

# ANÁLISE DISCRIMINANTE DE GRUPOS DE CARACTERÍSTICAS DE ACHADOS MAMOGRÁFICOS ATRAVÉS DA TÉCNICA SFS

C. L. S. Melo\*, Cícero F.F.Costa Filho\*\* e Marly G.F.Costa\*\*

\*Engenharia de Controle e Automação/UEA, Manaus, Brasil

\*\*Programa de Pós Graduação em Engenharia Elétrica/UFAM, Manaus, Brasil

e-mail: charles.melo@yahoo.com.br

**Abstract:** Classifying mammographic findings, microcalcifications and clusters of microcalcifications, as either benign or malignant, is a difficult task. This is mainly due to the variability of their appearance. Appropriate feature selection is probably the most critical step of an automatic classification process. This paper aimed to identify a set of features that allows for making the best automatic classification. Groups with different numbers of features were generated using the Scalar Feature Selection – SFS. Fisher’s Discriminant Ratio – FDR and the area under Receiver Operating Curve – ROC were used as auxiliary distance measurements. For classification purposes, different architectures of feedforward neural networks were employed. The results are evaluated through the cross validation method using measurements of accuracy, sensitivity and specificity.

**Keywords:** Microcalcification; cluster of microcalcification; neural network; pattern recognition.

## Introdução

O câncer de mama é o segundo tipo de câncer mais freqüente no mundo e o mais comum entre as mulheres e é uma das principais causas de óbito entre as mulheres no Brasil [1]. A detecção precoce é a principal estratégia para o controle do câncer de mama, sendo a mamografia uma das principais ferramentas utilizadas com esse propósito, já que sua resolução espacial permite o diagnóstico de nódulos milimétricos [1]. Os cânceres detectados através da mamografia apresentam-se na maioria dos casos na forma de *clusters* de microcalcificações [2].

Sistemas computadorizados de auxílio ao diagnóstico (CAD) têm sido propostos com o objetivo de auxiliar o radiologista, atuando como uma “segunda opinião”, ajudando-o na localização das anormalidades e na proposição do diagnóstico. Os principais módulos de um CAD em mamografia são mostrados na Figura 1: Captura da imagem, Detecção e Classificação.




Figura 1 – Diagrama de Bloco de um Sistema CAD de Mamografia.

Inicialmente, realiza-se a digitalização da imagem mamográfica, com diferentes taxas de amostragem e de quantização. Na etapa de realce, regiões de interesse (ROI) selecionadas a partir das imagens mamográficas, são realçadas, buscando-se eliminar ruídos e artefatos. A etapa de segmentação é realizada com o objetivo de encontrar áreas suspeitas contendo microcalcificações e/ou *clusters* e a separação das mesmas do fundo da imagem. Em seguida é realizada a etapa de extração de características. Usualmente, o conjunto de características extraídas pertence a um dos seguintes conjuntos: Descritores de forma, tais como: área, excentricidade, circularidade, irregularidade, perímetro, densidade, compacidade [4,5,6,7]; descritores de textura: energia, entropia, momento angular, correlação, contraste [8,9,10,11] e descritores de wavelet: energia, entropia [12]. O bloco de classificação engloba as etapas de pré-processamento de características e classificação. Na etapa de pré-processamento realiza-se a normalização das características e avalia-se o poder discriminante das características individuais ou de um grupo de características. Em muitos trabalhos mostrados na literatura os autores realizam a normalização dos valores das características para intervalos de 0 a 1 [4,8,12,13,14,15,16] ou a intervalos -1 a 1 [5,17], sem uma preocupação de estabelecer o poder discriminante das mesmas individualmente ou em grupo. Esta normalização é necessária, pois as características originais encontram-se em faixas dinâmicas distintas, o que pode influenciar de forma negativa a etapa de classificação [19].

Outros autores, no entanto, preocupam-se em selecionar grupos de características com um melhor poder discriminante. O rol de técnicas de seleção de características utilizadas é diverso. Nos trabalhos [6,18,23] os autores utilizaram a técnica de análise de componentes principais; Nos trabalhos [2, 7] os autores utilizaram técnicas de seleção reversa de características. Em [2,23] os autores utilizaram técnicas de seleção direta de características; A técnica *k-means* foi utilizada apenas em [20]. A distância de *Mahalanobis* foi utilizada em [10] e algoritmo genético foi utilizado em [11]. Na etapa de classificação são utilizados tanto classificadores supervisionados como não

supervisionados. Através da revisão da literatura evidenciou-se que, nas últimas décadas, o método supervisionado mais amplamente utilizado para classificação dos achados mamográficos foi o de redes neurais artificiais [2,4,5,6,8,9,11,12,14,15,18,20,21]. Dentre os métodos não supervisionados utilizados cita-se: *k-NN* [2,12,14,21] e *SVM (Support Vector Machine)* [12,16,23].

