

Medical Image Segmentation Using the Kohonen Neural Network

Â. Cunha, C. Watanabe, and C. Carvalho Jr., *Member, IEEE*

Abstract—An important definition of image segmentation is to divide an image into its features. This is a very important area in image processing field. The nontrivial image segmentation task is one of the most difficult challenges, since and there isn't a unique suitable method to target all kinds of images so far. There are several researches related to image segmentation, some of them is the application of Self-Organizing Maps - SOM. In order to explore this method, that differs of the most used, such as the spatial filtering using derivative filters as detectors of edge Sobel, Prewitt, Roberts and Canny, thresholding techniques and Otsu method, this work aimed the medical image segmentation using the Kohonen neural network so itself adopts a non-supervised learning in the training process.

Index Terms—Image segmentation, Self-organizing maps of Kohonen, Edge detection, Medical imaging.

I. INTRODUÇÃO

A Segmentação de imagens é uma importante área de investigação no campo de visão computacional, bem como no processamento de imagens. Ela divide uma imagem em suas partes constituintes [1]. Entretanto, a escolha de um método específico de segmentação depende das características do problema a ser resolvido, não existindo, até então, um único algoritmo que seja adequado para todos os domínios de imagens [2].

A maioria dos algoritmos de segmentação baseia-se nas seguintes propriedades básicas: descontinuidade e similaridade. Na primeira categoria, a abordagem é dividir uma imagem com base nas mudanças bruscas de intensidade, como as bordas. As abordagens principais da segunda categoria estão baseadas na divisão da imagem em regiões que sejam semelhantes de acordo com um conjunto de critérios predefinidos. A limiarização, o crescimento de região e a divisão e fusão são exemplos dos métodos dessa categoria [2].

O nível de detalhe em que a subdivisão é realizada depende do problema a ser resolvido. Ou seja, a segmentação deve parar quando os objetos ou as regiões de interesse de uma aplicação forem detectados. A segmentação de imagens não triviais é uma das tarefas mais difíceis no processamento de imagens. A precisão da segmentação determina o sucesso ou o fracasso final dos procedimentos de análise computadorizada [2]. Como exemplo, no trabalho de [3] é apresentado um vetor de características para a representação de imagens de mamografia que contém massas benignas ou malignas. Como a realização do diagnóstico é baseado na forma das massas,

o resultado da segmentação dessas imagens influencia diretamente na qualidade das características que são extraídas e, conseqüentemente, na sugestão de diagnóstico dada pelo sistema desenvolvido.

Uma abordagem promissora para a tarefa de segmentação é o uso de redes neurais artificiais. Em [4] são apresentados vários trabalhos recentes que aplicam redes neurais nesta tarefa, sendo as mais utilizadas as redes de Hopfield, Rede Neural com Retro Propagação (*Back Propagation Neural Network* - BPNN), Rede Neural de Retro Alimentação (*Feed Forward Neural Network* - FFNN), *Perceptron* Multicamadas (*Multilayer Perceptron* - MLP), Mapas Auto-Organizáveis (*Self-Organizing Maps* - SOM) e Rede Neural de Pulso Acoplado (*Pulse-Coupled Neural Network* - PCNN).

O uso de redes neurais artificiais na tarefa de segmentação de imagens pode auxiliar na detecção de regiões de interesse quando não há um conjunto de treinamento com a saída desejada, já que podem ser implementadas como técnicas de aprendizado não-supervisionado.

Muitas redes neurais artificiais necessitam de um conjunto de padrões de entradas e saídas desejadas para que possam ser devidamente treinadas, onde seus ajustes de matrizes de pesos e limiares são realizados a partir da apresentação sucessiva dessas amostras de treinamento, fato que configura uma rede neural de aprendizado supervisionado. Contudo, certas aplicações não possuem o conjunto de padrões de saída desejada. Mas, suas amostras possuem informações relevantes sobre o comportamento do sistema.

A maioria das redes utilizadas em problemas com essa configuração se auto-organizam por meio de métodos de treinamento competitivos, os quais têm a capacidade de detectar similaridades, regularidades e correlações entre os padrões do conjunto de entrada, agrupando-os em classes (*clusters*). Cada classe possui então características particulares que estão relacionadas a situações e condições que regem o funcionamento do processo. Assim, a identificação destes *clusters* é importante para o entendimento das relações entre os seus elementos constituintes, permitindo-se ainda identificar as funções de um componente ou amostra com base nos atributos dos outros elementos que fazem parte do grupo [5]. Uma das redes neurais mais utilizadas em relação à auto-organização são os mapas auto-organizáveis de Kohonen, propostos por Teuvo Kohonen nos anos de 1982 a 1984 [5].

As redes de Kohonen encontram inspiração biológica no córtex cerebral, onde a ativação de uma região específica corresponde à resposta frente a determinado estímulo sensorial, por exemplo, estímulo motor, visual ou auditivo [5]. Embora a rede de Kohonen seja utilizada para diversas aplicações, em diferentes áreas do conhecimento, os trabalhos mais bem

Ângela S. M. Cunha, Instituto de Ciências Matemáticas e de Computação - ICMC-USP, São Carlos, São Paulo, Brasil, angelassilviane@gmail.com.

