

08 a 11 de Outubro de 2018
Instituto Federal Fluminense
Búzios - RJ

ESTUDO COMPARATIVO DE TÉCNICAS DE LIMIAZIZAÇÃO DE HISTOGRAMAS EM IMAGENS DE NÓDULOS DE MAMOGRAFIA

Sílvia Mara da Costa Campos Victer – silviavicter@iprj.uerj.br

Brehna Sannae Inaba Silva - BrehnaSannaeis@gmail.com

Instituto Politécnico, Universidade do Estado do Rio de Janeiro, Nova Friburgo, RJ, Brasil.

Resumo. Este trabalho faz uma análise comparativa de algumas técnicas de segmentação de imagens baseadas em limiarização de histogramas, global e local, aplicadas à imagens digitais de nódulos de mamografia em níveis de cinza. Os nódulos malignos apresentam, em sua maioria, formatos mais espalhados comparados aos nódulos benignos, geralmente de formato mais arredondado. Será feito um estudo com um nódulo benigno e com um nódulo maligno a fim de se observar qual das técnicas abordadas consegue destacar melhor estes nódulos. O software Scilab foi utilizado como ferramenta de suporte computacional.

Palavras-chave: histograma, segmentação, limiarização, nódulos mamários.

1. INTRODUÇÃO

De acordo com (INCA, 2018), o câncer de mama é o tipo mais comum entre as mulheres, no Brasil e no mundo, correspondendo a 28% dos casos por ano. Quando a doença é detectada em fases iniciais, as chances de cura e sobrevivência do paciente são grandes. Logo, é indispensável uma análise cuidadosa da mama quando ocorre uma simples alteração de sua anatomia.

Exames simples como a mamografia permitem o estudo de nódulos mamários através das imagens. Nesse contexto, as técnicas de processamento de imagens podem se vistas como ferramentas de extrema importância para uma maior precisão do diagnóstico ao invés de apenas considerar a inspeção visual.

O processamento digital de imagens consiste em um conjunto de técnicas para capturar, representar e transformar imagens com o auxílio do computador. Através destas técnicas, é possível extrair e identificar informações das imagens e aperfeiçoar a qualidade visual de alguns aspectos estruturais, facilitando a percepção humana e a interpretação automática por meio de máquinas digitais (Pedrini, 2008).

Os radiologistas costumam classificar as mamografias de acordo com o formato da anormalidade. Geralmente, os tumores malignos têm contornos irregulares e mais difíceis de distinguir, e os tumores benignos têm contornos bem definidos (Conci, 2010; Martins, 2014).

A segmentação de imagens consiste em subdividir uma imagem em suas partes ou objetos constituintes. De forma geral, a segmentação é uma das tarefas mais difíceis em processamento de imagem e determina o eventual sucesso ou falha de toda análise (Gonzalez, 1992).

Há uma série de trabalhos que utilizam diversas técnicas de segmentação com aplicação em imagens de mamografia, tais como: em (Martins, 2014), que utiliza a técnica de crescimento de regiões; em (Souza, 2014), é apresentada a técnica de contorno ativo; Em (Conci, 2010), são vistas técnicas de processamento de imagens para detectar e classificar nódulos mamários. Diferentes métodos de segmentação aplicados a outras imagens médicas podem ser encontrados em (Coelho, 2012), que utiliza o método fuzzy c-means e o trabalho apresentado em (Victor, 2008) sobre comparação entre técnicas de segmentação automática em tecidos do encéfalo.

O presente trabalho aborda algumas técnicas de segmentação baseadas na limiarização de histogramas, aplicadas a imagens em níveis de cinza (a imagem é representada por um conjunto finito de números inteiros, de 0 a 255, onde cada valor é um nível de cinza, que define cada ponto da imagem, denominado pixel). Estes processos podem ser manuais, através da escolha de um limiar ou de vários limiares específicos através do que é observado no histograma, ou podem ser automáticas, em que o próprio sistema identifica qual seria o melhor limiar aplicado a determinada imagem. Serão vistas técnicas de limiarização global, que considera toda a imagem para obter um único limiar e técnicas de limiarização local, que considera os limiares para cada janela deslizante sobre a imagem. Este documento visa estender o trabalho em (Conci, 2010), com a aplicação destes métodos.

