



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

JULIANA CARNEIRO GOMES

**RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA
USANDO MÁQUINAS DE APRENDIZADO EXTREMO E ALGORITMOS DE
RETROPROJEÇÃO**

Recife

2019

JULIANA CARNEIRO GOMES

**RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA
USANDO MÁQUINAS DE APRENDIZADO EXTREMO E ALGORITMOS DE
RETROPROJEÇÃO**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Biomédica do Centro de Tecnologia e Geociências da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Mestre em Engenharia Biomédica.

Área de concentração: Computação Biomédica.

Orientador: Prof. Dr. Ricardo Emmanuel de Souza.

Coorientador: Prof. Dr. Wellington Pinheiro dos Santos.

Recife

2019

Catálogo na fonte
Bibliotecária Margareth Malta, CRB-4 / 1198

G633r Gomes, Juliana Carneiro.
Reconstrução de imagens de tomografia por impedância elétrica usando máquinas de aprendizado extremo e algoritmos de retroprojeção / Juliana Carneiro Gomes. - 2019.
109 folhas, figs., gráfs. tab.

Orientador: Prof. Dr. Ricardo Emmanuel de Souza.
Coorientador: Prof. Dr. Wellington Pinheiro dos Santos.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Biomédica, 2019.
Inclui Referências e Apêndices.

1. Engenharia Biomédica. 2. Tomografia por impedância elétrica. 3. Reconstrução de imagens. 4. Inteligência artificial. 5. Máquina de aprendizado extremo. 6. Algoritmo de retroprojeção. I. Souza, Ricardo Emmanuel de. (Orientador). II. Santos, Wellington Pinheiro dos. (Coorientador). III. Título.

UFPE

610.28 CDD (22. ed.)

BCTG/2019-188

JULIANA CARNEIRO GOMES

**RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA
USANDO MÁQUINAS DE APRENDIZADO EXTREMO E ALGORITMOS DE
RETROPROJEÇÃO**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Biomédica do Centro de Tecnologia e Geociências da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Mestre em Engenharia Biomédica.

Aprovada em: 22 de fevereiro de 2019.

Prof. Dr. Ricardo Emmanuel de Souza (Orientador)
Universidade Federal de Pernambuco

Prof. Dr. Wellington Pinheiro dos Santos (Coorientador)
Universidade Federal de Pernambuco

Prof. Dr. Ricardo Yara (Examinador interno)
Universidade Federal de Pernambuco

Prof. Dr. Washington Wagner Azevedo da Silva (Examinador externo)
Universidade Federal de Pernambuco

Recife
2019

À minha família, minha grande incentivadora.

AGRADECIMENTOS

Agradeço primeiramente ao Senhor Deus, o criador dos céus e da terra e detentor de toda sabedoria, à quem toda honra deste trabalho é devida.

Agradeço a minha família — meus pais e minha irmã Gabriela Gomes — por sempre caminhar lado a lado comigo desde pequena, participando da minha educação nos mínimos detalhes e me ensinando os valores mais preciosos desta vida.

Agradeço ao meu namorado Júlio Cassemiro, meu amor, pelo cuidado, compreensão e incentivo para ir adiante, muitas vezes acreditando em mim muito mais do que eu mesma.

Agradeço ao meu orientador Ricardo Emmanuel e ao meu coorientador Wellington P. dos Santos, pelos seus ensinamentos, muito além da teoria e da sala de aula. Agradeço por toda paciência, disponibilidade, e por nunca se negarem a dividir os conhecimentos comigo.

Agradeço ao Departamento de Engenharia Biomédica, aos secretários Rangel e Juliana, pela sempre disposição para me ajudar a solucionar as burocracias.

Agradeço aos meus colegas de mestrado, amigos, pesquisadores e professores, por toda parceria e compartilhamento, contribuindo nas diversas formas para a minha formação. Em especial, meus agradecimentos a Maíra Santana e Amanda Rodrigues, amigas que o mestrado me deu, parceiras que sempre pude contar.

Agradeço às minhas amigas e primas, especialmente na pessoa de Amanda Carneiro, Laís Carneiro e Laís Santos, e ao grupo de meninas da Primeira Igreja Presbiteriana do Recife, por ouvirem minhas queixas tantas vezes, por orarem por mim e me darem suporte emocional.

Agradeço à CAPES pelo apoio financeiro para realização desta pesquisa.

A todos vocês, todo o meu carinho e gratidão.

