

Uso de Mapas Auto Organizáveis de Kohonen para quantização de imagens de Tomografia por Impedância Elétrica reconstruídas pelo software EIDORS

Alancássio Eulálio¹, Leonardo R. Ribeiro¹, Mêuser J. S. Valença¹ e Wellington P. dos Santos²

¹Escola Politécnica de Pernambuco – UPE

²Departamento de Engenharia Biomédica - UFPE

eulalium@gmail.com, leorfr@gmail.com, meuser@ecomppoli.br, wellington.santos@ieee.org

Abstract – *This article presents the application of Kohonen Self-Organizing Maps (SOM) for the quantization of reconstructed electrical impedance tomographic images generated from EIDORS (Electrical Impedance and Diffuse Optical tomography Reconstruction Software), an extensible software base for EIT (Electrical Impedance Tomography) researchers. EIDORS uses Finite Elements Method to reconstruct images from electrical potential information acquired from skin electrodes. This paper consists of a proof concept: in order to get better defined EIT image boundaries, we employed SOM networks to generate quantized images versions without the smoothing effect resulting from the numeric solution of Laplace's Equation. The results were qualitatively evaluated, seeming interesting for potential use at the decision support in clinical visual qualitative analysis.*

Keywords – Electrical Impedance Tomography, Kohonen Self-Organizing Maps, Image Reconstruction Software, Anti-Smoothing Techniques

1 Introdução

A Tomografia por Impedância Elétrica (TIE) é uma técnica não invasiva e de baixo custo para aquisição de imagens tomográficas, consistindo na aplicação de correntes em um arranjo de eletrodos (usualmente montado na forma de cinta) preso sobre a superfície a ser imageada, e na posterior medição dos potenciais elétricos resultantes nos eletrodos [1] [2]. Embora a aquisição seja razoavelmente simples, a reconstrução de imagens de TIE é uma tarefa computacionalmente custosa, consistindo na resolução numérica da Equação de Laplace para uma determinada grade, usando Diferenças Finitas ou métodos baseados nos Métodos dos Elementos Finitos ou nos Métodos dos Volumes Finitos [1] [2] [3].

Contudo, o problema da reconstrução de imagens de TIE é um problema mal posto, ou seja, não possui uma solução única, sendo que os métodos de resolução numérica da Equação de Laplace resultam apenas na obtenção da imagem mais suave, o que pode não ser de tanto interesse para aplicações clínicas, onde é muito importante analisar com relativa precisão a fronteira de diversos objetos de interesse, tais como bordas de órgãos e fronteiras de tumores malignos e benignos [2] [3].

Neste trabalho é apresentada uma prova de conceito, que mostra que as imagens de TIE reconstruídas pelo EIDORS utilizando métodos baseados no Método dos Elementos Finitos podem ser transformadas em versões menos suaves usando uma combinação de classificação não supervisionada e quantização. Para tanto foram utilizados Mapas Auto-Organizáveis de Kohonen. O objetivo é agrupar as áreas da imagem em regiões bem definidas através da redução da suavização da imagem reconstruída, permitindo, dessa forma, que sejam realizadas leituras mais fortemente associadas às regiões de interesse.

O EIDORS é uma ferramenta de referência e formadora de uma base comparativa para desenvolvimentos de pesquisas acerca do tema de TIE. A geração do presente artigo faz parte de estudos mais amplos no campo da otimização das imagens tomográficas de TIE. Destacam-se estudos na área de reconstrução de imagens com o uso de Compressed Sensing aliada a técnicas de Inteligência Computacional, com o objetivo de reduzir o custo computacional, aumentar a velocidade de processamento e a aumentar a qualidade da imagem reconstruída.

Este artigo está organizado da seguinte forma: (2) Materiais e Métodos. Essa sessão apresenta conceitos e os materiais e métodos utilizados para a obtenção dos resultados; (3) Resultados. Essa sessão apresenta os resultados obtidos; (4) Conclusão. Apresenta a análise dos resultados e conclui o trabalho; (5) Referências.

