

Realce de Regiões em Imagens de Ultrassom de Câncer Mamário Baseado em Funções q -Sigmóides

P. G. Massa¹, M. P. Ribeiro¹, G. A. Wachs-Lopes², and P. S. Rodrigues²

¹Centro de Matemática, Computação e Cognição da Universidade Federal do ABC, Santo André, Brasil

²Departamento de Ciência Computação do Centro Universitário FEI, São Bernardo, Brasil

Resumo—Este artigo introduz pela primeira vez as funções q -Sigmóides, uma variação das funções Sigmoidais com kernel exponencial. Essa nova função baseia-se nas ideias da estatística não-extensiva de Tsallis, através do uso de kernels q -Exponenciais. O potencial dessa nova função é demonstrado no contexto de processamento digital de imagens, particularmente para aplicações de contraste e realce de regiões de interesse em imagens de ultrassom de câncer de mama. O método proposto apresentou boa performance tanto para imagens de tumores benignos quanto para imagens de tumores malignos, destacando consideravelmente as lesões do fundo. Isso sugere que a metodologia proposta pode ser explorada em Sistemas Automáticos do tipo CAD (Computer Aided Diagnosis) como uma etapa de pré-processamento de etapas posteriores, tais como segmentação e extração de contornos, visando a avaliação de formas tumorais em sistemas automáticos de diagnósticos.

Palavras-Chaves: melhoria de contraste; sigmóide; estatística de Tsallis; imagens de ultrassom; q -Exponencial; q -Sigmoid; q -Gaussiana

Abstract—This paper introduces by the first time the q -Sigmoid functions, a variation of the so called Sigmoid function, which is based on exponential kernels. This new function is based on non-extensive Tsallis statistics, through the use of q -Exponential kernels. The potential of this new function is demonstrated under the context of digital image processing, particularly for contrast enhancement and highlight regions of interest in ultrasound images of breast cancer. In the preliminary experiments, the proposed method showed good performance for both benign and malignant tumor images, significantly highlighting the region of interest from its background. This suggests that the proposed methodology can be explored in CAD (Computed Aided Diagnosis) systems as a pre-processing step of later stages such as segmentation and extraction of lesion contours before the shape and texture analysis stages in a system of automatic diagnosis.

Key-Words: contrast enhancement; sigmoid; Tsallis statistics; ultra-sound images; q -Exponential; q -Sigmoid; q -Gaussian

I. INTRODUÇÃO

O melhoramento de contraste e a remoção de ruído são dois dos desafios mais estudados na área de Visão Computacional, sobretudo quando se trata de imagens médicas; nesse caso,

torna-se uma tarefa indispensável. Em particular, quando envolve o diagnóstico de anomalias mamárias, geralmente pode-se avaliar as imagens de dois modos diferentes. O primeiro ocorre quando uma imagem de tomografia de raio-x, por exemplo, ressonância magnética ou ultrassom é diretamente avaliada por um especialista em busca de anomalias. O segundo modo ocorre quando esse mesmo tipo de imagem serve de entrada para sistemas de diagnóstico automático, os chamados Sistemas CAD (Computer Aided Diagnosis).

No caso particular de anomalias mamárias, a tarefa de melhoramento de contraste possui uma importância fundamental, uma vez que trata-se da segunda patologia que mais afeta mulheres em todo o mundo. Embora a taxa de diagnóstico positivo venha crescendo, a taxa de mortalidade tem caído consideravelmente, sobretudo devido ao diagnóstico precoce.

Entre as várias técnicas de diagnóstico, os transdutores de ultrassom se destacam devido ao fato de não serem invasivos e ao seu baixo custo. Consequentemente, sistemas CAD têm ganhado importância e, por consequência, também o pré-processamento para remoção de ruído ou melhoramento do contraste [13], [16], [5].

No entanto, os transdutores de ultrassom atuais são seriamente acometidos por ruído, sobretudo do tipo *speckle*. Além disso, o baixo contraste, má distribuição da escala de cinza e reverberação de outros órgãos em volta, são fatores que podem influenciar negativamente no diagnóstico, tanto direto, quando é realizado visualmente por especialistas, quanto de maneira automática, quando é realizado com a ajuda de um Sistema CAD. Por esse motivo, pesquisadores de Processamento Digital de Imagens têm empreendido grandes esforços no desenvolvimento de técnicas para lidar com esses problemas.

