

RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA USANDO EXTREME LEARNING MACHINE DE REGRESSÃO

JULIANA CARNEIRO GOMES^{1*}, WELLINGTON PINHEIRO DOS SANTOS¹, RICARDO EMMANUEL DE SOUZA¹

¹DEPARTAMENTO DE ENGENHARIA BIOMÉDICA, UNIVERSIDADE FEDERAL DE PERNAMBUCO
RECIFE, PERNAMBUCO, BRASIL
E-MAIL: JUCARNEIROG@HOTMAIL.COM*

Abstract: Electrical Impedance Tomography (EIT) is an imaging technique through the measurement of electrical properties through electrodes positioned on the surface of a domain. Its main advantages are the portability, low cost and non-use of ionizing radiation. Despite this, it has not yet been strongly established due to its low reconstruction speed and low spatial resolution. The reconstruction of EIT images depends on the resolution of the direct and inverse problems. The direct problem consists in determining the electrical potentials within the section from those measured on the surface of the body. The inverse problem is the estimation of the conductivity distribution from the potentials measured at the boundary. This work proposes the use of Artificial Neural Networks (ANN) of the type of Extreme Learning Machine (ELM) of Regression to obtain sinograms from the electrical potential data. Later, it is proposed to reconstruct the sinograms using Backprojection algorithm to reconstruct EIT images.

Keywords: Electrical Impedance Tomography, Image Reconstruction algorithm, Backprojection, Artificial Neural Networks, Extreme Learning Machine.

Resumo: Tomografia por Impedância Elétrica (TIE) é uma técnica de imageamento mediante a medição de grandezas elétricas através de eletrodos posicionados na superfície de um domínio. Suas principais vantagens são a portabilidade, o baixo custo e a não utilização de radiação ionizante. Apesar disso, a mesma ainda não foi fortemente estabelecida devido à sua baixa velocidade de reconstrução e baixa resolução espacial. A reconstrução de imagens de TIE depende da resolução dos problemas direto e inverso. O problema direto consiste na determinação dos potenciais elétricos no interior da seção a partir dos medidos na superfície do corpo. O problema inverso consiste na estimação da distribuição de condutividades a partir dos potenciais medidos na fronteira. Este trabalho propõe a utilização de Redes Neurais Artificiais (RNA) do tipo *Extreme Learning Machine* (ELM) de Regressão para a obtenção de sinogramas a partir dos dados de potenciais elétricos. Posteriormente, propõe-se a reconstrução dos sinogramas utilizando algoritmo de *Backprojection* para reconstrução de imagens de TIE.

Palavras-chave: Tomografia por Impedância Elétrica, algoritmo de reconstrução de imagens, *Backprojection*, Redes Neurais Artificiais, *Extreme Learning Machine*.

1 Introdução

A Tomografia por Impedância Elétrica (TIE) é uma técnica de imagem do interior de uma seção do corpo através da medição de grandezas elétricas em sua superfície. Eletrodos são posicionados na mesma, e são responsáveis por enviar um estímulo, ou seja, uma corrente elétrica alternada (Tehrani et al., 2010), e por captar respostas, que são as diferenças de potenciais elétricos (Figura 1). A corrente elétrica injetada é alternada, evitando o risco de eletrólise nos pólos dos eletrodos (Bera et al., 2011), de baixa amplitude, cerca de 0,1 a 5mA a máxima corrente de pico (Holder & Institute of Physics, 2005), e alta frequência (em geral, entre 10kHz e 250kHz) (Singh et al., 2015). Dessa forma, as imagens de TIE são a reprodução computacional de um mapeamento estimado de condutividades ou permissividades elétricas do interior de um domínio. Pode-se entender condutividade como a medida da possibilidade do meio em permitir o deslocamento de cargas elétricas, enquanto a permissividade a medida da facilidade de cargas elétricas se separarem, ou seja, o material se polarizar, sob a presença de um campo elétrico aplicado.




Figura 1. Funcionamento básico da TIE: Eletrodos na superfície do domínio estimulam o corpo com uma corrente elétrica e simultaneamente captam potenciais elétricos, que são enviados para um sistema de controle e aquisição, permitindo uma posterior reconstrução das imagens (Barbosa, 2017).