A primeira seção aborda o conceito de histograma de uma imagem. A seção seguinte exhibe as técnicas de segmentação de imagem que descrevem as limiarizações globais e locais utilizadas. Estas seções exibem algoritmos associados para descrever os passos de cada técnica. Logo após são apresentados os resultados e discussão e, por último, a conclusão.

2. HISTOGRAMA DE UMA IMAGEM

Uma imagem é uma função bidimensional $f(x, y)$ correspondente à intensidade de luz emitida ou refletida por uma cena, sendo x e y coordenadas espaciais, e f no ponto (x, y) representa a intensidade ou cor nesta coordenada. Esta intensidade é numericamente definida na imagem por um valor inteiro, não negativo e finito (Conci, 2008).

As imagens em escala de cinza correspondem à matrizes compostas por valores entre 0 e 255. O zero indica cor com menor intensidade (preto), e o valor 255 indica cor com maior intensidade (o branco).

O histograma de uma imagem corresponde à distribuição estatística dos níveis de cinza da imagem, geralmente representado por um gráfico que indica o número de pixels na imagem para cada nível de cinza. A visualização do histograma fornece uma indicação da qualidade da imagem quanto aos níveis de contraste e quanto ao seu brilho médio (Conci, 2008; Gonzalez, 1992).

Seja $f(x, y)$ uma imagem representada por uma matriz bidimensional, com dimensões $M \times N$ pixels e contendo L níveis de cinza no intervalo $[0, Lmax]$, o cálculo do histograma é apresentado no Algoritmo 1. O vetor H corresponde ao histograma com L elementos e $Lmax$ representa a luminância (intensidade por unidade de área) máxima.

Algoritmo 1 - Cálculo do histograma de uma imagem.

1. //Atribuir valor zero a todos os elementos do vetor H .
2. Para $i = 0$ até $Lmax$ faça
3. $H[i] \leftarrow 0$
4. //Calcular a distribuição dos níveis de cinza para cada pixel da imagem.
5. Para $x = 0$ até $M - 1$ faça
6. Para $y = 0$ até $N - 1$ faça
7. $H[f(x, y)] \leftarrow H(f(x, y)) + 1$

3. MATERIAIS E MÉTODOS

O processo de segmentação de imagens é considerado o primeiro passo para análise e entendimento da imagem e consiste em particioná-la de modo que seja possível explicitar regiões representativas da imagem. Ele consiste em dividir uma imagem em regiões que possuem o mesmo conteúdo no contexto de uma aplicação (Conci, 2008; Gonzalez, 1992).

Há várias formas de segmentar imagens. A segmentação pode ser baseada nas descontinuidades ou nas similaridades dos diferentes aspectos da imagem. Podem ser baseadas em limites (bordas) ou em áreas (regiões). As descontinuidades são representadas pelas mudanças bruscas nos níveis de tons, cores e texturas (Neves, 2001). A limiarização consiste na classificação dos pixels de uma imagem de acordo com a especificação de um ou mais limiares (Pedrini, 2008; Santos, 2017).

Nas imagens de mamografias, a segmentação tem como objetivo identificar lesões através do seu formato, possibilitando, num primeiro momento, caracterizar uma lesão como benigna ou maligna, de acordo com a sua forma estrutural (Conci, 2010).

A limiarização pode ser global ou local. Na limiarização global, um único valor de limiar é utilizado para segmentar toda a imagem. Não é, em geral, adequada, pois as imagens podem conter variações nos níveis de cinza dos objetos e do fundo por causa da iluminação não uniforme, ruído, ou outros fatores. Na limiarização local, podem ser obtidos melhores resultados através da utilização de múltiplos valores de limiares. Desta forma, os valores de limiar podem variar sobre a imagem como uma função de características locais (Pedrini, 2008).

