

Resumo

A aplicação da termografia na mastologia origina-se da constatação de que na região onde há um câncer de mama a temperatura da pele pode ser maior do que a temperatura do tecido normal. Também o sangue venoso responsável por drenar o câncer possui temperatura superior a do arterial. Com isso, se há grande assimetria na distribuição das temperaturas das mamas, então geralmente uma delas pode apresentar algum tipo de patologia. Esta dissertação apresenta uma análise da viabilidade do uso do Coeficiente de Hurst e da Lacunaridade no auxílio ao diagnóstico precoce de patologias da mama. A primeira etapa da metodologia proposta é a segmentação da região de interesse e reamostragem desta. Esta etapa dá origem a duas imagens: mama direita (MD) e mama esquerda (ME). A partir destas uma nova imagem (imagem Subtração (S)) é gerada pelo módulo da subtração pixel a pixel da imagem da mama esquerda com a imagem da mama direita rotacionada em 180° em relação a um eixo vertical. Janelas móveis de tamanhos variáveis ($w = 5, 7, 9, 11, 13$ e 15) percorrem pixel a pixel cada uma das três imagens criadas computando os valores do Coeficiente de Hurst (H). Para cada tamanho de janela é calculada para cada uma dessas imagens (MD, ME e S) a média e o desvio padrão de H. Sendo assim, trinta e seis características são extraídas utilizando o coeficiente de Hurst. A partir da avaliação da Lacunaridade é feita a extração de outras noventa e sete características.

Através de “gliding boxes” de tamanho s (com $2 \leq s \leq 25$) são calculadas a lacunaridade da mama direita ($\Lambda_R(s)$), mama esquerda ($\Lambda_L(s)$) e da imagem Subtração ($\Lambda_S(s)$) dando origem a setenta e duas características. Vinte e quatro características são obtidas a partir de $|\Lambda_R(s) - \Lambda_L(s)|$ com $2 \leq s \leq 25$. O desvio padrão dessas últimas fornece mais uma característica. Finalmente, as cento e trinta e três características extraídas (divididas em quatorze grupos) foram analisadas por técnicas de aprendizado de máquina para a classificação das imagens. A metodologia apresentou excelentes resultados para alguns grupos, enquanto que para outros não. Por exemplo, o classificador “Naive Bayes” obteve área ROC “receiver operating characteristic” de 0.958.

Palavras chaves: Termografia, Imagens térmicas, Imagens médicas, Geometria fractal, Coeficiente de Hurst, Lacunaridade, Reconhecimento de padrões.

Abstract

The use of the thermography in the mastology is related with the fact that region with breast cancer can present temperatures higher than that of the normal tissues. Moreover, the blood responsible for draining the cancer tissues has temperature higher than other veins or arteries. Then, if there is great asymmetry in the distribution of temperatures of the breasts, probably the patient has some type of pathology. This dissertation presents a study about the feasibility of using the Hurst coefficient and Lacunarity to diagnosis breast diseases in early stages. The first step is the segmentation and resampling of the thermal image. This step gives us two images: right (RB) and left breast (LB). From these images is generated a new image (Subtraction image (S)) by the module of the subtraction pixel by pixel in the image of the left breast with the image of the right breast rotated 180° on a vertical axis. A square pixel-by-pixel movable window is used to compute the values of Hurst coefficient. Such computation is accomplished of various window sizes ($w = 5, 7, 9, 11, 13$ and 15). For each image (RB, LB and S) is calculated the average and standard deviation of Hurst computed values in each window w . Then, thirty six features are extracted using Hurst Coefficient. From the evaluation of Lacunarity is extracted ninety-seven features. Using gliding boxes of size s (with $2 \leq s \leq 25$) the lacunarity of right breast ($\Lambda_R(s)$), left breast ($\Lambda_L(s)$), and Subtraction image ($\Lambda_S(s)$) are calculated generating seventy-two features. Twenty four features are obtained by $|\Lambda_R(s) - \Lambda_L(s)|$ with $2 \leq s \leq 25$. Additional feature is provided by the standard deviation of these values. Then, the one hundred and thirty-three features extracted (divided in fourteen groups) are used by machine learning techniques to classify the images. It presented excellent results for some groups, but not all. For example, a group using Naive Bayes obtained an incredible high receiver operating characteristic area of 0.958.

Key words: Thermography, Thermal imaging, Medical imaging, Fractal geometry, Pattern Recognition, Hurst Coefficient, Lacunarity.