

# Segmentação de Imagens Médicas do trato vocal através do Mapa auto-organizável de Kohonen

## ENEBI 2009: 2º Encontro Nacional de Engenharia Biomecânica

Alexandre de Souza Brandão, Programa de Pós-Graduação em Engenharia Mecânica, UFF, e-mail: [abrand@operamail.com](mailto:abrand@operamail.com)

Edson Cataldo, Departamento de Matemática Aplicada, Programa de Mestrado em Eng. de Telecomunicações, UFF, e-mail: [ecataldo@im.uff.br](mailto:ecataldo@im.uff.br)

Fabiana Rodrigues Leta, Departamento de Engenharia Mecânica, UFF, e-mail: [fabiana@ic.uff.br](mailto:fabiana@ic.uff.br)

### Introdução

A segmentação de imagens possui grande importância na modelagem de alguns sistemas biomecânicos, porém não existe um método único que permita a segmentação perfeita para qualquer tipo de imagem. Para imagens médicas, por exemplo, os melhores métodos para segmentação são os chamados métodos híbridos (Forsyth, 2003). Neste trabalho, a segmentação será feita através do mapa auto-organizável ou rede neural de Kohonen para classificar regiões da textura em imagens do trato vocal (região que vai da laringe à boca) com base em um vetor de características extraídas das imagens obtidas por ressonância magnética. O trato vocal modula os pulsos de pressão acústica gerados pelas cordas vocais originando o som que ouvimos. Sua segmentação torna-se importante para que possamos criar modelos de modo a sintetizar mecanicamente a voz humana, por exemplo. As características extraídas a partir das imagens serão descritores estatísticos de texturas e obtidos através da técnica de matrizes de co-ocorrência. O mapa auto-organizável de Kohonen possui a capacidade de formar *clusters* automaticamente, com base na distância euclidiana entre os vetores de características. Assim, se os descritores de texturas forem bem escolhidos, será possível classificar as regiões da imagem com base em suas características de textura.

### Descritores de textura

Os descritores de textura implementados neste trabalho foram baseados tanto em técnicas estatísticas aplicadas na análise da janela de *pixels* quanto na matriz de co-ocorrência (Gonzalez, 2002) de tons de cinza da imagem. Após várias experiências com descritores, escolhemos os descritores de textura obtidos a partir da matriz de co-ocorrência chamados de descritores de Haralick (1973), a saber: Contraste,

Correlação, Energia, Entropia, Homogeneidade, Máxima Probabilidade, Média, Momento de ordem 3, Momento inverso de ordem 3 e Variância Inversa. Os descritores estatísticos (Gonzalez, 2002) foram: Continuidade, Contraste, Desvio, Entropia, Máxima probabilidade, Média, Momento de ordem 3 e Uniformidade.

### Implementação

A implementação foi feita utilizando a ferramenta *Visual Basic* com chamadas a funções do *MATLAB*. As Figuras 1-(a) e (b) ilustram a interface criada e as funções usadas. A rede neural de Kohonen foi baseada na implementação de Juha Vesanto et al., com pequenas modificações.

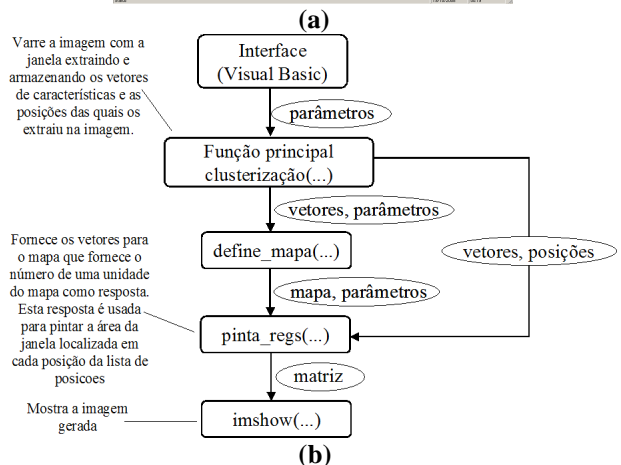
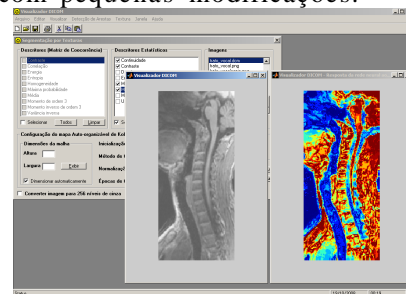



Figura 1: (a) Interface do programa (b) Diagrama do código da implementação.