Ao longo deste documento, será utilizada uma imagem de um nódulo de mamografia de um tumor benigno e um outro nódulo de um tumor maligno. As imagens consideradas são obtidas da base de dados disponibilizada em (Vianna, 2018). Esta base de dados contém 33 imagens de nódulos benignos e 33 imagens de nódulos malignos. As imagens utilizadas representam um fragmento da imagem denominado nesta base por ben27.gif (exemplo de um tumor benigno) e um fragmento da imagem denominado mal40.gif (exemplo de um tumor maligno), de dimensões 222 x 154 (34188 pixels ao total).

A Figura 1 mostra as imagens e os respectivos histogramas do tumor benigno e do tumor maligno considerado. Ao analisar o histograma, percebe-se a ausência de pixels brancos nas imagens, e um conjunto de pixels distribuídos em vários níveis de cinza diferentes, cada um com um peso associado. Ou seja, o que se tem é uma informação global obtida de toda a imagem. A primeira imagem (Fig. 1a) apresenta um nódulo mais arredondado e a segunda imagem (Fig. 1c) um nódulo mais espalhado, mas a visualização única através dos histogramas não revela essa informação.

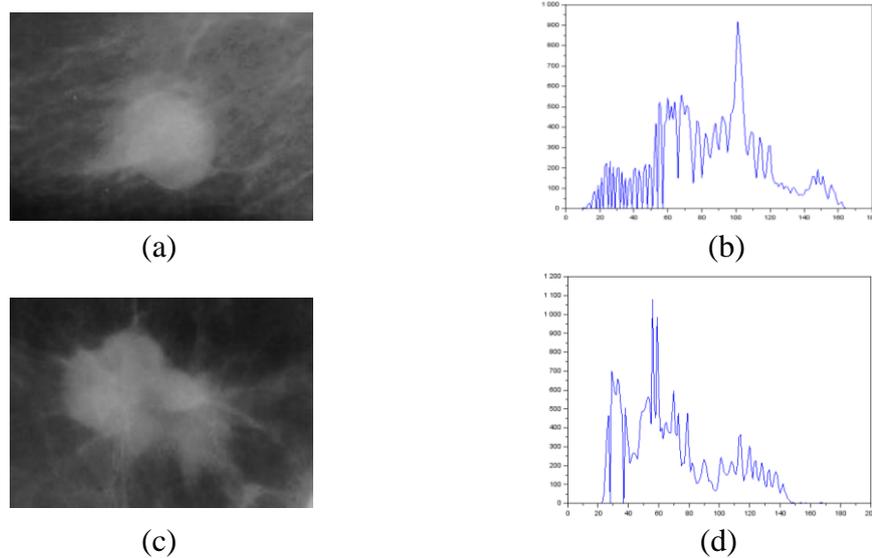


Figura 1 – Em (a) e (b), Imagem do tumor benigno e de seu histograma, respectivamente; Em (c) e (d), imagem do tumor maligno e de seu histograma, respectivamente.

Para a realização deste trabalho foram aplicadas as técnicas de segmentação por limiarização global (um método manual e o método iterativo de Ridler e Calward (1978)) e por limiarização local (métodos de Bernsen (1986) e Niblack(1986)). Para todas as técnicas automatizadas mencionadas, serão apresentados os algoritmos associados.

Todas as implementações foram feitas com o software Scilab 5.5.1 através das ferramentas de processamento de imagem SIVP (*Scilab Image and Video Processing toolbox*), versão 0.5.3.2; e IPD (*Image Processing Design*), considerando ser este um software robusto e gratuito (Yu, 2006). Todas as imagens analisadas foram convertidas em tons de cinza, variando entre o preto com menor intensidade ao branco com maior intensidade.

3.1 LIMIAZIZAÇÃO GLOBAL

A limiarização simples (ou global) resume-se em identificar os picos de um dado histograma e a partir destes, definir um valor que será utilizado como limiar para classificar os pixels em dois níveis de cinza, transformando a imagem em binária. O limiar é um valor que define um tom de cinza e, com base nesse valor, os pixels são classificados como preto, se os valores destes forem menores que o limiar, e, como branco, caso contrário. Resultando então em uma imagem binária (preto e branco) com duas classes (fundo e objeto). Pode ser obtida de forma manual ou automática.