Carolina Y. V. Watanabe, Universidade Federal de Rondônia, Porto Velho, Rondônia, Brasil, carolina@unir.br.

Carlos A. T. Carvalho Jr., Universidade Federal de Rondônia, Porto Velho, Rondônia, Brasil, tenorio@unir.br.

disseminados versam sobre problemas que envolvem classificação de padrões e agrupamento de dados (clusterização) [5]. Assim, a rede neural de *Kohonen* pode ser aplicada na tarefa de classificação de diferentes bases de imagens, utilizando o método de segmentação de imagens.

Devido à alta complexidade em se modelar imagens com redes neurais, é que o objetivo deste trabalho foi explorar a aplicação do algoritmo de redes neurais artificiais, mais especificamente da rede neural de *Kohonen*, para segmentar imagens médicas. Para tanto, foram implementados algoritmos de segmentação de imagens utilizando a rede neural de *Kohonen*, filtros derivativos e de *Canny*, e avaliado o desempenho dos métodos utilizados. Foram utilizadas três bases de imagens médicas: imagens de mamografia, tomografia e de pulmão.

II. PROCESSAMENTO DE IMAGENS

A visão é o mais avançado dos nossos sentidos, de forma que não é de surpreender que as imagens exerçam o papel mais importante na percepção humana. No entanto, diferentemente dos seres humanos, que são limitados à banda visual do Espectro Eletromagnético (EM), os aparelhos de processamento de imagens cobrem quase todo o espectro EM, variando de ondas gama a ondas de rádio. Eles podem trabalhar com imagens geradas por fontes que os seres humanos não estão acostumados a associar com imagens. Essas fontes incluem ultrassom, microscopia eletrônica e imagens geradas por computador. Dessa forma, o processamento digital de imagens inclui um amplo e variado campo de aplicações [2].

Muitas abordagens para segmentação podem ser encontradas na literatura, sendo normalmente classificadas em três grupos básicos: limiarização (*thresholding*), segmentação baseada em bordas e segmentação baseada em regiões. Recentemente várias outras categorias têm sido levadas em consideração tais como as técnicas baseadas em cores, redes neurais, lógica *fuzzy* e algoritmos genéticos [6], [7].

O processo de segmentação pode ser supervisionado ou não-supervisionado. No primeiro, há uma etapa anterior à segmentação que visa obter um conjunto de informações a partir de uma coleção de dados (por exemplo, um banco de imagens). Apesar de tentadora, a ideia de obter-se características sobre a imagem antes de segmentá-la nem sempre é possível e conveniente. Já no processo não-supervisionado, essas informações devem ser estimadas durante o processo de segmentação. Essa é uma abordagem bastante positiva especialmente em sistemas de visão computacional, nos quais a interação com o usuário é indesejável [6], [7].

Em [5] é abordado o conceito de aprendizado supervisionado e não-supervisionado aplicados em redes neurais. O aprendizado supervisionado consiste nas redes neurais artificiais que possuem a capacidade de aprender a partir da apresentação de amostras (padrões) que exprimem o comportamento do sistema, sendo que, em seguida, após a rede ter aprendido o relacionamento entre as entradas e saídas, esta é capaz de generalizar soluções. A rede então será capaz de produzir uma saída próxima daquela esperada (desejada) a partir de quaisquer sinais inseridos em suas entradas. Diferentemente do supervisionado, durante a aplicação de um algoritmo

de aprendizado baseado em treinamento não-supervisionado, inexistem as respectivas saídas desejadas. Consequentemente, a rede deve se auto-organizar em relação às particularidades existentes entre os elementos componentes do conjunto total de amostras, identificando subconjuntos (*clusters*) que contenham similaridades. Alternativamente, a quantidade máxima desses possíveis *clusters* pode ser especificada (*a priori*) pelo próprio projetista da rede, levando-se em consideração o seu conhecimento a respeito do problema a ser tratado.

Dentre as técnicas de aprendizado supervisionado encontram-se as redes *Perceptron* que foi proposto por Rosenblatt em 1958 [8] e o *Adaline*, idealizado por Widrow e Hoff em 1960 [9]. A técnica de aprendizado não-supervisionado pode ser exemplificada com a rede auto-organizável de *Kohonen* proposta em 1982 pelo finlandês Teuvo Kohonen [10], que é o enfoque do trabalho na tarefa de segmentação de imagens sem que haja um conhecimento prévio das mesmas.

A literatura [4], [6], [7], [13]–[17] define muito bem os conceitos referentes a representação e processamento de imagens digitais e alguns conceitos básicos referentes a redes neurais artificiais e suas formas de aprendizado: supervisionado e não-supervisionado, que podem ser aplicados na tarefa de segmentação de imagens. Pode ser visto em [2], [18]–[20] que uma imagem pode ser representada como binária, em níveis de cinza e como imagem colorida com três canais. Para aprimorar a imagem, podem ser aplicadas técnicas de processamento de imagens por meio da convolução, e aplicando filtros é possível a detecção de bordas de objetos da imagem [5], [18], [21], [22]. Outras técnicas de segmentação que utilizam redes neurais artificiais, como o *Perceptron*, *Adaline* e *Convolutional Neural Network* (CNN) que tratam de aprendizado supervisionado e a rede de *Kohonen* que trabalha com aprendizado não-supervisionado [10]–[12], [16], [23], [24].