Como uma das primeiras etapas no tratamento de imagens médicas de um modo geral é a remoção de ruídos, em [6], os autores propuseram um algoritmo bioinspirado, chamado de algoritmo cuckoo, recentemente proposto na literatura, que adapta os parâmetros da filtragem em imagens de raio-x e tomografia computadorizada, obtendo resultados satisfatórios para esse tipo de imagem. Em [9], Irrera e colaboradores propuseram uma metodologia para redução de ruídos ao mesmo tempo que melhoram o contraste, também em imagens de raio-x.

Em uma linha metodológica bem diferente, no trabalho de B. Li e W. Xie [11], [10] foi proposta a redução de ruídos em imagens de raios-x através de filtros baseados em cálculos

fracionais; e em [20], L. Xiao, C. Li e Z. Wang propuseram um método baseado em lógica fuzzy e filtragem homomórfica para remoção de ruídos e melhoramento de contraste, também em imagens de raio-x.

Com foco principalmente no melhoramento de contraste, N. Najdawi, M. Biltawi e S. Tedomi [1] combinaram diferentes técnicas visando aprimorar processos de segmentação de massas suspeitas em mamogramas; e em [19], os autores apresentaram um método para melhoramento de contraste em imagens de tomografia computadorizada, realizando segmentação de fundo com o conhecido algoritmo de Otsu.

Filtros baseados em Hessianas também são utilizados para melhoramento e contraste, no entanto, demandam por melhor performance computacional. Assim, em [21] S. Yang e H. Cheng propuseram um método baseado em coeficientes polinomiais e no critério de Routh-Hurwitz para acelerar o cálculo da matriz Hessiana em imagens de tomografia computadorizada.

Por outro lado, uma teoria relativamente recente que vem sendo utilizada em processamento digital de imagens e visão computacional, sobretudo em segmentação de imagens, é a chamada Estatística não-extensiva de Tsallis [18], que se baseia no parâmetro de não-extensividade $q \in \mathbb{R}$. Essa teoria, nascida na mecânica estatística, propõe uma melhor compreensão para sistemas não-extensivos, através do parâmetro q , e que não podem ser explicados com precisão com modelos da estatística extensiva clássica.

Na área de processamento de imagens e visão computacional, essa teoria surgiu com alguns trabalhos propostos para segmentação de imagens naturais [14], [2]. Logo em seguida, essa teoria passou a ser aplicada à segmentação de imagens médicas, sobretudo em sistemas CAD [15], [12], [17], [7].

Seguindo essa mesma linha de sistemas extensivos e não-extensivos, em [4], E. Borges demonstrou uma extensibilidade das funções gaussianas que podem ser aplicadas a sistemas não-extensivos; são as chamadas funções q-Gaussianas, matematicamente demonstráveis como sendo uma generalização das tradicionais funções gaussianas quando $q \rightarrow 1$.

Assim, essas funções reacenderam o interesse em diversos trabalhos já bem fundamentados e que baseavam-se nas gaussianas tradicionais. Em [3] L. Assirati e colaboradores apresentaram uma nova versão da q-Gaussiana, como uma proposta bidimensional para detecção de bordas em imagens genéricas; e C. Gallão [8] mostrou a eficiência dessa teoria em duas ferramentas tradicionais: como filtros espaciais passa-baixa e como kernel de uma rede neural q-SOM.

Tais funções gaussianas, tanto aquelas apresentadas em [3] quanto aquelas apresentadas em [8], são construídas a partir de funções q-Exponenciais, que também são generalizações de funções exponenciais comuns para desvio-padrão $\delta = 1.0$.

Outro tipo de função que é construída a partir de uma exponencial é a chamada função sigmóide, já utilizada como kernel de filtros para remoção de ruído e melhoramento de contraste em imagens digitais. Assim, neste artigo introduzimos uma nova função, equivalente à sigmóide tradicional, mas derivada da q-Exponencial, que convencionamos chamar aqui de q-Sigmóide.

O nosso foco experimental para a função proposta são as imagens de ultrassom de câncer de mama, onde mostramos também que uma família de funções q-Sigmóides supera os resultados equivalentes com funções Sigmóides com relação à melhoria de contraste nesse tipo de imagem.

O restante do artigo está organizado da seguinte forma: na Seção II é introduzida a teoria proposta neste artigo; e nas Seções III e IV são apresentados os resultados e conclusões, respectivamente.