Matematicamente, esta operação de limiarização global é descrita como :

$$g(x,y) = \begin{cases} 1, & \text{objeto se } f(x,y) \geq T \\ 0, & \text{fundo se } f(x,y) < T \end{cases} \quad (1)$$

onde $f(x,y)$ é a imagem original, T é o limiar e $g(x,y)$ a imagem limiarizada.

Existem imagens que, devido ao baixo contraste ou ruídos, podem não possuir uma boa distinção entre objetos e fundos. Neste caso, esta técnica torna-se inapropriada. Geralmente o

limiar é determinado de acordo com o nível de cinza que melhor separa os dois picos do histograma (Pedrini, 2008).

A limiarização manual consiste no usuário observar o histograma e selecionar manualmente o valor do limiar. A seleção correta do valor de limiar é crucial para que o processo de segmentação baseada na limiarização produza bons resultados.

Nas técnicas automatizadas, o próprio algoritmo analisa os dados do histograma e, através destas informações, define o melhor valor para ser usado como limiar, o que muitas vezes otimiza o processo de limiarização, mas nem sempre com bons resultados.

O método iterativo de Ridler e Calward (1978) é um método automático utilizado para selecionar iterativamente o valor de limiar baseado na combinação de modelos de duas distribuições gaussianas. A partir de uma estimativa inicial para o limiar, o método refina o cálculo do limiar baseado na média das distribuições dos níveis de cinza do objeto (μ_1) e do fundo (μ_2), até que esses valores não sofram alterações em iterações sucessivas. Na prática, as iterações terminam quando a diferença $|T_{i+1} - T_i|$ entre os limiares nas iterações i e $i + 1$ torna-se suficientemente pequena. Os passos do método são descritos pelo Algoritmo 2 (Pedrini, 2008):

Algoritmo 2 – Método iterativo de Ridler e Calward:

1. //Estimar um valor inicial, $T = T_0$, para o limiar, por exemplo, a intensidade //média da imagem.
2. //Particionar a imagem em duas regiões, R_1 e R_2 , com o limiar T , tal que todos os //pixels com intensidade menor que T sejam atribuídos à região R_1 e os demais à //região R_2 .
3. //Calcular um novo limiar T como:
4. $T = T_{i+1} = \frac{\mu_1^k + \mu_2^k}{2}$
5. //Repetir os passos (2) a (3) até que o limiar T não sofra alterações significativas //em iterações sucessivas:
6. $T_{i+1} \approx T_i$

3.2 LIMIAZIZAÇÃO LOCAL

As técnicas de limiarização local podem ser uma alternativa mais apropriada à limiarização global, nos casos em que a utilização de um único limiar para segmentar toda a imagem não produza bons resultados (Gonzalez, 1992).

Uma forma comum de realizar a limiarização local é analisar as intensidades dos pixels em uma região da imagem para determinar limiares locais através de janelas deslizantes. É preciso selecionar o tamanho da janela, pois o resultado também irá depender deste parâmetro; ou seja, janelas maiores garantem uma boa estimativa do valor da média e janelas menores evitam distorções devido a não uniformidade do fundo.

Os métodos locais utilizados neste trabalho são os métodos propostos por Bernsen (1986) e Niblack (1986). Algumas medidas estatísticas para o cálculo destes métodos são: a média dos valores de intensidade em uma vizinhança local da imagem, a mediana dos valores e/ou a média dos valores mínimo e máximo (Pedrini, 2008).