Este trabalho tem como tema principal aprimorar a etapa de classificação buscando identificar um grupo de característica que apresentam um poder de discriminação, sem a necessidade de utilização de todas as características extraídas de achados mamográficos e uma arquitetura de um classificador neural de propagação direta com o intuito de identificar casos malignos e benignos. Os achados mamográficos foram extraídos em trabalho anterior [17]. Os diversos conjuntos de características utilizados foram selecionados através da técnica *Scalar Feature Selection-SFS*. Como medidas de distância auxiliares foram utilizadas a medida *FDR (Fisher's discriminant ratio)* e a área sob a curva ROC (*Receiver Operating Characteristics*). O desempenho do método foi avaliado através da técnica de validação cruzada, utilizando as medidas de acurácia (percentual de classificação correta do método com o laudo histológico), sensibilidade (percentual de classificação correta do método com casos malignos do laudo) e especificidade (percentual correta do método com os casos benignos do laudo).

## Materiais e Métodos

O banco utilizado contém um conjunto de 16 características. Oito delas são características de microcalcificações, enquanto que a outra metade são características de *clusters* de microcalcificações. Essas características são provenientes de 80 amostras (ROI), de imagens coletadas do banco de imagens do MIAS (*Mammographic Image Analysis Society*) e INCa-RJ, acompanhadas com o respectivo laudo histológico (biopsia).

As oitos características referentes à microcalcificações são: área –  $m_1$ , excentricidade –  $m_2$ , compacidade –  $m_3$ , dobradura –  $m_4$ , contraste –  $m_5$ , irregularidade estreita –  $m_6$ , irregularidade larga –  $m_7$  e orientação –  $m_8$ . Referentes à *clusters* de microcalcificações são: perímetro –  $c_1$ , área –  $c_2$ , densidade –  $c_3$ , excentricidade –  $c_4$ , distância média das microcalcificações ao centro do *cluster* –  $c_5$ , orientação –  $c_6$ , distâncias relativas à borda do seio –  $c_7$  e ao músculo peitoral –  $c_8$ .

O método de classificação automática das microcalcificações e *clusters* de microcalcificações utilizado neste trabalho pode ser dividido em quatro etapas:

**ETAPA 1.** Definição de um ranking das melhores características referentes às microcalcificações e *clusters* de microcalcificações, para isto utilizando-se as medidas auxiliares: FDR e Área sob a curva ROC.

FDR é muitas vezes usada para quantificar a capacidade de discriminação de uma característica [22]. Esta medida é calculada conforme equação:

$$FDR = \frac{(\mu_1 - \mu_2)^2}{\sigma_1^2 + \sigma_2^2} \quad (1)$$

Em que:  $\mu_1$  – média da amostra da classe  $\omega_1$ ;  $\mu_2$  – média da amostra da classe  $\omega_2$ ;  $\sigma_1^2$  – variância da amostra da classe  $\omega_1$ ;  $\sigma_2^2$  – variância da amostra da classe  $\omega_2$ .

A área sob a curva ROC é um gráfico bidimensional, onde o eixo Y representa o valor da taxa de verdadeiros positivos – *tp* (casos que são classificados corretamente conforme o laudo histológico) e o eixo X representa o valor da taxa de falsos positivos – *fp* (casos classificados erroneamente comparado pelo laudo histológico).

Todas as características foram normalizadas para uma faixa de valores entre -1 a 1.

**ETAPA 2.** Como as características de cada achado mamográfico são oito, optou-se na formação de quatro grupos de características com 5, 6, 7 e 8 características, que apresentem maior poder discriminante, para o conjunto de características das microcalcificações e para o conjunto de características referentes aos *clusters* de microcalcificações, totalizando na formação de oito grupos.

