operações possa resultar em segmentações razoavelmente boas para vários tipos de texturas (Parker 1996).

3.1 Matriz de Co-ocorrência de Níveis de Cinza

Uma matriz de co-ocorrência de níveis de cinza (GLCM – *grey level co-occurrence matrix*) contém informações sobre as posições de *pixels* que têm valores similares de níveis de cinza. A idéia é percorrer a imagem e calcular a frequência de *pixels* que diferem em $\Delta\zeta$ em valor e são separados por uma distância fixa δ em posição. Normalmente, a direção entre dois *pixels* é também considerada, havendo, portanto, múltiplas matrizes, uma para cada direção de interesse. Usualmente, existem quatro direções: horizontal, vertical e as duas diagonais. Para cada valor de δ , existem quatro imagens, cada uma com um tamanho de 256 x 256, para uma imagem original de 256 níveis de cinza. Devido a grande quantidade de dados, o mais usual é analisar essas matrizes e calcular alguns valores numéricos que encapsulam a informação, chamados de descritores. A entropia pode ser usada como descritor numérico para a imagem e é mostrada na Equação 1, que é a medida de informação contida na matriz M (Parker, 1996).

$$H = -\sum_i \sum_j M[i, j] \log(M[i, j]) \quad (1)$$

Outros descritores de textura importantes são: contraste que mede a variação local na matriz de co-ocorrência de níveis de cinza, a homogeneidade que mede a distância entre os elementos da matriz de co-ocorrência de níveis de cinza e sua diagonal e a energia que mede o segundo momento angular da imagem.

3.2 Filtro de Mediana

O filtro de mediana utiliza uma técnica de filtragem não linear, reduz o ruído aleatório sem prejudicar os flancos da imagem, sendo comparáveis a filtros lineares passa-baixo. De um modo geral, objetos claros ou escuros com menos da metade da área do filtro da mediana são essencialmente eliminados enquanto objetos maiores são preservados (Castleman, 1996).

4 O Modelo ANFIS

Um dos primeiros sistemas híbridos neuro-fuzzy para aproximação de funções foi o modelo ANFIS. Ele representa um sistema fuzzy do tipo Sugeno em uma arquitetura de RNA (Redes Neurais Artificiais) *feed-forward* de cinco camadas (Jang, 1993). O modelo ANFIS implementa regras conforme Equação 2.

$$Rr: \text{Se } x_1 \text{ é } A_{j1}^{(1)} \wedge \dots \wedge x_n \text{ é } A_{jn}^{(n)} \quad (2)$$

$$\text{Então } y = \alpha_0^{(r)} + \alpha_1^{(r)}x_1 + \dots + \alpha_n^{(r)}x_n$$

A base de regras deve ser conhecida anteriormente. O modelo ANFIS ajusta apenas as funções de pertinência dos parâmetros antecedentes e consequentes.

A estrutura da rede ANFIS, mostrada na Figura 1, contém η unidades de entrada na camada U_0 (não computada por Jang). As outras camadas (denotadas como U_1, \dots, U_5) tem as seguintes funcionalidades (Nauck et al., 1997):

Camada 1: Cada unidade em U_1 armazena três parâmetros para definir uma função de pertinência em forma de sino que representa um termo lingüístico. Cada unidade é conectada a exatamente a uma unidade de entrada e calcula o grau de pertinência do valor de entrada obtido.

Camada 2: Cada regra é representada por uma unidade em U_2 . Cada unidade é conectada àquelas unidades na camada anterior que pertencem aos antecedentes da regra.

Camada 3: Nesta camada, para cada regra R_r existe uma unidade que calcula seu grau relativo de preenchimento.

Camada 4: As unidades de U_4 são conectadas a todas as unidades de entrada (não mostrado na Figura 1) e a exatamente uma unidade em U_3 .

Camada 5: A unidade de saída calcula a saída final através da somatória de todas as saídas de U_4 .