RESUMO

A Tomografia por Impedância Elétrica (TIE) é uma técnica de imageamento baseada na aplicação de uma corrente elétrica alternada em eletrodos posicionados na superfície do domínio, também responsáveis pela medição do potencial elétrico resultante. As principais vantagens da TIE são a portabilidade, o baixo custo associado e a não utilização da radiação ionizante. A reconstrução de suas imagens depende da resolução dos problemas direto e inverso, sendo o último um problema não linear e mal-posto. Por isso, diversos métodos de reconstrução têm sido desenvolvidos. Neste trabalho é proposta uma nova abordagem: o uso de Redes Artificiais Neurais de pesos aleatórios, especialmente Máquinas de aprendizado extremo (ELM), para aproximar sinogramas a partir de dados de potenciais elétricos e, assim, utilizar o algoritmo clássico de Retroprojeção para reconstrução da imagem. O banco de imagens sintéticas de TIE e suas reconstruções foram implementados em ambiente de GNU/Octave e as ELMs foram treinadas com 4000 imagens. De forma qualitativa, as imagens reconstruídas com as ELMs foram comparadas com as imagens originais e com as reconstruções a partir da direta aplicação do algoritmo de Retroprojeção, apresentando alta similaridade neste último caso. Os resultados também foram analisados quantitativamente com o Índice de Similaridade Estrutural e com a Relação Sinal-Ruído de pico, comprovando a consistência dos resultados.

Palavras-chave: Tomografia por impedância elétrica. Reconstrução de imagens. Inteligência artificial. Máquina de aprendizado extremo. Algoritmo de retroprojeção.

ABSTRACT

Electrical Impedance Tomography (EIT) is an image technique based on the application of an alternating electrical current on electrodes placed on the surface of the domain, which are also responsible for measuring the resulting electrical potentials. EIT main advantages are portability, low cost and non-use of ionizing radiation. EIT image reconstruction depends on the resolution of the direct and inverse problems, which is non-linear and ill-posed. Thereby, several reconstruction methods have been developed. In this work we propose a new approach: the use of random-weighted neural networks, specially Extreme Learning Machines (ELM), to approximate sinograms from electrical potential data and, therefore, use the classical Backprojection algorithm for image reconstruction. The synthetic images data and all reconstructions were implemented in GNU/Octave environment, and ELMs were trained with 4000 images. Qualitatively, reconstructed images with ELMs were compared with original images and with reconstructions from direct application of Backprojection algorithm, showing high similarity in the last case. Results were also analyzed quantitatively with Structural Similarity Index Results and Peak Signal-to-noise ratio, proving the consistency of the results.

Keywords: Electrical impedance tomography. Image reconstruction. Artificial intelligence. Extreme learning machine. Backprojection algorithm.

LISTA DE FIGURAS

Figura 1 – Esquemático do funcionamento básico da Tomografia por impedância elétrica	18
Figura 2 – Tomógrafo por Impedância Elétrica para monitoramento pulmonar desenvolvido pela Timpel	19
Figura 3 – Esquema dos problemas direto e inverso	19
Figura 4 – Variação da condutividade em relação à frequência	23
Figura 5 – Domínio da TIE	24
Figura 6 – Aplicação da TIE para detectar objetos enterrados em sedimentos . . .	25
Figura 7 – Utilização da TIE para examinar estruturas em construções civis	26
Figura 8 – Aplicação da TIE para detecção do câncer de mama	27
Figura 9 – Aplicação da TIE para hematomas subdurais	27
Figura 10 – A visualização de objetos opacos em diferentes ângulos permite a predição da sua estrutura interna	29
Figura 11 – Funcionamento do algoritmo de Retroprojeção e representação em Sinogramas	30
Figura 12 – Distribuição de técnicas de inteligência computacional utilizadas no contexto de imagens médicas	32
Figura 13 – Funcionamento básico das Redes Neurais Artificiais	32
Figura 14 – Estrutura do neurônio biológico	33
Figura 15 – Modelo de um neurônio artificial	33
Figura 16 – Comparação entre o neurônio artificial e o biológico	34
Figura 17 – Modelo de Máquina de aprendizado extremo para este trabalho	37
Figura 18 – Metodologia geral do trabalho	47
Figura 19 – Método de reconstrução de imagens proposto	48
Figura 20 – Imagens sintéticas de TIE originais (a) e negativas (b)	49
Figura 21 – Reconstruções padrão ouro das imagens de TIE usando <i>Backprojection</i> a partir dos Sinogramas padrão ouro	50
Figura 22 – Organização dos arquivos .ARFF	50
Figura 23 – Comparação entre diferentes funções contínuas de ativação	52
Figura 24 – Comparação entre as melhores funções contínuas de ativação	52
Figura 25 – Função de ativação contínua Sigmoidal	54
Figura 26 – Comparação das imagens e reconstruções padrão ouro com as reconstruções realizadas com o método proposto a partir do conjunto de treino	55
Figura 27 – Representação das reconstruções do conjunto de treino em pseudocores	55
Figura 28 – Comparação das imagens e reconstruções padrão ouro com as reconstruções realizadas com o método proposto a partir do conjunto de teste	56

Figura 29 – Representação das reconstruções do conjunto de treino em pseudocores	56
Figura 30 – Boxplots do PNSR e SSIM	58