Para a formação desses grupos foi utilizada a técnica *SFS (Scalar Feature Selection)*. Em geral, na seleção de características, usa-se como critério uma medida de distância entre classes –  $C(k)$ . Nesse trabalho utilizou-se as medidas auxiliares mencionadas na Etapa 1. A formação dos grupos de características obedece ao seguinte procedimento:

- Calcula-se  $C(k)$  para todas as características e organiza-se as características em um vetor segundo a ordem decrescente de  $C(k)$ ;
- Seleciona-se a 1ª característica que corresponde ao primeiro elemento do vetor de distância ordenado;
- Calcula-se o coeficiente de correlação entre a característica escolhida e todas as outras características, aplicando:

$$\rho_{ij} = \frac{\sum_{n=1}^N x_{ni} x_{nj}}{\sqrt{\sum_{n=1}^N x_{ni}^2 \sum_{n=1}^N x_{nj}^2}} \quad (2)$$

Em que:  $x_{ni}$  – amostra  $n$  da característica  $i$ ;  $x_{nj}$  – amostra  $n$  da característica  $j$ ;  $N$  – quantidade total de amostras de uma característica.

Escolhe-se a característica  $C_2$  para a qual:

$$i_2 = \arg \max_j \left\{ \alpha_1 C(j) - \alpha_2 |\rho_{i_1 j}| \right\} \text{ para todo } j \neq i_1 \quad (3)$$

Em que:  $\alpha_1$  e  $\alpha_2$  são constantes gaussianas ( $0 < \alpha < 1$ ) que priorizam a importância dos termos  $C(j)$ ;  $\rho_{ij}$  representa o coeficiente de correlação entre as características  $i$  e  $j$ ;  $C(j)$  representa a medida de distância da característica  $j$ .

- Para a escolha da  $k$ -ésima característica aplica-se:

$$i_k = \arg \max_j \left\{ \alpha_1 C(j) - \frac{\alpha_2}{k-1} \sum_{r=1}^{k-1} |\rho_{i,j}| \right\} \text{ para todo } j \neq i_r \quad (4)$$

As Tabela 1 e 2 mostram os grupos de características de microcalcificações e *clusters* de microcalcificações usando como medida de distância a FDR e área sob a curva ROC, respectivamente. As características desses grupos foram aplicadas como variáveis de entrada de uma rede neural de propagação direta para a classificação das Microcalcificações e *Clusters* de microcalcificações em casos benignas ou malignas.

Tabela 1 – Grupos resultantes da aplicação da medida FDR

| Grupo  | Características de microcalcificações    | Características de <i>clusters</i> de microcalcificações |
|--|--|--|
| GRUPO 1 – contendo as 5 melhores características | $m_6, m_8, m_1, m_3, m_2$                | $c_7, c_1, c_8, c_5, c_6$                                |
| GRUPO 2 – contendo as 6 melhores características | $m_6, m_8, m_1, m_3, m_2, m_7$           | $c_7, c_1, c_8, c_5, c_6, c_2$                           |
| GRUPO 3 – contendo as 7 melhores características | $m_6, m_8, m_1, m_3, m_2, m_7, m_4$      | $c_7, c_1, c_8, c_5, c_6, c_2, c_4$                      |
| GRUPO 4 – todas as características               | $m_6, m_8, m_1, m_3, m_2, m_7, m_4, m_5$ | $c_7, c_1, c_8, c_5, c_6, c_2, c_4, c_3$                 |

Tabela 2 – Grupos resultantes da aplicação da medida área sob a curva de ROC

| Grupo  | Características de microcalcificações    | Características de <i>clusters</i> de microcalcificações |
|--|--|--|
| GRUPO 1 – contendo as 5 melhores características | $m_3, m_4, m_1, m_6, m_2$                | $c_3, c_7, c_6, c_8, c_1$                                |
| GRUPO 2 – contendo as 6 melhores características | $m_3, m_4, m_1, m_6, m_2, m_7$           | $c_3, c_7, c_6, c_8, c_1, c_5$                           |
| GRUPO 3 – contendo as 7 melhores características | $m_3, m_4, m_1, m_6, m_2, m_7, m_8$      | $c_3, c_7, c_6, c_8, c_1, c_5, c_2$                      |
| GRUPO 4 – todas as características               | $m_3, m_4, m_1, m_6, m_2, m_7, m_8, m_5$ | $c_3, c_7, c_6, c_8, c_1, c_5, c_2, c_4$                 |

**ETAPA 3.** Uso do classificador baseado na rede neural artificial com três camadas: entrada, intermediária e saída.

A definição da arquitetura das redes neurais para as microcalcificações e *clusters* de microcalcificações foi definido pelos passos descritos em [25]. O procedimento foi empregado para as seguintes arquiteturas de redes neurais: 8-n-1, 7-n-1, 6-n-1 e 5-n-1. Para todas essas arquiteturas a melhor combinação de acurácia e tempo de convergência para redes que utilizaram características de microcalcificações na entrada, foi obtida com dois neurônios na camada intermediária. Já para a rede que utilizou na entrada as

características de *clusters* de microcalcificações, a melhor combinação foi obtida com três neurônios na camada intermediária.