A. Rede Auto-Organizável de Kohonen

Os mapas auto-organizáveis também chamados de grades neurais são baseados na aprendizagem competitiva; os neurônios de saída da grade competem entre si para serem ativados, com o resultado de apenas um neurônio de saída. Esse neurônio é chamado de um neurônio vencedor leva tudo ou simplesmente neurônio vencedor. Normalmente esses neurônios estão colocados em nós de uma grade que pode ser uni- ou bidimensional [16].

Dimensionalidades mais altas são também possíveis, mas não são tão comuns. Os neurônios se tornam sintonizados a vários padrões de entrada (estímulos) ou classes de padrões de entrada no decorrer de um processo de aprendizagem. As localizações nos neurônios assim sintonizados (i.e., os neurônios vencedores) se tornam ordenadas de forma que um sistema de coordenadas significativo para diferentes características de entrada é criado sobre a grade. Um mapa auto-organizável é, portanto, caracterizado pela formação de um mapa topográfico dos padrões de entrada no qual as localizações espaciais (i.e., as coordenadas) dos neurônios na grade são indicativas das características estatísticas contidas nos padrões de entrada, daí o nome “mapa auto-organizável” [16].

Um mapa auto-organizável ou rede de *Kohonen* (*Self-Organizing Map* - SOM) é um modelo de rede neural desenvolvido na década de 80 por Teuvo Kohonen. Diferentemente dos outros modelos de redes neurais, redes SOM têm uma forte inspiração fisiológica. Este tipo de rede baseia-se no mapa topológico existente no córtex cerebral. Neurônios topologicamente próximos uns dos outros tendem a produzir respostas para o mesmo tipo de estímulo no córtex cerebral [15].

Na rede de *Kohonen*, o tipo de aprendizado é não-supervisionado, ou seja, nenhum “professor” é envolvido, a rede é exposta a um número de entradas e se organiza de modo a fazer suas próprias classificações unicamente com base nesses dados [24].

O treinamento da rede de *Kohonen* pode ser feito pelo método padrão ou pelo método em lote (*batch training*). No treinamento pelo método padrão, também chamado de método sequencial, o processo de treinamento da rede começa com a inicialização dos pesos sinápticos, atribuindo-lhes valores aleatórios. Em seguida, três etapas são realizadas: competição, cooperação e adaptação sináptica, as quais podem ser vistas com maiores detalhes em [5], [16], [24].

Os mapas-auto organizáveis são amplamente utilizados no agrupamento de dados e no reconhecimento de padrões, na segmentação de imagens coloridas e compressão de imagens [25]. Também podem ser aplicados na resolução problemas não-lineares de alta dimensionalidade, tais como: extração de características e classificação de imagens e padrões acústicos, controle adaptativo de robôs, equalização, demodulação e transmissão de sinais assim como em aplicações nas áreas de estatística, processamento de sinais, química e medicina [24].

Propriedades importantes como a capacidade de aproximar o espaço de entrada, ordenação topológica e casamento de densidade, aliadas a simplicidade do modelo e à facilidade de implementação do seu algoritmo de aprendizagem justificam seu sucesso e o colocam como um dos principais modelos de redes neurais [26].

III. METODOLOGIA E APLICAÇÃO

O principal objetivo deste trabalho consistiu na implementação da rede neural de *Kohonen*, dos filtros derivativos de *Roberts*, *Prewitt* e *Sobel* e do algoritmo de *Canny*, para segmentar um conjunto de imagens, sendo este composto por imagens de mamografia, tomografia e de pulmão. Logo em seguida, será realizada uma avaliação visual dos resultados obtidos com o propósito de determinar qual o melhor método a ser utilizado em uma determinada imagem do conjunto.

A base de imagens foi obtida do Hospital das Clínicas de Ribeirão Preto (HCRP-USP) [27].

Nas imagens de mamografia, por exemplo, o objetivo foi verificar se a rede neural é capaz de detectar as bordas dos objetos presentes nas imagens. Para realizar as avaliações com as imagens de tomografia, a rede realiza segmentação das bordas do crânio e o restante dos tecidos. E por fim, para imagens de pulmão, foi feita uma segmentação para detectar as bordas da sua estrutura.

Foram utilizadas 13 imagens, sendo 4 de tomografias de crânio, 4 de mamografias e 5 tomografias de pulmão.

A. Metodologia

A metodologia adotada neste trabalho foi uma adaptação da pesquisa desenvolvida em [25], onde se estuda a detecção de bordas em imagens biomédicas utilizando os mapas auto-organizáveis de *Kohonen*.