II. A DISTRIBUIÇÃO q-EXPONENCIAL E A FUNÇÃO q-SIGMÓIDE PROPOSTA

A distribuição q-Exponencial, dada na forma da Equação (1), $\lambda > 0$, e baseada na função q-Exponencial, dada pela Equação (2), é a distribuição de probabilidade gerada a partir da maximização da entropia de Tsallis [18], dada por $S_q = (1 - \sum p_i^q)/(q - 1)$, $q \in \mathbb{R}^+$, sob determinadas condições, incluindo o domínio positivo $x \geq 0$. A distribuição q-Exponencial é uma generalização da distribuição normal da mesma forma que a entropia de Tsallis é uma generalização da entropia padrão de Boltzmann–Gibbs–Shannon. Assim, a distribuição normal e^x é recuperada quando $q \rightarrow 1$ nas Equações (1) e (2).

$$(2 - q)\lambda e_q^{-\lambda x} \quad (1)$$

onde

$$e_q^x = [1 + (1 - q)x]^{1/(1-q)} \quad (2)$$

Por outro lado, a função Sigmóide tradicional é definida como:

$$f(x) = \frac{1}{1 + e^{-\lambda x}} \quad (3)$$

onde $\lambda \in \mathbb{R}$

Em processamento digital de imagens, quando o objetivo é realçar o contraste de uma determinada região de uma imagem $I(x, y) \in [0 : L]$, onde L é o valor de luminância máximo, cujo valor de luminância médio $\beta \in [0 : L]$ e uma faixa de variância $\alpha \in [0 : L]$ em torno de β são conhecidos a priori, a Equação (3) pode ser reescrita como:

$$\tilde{I}(x, y) = \frac{L}{1 + e^{-\frac{|I(x, y) - \beta|}{\alpha}}} \quad (4)$$

onde $\tilde{I}(x, y)$ é o valor de luminância mapeado a partir do valor de entrada $I(x, y)$. A Fig. 1 mostra um exemplo da utilização dos parâmetros β e α . Equanto o valor de β indica um valor de luminância buscado na aplicação da Equação (4), e α indica uma faixa de valores de luminância em torno de β .

Neste trabalho, como transformação de uma imagem I , visando o melhoramento de contraste em regiões de interesse que serão indicadas por β e α , propomos a função estendida da Equação (4), chamada aqui de q-Sigmóide, e definida com base na função q-Exponencial, dada pela Equação (2). Assim, re-escrevemos a Equação (4) na forma da Equação (5).

$$\tilde{I}(x, y) = \frac{L}{1 + [1 - (1 - q)] \frac{|I - \beta|}{\alpha}]^{1/(1-q)}} \quad (5)$$

Considerando as restrições impostas em [18] e [4], onde $0 \leq q < 3$, e assumindo os valores constantes $L = 255$, $\beta = 128$ e




Figura 1. Exemplo do domínio de luminância de $0 \leq I(x, y) \leq L$, onde os parâmetros β e α da Equação (4) são indicados. A faixa de espectro de luminância superior é a entrada do mapeamento e a faixa inferior é o resultado final. Note que o local e a faixa indicadas por β e α , respectivamente, na faixa superior são realçados na faixa de baixo.

$\alpha = 30$, a Fig. 2 mostra os comportamentos comparativos das Equações (4) e (5) para vários valores de q , incluindo quando $q = 1$.




Figura 2. Comportamento topológico das funções Sigmoid (esquerda) e q -Sigmoid (direita) para quatro valores diferentes de $q = \{0.1, 0.5, 1.0, 2.0\}$. No eixo horizontal são mostrados o domínio (luminância) de entrada e no eixo vertical são mostrados os valores de saída das funções (mapeamento).

De acordo com a Fig. 2, a função q -Sigmoid proposta possui um decaimento simétrico em torno de um ponto fixo para todos os valores de q exibidos. Esse ponto fixo é exatamente o valor de β , logo, ele indica previamente onde a função possuirá um forte ponto de inflexão, indicando a região de interesse. A medida que os valores de x vão se afastando desse ponto, os valores da função vão se tornando cada vez mais equalitários, dependendo do valor de α . A conclusão que pode-se tomar do comportamento observado na Fig. 2, é que a função q -Sigmoid, assim como sua correspondente Sigmoid tradicional, é capaz de realçar o contraste de uma região de interesse na imagem ajustando-se previamente os valores de β e α . Por outro lado, no caso específico da q -Sigmoid, essa topologia varia, indo de um decaimento maior para um menor, a medida que o valor de q aumenta.