O treinamento das redes neurais foi realizado utilizando o método de otimização de *Levenberg-Marquardt* [24]. O critério de convergência utilizado foi um erro quadrático médio menor do que  $10^{-4}$ . A Tabela 3 define as arquiteturas das redes neurais usadas nesse trabalho. Todas as arquiteturas foram testadas com os grupos de variáveis definidos nas Tabelas 1 e 2.

Tabela 3: Arquitetura das Redes Neurais e variáveis de entrada utilizada

| Variáveis de Entrada | Arquitetura das RNA de Microcalcificações | Arquitetura das RNA de Clusters de Microcalcificações |
|----------------------|---|---|
| Grupo 1, 2, 3, 4     | 5-3-1                                     | 5-2-1   |
| Grupo 1, 2, 3, 4     | 6-3-1                                     | 6-2-1   |
| Grupo 1, 2, 3, 4     | 7-3-1                                     | 7-2-1   |
| Grupo 1, 2, 3, 4     | 8-3-1                                     | 8-2-1   |

## Resultados

Para a obtenção dos resultados foi utilizado o método de validação cruzada. As amostras foram divididas em quatro subconjuntos de vinte imagens cada. Cada arquitetura de rede neural foi treinada com 3 subconjuntos e testada com o subconjunto remanescente. Como existem 4 possibilidades de se agruparem os 4 subconjuntos de imagens três a três, esse procedimento foi repetido quatro vezes. Para os quatro testes realizados tirou-se então a média da acurácia, sensibilidade e especificidade.

As Tabelas 4 e 5 mostram os melhores desempenhos das várias arquiteturas da rede neural utilizando como variáveis de entradas as características dos *clusters* de microcalcificações, quando se usam as medidas de distância FDR e área sob a curva de ROC, respectivamente. Para cada arquitetura é mostrado os valores médios de acurácia, sensibilidade e especificidade do grupo que apresentou o melhor resultado para a acurácia. Pode-se observar que os melhores resultados em termos de acurácia utilizando as características de *clusters* de microcalcificações foram obtidos com a arquitetura 6-2-1, utilizando o grupo com seis características e a medida de distância a FDR.

Tabela 4 – Melhores desempenhos das quatro arquiteturas de redes neurais utilizando como variáveis de entrada as características de *clusters* de microcalcificações e como medida de distância a medida FDR.

| Arquitetura | Ac (%) | S (%) | E (%) | Grupo |
|-------------|--------|-------|-------|-------|
| 5 – 2 – 1   | 82,74  | 80,25 | 88,69 | 1     |
| 6 – 2 – 1   | 86,19  | 80,56 | 95,83 | 2     |
| 7 – 2 – 1   | 82,86  | 81,50 | 85,42 | 3     |
| 8 – 2 – 1   | 82,74  | 85,57 | 80,36 | 4     |

Tabela 5 – Melhores desempenhos das quatro arquiteturas de redes neurais utilizando como variáveis de entrada as características de *clusters* de microcalcificações e como medida de distância a área sob curva ROC.

| Arquitetura | Ac (%) | S (%) | E (%) | Grupo |
|-------------|--------|-------|-------|-------|
| 5-2-1       | 80,83  | 80,90 | 82,44 | 3     |
| 6-2-1       | 84,52  | 87,15 | 82,89 | 2     |
| 7-2-1       | 86,01  | 86,61 | 85,71 | 2     |
| 8-2-1       | 81,07  | 85,42 | 79,18 | 4     |

As Tabelas 6 e 7 mostram os melhores desempenhos das várias arquiteturas da rede neural utilizando como variáveis de entrada as características das microcalcificações, quando se usam as medidas de distância FDR e área sob a curva de ROC, respectivamente. Para cada arquitetura é mostrado os valores de acurácia, sensibilidade e especificidade médios do grupo que apresentou o melhor resultado para a acurácia. Pode-se observar que o melhor resultado em termos de acurácia utilizando as características de microcalcificações foram obtidos com a arquitetura 6-3-1, utilizando como variáveis de entrada o grupo com sete características e como medida distância a medida FDR.