Para cada imagem dos conjuntos de testes, foi realizada uma segmentação com a rede neural combinando os métodos e técnicas descritas anteriormente. Na Figura 1 pode-se ter uma visão geral da metodologia desenvolvida.

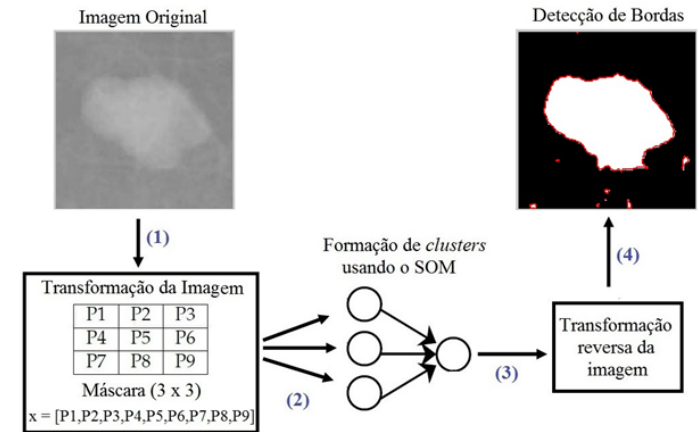


Fig. 1. Visão geral da metodologia desenvolvida.

Na Figura 1 a seqüência dos seguintes passos são:

Passo 1: Primeiramente é obtida uma imagem em níveis de cinza da base de imagens, em seguida ocorre a transformação dessa imagem utilizando máscara 3 x 3, onde serão gerados vetores de entrada com 9 variáveis cada;

Passo 2: São formados agrupamentos (*clusters*) utilizando o SOM, o conjunto de entrada é classificado em duas classes;

Passo 3: Ocorre a transformação reversa da imagem, ou seja, o conjunto de vetores classificados é reversamente transformado em uma imagem. Os valores de intensidade são substituídos pelos valores de cada membro da classe, assim a imagem será binarizada;

Passo 4: São detectadas as bordas da imagem binarizada.

A seguir são detalhadas as etapas da metodologia proposta.

1) *Transformação da Imagem:* Cada imagem foi transformada a partir de uma máscara 3 × 3 conforme a Figura 1.

A máscara (9 *pixels* adjacentes) é movida ao longo de toda a imagem de entrada, *pixel* a *pixel* e linha por linha, até que toda a imagem seja percorrida, realizando, assim, o processo de convolução.

Em cada ponto da máscara da imagem, um único vetor de entrada é formado, i.e., $\vec{X} = [P1, P2, P3, P4, P5, P6, P7, P8, P9]$, em que $P1 - P9$ denotam os valores de intensidade de um *pixel* da imagem. Assim, são formados os vetores de entrada, onde cada vetor \vec{X} terá nove variáveis.

2) *Formação de Clusters Usando SOM:* Depois que a imagem é transformada em máscaras 3 × 3, a rede neural terá vários vetores de entrada e esses vetores serão classificados ou agrupados em duas classes. A Figura 2 ilustra o processo.

As saídas com valor zero (0) são os *pixels* pretos, pertencentes à Classe 1, que representam o fundo da imagem ou




Fig. 2. Formação de *clusters*.

background. E os valores um (1) da Classe 2, são os *pixels* brancos que formam o objeto da imagem.

3) *Transformação Reversa da Imagem*: Assim que as duas classes são formadas, os conjuntos de vetores classificados são inversamente transformados em imagem. Os valores de intensidade de cada *pixel* da imagem original são substituídos por valores das classes já definidas, ou seja, Classe 1 e Classe 2. Assim, o SOM foi utilizado na redução dos níveis de intensidade da imagem, de 256 para 2 níveis. Esse processo gerou a imagem binária que será fundamental no próximo passo que será a detecção das bordas.

4) *Detecção das Bordas da Imagem*: Depois que são realizados todos os processamentos anteriores usando o SOM, a imagem já está binarizada, assim *pixels* com valor um (1), que são os *pixels* brancos, pertencem a um objeto e os demais constituem o fundo da imagem. No processo de detecção de bordas são traçados os limites da imagem binarizada, os limites exteriores dos objetos (pais) e seus filhos (objetos completamente fechados pelos pais).

E assim, a imagem segmentada é exibida, delimitando as possíveis bordas encontradas. A descrição da configuração da rede neural de *Kohonen* implementada neste trabalho foram: (i) Quantidade de neurônios: 2; (ii) Tipo de inicialização dos pesos: Gerados aleatoriamente; (iii) Taxa de aprendizagem: 0,001; (iv) Topologia: Unidimensional; (v) Tipo de medida de distância: Euclidiana; (vi) Número de épocas: 500; e (vii) Critério de vizinhança: Raio = 1.