A TIE é atualmente aplicada em diversas áreas do conhecimento: na geofísica, também conhecida como Tomografia por Resistividade Elétrica (Bouchette et al. 2014), pode ser usada na detecção de depósitos minerais e armazenamento subterrâneo de minerais (Cheney et al. 1999), por exemplo; na área industrial, como na detecção de vazamentos de tanques e estimação de taxa de parâmetros de fluxo (Jordana et al., 1999); na botânica, gerando imagens do interior de troncos de árvores (Filipowicz & Rymarczyk 2012), e na área médica. Dentre as aplicações médicas, pode-se citar aplicações na detecção de câncer de mama, no monitoramento de ventilação pulmonar imposta por ventilação mecânica, na medição de sangramento intracraniano (Dai et al. 2013) e no diagnóstico de câncer de próstata (Wan et al., 2013).

A técnica de TIE pode ser muito vantajosa, devido ao fato de não ser invasiva, ser segura e de baixo custo, quando comparada a outras técnicas de

imagens médicas como a Tomografia Computadorizada (CT) e a Ressonância Magnética Nuclear (RMN). Além disso, a TIE não utiliza radiação ionizante, que é prejudicial à saúde, e o seu equipamento possui dimensões reduzidas, podendo ser facilmente transportado para junto de um paciente que esteja em um leito, por exemplo (Tehrani et al. 2010; Pravin Kumar et al. 2010).

Apesar dos seus benefícios, a reconstrução de imagens de TIE consiste na resolução de um problema direto e de um problema inverso não linear e mal-posto. O primeiro consiste na determinação dos potenciais elétricos no interior da seção do corpo e dos medidos na borda tendo como base o padrão de corrente alternada aplicada, sendo essa relação dada pela Equação de Laplace. Por outro lado, o problema inverso busca estimar a distribuição de condutividade e permissividade elétrica do interior do domínio, não sendo única para um determinado conjunto de potenciais elétricos. A solução do problema pode ser instável, apresentando grande sensibilidade a erros numéricos e com os potenciais elétricos variando de forma não-linear com a corrente de excitação. Assim, a TIE é uma técnica que não foi fortemente estabelecida devido à sua baixa velocidade de reconstrução e baixa resolução espacial (Tehrani et al. 2010; Pravin Kumar et al. 2010).

Desse modo, diversos métodos tem sido estudados e aplicados buscando solucionar esses problemas. Uma das formas de reconstrução é através de métodos iterativos de otimização. Diversos trabalhos como (Barbosa, 2017; Feitosa et al. 2014; Martins et al., 2012), por exemplo, tem se inspirado em algoritmos evolucionários e bioinspirados da Inteligência Computacional. Em outro estudo (Hongbin Wang et al., 2015), por outro lado, foi proposto um método baseado no algoritmo linear do *Backprojection*: o *Generalized Backprojection Algorithm* (GBPA). Neste caso, diferentemente do algoritmo de *Backprojection* original, considera-se o meio como anisotrópico, ou seja, que as propriedades físicas do meio variam com a direção. Ao fazer essa consideração, o método proposto aproxima o meio imageado às condições biológicas e médicas. Outros métodos de reconstrução de TIE tem se baseado no uso de Redes Neurais Artificiais (RNA), onde diversos trabalhos (Hamilton et al., 2017; Martin et al., 2016) tem proposto o uso das mesmas para a resolução do problema inverso.

Diante do exposto, este presente trabalho, visa propor um método ainda não descrito na literatura para a reconstrução de imagens de TIE, como simplificado na Figura 2. Tendo em vista a tendência do uso da inteligência artificial, em especial de RNAs em diversos estudos, bem como o sucesso do emprego do algoritmo de *Backprojection* na reconstrução de imagens, sugere-se a utilização inovadora de RNAs do tipo Máquinas de aprendizado extremo (*Extreme Learning Machine – ELM*) de Regressão para a obtenção de sinogramas a partir dos dados de diferenças de potenciais elétricos medidos na superfície do domínio estudado. Posteriormente,

deseja-se reconstruir os sinogramas com o algoritmo de Retroprojeção (*Backprojection*) para a geração de imagens de TIE.




Figura 2. O método proposto visa a obtenção de imagens de TIE a partir de diferenças de potenciais elétricos medidas na superfície do domínio.

1.1 Organização do trabalho

Este trabalho está organizado na forma que se segue: na seção de “Materiais e Métodos”, apresentam-se as informações necessárias para um bom entendimento deste trabalho bem como os “Métodos e experimentos propostos”. Em seguida, a seção de “Resultados e discussões” e comentários adicionais estão presentes na seção de “Conclusão”.