O método proposto por Bernsen é apresentado no Algoritmo 3. A partir da imagem original e do tamanho de uma janela centrada em cada pixel, o algoritmo calcula, para cada

pixel dentro desta janela, os valores mínimo (z_{\min}) e máximo (z_{\max}) do nível de cinza e obtém a média desses valores e atribui o resultado ao T, na forma:

$$T(x, y) = \frac{z_{\min} + z_{\max}}{2} \quad (1)$$

Algoritmo 3 – Limiarização Local pelo método de Bernsen

1. // Dados f: a imagem original de dimensões NxM, pixels (x,y),
// W: uma janela de dimensões jan x jan,
// fb: a imagem resultante (inicializada com zero),
// z_{\min} e z_{\max} : os valores de níveis de cinza mínimo e máximo em uma
// vizinhança de $n \times n$ pixels centrada em (x, y).
2. // Obter os limites da janela:
3. $k = \left\lfloor \frac{\text{Jan}}{2} \right\rfloor$
4. // Obter os valores iniciais e finais para aplicar a janela na imagem.
5. intervalo \leftarrow Jan - k
6. Para x = intervalo até M - intervalo - 1 faça
7. Para y = intervalo até N - intervalo - 1 faça
8. $z_{\min} = 255$
9. $Z_{\max} = 0$
10. Para i = -k até k faça
11. Para j = -k até k faça
12. //Calcular o valor máximo z_{\max} e o valor mínimo z_{\min}
13. Se $f(x + i, y + j) < z_{\min}$ faça
14. $z_{\min} \leftarrow f(x + i, y + j)$
15. Se $f(x + i, y + j) > z_{\max}$ faça
16. $Z_{\max} \leftarrow f(x + i, y + j)$
17. //Calcular o limiar T:
18. $T = \frac{z_{\min} + z_{\max}}{2.0}$
19. //Comparar o valor de T com o valor original do pixel
20. Se $f(x, y) > T$ faça $fb(x, y) \leftarrow 1$

O método proposto por Niblack é apresentado no Algoritmo 4. A partir da imagem original, de um tamanho da janela, e de um parâmetro de ajuste K , o algoritmo calcula o valor do limiar em um pixel (x,y) baseado na média local $\mu(x, y)$ e no desvio padrão como $\sigma(x, y)$:

$$T(x, y) = \mu(x, y) + k\sigma(x, y) \quad (2)$$

Algoritmo 4 – Limiarização Local pelo método de Niblack

1. // Dados: f: a imagem original de dimensões NxM,
// W: uma janela de dimensões jan x jan,
// K : um fator de ajuste,
// fb: a imagem resultante (inicializada com zero).
2. // Obter os limites da janela

3. $k = \left\lfloor \frac{Jan}{2} \right\rfloor$
4. //Obter os valores iniciais e finais para aplicar a janela na imagem.
5. Intervalo $\leftarrow Jan - k$
6. Para $x = intervalo$ até $M - intervalo - 1$ faça
7. Para $y = intervalo$ até $N - intervalo - 1$ faça
8. $zmin = 255$
9. $zmax = 0$
10. Para $i = -k$ até k faça
11. Para $j = -k$ até k faça
12. //Calcular a media
13. Para $i = -k$ até k faça
14. Para $j = -k$ até k faça
15. //Calcular o desvio padrão
16. //Calcular o limiar T:
17. $T = media + K * desvio_padrao$
18. //Comparar o valor de T com o valor original do pixel
19. Se $f(x,y) > T$ Então $fb(x,y) \leftarrow 1$

O valor escolhido para a constante K é ajustado de acordo com o tipo de aplicação ou da característica da imagem sendo processada. A escolha do K proporciona um equilíbrio entre supressão de ruído e preservação de detalhes, além de atribuir menor ou maior presença de contorno do objeto na imagem limiarizada.

4. RESULTADOS E DISCUSSÃO

Todas as técnicas mencionadas serão aplicadas às imagens de um nódulo benigno e de um nódulo maligno das Figs. 1a e 1c respectivamente, e será feito um estudo comparativo entre elas, no intuito de se verificar qual delas consegue identificar os nódulos com maior precisão. É claro que, em todos os casos, também é necessário obter a opinião dos especialistas da área médica.

Nas imagens da Figura 2, são apresentados os resultados por limiarização global manual do tumor benigno para os limiares $T=90$, $T=110$ e $T=118$.