Serão utilizados somente dois neurônios, pois a rede neural tem o propósito de realizar o agrupamento e separação das amostras em duas classes. A inicialização dos pesos será de forma aleatória e com taxa de aprendizagem de 0,001; essa variável exprime o quão rápido o processo de treinamento da rede estará sendo conduzido rumo à convergência (estabilização) da rede neural [5]. A métrica de distância entre os vetores de entrada e os vetores de pesos dos neurônios é a distância euclidiana. O número de épocas contabiliza o número de épocas de treinamento, ou seja, quantas vezes são necessárias apresentar todas as amostras do conjunto de treinamento visando o ajuste dos vetores de pesos. O critério de vizinhança raio é um dos mais utilizados e indica como os neurônios estarão cooperando em relação aos seus vizinhos.

Foi visto que é feita a convolução da imagem, formando vetores de entrada com nove variáveis, pois é utilizada uma máscara 3×3 . Em seguida a rede de *Kohonen* separa esses vetores de entrada em duas classes, ou seja, preto e branco, formando os *clusters* ou agrupamentos. Logo depois, ocorre a formação inversa da imagem, assim os valores de intensidade da imagem são substituídos por valores das classes já definidas

gerando a imagem binária. No processo de detecção de bordas são traçados os limites da imagem já binarizada, detectando suas respectivas bordas, e, finalmente, a imagem é exibida.

IV. RESULTADO E DISCUSSÕES

Nesta seção são apresentados os experimentos e resultados da aplicação da metodologia proposta neste trabalho em imagens de mamografia, tomografia e de pulmão.

As imagens segmentadas com a rede neural de *Kohonen* foram comparadas com os métodos de detecção de bordas de *Sobel*, *Prewitt*, *Roberts* e *Canny*, com o objetivo de realizar uma comparação visual e determinar o melhor método de detecção de bordas. Serão apresentados alguns experimentos aplicando o SOM no conjunto de imagens propostos. É apresentado uma comparação dos métodos de detecção de bordas utilizando o SOM, os filtros derivativos e o detector de bordas de *Canny*, cada resultado de um conjunto de imagens é analisado separadamente.

A. Experimento 1 - Detecção de bordas em imagens de mamografia utilizando SOM

A primeira base preparada para a realização de testes é composta por 4 imagens, com dimensões de 170×170 , 118×118 , 148×150 e 241×241 *pixels* retiradas de exames de mamografia. O primeiro experimento consistiu na detecção de bordas nessas imagens aplicando a rede neural de *Kohonen*, o objetivo consistiu em identificar todas as bordas das lesões tumorais. Um exemplo pode ser observado na Figura 3, onde as amostras (a), (b) e (c) representam possíveis tumores benignos, enquanto a Figura 3 (d) representa uma lesão de aparente tumor maligno.

A forma e o tamanho dos tumores são de muita importância na hora de classificá-los como malignos ou benignos. Tumores com bordas irregulares têm uma alta probabilidade de serem malignos e aqueles que mostram bordas regulares geralmente são benignos [28].

A avaliação será por meio de uma comparação visual, com o objetivo de analisar se o SOM detecta todas as bordas presentes nas imagens. A Figura 3 mostra alguns exemplos dos resultados obtidos.

Analisando a Figura 3 pode-se perceber que a segmentação utilizando o SOM apresentou um desempenho significativo e isto pode ser explicado pelo fato de que a rede de *Kohonen* em seu processo de treinamento realiza a binarização da imagem seguida de detecção das bordas. A Figura 3 delimitou todas as bordas dos tumores presentes no conjunto de imagens, em (a), (b) e (c) as bordas das lesões tracejadas permitem supor que os tumores presentes são benignos. Resultado oposto ocorre em (d) onde todas as bordas são delimitadas, mas estas são irregulares, o que possivelmente trata-se de tumor maligno.

B. Experimento 2 - Detecção de bordas em imagens de pulmão utilizando SOM

Neste segundo experimento foram utilizadas 5 imagens de testes de dimensões de 512×512 *pixels*, todas elas de pulmão normal sem a presença de lesões.




Fig. 3. Exemplos da aplicação do SOM em imagens de mamografia.

Como pode ser visto na Figura 4 a metodologia detectou as bordas de interesse, no caso, as bordas do pulmão (esquerdo e direito), com exceção da Figura 4 (a) onde as respectivas bordas não foram detectadas, visto que a região de interesse, o pulmão, não foi delimitado com nenhuma das respectivas cores (verde e vermelho). Nota-se que os tamanhos e formas variam em cada imagem.

Para o caso de haver lesões pulmonares, os passos que os médicos realizam na análise visual dos achados são [27]: (a) Deslocamento da estrutura normal; (b) Aumento de tamanho relativo à estrutura normal; (c) Presença de densidades anormais; e (d) Destruição da estrutura normal ou bordas.

Todas essas características se relacionam com características básicas como forma, tamanho, densidade, bordas e contornos de estruturas presentes na imagem.

C. Experimento 3 - Detecção de bordas em imagens de tomografia utilizando SOM

Foram utilizadas 4 imagens de tomografia de dimensões 256×256 pixels, para realizar as avaliações visuais. A Figura 5 mostra alguns exemplos da segmentação.

Na Figura 5 são apresentados os resultados da avaliação feita com o conjunto de imagens de tomografia, nota-se que mesmo com imagens diversas o processo de detecção de bordas mostra-se eficiente.