2 Materiais e Métodos

2.1 Fundamentação teórica

• Tomografia por Impedância Elétrica

A técnica de TIE consiste na solução dos problemas direto e inverso (Tehrani et al. 2010; Pravin Kumar et al. 2010). Do ponto de vista matemático, o problema de TIE é determinado pela Equação de Poisson (1):

$$\nabla \cdot [\sigma(\vec{u}) \nabla \phi(\vec{u})] = 0, \quad \forall \vec{u} \in \Omega \quad (1)$$

Com as condições de contorno:

$$\phi_{ext}(\vec{u}) = \phi(\vec{u}), \quad \forall \vec{u} \in \partial\Omega \quad (2)$$

$$I(\vec{u}) = -\sigma(\vec{u}) \nabla \phi(\vec{u}) \cdot \hat{n}(\vec{u}), \quad \forall \vec{u} \in \partial\Omega \quad (3)$$

Onde $u = (x, y, z)$ é a posição do objeto, $\phi(\vec{u})$ a distribuição de potenciais no interior do domínio, $\phi_{ext}(\vec{u})$ a distribuição de potenciais na borda, $I(\vec{u})$ a corrente elétrica de excitação, $\sigma(\vec{u})$ a distribuição de condutividade elétrica ou a imagem a ser encontrada, Ω o domínio, $\partial\Omega$ a borda e $\hat{n}(\vec{u})$ o vetor normal à borda. (Pinheiro dos Santos et al. 2017)

No problema direto, por sua vez, são determinados os potenciais elétricos na superfície do domínio em estudo, tendo como modelo matemático a relação a seguir:

$$\phi_{ext}(\vec{u}) = f(I(\vec{u}), \sigma(\vec{u})), \quad \forall \vec{u} \in \partial\Omega \wedge \vec{u} \in \partial \quad (4)$$

Com as condições de contorno:

$$\sigma \frac{\partial \phi}{\partial \hat{n}} = J \quad (5)$$

Onde J é a densidade de corrente elétrica (Ogawa et al, 2017).

- **Reconstrução de imagens utilizando Backprojection**

O método de retroprojeção (*Backprojection*) é um método somatório simples e rápido, comumente utilizado em reconstruções de imagens de CT, onde projeções de diversos ângulos são somadas. Em CT, cada projeção representa a soma de coeficientes de atenuação do objeto irradiado ao longo de um determinado ângulo (Figura 3).




Figura 3. Geração de Sinogramas a partir de projeções do objeto obtidas com a técnica de Tomografia Computadorizada em diversas angulações (Hsieh et al., 2009).

No caso de TIE, tem-se os ângulos definidos pela quantidade de eletrodos na superfície do domínio e cada projeção representa a soma de condutividades ou resistividades. Há diversas formas de representar essas projeções, sendo os sinogramas a forma mais conhecida e usada. Os mesmos consistem de uma coleção de projeções de uma única fatia ou plano organizadas em uma matriz. Por fim, pode-se facilmente utilizar o algoritmo de retroprojeção para obtenção de imagens tomográficas a partir de sinogramas (Guardo et al. 1991; Hsieh et al., 2009).

- **Redes Neurais Artificiais**

Com inspiração no funcionamento do cérebro humano, as Redes Neurais Artificiais são máquinas baseadas no paralelismo, que buscam modelar a forma como respondemos a determinadas funções, podendo ser lineares ou não-lineares. As mesmas se baseiam na ideia de processo de aprendizagem a partir da observação do meio e na conexão neuronal para armazenamento dessas informações. Ou seja, receptores recebem estímulos do ambiente, que são enviados às RNAs. As mesmas processam as informações e acionam atuadores, que são responsáveis pela geração de uma resposta. Esse sistema possui ainda realimentação, indicada pelas setas no sentido oposto (Figura 4) (Haykin & Engel 2001).

As Redes Neurais Artificiais são constituídas por unidades básicas de processamentos, os neurônios, análogos aos neurônios biológicos. As unidades responsáveis pelas interações entre neurônios são as sinapses. Em um cérebro adulto, a criação e modificação dessas comunicações conferem ao mesmo plasticidade, o que significa que o cérebro é capaz de se adaptar ao meio ambiente. De maneira similar, o processo de aprendizagem nas RNAs se dá através da modificação dos pesos sinápticos da rede, buscando maior aproximação com os objetivos desejados. Além disso, dependendo da forma como a rede aprende, a mesma pode ser classificada como

supervisionada, quando se tem a presença de um professor, ou não-supervisionada (Haykin & Engel 2001).