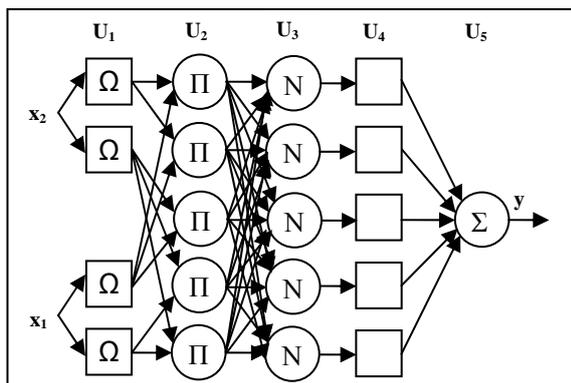


Figura 1 – Estrutura de uma ANFIS (Jang, 1993)

5 O Sistema Proposto

O sistema proposto consiste de três estágios: pré-processamento, extração de características e classificação, mostrado na Figura 2.

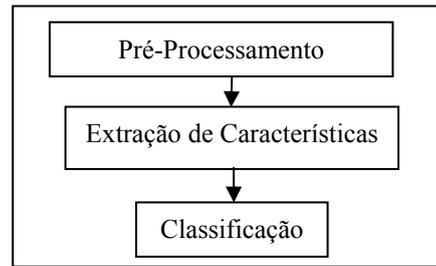


Figura 2 – Sistema proposto

Na fase de pré-processamento, as imagens utilizadas foram provenientes da base de dados Mini-MIAS (Suckling et al., 1994), as quais são selecionadas pelo critério de apenas conter microcalcificações, resultando em um total de 27 casos. Utilizando um procedimento pseudo-aleatório, as imagens são divididas em dois grupos, um de treinamento e outro de validação ou testes. Em seguida de cada imagem de mamograma é extraída a ROI, localização indicada pela base de dados Mini-MIAS e extraída utilizando-se a função *imcrop* da linguagem Matlab (2003), conforme Figura 3.

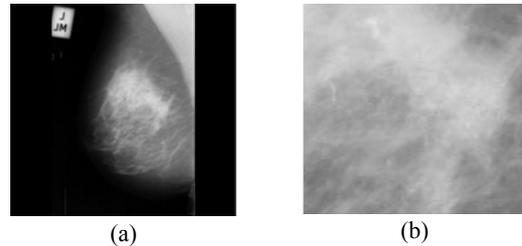


Figura 3 – Mamograma original (a) e correspondente ROI (b)

Com cada ROI é realizada uma redução de ruído utilizando-se um filtro de mediana *medfilt2* da linguagem Matlab (2003) que reduz o ruído e preserva os flancos da imagem, conforme Figura 4.



Figura 4 – ROI original (a) e ROI sem ruído (b)

Em seguida cada ROI sem ruído recebe uma equalização de histograma adaptativo, *adapthisteq* da linguagem Matlab (2003) que amplia o contraste da imagem, mostrado na Figura 5.

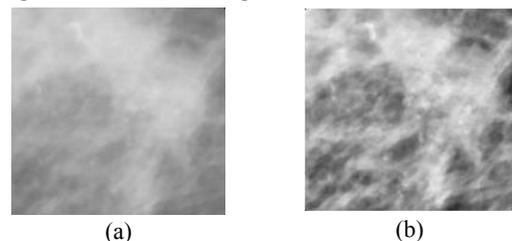


Figura 5 – ROI sem ruído (a) e ROI com equalização adaptativa de histograma (b)

Tabela 1. Extração de descritores texturais

Imagem	Entropia	Contraste	Energia	Homogeneidade
I_211	6.373	124.863	0.001	0.181
I_212	1.021	8.689	0.025	0.360
I_218	6.115	48.001	0.003	0.252
I_219	6.707	584.209	0.001	0.109
I_222	6.319	201.359	0.001	0.160
I_223	6.801	593.822	0.002	0.109

Na fase de extração de características são extraídos os descritores texturais de todas as 27 ROI, mostrados parcialmente na Tabela 1.

A classificação é realizada criando-se a partir dos conjuntos de treinamento e de testes, arquivos com os descritores de textura mostrados na Tabela 1, referenciando como saída da rede ANFIS a benignidade com o valor numérico 0 e a malignidade com o valor numérico 1. Em seguida, a aprendizagem da rede é feita submetendo o arquivo do conjunto de treinamento ao *Anfisedit*, que é uma implementação do modelo ANFIS (Matlab, 2003), variando os parâmetros de função de pertinência, neurônios de entrada, método de treinamento e épocas para se obter o melhor desempenho. A Figura 6 mostra um exemplo de treinamento com os parâmetros especificados na Tabela 2.