Fig. 4. Exemplos da aplicação do SOM em imagens de pulmão.

D. Comparação entre os métodos de segmentação

Nesta Seção são discutidos os resultados pertinentes à detecção de bordas com o SOM, os filtros derivativos e o método de *Canny*. Nos resultados apresentados é importante ressaltar que a avaliação será por meio de uma comparação visual entre os métodos para determinar qual o melhor operador a ser aplicado para detectar bordas nas imagens.

A metodologia adotada para o SOM permanece a mesma. Para os demais filtros, primeiramente serão implementados nas imagens, logo em seguida será realizada uma comparação




Fig. 5. Exemplos da aplicação do SOM em imagens de tomografia.

visual dos resultados do SOM e com os demais detectores de bordas. A próxima etapa consiste em realizar um pré-processamento das imagens e aplicar os algoritmos detectores de bordas, e por fim, realizar uma nova comparação dos resultados com a rede de *Kohonen*.

1) *Imagens de Mamografia*: Os operadores foram aplicados nas imagens de mamografia e consistiram em detectar todas as bordas das lesões tumorais. A Figura 6 mostra uma das imagens do conjunto e a comparação da segmentação utilizando o SOM e as demais técnicas de detecção de bordas. Pode-




Fig. 6. (a) Imagem original de mamografia. (b) Segmentação utilizando o SOM. (c) Detectores de bordas de *Canny*, (d) *Sobel*, (e) *Prewitt* e (f) *Roberts*.

se perceber que a segmentação utilizando o SOM apresentou um desempenho significativamente melhor que o dos outros métodos. Nos métodos (*Sobel*, *Prewitt* e *Roberts*) a imagem é segmentada com base nas mudanças abruptas de intensidade,

formando assim, bordas irregulares. No detector de bordas de *Canny*, Figura 6 (c), foram encontradas bordas irrelevantes, tornando o método inadequado se comparado aos demais.

Ao realizar a equalização, ou seja, um pré-processamento na imagem original e em seguida aplicar os métodos de *Canny*, *Sobel*, *Prewitt* e *Roberts*, é possível obter melhores resultados como mostra a Figura 7. O pré-processamento




Fig. 7. (a) Imagem original de mamografia e (b) sua equalização. (c) Segmentação utilizando o SOM. (d) Detectores de bordas de *Canny*, (e) *Sobel*, (f) *Prewitt* e (g) *Roberts*.

da imagem melhorou os resultados de todos os métodos, se comparado com a Figura 6. O método de *Canny* obteve resultados significativos em relação ao anterior Figura 6 (c). A equalização redistribuiu os valores dos níveis de cinza da imagem, tornando o tumor bem visível na imagem equalizada, Figura 7 (b). Na segmentação com o SOM não foi aplicado equalização e mesmo assim, se torna o melhor método a ser empregado nas imagens de mamografia.

2) *Imagens de Tomografia*: Para avaliar os resultados das imagens de tomografia do cérebro, foi adotada a mesma metodologia abordada nas imagens de mamografia. A Figura 8 mostra os exemplos de segmentação. Pode-se perceber, primeiramente, que de todos os métodos segmentadores, apenas o detector de bordas de *Roberts*, Figura 8 (f) não obteve total detecção das bordas exteriores. Novamente o método de (c) *Canny* encontra todas as bordas da imagem, incluindo a massa cinzenta e os detectores de (d) *Sobel* e (e) *Prewitt* obtiveram resultados muito semelhantes. Sendo que o objetivo é encontrar as bordas do crânio, a rede neural de *Kohonen* oferece resultados satisfatórios.

O próximo passo também será aplicar o mesmo pré-processamento de equalização seguido da aplicação dos detectores de bordas, com exceção do SOM. Na Figura 9 pode-se observar todos os resultados. Quando aplicado o pré-processamento os resultados quase que se equiparam com o já mostrado na Figura 8. Assim, é possível observar somente pequenas mudanças, como a diminuição de bordas detectadas na massa cinzenta.

3) *Imagens de Pulmão*: O último conjunto avaliado neste trabalho consistiu em imagens de pulmão. A Figura 10 mostra uma das imagens do conjunto segmentada com os métodos adotados anteriormente. Neste caso, o SOM detectou as bordas dos dois lados do pulmão de forma satisfatória, Figura 10 (b). O método de *Canny*, Figura 10 (c), realizou a detecção de muitas bordas irrelevantes, e os três operadores restantes, Figura 10 (d) e Figura 10 (e) obtiveram uma segmentação




Fig. 8. (a) Imagem original de tomografia do cérebro. (b) Segmentação utilizando o SOM. (c) Detectores de bordas de Canny, (d) Sobel, (e) Prewitt e (f) Roberts.




Fig. 9. (a) Imagem original de tomografia do cérebro e (b) sua equalização. (c) Segmentação utilizando o SOM. (d) Detectores de bordas de Canny, (e) Sobel, (f) Prewitt e (g) Roberts.

semelhante, mas o detector de Roberts Figura 10 (f) apresentou resultado inferior aos dois anteriores.