Dessa forma, devido à sua habilidade de aprender, as RNAs são capazes de generalizar, fornecendo respostas apropriadas até para situações que não foram apresentadas anteriormente no processo de treinamento ou no algoritmo de aprendizagem, tornando possível a resolução de problemas complexos. Além disso, se o ambiente em que a rede está presente sofrer modificações, a mesma é capaz de se adaptar, sendo retreinada ou ainda sendo projetada para fazer o mesmo em tempo real (Haykin & Engel 2001).



Figura 4. Diagrama de blocos do funcionamento do processo de aprendizagem de uma Rede Neural Artificial (Elaborado pela autora).

- **Extreme Learning Machine**

Uma rede neural que tem sido muito utilizada é a Máquina de aprendizado extremo (ELM – *Extreme Learning Machine*). A mesma trata-se de uma rede supervisionada e de única camada oculta que pode ser aplicada em problemas tanto de classificação quanto de regressão. É conhecida pela sua velocidade, menor complexidade computacional e boa capacidade de generalização. Além disso, todas as funções contínuas podem ser usadas como função de ativação. Assim, uma rede de camada única pode ser modelada como

$$\sum_{i=1}^{\tilde{N}} \beta_i f(w_i x_j + b_i) = t_i, \quad j \in [1, N] \quad (6)$$

onde N constitui um conjunto de amostras (x_i, t_i) , $\tilde{N}$ o número de neurônios da camada escondida, $f(x)$ a função de ativação, w_i os pesos de entrada, b_i o bias, β_i os pesos de saída e t_i a saída desejada.

Dessa forma, os pesos de entrada da camada oculta são determinados aleatoriamente e independentemente do conjunto de treinamento (Figura 5). Por outro lado, os pesos de saída podem ser determinados analiticamente através da equação (6), que pode ser escrita de forma mais compacta como $H\beta = T$, onde

$$H = \begin{pmatrix} f(w_1 x_1 + b_1) & \cdots & f(w_{\tilde{N}} x_1 + b_{\tilde{N}}) \\ \vdots & \ddots & \vdots \\ f(w_1 x_N + b_1) & \cdots & f(w_{\tilde{N}} x_N + b_{\tilde{N}}) \end{pmatrix} \quad (7)$$

$$T = [t_1, \dots, t_N]^T \quad (8)$$

$$\beta = (\beta_1^T \dots \beta_{\tilde{N}}^T) \quad (9)$$




Figura 5: Diagrama de fluxos do cálculo dos pesos de saída de uma ELM (Elaborado pela autora). Os pesos de entrada são aleatórios, enquanto os pesos de saída são determinados analiticamente.

Dessa forma, através de uma operação simples de inversa generalizada das matrizes de saída da camada oculta, pode-se obter o menor erro de treinamento e a menor norma de pesos dentre as soluções possíveis da equação (Huang et al. 2006; Guang-Bin Huang et al. 2012; Li et al. 2017; Lei et al. 2018).

Algoritmo ELM: Dado um conjunto de treinamento $\mathcal{N} = \{(x_i, t_i) | x_i \in R^n, t_i \in R^m, i = 1, \dots, N\}$, uma função de ativação $f(x)$, e $\tilde{N}$ neurônios escondidos,

1. Passo 1: Estabelecer randomicamente pesos de entrada w_i e um bias b_i , $i = 1, \dots, N$.
2. Passo 2: Calcular a matriz de saída da camada escondida H .
3. Passo 3: Calcular os pesos de saída β . Assim, $\beta = H^\dagger T$, onde $H^\dagger$ é a matriz inversa generalizada de Moore-Penrose da matriz H ($H^\dagger = (H^T H)^{-1} H^T$) (Guang-Bin Huang et al. 2012).

2.2 Infraestrutura experimental

• GNU/ Octave

GNU/Octave é um software livre, com linguagem em sua maioria compatível com o Matlab, tendo sido desenvolvido para computação matemática. Possui ainda uma interface de linha de comando para a resolução de problemas e experimentos.