2 Materiais e Métodos

2.1 Tomografia por Impedância Elétrica – TIE

A TIE é uma técnica de aquisição de imagens a partir de potenciais elétricos medidos na fronteira de um domínio de interesse, obtidos pela injeção de correntes alternadas nas fronteiras desse domínio. A ideia por trás da TIE data de 1978 proposta, independentemente, por Henderson e Webster [5]. Dentre várias aplicações de TIE destacamos, nesse artigo, as da área médica. Na área médica, a TIE vem ganhando espaço, uma vez que os pacientes submetidos a exames de tomografia não são expostos à radiação ionizante e requer uma organização de hardware relativamente simples [1], o equipamento é compacto, podendo ir até o paciente, e constitui-se em uma ferramenta de baixo custo. Porém, encontra certa desvantagem quanto à qualidade da imagem recuperada.

2.2 EIDORS - Electrical Impedance and Diffuse Optical Reconstruction Software.

O EIDORS é uma ferramenta para reconstrução de imagens em Tomografia por Impedância Elétrica- TIE e Tomografia de Óptica Difusa (ainda não implementada, pelo projeto EIDORS), cujo objetivo é oferecer um software de reconstrução de imagem que seja distribuído e também modificável livremente. O EIDORS permite que sejam construídas referências com a finalidade de se realizarem comparações com novos sistemas e métodos, bem como permitir que novas ideias sejam construídas e devidamente testadas. O fato de ser um código livremente modificado dá ao EIDORS a possibilidade de que outros pesquisadores possam criticar os algoritmos originais, bem como suas implementações. A versão original do EIDORS (versão1) está baseada no software da tese de Vaukhonen. A versão1 do EIDORS implementa um pacote do MATLAB para a geração de malhas bidimensionais, solução do problema direto e exibição das imagens [4].

2.2.1 Arquitetura do Software

Basicamente, a arquitetura do EIDORS pode ser descrita como as diversas combinações das seguintes estruturas primárias: *data*, *image*, *fwd_model* e *inv_model*. Cada um desses objetos é representado por uma estrutura. Todos os objetos têm as propriedades de nome e tipo. O nome é arbitrário, ele é exibido por funções gráficas, que pode ser útil na distinção de funções especificadas pelo usuário. O tipo é usado para identificar as diversas categorias de objeto (ex.: *data*, *image*, etc) [4].

Fwd_model:

É a mais complexa das estruturas, projetado para representar o modelo de elementos finitos (MEF), posição e propriedades dos eletrodos e padrões de estimulação, assim como os ponteiros às funções para resolver o problema direto nesse modelo

Data:

O objeto *data* representa um quadro de medições ou dados simulados. Essa estrutura requer os campos de medições, *meas*, e o tempo de aquisição, *time*, em segundos após a iteração. Em uma aplicação particular, *time* pode ser definido como em relação a um outro ponto de início, tal como o início de um experimento, ou pode ser admitido como 0 ou -1 para tempos desconhecidos ou dados simulados.

Inv_model:

Esse objeto do EIDORS agrupa as informações necessárias para permitir a reconstrução das imagens. Existem dois tipos básicos de reconstrução, baseados no campo *reconst_type* desse objeto, ou seja, o *difference*, que calcula uma imagem baseada em dois objetos *data* e o *static*, que calcula uma imagem baseada em uma única imagem.

Image:

O objeto *image* do EIDORS expressa os valores de condutividade simulados ou reconstruídos. O *elem_data* ($N \times 1$) é o valor de cada um dos elementos da imagem no modelo dos elementos finitos (no campo *fwd_model*). Por exemplo, para um dado objeto *inv_model* de nome **imdl**, pode-se expressar a reconstrução de uma imagem por:

```
img = inv_solve(imdl, dado1, dado2);
```

De um modo análogo, a fim de simularmos um objeto **data** *datasim* de uma simulação de imagem *imgsim*, onde podemos escrever:

```
datasim=fwd_solve (fmdl, imgsim);
```

Neste artigo foi utilizado o software EIDORS para resolver dois diferentes problemas inerentes à técnica de TIE. O primeiro deles, é o problema direto, que está associado à solução da equação elíptica de difusão, considerando-se um domínio

limitado e simplesmente conexo $\Omega \in \mathbb{R}^n$, $n \geq 2$, com coeficientes variáveis, que governa a distribuição do potencial eletrostático em Ω é dada por:

$$\nabla \cdot (\sigma \nabla u) = 0. \quad (1)$$

Onde σ representa a condutividade elétrica [6]. Ao se resolver o problema direto lança-se mão do método dos elementos finitos (MEF) que busca linearizar as equações atribuindo-se valores a coeficientes desconhecidos e depois resolve-se um sistema de equações lineares a fim de se atualizarem os coeficientes [2]. Tirando proveito da funcionalidade do EIDORS de se adaptar às necessidades do pesquisador, fez-se modificações a fim de resolver o problema direto e gerar uma figura representativa da solução. O EIDORS faz uso de um pacote do MATLAB para gerar malhas bidimensionais, resolver o problema direto, através do método dos elementos finitos e exibir as imagens.