A Figura 11 demonstra a segmentação após o pré-processamento da imagem. O detector de Canny, Figura 11 (d), realizou uma segmentação de bordas desnecessárias, visto que o principal objetivo é definir as principais bordas do pulmão. Nesse sentido pode-se observar que mesmo sem




Fig. 10. (a) Imagem original do pulmão. (b) Segmentação utilizando o SOM. (c) Detectores de bordas de Canny, (d) Sobel, (e) Prewitt e (f) Roberts.




Fig. 11. (a) Imagem original do pulmão e (b) sua equalização. (c) Segmentação utilizando o SOM. (d) Detectores de bordas de Canny, (e) Sobel, (f) Prewitt e (g) Roberts.

utilizar a equalização da imagem para implementar o SOM, Figura 11 (c), o mesmo atingiu as metas esperadas. Os demais métodos, Figuras 11 (e), (f) e (g), apresentaram resultados similares e falhas nas bordas.

As comparações realizadas entre o algoritmo do SOM com os demais filtros derivativos (Sobel, Prewitt e Roberts) e detector de bordas de Canny, mostraram que a metodologia proposta possui resultados satisfatórios ao ser utilizado o mapa auto-organizável de Kohonen no processo de detecção de bordas nas imagens de mamografia, tomografia e de pulmão.

Ao ser realizado o pré-processamento e em seguida aplicado os demais detectores de bordas, com exceção do SOM, observa-se que nas três bases de imagens os resultados foram um pouco mais relevantes, sempre com falhas ao encontrar bordas, mas o processo mostrou-se um pouco superior.

V. CONCLUSÃO

O processo de segmentação de imagens possui uma vasta área de aplicação e como demonstrado neste trabalho, a aplicação da segmentação utilizando a rede neural de *Kohonen* apresentou resultados satisfatórios em todos os conjuntos de testes. Atualmente não existe um método de segmentação que possa ser aplicado de maneira satisfatória a todos os tipos de imagens, por esse motivo é importante conhecer a aplicabilidade de um determinado algoritmo em relação a uma classe de imagens. As principais contribuições deste trabalho foram a metodologia de detecção de bordas utilizando a rede neural de *Kohonen* e a comparação dessa metodologia com os métodos baseados em gradiente existentes na literatura.

As perspectivas futuras são na aplicação de morfologia matemática, para redução de ruídos nas imagens. Comparar os resultados com outros métodos, por exemplo, com o algoritmo EM/MPM que segmenta imagens baseado em textura, neste processo são utilizados Campos Aleatórios de *Markov* que se constituem em um modelo estocástico. E comparar os resultados da segmentação dos conjuntos de teste com imagens de referência denominadas na literatura de *ground-truth*.

AGRADECIMENTOS

Agradecemos ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo suporte financeiro.