Tabela 6 – Melhores desempenhos das quatro arquiteturas de redes neurais utilizando como variáveis de entrada as características de microcalcificações e como medida de distância a medida FDR.

| Arquitetura | Ac (%) | S (%) | E (%) | Grupo |
|-------------|--------|-------|-------|-------|
| 5-3-1       | 66,11  | 69,22 | 64,87 | 1     |
| 6-3-1       | 72,81  | 67,15 | 59,69 | 3     |
| 7-3-1       | 68,47  | 70,49 | 66,34 | 3     |
| 8-3-1       | 72,57  | 79,83 | 67,71 | 4     |

Tabela 7 – Melhores desempenhos das quatro arquiteturas de redes neurais utilizando como variáveis de entrada as características de microcalcificações e como medida de distância a área sob curva ROC

| Arquitetura | Ac (%) | S (%) | E (%) | Grupo |
|-------------|--------|-------|-------|-------|
| 5-3-1       | 68,61  | 73,75 | 63,75 | 1     |
| 6-3-1       | 72,36  | 75,48 | 70,18 | 2     |
| 7-3-1       | 68,47  | 70,49 | 66,34 | 3     |
| 8-3-1       | 71,57  | 78,83 | 68,71 | 4     |

## Discussão e Conclusão

A partir das Tabelas 1 e 2 verifica-se que as medidas de distância FDR e área sob a curva de ROC resultam em grupos distintos de características ao se utilizar a técnica de seleção SFS.

A partir das Tabelas 4,5,6 e 7 verifica-se que os melhores desempenhos dos classificadores neurais utilizados não são obtidos com o número máximo de características disponíveis. Isso demonstra a validade de se usar uma técnica de seleção de características, preocupando-se assim com a análise do poder discriminante das características dos achados mamográficos

Os classificadores utilizando características de clusters de microcalcificações apresentaram resultados superiores.

Embora não tenha sido mostrado, o desempenho de classificadores neurais utilizando simultaneamente ambos os grupos de características foi inferior aos resultados obtidos e aqui apresentados para os grupos de características utilizadas separadamente.

Logo, percebe-se que para identificar e/ou classificar, achados mamográfico não se é necessário utilização de todas as características que o descreve.

## Agradecimentos

A CAPES pelo apoio financeiro. Aos Prof. Drs. Wagner C. A. Pereira e Antonio F. C. Infantosi, pelo auxílio no desenvolvimento deste trabalho e a cooperação acadêmica entre PEB/COPPE/UFRJ e PPGEE/UFAM.

## Referências

- [1] INCa, 2008, Estimativas 2010: Incidência de Câncer no Brasil. Rio de Janeiro.
- [2] D. Kramer, F. Aghdasi, "Texture analysis techniques for the classification of microcalcifications in digitised mammograms," Proceedings of the 1999 Fifth IEEE AFRICON Conference Electrotechnical Service for Africa, September 28-October 1, 1999, pp. 395-400.
- [3] H.D. Cheng, X. Cai, X.Chen, L. Hu, X. Lou, "Computer-aided detection and classification of microcalcifications in mammograms: a survey," Journal of the Pattern Recognition Society, IEEE,v.36, pp. 2967-2991, Março 2003.
- [4] Y. Jiang, R.M. Nishikawa, D.E. Wolverton, C.E. Metz, R.A. Schmidt, K. Doi, "Malignant and Benign Clusterd Microcalcifications: Automated Feature Analysis and Classification," Radiology, v. 198, Number 3, pp.671-678, March, 1996.
- [5] H. Nguyen, W.T. Hung, B.S. Thornton, E. Thornton, W. Lee, "Classification of Microcalcifications in Mammograms using Artificial Neural Networks,"Proceedings of the 20<sup>th</sup> Annual International Conference of the IEEE Engineering in Medicine and Biology Society, vol. 20, No 2, 1998.
- [6] A. Sepehr, M.H. Jamarani, B. Gholamali Rezai-rad, C. Hamid Behnam, "A Novel Method for Breast Câncer Prognosis Using Wavelet Packet Based Neural Network," Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27<sup>th</sup> Annual Conference, September 1-4, 2005..
- [7] L. Wei, Y. Yang, R.M. Nishikawa, "Microcalcification Classification Assisted by Content-based Image Retrieval for Breast Câncer Diagnosis,"Pattern Recognition, 2008.
- [8] D.Tsai, H.Fujita, K.Horita, T. Endo, "Classification of Breast Tumors in Mammograms using a Neural Network: Utilization of Selected Features,"Proceedings of 1993 International Joint Conference on Neural Networks.
- [9] B. Verma, J. Zakos, "A Computer-Aided Diagnosis System for Digital Mammograms Based on Fuzzy-Neural and Feature Extraction Techniques,"IEEE