No presente trabalho foram geradas imagens de malhas bidimensionais para a solução de três modelos de problema direto, cujo domínio consiste de objetos que a impedância é considerada duas vezes maior que a impedância de fundo. As leituras do domínio foram realizadas segundo um padrão de estimulação por correntes alternadas externas através de 32 eletrodos dispostos de maneira regular e oposta na fronteira do domínio.

O segundo problema a ser tratado pelo EIDORS reside no cálculo do problema inverso, considerado um problema mal posto, dado que os potenciais no interior da estrutura de interesse dependem fortemente das impedâncias, além de erros de quantização, por meio do método dos elementos finitos, bem como aqueles associados às medições [5]. O problema inverso é resolvido de modo iterativo, por meio da minimização de uma função objetivo encontrando por fim uma equação atualizada da distribuição de resistividades [1]. O EIDORS usa um solucionador não linear regularizado, a fim de encontrar a única e estável solução para o problema inverso [5]. No presente artigo utilizou-se para a reconstrução das imagens o método iterativo de Gauss-Newton, estabelecendo uma aproximação do tipo *difference*, pelo método de Laplace.

2.3 Mapas Auto-Organizáveis de Kohonen

As redes de Kohonen tem inspiração neurofísica sendo baseadas em observações do funcionamento cerebral onde o aprendizado não supervisionado é predominante. Os mapas auto-organizáveis de Kohonen são analogias a forma lógica de organização das informações no cérebro [7] e sua principal utilização é agrupar as entradas que são semelhantes entre si formando classes ou agrupamentos denominados clusters [8]. Os mapas auto-organizáveis de Kohonen em geral podem ser unidimensionais ou bidimensionais e tem por base um aprendizado competitivo de forma que se faz necessário uma função objetivo para definir um neurônio vencedor. Uma das métricas mais utilizadas e que foi usada neste trabalho é a distância euclidiana entre as entradas (x_j) e o conjunto de pesos dos neurônios (w_{ij}) definida por:

$$d_{xw} = \sqrt{\sum_{j=1}^n (x_j - w_{ij})^2} \quad (2)$$

Definido o neurônio vencedor, seus pesos são ajustados de acordo com a forma de processo competitivo. Existem duas formas de processos competitivos: o vencedor leva tudo (winner take all) ou o vencedor leva parte (winner take quota). No primeiro, apenas os pesos do neurônio vencedor são ajustados. No segundo, os pesos dos neurônios vizinhos ao neurônio vencedor também são ajustados. A vizinhança do neurônio vencedor é estabelecida pela função de vizinhança das quais destaca-se a função gaussiana que cria uma região de vizinhança circular em torno do neurônio vencedor. No presente artigo utilizamos a forma de processo competitivo onde o neurônio vencedor leva tudo. Os pesos foram ajustados de acordo com a seguinte expressão:

$$w_{ij}^v(\text{novo}) = w_{ij}^v(\text{antigo}) + \alpha \cdot (x_j - w_{ij}^v(\text{antigo})) \quad (3)$$

Onde w_{ij}^v são os pesos sinápticos que ligam a entrada ao neurônio vencedor, α a taxa de aprendizagem e x_j são as entradas.

No presente artigo, a taxa de aprendizado α foi reduzida a cada iteração de forma a se conseguir ajustes cada vez mais finos e evitar que a rede ficasse presa em mínimos locais. A nova taxa de aprendizado foi calculada da seguinte forma:

$$\alpha(\text{novo}) = \alpha(\text{antigo}) \cdot 0,9 \quad (4)$$

2.4 Implementação

O código para clusterização e quantização de imagens de TIE reconstruídas com EIDORS foi elaborado em Matlab. Foram utilizados como parâmetros a taxa de aprendizado inicial (Tapini), o número de iterações (Nit) e o número de clusters (Nclusters) na saída do mapa auto-organizável de Kohonen.