Existem então três parâmetros dos quais dependem o resultado final da aplicação da q -Sigmoid. Por esse motivo, na próxima seção, este trabalho apresenta uma série de experimentos que demonstram o desempenho da q -Sigmoid em imagens de ultrassom de câncer de mama.

III. RESULTADOS EXPERIMENTAIS

Para testar a eficiência da metodologia proposta neste trabalho, foi implementado o mapeamento de imagens com as Equações (4) e (5) em uma base de dados de imagens de ultrassom de câncer de mama, contendo 250 imagens classificadas manualmente por especialistas, sendo 100 imagens de tumores benignos e 150 malignos. Esta base é uma das mais utilizadas na literatura correlata [13], [16], [14], [5]. Os testes realizados e apresentados aqui visam apenas demonstrar a viabilidade do método.

A Fig. 3 (linha superior) mostra três imagens aleatórias da classe de tumores benignos e a linha inferior mostra outras três imagens aleatórias da classe de tumores malignos.

Cada uma dessas seis imagens foi processada com valores de $q = \{0.1, 1.0, 2.0\}$. Lembrando que, quando $q = 1.0$, equivale a usar a função sigmoid tradicional. A relação desse valor com a classe e características de cada imagem é uma questão ainda em aberto na literatura correspondente [14], [15], [17].




Figura 3. Seis exemplos (três de benignos e três de malignos) de imagens originais usadas nos testes.

A Fig. 4 mostra o resultado da aplicação da Equação (5) em cada uma das três imagens da primeira linha da Fig. 3. A primeira coluna mostra a aplicação quando $q = 0.1$, e as colunas dois e três mostram os resultados quando os valores de q são iguais a 1.0 e 2.0, respectivamente.

A observação mais notável nos mapeamentos da Fig. 4 é o maior contraste conseguido quando $q = 0.1$ (primeira coluna) em relação aos demais valores.

Da mesma forma, a Fig. 5 mostra a aplicação da Equação (5) nas três imagens correspondentes a tumores malignos apresentadas na linha de baixo da Fig. 3.

Assim como no experimento anterior, a coluna da esquerda mostra a aplicação da Equação (5) quando $q = 0.1$ e as demais colunas são para $q = 1.0$ e 2.0, respectivamente.

Também aqui, é notável a superioridade do resultado obtido para $q = 0.1$, uma vez que atingiu maior contraste na região de interesse.

IV. CONCLUSÕES E CONTINUIDADE DO TRABALHO

O presente trabalho introduziu a função q -Sigmoid, baseada na ideia de distribuições não-extensivas, através da




Figura 4. Três exemplos de resultados (um por linha), correspondentes às três imagens da linha superior da Fig. 3. Para comparação, cada coluna aqui corresponde a um valor de q diferente. Para todas as imagens, foram usados $\beta = 20$ e $\alpha = 15$ na Equação (5).




Figura 5. Três exemplos de resultados (um por linha), correspondentes às três imagens da linha inferior da Fig. 3. Para comparação, cada coluna aqui corresponde um a valor de q diferente. Para todas as imagens, foram usados $\beta = 20$ e $\alpha = 15$ na Equação (5).

introdução do parâmetro real positivo q . A performance observada através da aplicação a imagens de ultrassom de câncer de mama, que são seriamente acometidas por ruído e baixo contraste.

Os resultados apresentados mostraram-se promissores, uma vez que geraram contornos mais proeminentes das lesões, tanto para tumores malignos quanto para benígnos em relação à aplicação da função quando valores de $q = 1.0$ (sigmoid tradicional) e $q = 2.0$.

Como continuidade desta pesquisa, pretende-se aplicar as funções q -Sigmóides em Sistemas CAD, estudando sua efici-

ência na extração automática da região de interesse do fundo da imagem desse tipo de lesão, facilitando assim a análise e classificação automática em lesões dessa natureza.