2.3 Métodos e experimentos propostos

O presente trabalho propõe um método inovador para obtenção de sinogramas a partir dos dados de diferenças de potenciais elétricos obtidos na superfície do domínio em estudo. Para isso, deseja-se treinar ELMs de Regressão para encontrar uma função que modele os dados. Em seguida, os sinogramas poderão ser utilizados para a reconstrução de imagens de TIE através do método de reconstrução por Retroprojeção (Figura 6).




Figura 6. As informações dos Potenciais elétricos do domínio podem ser organizadas em sinogramas utilizando ELMs. A partir dos sinogramas, imagens de TIE podem ser reconstruídas por *Backprojection*.

Com o objetivo de treinar e testar as ELMs, desenvolveu-se um código em Octave para geração de um banco de imagens sintéticas (128x128) de TIE.

As imagens são em escala de cinza, tendo como entrada no código o número de objetos em forma de círculos e elipses, de forma a representar as estruturas no interior do domínio a serem imageadas (Figura 7a). O programa gera os objetos com raios, posições e intensidades aleatórias e as intensidades dos pixels representam diferentes valores de condutividade. Os valores, porém, serão posteriormente dimensionados baseados na estimativa de condutividades e permissividades dos órgãos e tecidos humanos (Tabela 1). Assim, as imagens geradas possuem entre dois e seis objetos aleatórios no interior do fantoma sintético. Por fim, além de gerar as imagens, o código também posiciona os eletrodos, sendo sua quantidade determinada pelo usuário. Para a realização de testes preliminares, imagens com 16 eletrodos serão consideradas, utilizando um banco de dados com 100 imagens.

Visando obter as diferenças de potenciais elétricos entre os eletrodos posicionados na superfície do domínio, o negativo das imagens foram gerados (Figura 7b), de forma que as intensidades dos pixels representassem as resistividades dos objetos e do meio. Assim, para a determinação dos potenciais, foi simplificado e aproximado o caminho percorrido pela corrente elétrica como em linha reta, apesar de na prática a mesma procurar locais de menor resistência.

Tabela 1. Valores típicos de condutividade de tecidos humanos. (Pinheiro dos Santos et al, 2017)

TECIDO	CONDUTIVIDADE (mS/cm)
SANGUE	6.79
FÍGADO	2.8
MÚSCULO – LONGITUDINAL	8
MÚSCULO – TRANSVERSAL	0.6
MÚSCULO CARDÍACO – LONG	6.3
MÚSCULO CARDÍACO – TRANS	2.3
TECIDO NERVOSO	1.7
PULMÃO – EXPIRAÇÃO	1
PULMÃO – INSPIRAÇÃO	0.4
GORDURA	0.36
OSSO	0.06

O programa ainda tem como objetivo a geração de sinogramas (16x128) das imagens sintéticas e a reconstrução das imagens por *Backprojection* (Figura 7c), que servirão posteriormente como imagens de referência. Os sinogramas são construídos através da soma dos pixels em 16 diferentes posições, correspondentes ao número de eletrodos.




Figura 7. Imagem sintética de TIE gerada no Octave (a), Negativo da imagem original (b) e Reconstrução por *Backprojection* (c).

Por fim, as informações obtidas permitem a geração de arquivos no formato .ARFF para a realização de treinamentos e testes de ELM de

Regressão. Para isso, separou-se os potenciais medidos e os sinogramas de cada eletrodo correspondente a cada imagem, gerando, assim, 16 arquivos .ARFF, organizados da forma que se segue (Figura 8). Em seguida, utilizou-se a ELM proposta por (Huang et al. 2006) na versão para Matlab/Octave.

$$\begin{bmatrix} V_{1,1} & \cdots & V_{1,240} & S_{1,1} & \cdots & S_{1,128} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ V_{4000,1} & \cdots & V_{4000,240} & S_{4000,1} & \cdots & S_{4000,128} \end{bmatrix}$$