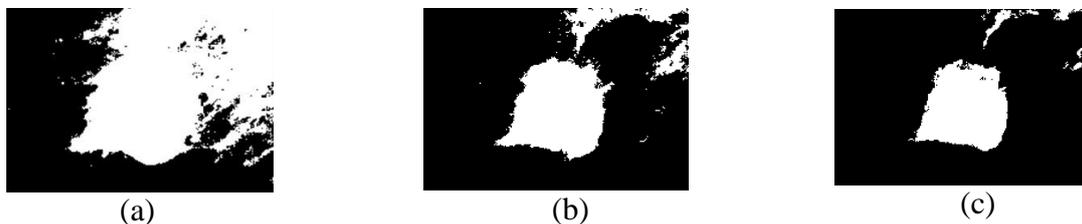


Figura 2 – Limiarização global manual do tumor benigno.
Limiares: (a) $T=90$, (b) $T=110$ e (c) $T=118$.

Observa-se da Fig. 2a que o limiar $T=90$ não destaca o nódulo precisamente. Com o limiar igual a 118 (Fig. 2c), é possível verificar a existência do nódulo na imagem, mas uma parte bem pequena do nódulo foi perdida. Para o limiar igual a 110 (Fig.2b), a parte que foi perdida com o limiar 118 permanece, ou seja, o nódulo fica bem perceptível, mas aparecem

também outras regiões. Após a análise de vários limiares, o que mais permitiu a visualização da existência do nódulo, sem também mostrar regiões que não são de interesse, foi o limiar 118.

A Figura 3 exibe o resultado para o tumor maligno, considerando os mesmos limiares da Fig. 2. Esta imagem revela com menor precisão qual seria exatamente o resultado mais apropriado. Assim, apenas a opinião de um especialista no assunto seria capaz de auxiliar a identificar qual destes limiares seria o mais adequado.

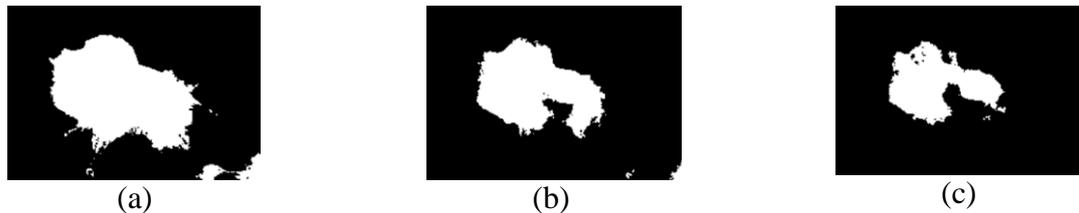


Figura 3 – Limiarização global manual do tumor maligno.
Limiares: (a) T=90, (b) T=110 e (c) T=118.

A Figura 4 exibe o resultado da técnica global introduzida por Ridler e Calward das duas imagens. Como se pode observar, o resultado não é satisfatório pois não foi capaz de destacar os nódulos de interesse corretamente.



Figura 4 – Limiarização automática pelo método de Ridler e Calward,
(a) nódulo benigno, (b) nódulo maligno.

Existem vários outros métodos globais automáticos, tal como o método de Otsu (1979). Este método considera o histograma da imagem composto de duas classes, os pixels do objeto e os pixels do fundo, onde cada classe possui suas próprias características, que são sua média e desvio padrão (Gonzalez, 1992; Victor, 2008). O método de Otsu possui bom desempenho em imagens com maior variância de intensidade. Uma desvantagem é que o método assume que o histograma da imagem é bimodal. O resultado da segmentação fica semelhante ao obtido na Fig. 4.

O que se verifica é que a localização global não é adequada para este tipo de imagem, de baixo contraste e com ruídos, o que justifica um estudo sobre as técnicas de limiarização local.

A Figura 5 mostra o resultado da aplicação do método automático adaptativo de Bernsen para uma janela quadrada de tamanho 3. A escolha do tamanho da janela deve ser feita considerando que um valor pequeno é capaz de preservar detalhes locais e, valores grandes, podem suprimir ruídos. É possível perceber que este método foi capaz de destacar o contorno do nódulo benigno automaticamente e de forma eficiente. Quanto a nódulo maligno do estudo, não se pode validar exatamente o contorno sem a ajuda de um especialista da área médica.