REFERÊNCIAS

- [1] J. S. Sevak, A. D. Kapadia, J. B. Chavda, A. Shah and M. Rahevar, Survey on semantic image segmentation techniques, International Conference on Intelligent Sustainable Systems (ICISS), Palladam, pp. 306-313, 2017, doi: 10.1109/ISSI.2017.8389420.
- [2] R. C. González and R. E. Woods. Digital image processing. New York, NY: Pearson, 2018.
- [3] C. Y. V. Watanabe, J. S. Ramos, A. J. M. Traina, C. Traina, A CAD system based on complex networks theory to characterize mass in mammograms, Proc. SPIE 8315, Medical Imaging 2012: Computer-Aided Diagnosis, 831522, 2012.
- [4] S. Jain, V. Laxmi, Color Image Segmentation Techniques: A Survey. In: Nath V. (eds) Proceedings of the International Conference on Microelectronics, Computing & Communication Systems. Lecture Notes in Electrical Engineering, vol 453. Springer, Singapore, 2018.
- [5] S. Ma, X. Zhang, C. Jia, Z. Zhao, S. Wang and S. Wang, Image and Video Compression with Neural Networks: A Review, IEEE Transactions on Circuits and Systems for Video Technology, doi: 10.1109/TCSVT.2019.2910119, 2019.
- [6] P. Aggarwal, H. Mittal, P. K. Samanta and B. Dhruv, Review of Segmentation Techniques on Multi-Dimensional Images, International Conference on Power Energy, Environment and Intelligent Control (PEEIC), Greater Noida, India, pp. 268-273, 2018, doi: 10.1109/PEEIC.2018.8665405.
- [7] T. M. Almeida, T. S. Cavalcante and P. C. Cortez, Three-dimensional Radial Active Contour Model: A 3-D to 1-D Image Segmentation Technique, IEEE Latin America Transactions, vol. 15, no. 2, pp. 365-373, 2017, doi: 10.1109/TLA.2017.7854634.
- [8] F. Rosenblatt, Principles of Neurodynamics. Washington, DC.: Spartan Books 1962.
- [9] B. Widrow, M. E. Hoff, Adaptive switching circuits. IRE WESCON Convention Record 1960.
- [10] T. Kohonen, Self-organized formation of topologically correct feature maps. Biological Cybernetics. vol. 43, no. 1, pp.59-69, 1982, doi:10.1007/BF00337288.
- [11] H. Ajmal, S. Rehman, U. Farooq, Q. U. Ain, F. Riaz, and A. Hassan, Convolutional neural network based image segmentation: a review, Proc. SPIE 10649, Pattern Recognition and Tracking XXIX, 106490N, 2018, https://doi.org/10.1117/12.2304711.
- [12] J. Bullock, C. Cuesta-Lázaro and A. Quera-Bofarull, XNet: a convolutional neural network (CNN) implementation for medical x-ray image segmentation suitable for small datasets, Proc. SPIE 10953, Medical Imaging 2019: Biomedical Applications in Molecular, Structural and Functional Imaging, 2019, doi: 10.1117/12.2512451.
- [13] A. O. Artero, Inteligência artificial: teórica e prática. São Paulo: Livraria da Física, 2008.
- [14] R. Vinoth and C. Venkatesh, Segmentation and Detection of Tumor in MRI images Using CNN and SVM Classification, 2018 Conference on Emerging Devices and Smart Systems (ICEDSS), Tiruchengode, pp. 21-25, 2018, doi: 10.1109/ICEDSS.2018.8544306.
- [15] S. Pereira, A. Pinto, V. Alves, C. A. Silva, Brain Tumor Segmentation Using Convolutional Neural Networks in MRI Images, IEEE Transactions on Medical Imaging, vol. 35, no. 5, 2016.
- [16] S. Ma, X. Zhang, C. Jia, Z. Zhao, S. Wang and S. Wang, Image and Video Compression with Neural Networks: A Review. IEEE Transactions on Circuits and Systems for Video Technology, pp. 1-16, 2019, doi:10.1109/tcsvt.2019.2910119.
- [17] J. J. Hopfield, Neural networks and physical systems with emergent collective computational abilities. Proceedings of the National Academy of Sciences. USA, vol. 79, no. 8, pp. 2554-2558, 1982.
- [18] J. C. Russ, The Image processing handbook. Boca Raton, FL: CRC Press LLC, printed, 2016.
- [19] N. A. Otsu, A threshold selection method from gray-level histograms. IEEE Transactions on Systems, Man and Cybernetics. vol. 9, no. 1, 1979.
- [20] J. S. Ramos, A. J. M. Traina, C. Y. V. Watanabe, D. Hungria, T. C. Fernandes and C. R. C. Doria. Automatic counting and measuring fish oocytes from microscopic images. Proceedings of XI Workshop de Visão Computacional, pp. 38-43, 2015. <http://www.lbd.dcc.ufmg.br/colecoes/wvc/2015/007.pdf>
- [21] Y. Hu, Z. Chen and W. Lin, RGB-D Semantic Segmentation: A Review, IEEE International Conference on Multimedia & Expo Workshops (ICMEW), San Diego, CA, pp. 1-6, 2018, doi: 10.1109/ICMEW.2018.8551554.
- [22] C. Solomon and T. Breckon. Fundamentals of digital image processing: a practical approach with examples in Matlab. Chichester: Wiley-Blackwell, 2011.
- [23] C. C. R. Aldasoro, Image Segmentation with Kohonen Neural Network Self-Organising Maps. Instituto Tecnológico Autónomo de México, 2011. Disponível em: <http://www.cs.jhu.edu/~cis/cista/446/papers/SegmentationWithSOM.pdf>.
- [24] M. V. Akinin, A. I. Taganov, M. B. Nikiforov and A. V. Sokolova, Image segmentation algorithm based on self-organized Kohonen's neural maps and tree pyramidal segmenter, 2015 4th Mediterranean Conference on Embedded Computing (MECO), Budva, pp. 168-170, 2015, doi: 10.1109/MECO.2015.7181893.
- [25] A. Sasi, S. Sharma and A. N. Cheeran, Automatic car number plate recognition, International Conference on Innovations in Information, Embedded and Communication Systems (ICIIECS), Coimbatore, pp. 1-6, 2017, doi: 10.1109/ICIIECS.2017.8275893.
- [26] M. L. Gonçalves, M. L. D. A. Netto, J. A. F. Costa, Explorando as Propriedades do Mapa Auto-organizável de Kohonen na Classificação de Imagens de Satélite. VI Encontro Nacional de Inteligência Artificial (SBC ENIA), 2007. Disponível em: http://www.cos.ufrj.br/~ines/enia07_html/pdf/27845.pdf.
- [27] M. Ponciano-Silva, Processamento de Consultas por Similaridade em Imagens Médicas Visando à Recuperação Perceptual Guiada pelo Usuário. Dissertação de Mestrado Instituto de Ciências Matemáticas e de Computação, ICMC, USP, São Carlos, 2009.
- [28] SM. Hsu, WH. Kuo, FC. Kuo, et al., Breast tumor classification using different features of quantitative ultrasound parametric images, International Journal of Computer Assisted Radiology and Surgery, vol. 14, no. 4, pp. 623-633, 2019, doi: 10.1007/s11548-018-01908-8.