Figura 8. Organização das entradas e saídas dos arquivos .ARFF

3 Resultados e discussões

Com o intuito de buscar a melhor configuração da RNA, ou seja, o número adequado de neurônios da camada escondida, assim como a função de ativação que melhor modela os dados, as ELMs foram treinadas com o método de amostragem e validação de algoritmo *Percentage Split* de 66%. Em outras palavras, 2/3 da amostra foi utilizada no treinamento das RNAs, enquanto 1/3 da mesma foi utilizada para realização de testes ou medidas de acurácia. Assim, essas medições permitem selecionar configurações de ELMs com menor erro possível. Escolheu-se como função de ativação a função Sigmoidal para a realização desses testes iniciais, variando o número de neurônios da camada escondida entre 50 e 500, com passos de 50, onde para cada configuração foram realizados 30 treinamentos diferentes. Por fim, a acurácia dos testes são determinadas pelo cálculo do Erro Médio Quadrático (*Root Mean Square Error – RMSE*)

Os resultados desses testes podem ser observados no *boxplot* da Figura 8. Ao analisar o gráfico, fica clara uma maior dispersão e menor simetria dos dados para um menor número de neurônios. Além disso, percebe-se que os menores Erros Médio Quadráticos encontram-se para testes com 500 neurônios na camada escondida e, dessa forma, pode-se dizer que esse valor consiste de um forte candidato para realização de treinamentos das ELMs de regressão.

Então, utilizando a função Sigmoidal e 500 neurônios na camada escondida, os sinogramas das 100 imagens foram gerados e em seguida reconstruídos por *Backprojection*. Uma síntese desses resultados preliminares é apresentada na Figura 9 a seguir.

Por fim, observa-se que as reconstruções demonstradas apresentaram consistência em relação às imagens de referência. Percebe-se que os domínios foram bem demarcados na reconstrução e os objetos interiores aos mesmos localizaram-se em posições correspondentes, sendo os de maior intensidade mais facilmente identificados. Apesar disso, as bordas dos mesmos não puderam ser distinguidas.




Figura 9. Imagens originais com objetos interiores aleatórios (a) e Reconstruções por *Backprojection* dos sinogramas gerados pelas ELMs (b).

4 Conclusão

A Tomografia por Impedância Elétrica é uma técnica promissora, que poderá acompanhar outras técnicas atuais para diagnósticos médicos mais precisos. Assim, a implementação de métodos de reconstrução rápidos e eficientes é necessária.

A utilização de Redes Neurais Artificiais, em especial ELMs de Regressão, bem como a reconstrução com algoritmo de *Backprojection* tem mostrado um potencial interessante para a obtenção de imagens de TIE.




Figura 8. *Boxplot* dos Erros Médio Quadráticos obtidos nos testes realizados após os treinamentos das ELMs de Regressão.

Em testes futuros, deverão ser consideradas outras funções de ativação nas ELMs, bem como outros valores de *Percentage Split* da amostra de treinamento, por exemplo 75%, e, ainda, *Cross-Validation* com 10 *folds*. Uma base de dados com mais imagens também deverá ser considerada no processo de treinamento e testes. Finalmente, poderá ser feita uma análise quantitativa das imagens e poderá se ter uma configuração mais adequada para reconstrução de imagens de TIE mais próximas com o desejado.

Acredita-se que o presente método proposto será capaz de reduzir o tempo de reconstrução de imagens de TIE, devido principalmente à alta velocidade das Máquinas de Aprendizado Extremo (ELM), obtendo imagens razoáveis e consistentes. Além disso, será construída uma ferramenta computacional em código aberto para reconstrução de imagens de TIE utilizando a abordagem proposta. Dessa forma, o método é promissor e pode proporcionar um grande desenvolvimento da TIE.

Agradecimentos

Os autores agradecem às agências de fomento à pesquisa CAPES e FACEPE pelo financiamento parcial desta pesquisa.