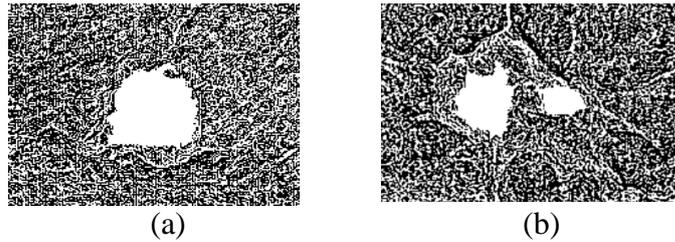


Figura 5 – Limiarização adaptativa pelo método de Bernsen (janela 3x3). Em (a), resultado para o nódulo benigno. Em (b), para o nódulo maligno.

A Figura 6 apresenta a imagem original limiarizada pelo método de Niblack para dois valores diferentes de k e assumindo uma janela deslizante 3x3. Percebe-se que o maior valor de k foi mais favorável para a identificação mais eficiente do nódulo. Valores ótimos para cada imagem devem ser estabelecidos, uma vez que o valor de k afeta diretamente o resultado da limiarização.

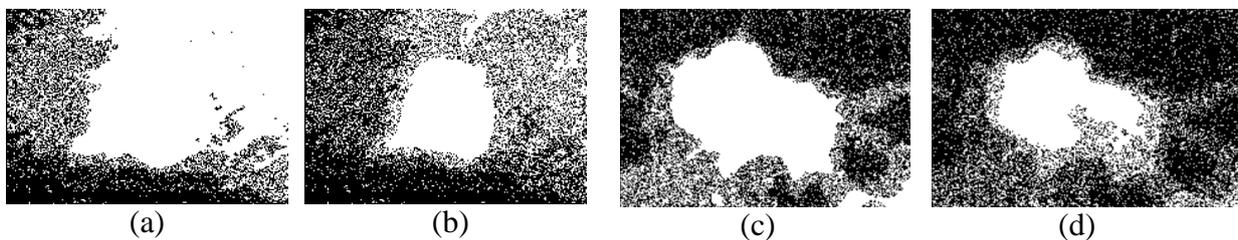


Figura 6 – Limiarização adaptativa pelo método de Niblack. Em (a) e (b), nódulo benigno, $k=15$ e 20 ; em (c) e (d), nódulo maligno, $k=15$ e 20 ;

Obviamente que todas essas figuras apresentam resultados preliminares de um estudo sobre diversas técnicas de segmentação de imagens por limiarização aplicado a esses nódulos e que, apenas com a opinião de um especialista será possível determinar com mais precisão qual das técnicas estariam mais próximas à detecção do nódulo de interesse a fim de auxiliar em um possível diagnóstico na identificação entre tumores benignos ou malignos. Mas já verifica-se que a limiarização local seria a mais adequada comparada às técnicas globais.

5. CONCLUSÕES

Este trabalho apresentou técnicas manuais e automáticas de segmentação de imagens por limiarização de histogramas aplicadas à imagens de nódulos mamários, com o intuito de se verificar se um tumor tem uma aspecto que possa caracterizá-lo, a primeira vista, como benigno ou maligno, e que possa servir de auxílio no diagnóstico médico. Com base nos resultados apresentados, percebe-se a importância do emprego de diferentes técnicas para análise desses nódulos, permitindo a comparação entre elas.

Nota-se que as técnicas de limiarização locais apresentaram-se mais adequadas para a identificação destes nódulos, além de não precisarem de uma intervenção manual para a escolha do limiar adequado. Para se validar o melhor desempenho destas técnicas serão necessários testes adicionais das outras imagens da base de dados, mas o estudo apresentado neste documento já é capaz de indicar o comportamento destas técnicas para este fim.