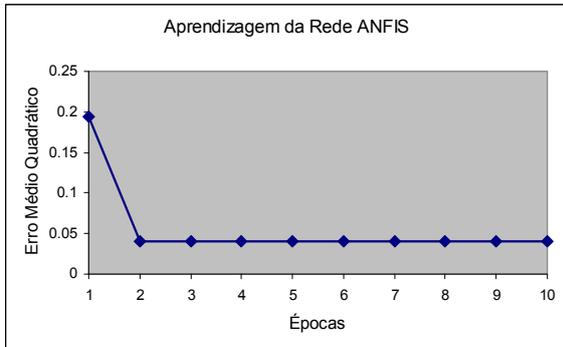


Figura 6 – Anfisedit em treinamento

Tabela 2. Parâmetros de treinamento da rede ANFIS

Função de Pertinência	<i>psigmf</i>
Épocas	10
Método de otimização	Híbrido
Neurônios de entrada	4
Neurônios de Saída	1

O EMQ (Erro Médio Quadrático) da rede ANFIS permanece estável a partir da segunda época de treinamento, mostrado na Figura 6. O resultado do treinamento da rede é mostrado na Figura 7, observa-se um ajuste da rede aos dados e um valor baixo de EMQ.

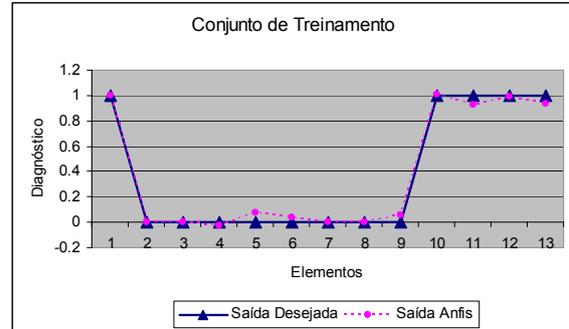


Figura 7 – Resultado do treinamento do ANFIS

Em seguida é realizada a submissão do conjunto de testes à rede treinada, mostrado na Figura 8, onde a rede ANFIS acerta bem para alguns elementos e erra muito para outros elementos, apresentando um valor mais alto de EMQ.

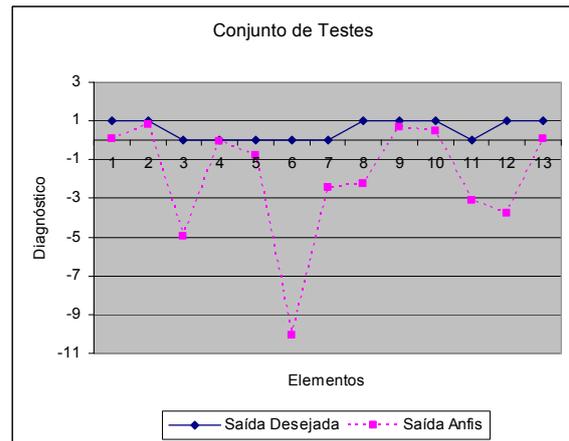


Figura 8 – Validação da rede ANFIS previamente treinada

A rede ANFIS fornece como resultado o EMQ e o gráfico mostrado na Figura 8 para o cálculo da taxa de classificação.

6 Resultados

Nesta seção vários experimentos foram realizados utilizando a abordagem proposta, variando-se as funções de pertinência do modelo ANFIS. A função de pertinência *trimf* é uma coleção de três pontos formando um triângulo e a *trapmf* é uma função trapezoidal. A função de pertinência *pimf* é uma curva polinomial assimétrica. As funções *gaussmf* e *gbelmf* são funções gaussianas e de sino. A função *psigmf* é uma função de pertinência produto de duas funções sigmoidais. A Tabela 3 mostra os resultados dos testes.