Referências

- Barbosa, V., (2017). *Reconstrução de imagens de Tomografia por Impedância Elétrica Utilizando Busca por Cardumes de Peixes e Evolução Diferencial*. Universidade Federal de Pernambuco.
- Bera, T.K. et al., (2011). Improving image quality in Electrical Impedance Tomography (EIT) using Projection Error Propagation-based Regularization (PEPR) technique: A simulation study. *Journal of Electrical Bioimpedance*, 2(1), pp.2–12.
- Bouchette, G. et al., (2014). Imaging of Compact Objects Buried in Underwater Sediments Using Electrical Impedance Tomography. *IEEE Transactions on Geoscience and Remote Sensing*, 52(2), pp.1407–1417.
- de Castro Martins, T. & de Sales Guerra Tsuzuki, M., (2012). Electrical impedance tomography reconstruction through simulated annealing with total least square error as objective function. In *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, pp. 1518–1521.
- Cheney, M., Isaacson, D. & Newell, J.C., (1999). Electrical Impedance Tomography. *SIAM Review*, 41(1), pp.85–101.
- Dai, M. et al., (2013). In Vivo Imaging of Twist Drill Drainage for Subdural Hematoma: A Clinical Feasibility Study on Electrical Impedance Tomography for Measuring Intracranial Bleeding in Humans B. Rubinsky, ed. *PLoS ONE*, 8(1), p.e55020.
- Feitosa, A.R.S. et al., (2014). Reconstruction of electrical impedance tomography images using particle swarm optimization, genetic algorithms and non-blind search. In *5th ISSNIP-IEEE Biosignals and Biorobotics Conference (2014): Biosignals and Robotics for Better and Safer Living (BRC)*. IEEE, pp. 1–6.
- Filipowicz, S.F. & Rymarczyk, T., (2012). Measurement Methods and Image Reconstruction in Electrical Impedance Tomography. *PRZEGLĄD ELEKTROTECHNICZNY (Electrical Review)*.
- Guang-Bin Huang et al., (2012). Extreme Learning Machine for Regression and Multiclass Classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42(2), pp.513–529.
- Guardo, R. et al., (1991). An experimental study in electrical impedance tomography using backprojection reconstruction. *IEEE transactions on bio-medical engineering*, 38(7), pp.617–27.
- Hamilton, S.J. & Hauptmann, A., (2017). Deep D-bar: Real time Electrical Impedance Tomography Imaging with Deep Neural Networks.
- Haykin, S. & Engel, P.M., (2001). *Redes neurais : princípios e prática*, Bookman.
- Holder, D. & Institute of Physics (Great Britain), (2005). *Electrical impedance tomography : methods, history, and applications*, Institute of Physics Pub.
- Hongbin Wang et al., (2015). An Implementation of Generalized Back Projection Algorithm for the 2-D Anisotropic EIT Problem. *IEEE Transactions on Magnetics*, 51(3), pp.1–4.
- Hsieh, J. & SPIE (Society), (2009). *Computed tomography : principles, design, artifacts, and recent advances*, Wiley Interscience.
- Huang, G.-B., Zhu, Q.-Y. & Siew, C.-K., (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1–3), pp.489–501.
- Jordana, J., Gasulla, M. & Pallás-Areny, R., (1999). Leakage Detection in Buried Pipes by Electrical Resistance Imaging. 1st World Congress on Industrial Process Tomography.
- Lei, J. et al., (2018). Data-driven reconstruction method for electrical capacitance tomography. *Neurocomputing*, 273, pp.333–345.
- Li, Q. et al., (2017). Ferrography Wear Particles Image Recognition Based on Extreme

- Learning Machine. *Journal of Electrical and Computer Engineering*, 2017, pp.1–6.
- Martin, S. & Choi, C.T.M., (2016). Nonlinear Electrical Impedance Tomography Reconstruction Using Artificial Neural Networks and Particle Swarm Optimization. *IEEE Transactions on Magnetics*, 52(3), pp.1–4.
- Martin, S. & Choi, C.T.M., (2016). On the influence of spread constant in radial basis networks for electrical impedance tomography. *Physiological Measurement*, 37(6), pp.801–819.
- Ogava, R. Gomes, J., Soares, N., Barbosa, V., dos Santos, W., de Souza, R., Ribeiro, R. e Ribeiro, D. (2017). Algoritmo de Evolução Diferencial hibridizado e Simulated Annealing aplicados a Tomografia por Impedância Elétrica. In: I Simpósio de inovação em Engenharia Biomédica (SABIO).
- Pinheiro dos Santos, W. de Souza, R., Ribeiro, R., Feitosa, A., Barbosa, V., da Silva, V. Ribeiro, D. e de Freitas, R. (2017). Electrical Impedance Tomography Using Evolutionary Computing: A Review. In: Acharhya e V. Santhi, ed., *Bio-inspired computing for Image and video processing*, 1st ed. Boca Raton: CRC Press, pp.93-128.
- Pravin Kumar, S. et al., (2010). Reconstruction of brain electrical impedance tomography images using particle swarm optimization. In *2010 5th International Conference on Industrial and Information Systems*. IEEE, pp. 339–342.
- Singh, G. et al., (2015). Development of a microcontroller based electrical impedance tomography system. In *2015 Long Island*.