Como trabalho futuro, sugere-se um estudo visando o desenvolvimento de outros métodos para a detecção automática desses nódulos, como também a realização de testes com imagens

de melhor resolução, como as disponibilizadas em outras bases diferentes, tal como a base denominada *Digital Database for Screening Mammography* (DDSM) (Heath, 2000).

REFERÊNCIAS

- Coelho, S, T. et al. (2012), “Uso do Método Fuzzy C-Means para Segmentação de Imagens Dermatoscópicas de Lesões de Pele”, *XVII Congresso Brasileiro de Física Médica*, Salvador.
- Conci, A., LETA, F, R. (2008) *Computação Gráfica*, vol. 2, editora: Campus/Elsevier, 2008, 412p.
- Conci, A. et al (2010), “*Processamento digital de imagens para a detecção e classificação de nódulos em mamografias*”, Revista Eletrônica da Faculdade Metodista Granbery, <http://re.granbery.edu.br> - ISSN 1981 0377, Curso de Sistemas de Informação - N. 9.
- Gonzalez, Rafael C., Woods, Richard E. (1992), *Processamento de Imagens Digitais*, Addison-Wesley Publishing Company, Inc.
- Heath, M. et al (2018). “The digital database for screening mammography”. Disponível em: <http://marathon.csee.usf.edu/Mammography/Database.html>. Acessado em: julho de 2018.
- INCA, Instituto Nacional do Câncer José Alencar Gomes da Silva. Disponível em: http://www2.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/mama/deteccao_precoce++>. Acessado em: 27 jul. 2018.
- Martins, M, N, Goes-Junior, E, S., Ambrosio, P, E. (2014), “Segmentação por crescimento de regiões em imagens de mamografia”, *XXIV Congresso Brasileiro de Engenharia Biomédica CBEB*, Uberlândia, MG.
- Neves, S. C., Pelaes, E. G. (2001), “Estudo e Implementação de Técnicas de Segmentação de Imagens”, *Revista Virtual de Iniciação Acadêmica*, Vol.1, no.2, pag. 1-11.
- Pedrini H. Schwartz, W. R. (2008), *Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações*. Editora: Thomson, 509p.
- Santos, A. R., Paulista, C. R. ET et al, (2017), “Aplicação da técnica de limiarização de histogramas de imagens digitais utilizando o MATLAB”, *XX ENMC – Encontro Nacional de Modelagem Computacional e VIII ECTM – Encontro de Ciências e Tecnologia de Materiais*, Nova Friburgo, RJ.
- Souza, L. B. S., Ângelo, M. F. (2014), “Utilização de Contorno Ativo para Segmentação de Nódulos em imagens de Mamografia”, *XXIV Congresso Brasileiro de Engenharia Biomédica CBEB*, Uberlândia, MG.
- Vianna, A., Conci, A., TORREÃO, J. R. (1998), *Mammography Image Databases*. Disponível em <http://www.ic.uff.br/~aconci/mam>> Acessado em: Julho de 2018.
- Victer, S.M, Conci, A. et al. (2008). “Avaliação dos métodos para a segmentação Automática dos tecidos do encéfalo em ressonância Magnética”, *SPOLM*, ISSN 1806-3632 , Rio de Janeiro.
- Yu, S., Shang, S. (2006) *SIVP: Scilab image and video processing toolbox*, versão 0.4.0. Free Software Association, Institute of Automation, Chinese Academy of Sciences. Disponível em: <http://sivp.sourceforge.net/sivp-doc-2006.en.pdf>>. Acessado em: Julho de 2018.

COMPARATIVE STUDY OF HISTOGRAM THRESHOLDING TECHNIQUES APPLIED INTO BREAST NODULES IMAGES

Abstract. *This work presents a comparative study of some image segmentation techniques based on global and local histograms thresholding, applied into breast digital images showed in gray level. The malignant nodules are typically more widespread compared to the benign ones, which are generally more rounded. An analysis will be carried out for a malignum and a benign nodule so as to comply about which of the techniques discussed is able to better highlight this nodules. The implementation was performed through Scilab software as a computational aid.*

Keyword. *Histogram, segmentation, thresholding, breast nodules.*