- 
- Transactions on Information technology in Biomedicine, vol. 5, No. 1, march 2001.
- [10] P. Zhang, B. Verma, K. Kumar, "Neural vs. Statistical Classifier in Conjunction with Genetic Algorithm Feature Selection in Digital Mammography," IEEE, pp. 1206-1213, 2003.
- [11] K. Geetha, K. Thanushkodi, A.K. Kumar, "New Particle Swarm Optimizations for Feature Selection and Classification of Microcalcifications in Mammograms," IEEE- International Conference on Signal Processing, Communications and Networking Madras Institute of Technology, Jan 4-6, pp. 458-463, 2008.
- [12] M.A. Alofe, A.M. Youssef, Y.M. Kadh, A.S. Mohamed, "Computer - aided diagnostic system based on wavelet analysis for microcalcification detection in digital mammograms," IEEE Transactions on Medical Imaging, CIBEC, 2008.
- [13] Y. Jiang, R.M. Nishikawa, D.E. Wolverton, C.E. Metz, "Computerized Classification of Malignant and Benign Clustered Microcalcifications in Mammograms," Proceedings - 18<sup>th</sup> International Conference - IEEE/EMBS Oct. 30-Nov. 2, pp. 521-523, 1997.
- [14] L. Arbach, J.M. Reinhart, D.L. Bennett, G. Fallouh, "Mammographic Masses Classification: Comparison between BNN, KNN and Human Readers," CECE-CCGEI, May, 2003.
- [15] W. Chiracharit, R. Kongkachandra, "Clustered Microcalcification Classification Using CC-MLO- View Corresponding Shape and Distribuição Features," SICE Annual Conference, August 20-22, 2008.
- [16] S. Singh, V. Kumar, H.K. Verma, D. Singh, "SVM Based System for classification of Microcalcifications in Digital Mammograms," Proceedings of the 28<sup>th</sup> IEEE, EMBS Annual International Conference, Aug 30-Sept 3, 2006.
- [17] F.V. Pimentel, "Extração de parâmetros das microcalcificações de imagens mamográficas usando morfologia matemática," COPPE - UFRJ, Tese de Mestrado, Março 2004.
- [18] S. Sehad, S. Desarnaund, A. Strauss, "Artificial Neural Classification of Clustered Microcalcifications on Digitized Mammograms," IEEE, pp. 4217-4222, 1997.
- [19] T.H. Lin, H.Li, K.C. Tsai, "Implementing the Fisher's Discriminant Ratio in a K-means Clustering Algorithm for Feature Selection and Data Set Trimming," American Chemical Society, June, 2003.
- [20] Y. Chitre, A. P. Dhawan, M. Moskowitz, "Artificial Neural Network Based Classification of Mammographic Microcalcifications Using Image Structure and Cluster Feature," IEEE 1993.
- [21] R. Panchal, B. Verma, "Classification of Breast Abnormalities in Digital Mammograms using Image and BI-RADS Features in Conjunction with Neural Network," Proceedings of International Joint Conference on neural networks, July 31-Aug 4, 2005.
- [22] S. Theodoridis e K. Koutroubas, Pattern Pattern Recognition, 3th Edition, Elsevier Academic Press, 2003.
- [23] C. Wang, W. Jiang, X. Dong, "Characterization of clustered microcalcifications in mammograms based on support vector machines with genetic algorithms," IEEE, 2006.
- [24] A. Cichoki, R. Unbehauen, "Neural Networks optimization and signal processing," John Wiley & Sons, New York, 1993.
- [25] de Melo, C.L.S.; Costa Filho, C.F.F.; Costa, M.G.F.; Pereira, W.C.A.; "Matching Input Variables Sets and Feedforward Neural Network Architectures in Automatic Classification of Microcalcifications and Microcalcification Clusters", In: 3rd International Conference on Biomedical Engineering and Informatics (BMEI 2010), Yantai, p., 358-362, 18-21 Nov