Como entrada do Mapa Auto-Organizável de Kohonen, foram geradas, através do EIDORS, 03 imagens pelo Modelo Direto. As imagens simulam a existência de uma estrutura a ser detectada através dos eletrodos que se encontram dispostos sobre a fronteira da circunferência. A partir da reconstrução dessas imagens pelo EIDORS, foram geradas 03 imagens de testes

denominadas (3.1) Círculo Central, (3.2) Losango e (3.3) Tumor Maligno. A partir dessas imagens e com as variações dos parâmetros obtivemos os resultados que estão na próxima sessão.

3 Resultados

Adiante são apresentados os resultados da aplicação dos Mapas Auto Organizáveis de Kohonen em imagens reconstruídas pelo EIDORS..

3.1 Círculo Central




Figura 1 – (a) Círculo central simulado pelo EIDORS com 32 eletrodos (Modelo Direto). (b) Reconstrução da imagem (a) pelo EIDORS.

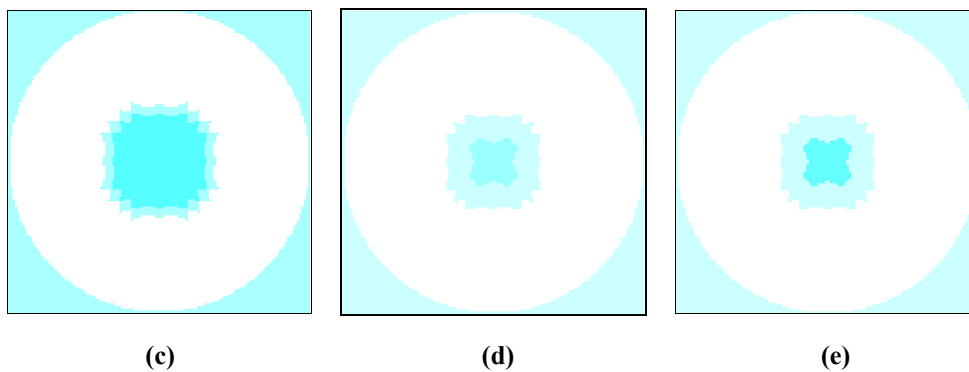


Figura 2 – Clusterização da Imagem (b) usando Mapas Auto Organizáveis de Kohonen. (c) clusters = 3; Tapini=0,9; Nit=150 (d) clusters = 5; Tapini=0,9; Nit=150 (e) clusters = 5; Tapini=0,9; Nit=200.




Figura 3 – Quantização da Imagem (b) usando Mapas Auto Organizáveis de Kohonen. (f) clusters = 3; Tapini=0,9; Nit=150 (g) clusters = 5; Tapini=0,9; Nit=150 (h) clusters = 5; Tapini=0,9; Nit=200.

3.2 Losango

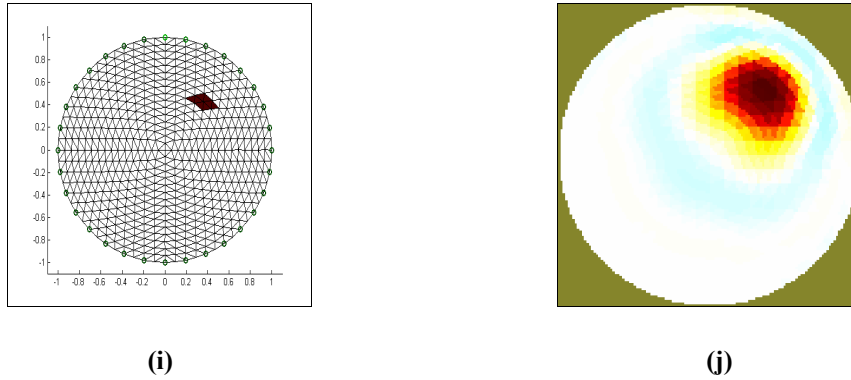


Figura 4 – (i) Losango simulado pelo EIDORS com 32 eletrodos (Modelo Direto). (j) Reconstrução da imagem (i) pelo EIDORS.