Os vetores de características vão sendo extraídos com base em uma janela quadrada  $n \times n$  onde  $n$  é ímpar e a posição central desta janela, armazenada em um vetor de posições, é o pixel de referência. Durante a fase de treinamento, os vetores de características de textura são fornecidos para a rede neural e o algoritmo de treinamento em lote é executado para o ajuste dos pesos. Após o ajuste dos pesos na rede, os vetores de características são dados como entrada para a rede que fornece como resposta o número da unidade (neurônio) que mais se assemelha ao padrão do vetor de entrada. O número desta unidade é convertido em uma cor  $R_n$  e usado para pintar toda a região da janela em torno do pixel cuja posição corresponde a este vetor de entrada. Em imagens médicas, de uma mesma seqüência de fatias com as mesmas texturas, não é necessário treinar novamente a rede. Identificadas as regiões em uma imagem, é possível aplicar vetores de entrada contendo características extraídas de uma outra imagem da mesma seqüência.


Para agilizar o processo de treinamento, é possível alterar o passo da janela de modo a não obter tantos vetores de treinamento ao longo da imagem, ilustrado na Figura (2).



**Figura 2: Pintura da imagem segmentada.**

## Resultados

A seguir, mostramos algumas imagens do trato vocal segmentadas com esta técnica.



**Figura 3: Segmentação do trato vocal: (a) Original. (b) Descritores estatísticos: Continuidade, Contraste, Máxima Probabilidade e Média. (c) Descritor de co-ocorrência: média. (d) Descritor estatístico: Uniformidade.**

A partir da imagem de ressonância magnética do trato vocal na Figura 3-(a), selecionamos

no programa os descritores estatísticos: Continuidade, Contraste, Máxima Probabilidade e Média, obtendo o resultado na Figura 3-(b), onde a rede identifica uma boa parte das diferenças entre as regiões. Na Figura 3-(c) utilizamos o descritor Média, baseado na matriz de Co-ocorrência. E, finalmente, na Figura 3-(d) foi utilizado o descritor estatístico uniformidade. Foram feitos ensaios com as diferentes combinações de descritores até chegar em cada uma das segmentações, Figuras 3-(b), (c) e (d). Os descritores de co-ocorrência foram menos utilizados por serem computacionalmente dispendiosos e porque tiveram desempenho equivalente aos descritores estatísticos, que são mais rápidos de se calcular. Em todos os casos a rede foi capaz de detectar as arestas e algumas regiões. Como a rede classifica posição a posição da janela, serão necessárias ainda algumas modificações visando tornar as regiões mais homogêneas. Apesar disso, a rede se saiu razoavelmente bem nas tarefas de segmentação solicitadas, sendo capaz de identificar as diferenças entre os tecidos.

## Conclusões

A rede neural de Kohonen é sensível a vetores com características através das quais seja difícil formar *clusters*. Isto quer dizer que nem sempre é necessário incluir todos os descritores para obter uma boa classificação.

A técnica utilizada para construção da imagem a partir da resposta da rede neural treinada foi bastante simples. Apesar disso, a rede realmente armazenou os padrões de texturas e foi capaz de identificá-los em outras imagens, em especial nas imagens médicas, e com resolução relativamente boa.

É interessante notar que, para este método, não é necessária a seleção de sementes como nos métodos de crescimento de regiões. Por outro lado, a extração dos vetores de características e o treinamento da rede consomem mais tempo.

Esta técnica será utilizada na segmentação de fatias do trato vocal para, por exemplo, posterior geração de malha de elementos finitos, favorecendo sua aplicação em métodos computacionais para síntese de voz.

## Referências bibliográficas

- Forsyth, D. A. ; Ponce, J., Computer Vision - A Modern Approach, Prentice-Hall, 2003.  
 Gonzalez, R.C. ; Woods, R.E., Digital Image Processing, 2 Ed., Prentice-Hall, 2002.  
 Haralick, R.M. ; Shanmugam, K. ; Dinstein, I., Textural Features for Image Classification. IEEE Transactions on Systems, Man, and Cybernetics, vol. SMC-3, n. 6, November 1973.  
 Vesanto, J. et. al., SOM TOOLBOX, <http://www.cis.hut.fi/projects/somtoolbox/>