REFERÊNCIAS

- [1] N. Al-Najdawia, M. Biltawi, and S. Tedmori. Mammogram image visual enhancement, mass segmentation and classification. *Applied Soft Computing*, 35:175–185, 2015.
- [2] M. P. Albuquerque, M. P. Albuquerque, I. A. Esquef, and A. R. G. Mello. Image thresholding using tsallis entropy. *Pattern Recognition Letters*, 25:1059–1065, 2004.
- [3] L. Assirati, N. R. Silva, L. Berton, A. A. Lopes, and O. M. Bruno. Performing edge detection by difference of gaussians using q -gaussian kernels. In *Journal of Physics: Conference Series*, volume 40, pages 0120120–1–012012–4, 2014.
- [4] Ernesto P. Borges. Irreversibilidade, desordem e incerteza: Três visões da generalização do conceito de entropia. *Revista Brasileira de Ensino de Física*, 21(4):453, Dez 1999.
- [5] H. H. Cheng, J. Shan, W. Ju, Y. Guo, and L. Zhang. Automated breast cancer detection and classification using ultrasound images: A survey. *Pattern Recognition*, 43:299–317, 2010.
- [6] E. Daniel and J. Anitha. Optimum wavelet based masking for the contrast enhancement of medical images using enhanced cuckoo search algorithm. *Computers in Biology and Medicine*, 71:149–155, 2016.
- [7] H. Erdmann, G. Wachs-Lopes, C. Gallão, M. P. Ribeiro, and P. S. Rodrigues. *A study of a firefly meta-heuristics for multithreshold image segmentation*, chapter 37, pages 211–217. 2015.
- [8] C. D. Gallao. *Definicao da Funcao q-Gaussiana Bidimensional com Aplicacoes em Processamento Digital de Imagens*. Tese de doutorado, Centro Universitario da FEI, Sao Bernardo do Campo, AP, 2016.
- [9] P. Irrera, I. Bloch, and M. Delplanque. A flexible patch based approach for combined denoising and contrast enhancement of digital x-ray images. *Medical Image Analysis*, 28:33–45, 2016.
- [10] B. Li and W. Xie. Adaptive fractional differential approach and its application to medical image enhancement. *Computers and Electrical Engineering*, 45:324–335, 2015.
- [11] B. Li and W. Xie. Image denoising and enhancement based on adaptive fractional calculus of small probability strategy. *Neurocomputing*, 175:704–714, 2016.
- [12] K.M. Meiburger, F. Molinari, U. R. Acharya, L. Saba, P. Rodrigues, and W. Liboni. Automated carotid artery intima layer regional segmentation. *Physics in medicine and biology*, 56(13):4073–4090, 2011.
- [13] P. S. Rodrigues, R. F. Chang, and J. S. Suri. *Non-extensive entropy for cad systems of breast cancer images*, pages 121–128. Proceedings of 19th Brazilian Symposium on Computer Graphics and Image Processing, 2006.
- [14] P. S. Rodrigues and G. A. Giralardi. Computing the q -index for tsallis nonextensive image segmentation. In *Proceedings of SIBIGRAPI 2009*, pages 232–237, 2009.
- [15] P. S. Rodrigues and G. A. Giralardi. Improving the non-extensive medical image segmentation based on tsallis entropy. *Pattern Analysis and Applications*, 14(4):369–379, 2011.
- [16] P. S. Rodrigues, G. A. Giralardi, M. Provenzano, M. D. Faria, R. F. Chang, and J. S. Suri. A new methodology based on q -entropy for breast lesion classification in 3-d ultrasound images. In IEEE, editor, *Proceedings of 28th Annual International Conference of the IEEE, EMBS'06*, pages 1048–1051, New York, 2006.
- [17] P. S. Rodrigues, G. A. Wachs-Lopes, H. R. Erdmann, M. P. Ribeiro, and G. A. Giralardi. Improving a firefly meta-heuristic for multilevel image segmentation using tsallis entropy. *Pattern Analysis and Applications*, pages 1–20, 2015.
- [18] C. Tsallis. Nonextensive statistics: Theoretical, experimental and computational evidences and connections. *Brazilian Journal of Physics*, 29(1), March 1999.
- [19] H. T. Wua, J. Huang, and Y. Q. Shi. A reversible data hiding method with contrast enhancement for medical images. *J. Vis. Commun. Image R.*, (31):146–153, 2015.
- [20] L. Xiao, C. Li, Z. Wu, and T. Wang. An enhancement method for x-ray image via fuzzy noise removal and homomorphic filtering. *Neurocomputing*, 195:56–64, 2016.
- [21] S. F. Yang and C. H. Cheng. Fast computation of hessian-based enhancement filters for medical images. *J. Vis. Commun. Image R.*, (116):215–225, 2014.