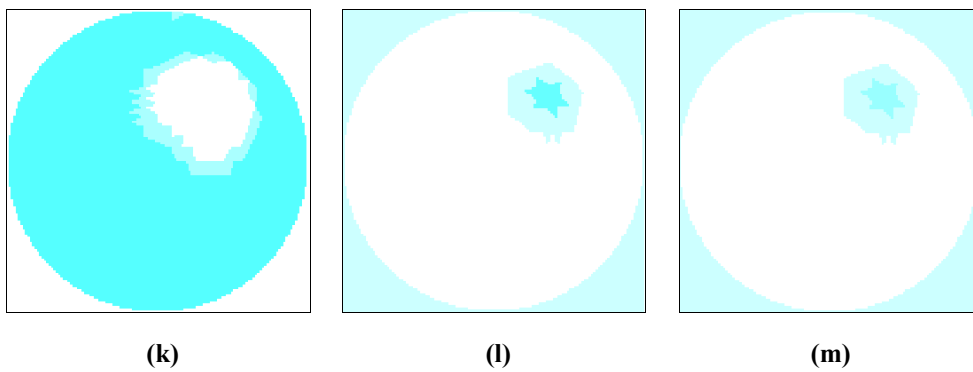


Figura 5 – Clusterização da Imagem (j) usando Mapas Auto Organizáveis de Kohonen. (k) clusters = 3; Tapini=0,9; Nit=150 (l) clusters = 5; Tapini=0,9; Nit=150 (m) clusters = 5; Tapini=0,9; Nit=200.




Figura 6 – Quantização da Imagem (j) usando Mapas Auto Organizáveis de Kohonen. (n) clusters = 3; Tapini=0,9; Nit=150 (o) clusters = 5; Tapini=0,9; Nit=150 (p) clusters = 5; Tapini=0,9; Nit=200.

3.2 Tumor Maligno




Figura 7 – (q) Losango simulado pelo EIDORS com 32 eletrodos (Modelo Direto). (r) Reconstrução da imagem (q) pelo EIDORS .




Figura 8 – Clusterização da Imagem (r) usando Mapas Auto Organizáveis de Kohonen. (s) clusters = 3; Tapini=0,9; Nit=150 (t) clusters = 5; Tapini=0,9; Nit=150 (u) clusters = 5; Tapini=0,9; Nit=200.




Figura6 – Quantização da Imagem (r) usando Mapas Auto Organizáveis de Kohonen. (v) clusters = 3; Tapini=0,9; Nit=150 (x) clusters = 5; Tapini=0,9; Nit=150 (y) clusters = 5; Tapini=0,9; Nit=200.

4 Conclusões

Os resultados apresentados mostram que a aplicação de Mapas Auto Organizáveis de Kohonen em imagens de tomografia por Impedância Elétrica reconstruídas pelo EIDORS geram imagens menos suaves com destaque para a região de interesse onde esta localizada a estrutura desejada. Verifica-se que com o código implementado e com uma taxa de aprendizado inicial da rede em 0,9, todas as estruturas das imagens de teste são quantizadas com o número de iterações igual a 150 e com a quantidade de clusters igual a 5. Durante os experimentos, não foram obtidas melhorias na clusterização e consequentemente na quantização a partir da redução do número de iterações, do aumento do número de clusters e do aumento do número de iterações.

Clinicamente, a aplicação de Mapas de Kohonen em imagens reconstruídas pelo EIDORS pode auxiliar o profissional da área médica visto que a imagem resultante pode ser classificada em regiões bem definidas reduzindo assim a região de pesquisa do profissional.

5 Referências Bibliográficas

- [1] A.D. Garnadi; D. Kurniadi. Two Dimensional Numerical Reconstruction of Electrical Impedance Tomography using Tikhonov Regularization Algorithms with a-posteriori parameter choice rule, IPB (Bogor Agricultural University), (2005).
- [2] W.R.B. Lionheart *et al*, Electrical Impedance and Diffuse Optical Tomography Reconstruction Software, Artigo, 1st World Congress on Industrial Process Tomography, Buxton, Greater Manchester, 14-17 de abril, (1999).
- [3] E.D. Holder, Part 1 of Electrical Impedance Tomography: Methods, History and Applications, p3-64, Institute of Physics Publishing, (2004).
- [4] A. Adler, W.R.B. Lionheart, Uses and abuses of EIDORS: an extensible software base for EIT, IOP Publishing Ltd, (2006).
- [5] R.W. Stacey, Electrical Impedance Tomography, Stanford Geothermal Program, Stanford University, (2006).
- [6] J. C. Z. Aguilar, N. M. Kuhl, Estudos numéricos do problema direto na tomografia por impedância elétrica, USP, (2007).
- [7] Taner, M Turham, Kohonen Self Organizing Networks with “Conscience”, Rock Solid Images, (1997).
- [8] S. Haykin, Neural Networks: A Comprehensive Foundation, Macmillian College Publishing Company, New York, (1994).