Tabela 3. Resultados dos testes no modelo ANFIS

Função de Pertinência	Quantidade de neurônios de entrada	Treinamento	Épocas	Taxa de classificação
<i>psigmf</i>	3	híbrido	1000	87,5%
<i>trapmf</i>	3	híbrido	1000	72,3%
<i>gbellmf</i>	3	híbrido	1000	77,9%
<i>gaussmf</i>	3	híbrido	1000	75,8%
<i>pimf</i>	3	híbrido	1000	75,7%
<i>trimf</i>	3	híbrido	1000	71,7%

A taxa de classificação foi calculada para cada experimento pela divisão do número de classificações corretas pelo número total de imagens do conjunto referente, correlacionada ao EMQ. Cada classificador foi treinado com um número diferente de iterações. A função produto de duas funções sigmóides *psigmf* associada a nove regras foram utilizadas, pois produziram um melhor resultado se comparado com outros parâmetros. Resultados também foram melhores com o treinamento híbrido a partir de 100 épocas se comparado ao treinamento em *backpropagation* com épocas acima de 10.000. A Figura 9 mostra comparações baseadas nos dados da Tabela 3.

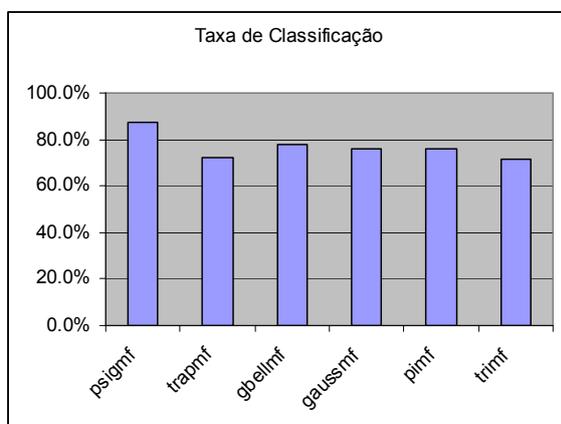


Figura 9 – Comparação de funções de pertinência

7 Conclusão

Neste artigo foi apresentado e discutido um modelo para a construção de um sistema de diagnóstico auxiliado por computador para detecção e classificação de microcalcificações em mamogramas. O modelo neuro-fuzzy ANFIS se mostrou adequado atingindo índices de acerto de até 87,5%. A avaliação do sistema atual foi realizada utilizando-se a base de dados Mini-MIAS. Em uma segunda etapa, o mesmo será testado com uma base de dados de mamogramas que reflita a população feminina brasileira e com melhor

qualidade de imagem para um estudo mais aprofundado.

Finalizando, métodos como estes podem auxiliar os radiologistas e melhorar sua acurácia no diagnóstico do câncer de mama.

Referências Bibliográficas

- Castleman, K. R. (1996). Digital Image Processing. New Jersey, USA: *Prentice Hall*.
- Cheng, H. D., Wang, J., Shi, X. (2003). Microcalcification Detection using Fuzzy Logic and Scale Space Approaches. *The Journal of Pattern Recognition Society*.
- INCA – Instituto Nacional de Câncer. Disponível em <http://www.inca.gov.br>. Acesso em 25 de setembro de 2006.
- Jang, R. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on System, Man and Cybernetics*, **23**(6), 181-198
- Mousa, R., Munib, Q., Moussa, A. (2005). Breast Cancer Diagnosis System Based on Wavelet Analysis. *Expert Systems with Applications* **28**.
- Nauck, D., Klawonn, F., Kruse, R. (1997). Foundations of neuro-fuzzy systems. *Wiley Press*. USA.
- Organização Mundial de Saúde. Disponível em <http://www.who.int>. Acesso em 25 de setembro de 2006.
- Parker, J. R. (1996). Algorithms for image processing and computer vision. *Wiley Press*. USA.
- Santos, V. T. (2002). Segmentação de Imagens Mamográficas para Detecção de Nódulos de Mamas Densas. Orientador: Homero Schiabel. São Carlos: USP, 112p. Dissertação. (Mestrado em Engenharia Elétrica).
- Suckling, J., Parker, J., Dance, D., Astley, S., Hutt, I., Boggis, C., et al. (1994). The mammographic images analysis society digital mammogram database. *Excerpta Medical International Congress Series*, **1069**, 375-378.
- The mathworks. MatLab (2003). Disponível em: <<http://www.mathworks.com>>. Acesso em: 25 setembro 2006.