LISTA DE TABELAS

Tabela 1 – Teor de água de vários tecidos e órgãos humanos	23
Tabela 2 – Pseudocódigo: Algoritmo da ELM	37
Tabela 3 – Resumo dos trabalhos relacionados	45
Tabela 4 – Valores comparativos de resistividade de diferentes tecidos humanos . .	49
Tabela 5 – Funções de ativação utilizadas no Teste piloto	51
Tabela 6 – Configurações de Kernel utilizados no Teste Piloto	51
Tabela 7 – Contribuições geradas pelos resultados parciais desta pesquisa	62

LISTA DE ABREVIATURAS E SIGLAS

ARFF	<i>Attribute Relation File Format</i>
ANN	<i>Artificial Neural Networks</i>
BEM	<i>Boundary Element Method</i>
CG	<i>Conjugate gradient</i>
CS	<i>Compressive sensing</i>
CT	Tomografia computadorizada
dB	Decibéis
EIDORS	<i>Electrical Impedance Tomography and Diffuse Optical Tomography Reconstruction Software</i>
EM	<i>Expectation Maximization</i>
ELM	<i>Extreme Learning Machine</i>
FSS	<i>Fish School Search</i>
GBPA	<i>Generalized Backprojection Algorithm</i>
HR	<i>High resolution</i>
IA	Inteligência artificial
IGN	<i>Improved Gauss-Newton</i>
IHR	Imagens intermediárias HR
IM	Imagiologia médica
LH	<i>Low Resolution</i>
MEF	Malha de elementos finitos
ML	<i>Machine Learning</i>
MLP	<i>Multilayer perceptron</i>
MSE	<i>Mean squared error</i>
OEIT	<i>Open Electrical Impedance Tomography</i>

PDIPM	<i>Primal/dual interior point method</i>
PE	<i>Position Error</i>
PET	Tomografia por emissão de pósitrons
PSNR	<i>Peak Signal to Noise Ratio</i>
PSO	<i>Particle Swarm Optimization</i>
RAM	<i>Random Access Memory</i>
RE	Erro relativo
RES	Resolução
RMN	Ressonância magnética nuclear
RNA	Redes Neurais Artificiais
RNG	<i>Ringling</i>
ROI	Região de interesse
SCG	<i>Sensitivity-theorem-based conjugate gradient</i>
SI	Sistema Internacional de Unidades
SNC	Sistema nervoso central
SNP	Sistema nervoso periférico
SRR	<i>Super resolution reconstruction</i>
SSIM	<i>Structural Similarity Index</i>
SVM	<i>Support Vector Machine</i>
TIE	Tomografia por impedância elétrica
TS	<i>Temporal regularization</i>
TV	<i>Total variation</i>
2D	Duas dimensões

LISTA DE SÍMBOLOS

Z	Impedância elétrica
R	Resistência elétrica
X	Reatância elétrica
X_c	Reatância capacitiva
X_L	Reatância indutiva
I	Corrente elétrica de um circuito qualquer
V	Potencial elétrico de um circuito qualquer
Ω	Domínio fechado
$\partial\Omega$	Contorno do domínio
$u = (x, y)$	Posição do objeto
$\phi(\vec{u})$	Distribuição dos potenciais elétricos
$\phi_{ext}(\vec{u})$	Distribuição dos potenciais elétricos na superfície do domínio
$I(\vec{u})$	Corrente elétrica alternada injetada
$n(\vec{u})$	Vetor normal à borda do domínio
$\sigma(\vec{u})$	Distribuição de condutividade elétrica
J	Densidade de corrente elétrica
$f(r, \phi)$	Função de variáveis polares r e ϕ
l	Distância da origem
θ	Ângulo com eixo vertical
R	Operador da Transformada de Radon
p	Função qualquer
x_n	Entrada de uma rede neural artificial
y	Saída de uma rede neural artificial
w_n	Peso sináptico de uma rede neural artificial

u	Potencial de ativação de uma rede neural artificial
$g(u)$	Função de ativação de uma rede neural artificial
$f(x)$	Função contínua de ativação
(x_j, y_j)	Amostras para treinamento da ELM
N	Conjunto de amostras
m	Número de neurônios da camada escondida
a_i	Pesos de entrada da ELM
b_i	Bias
β_i	Pesos de saída da ELM
y_i	Saída desejada da ELM
H	Matriz de saída da camada escondida da ELM
β	Matriz de pesos de saída da ELM
Y	Matriz resultante da ELM
T	Conjunto de treinamento
$K(x_i, x_j)$	Kernel da ELM
μ_x	Média da imagem x
σ_x^2	Variância da imagem x
σ_{xy}	Covariância entre as imagens x e y

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Motivação e Justificativa	17
1.2	Objetivos	20
1.3	Organização do trabalho	21
2	FUNDAMENTAÇÃO TEÓRICA	22
2.1	Tomografia por Impedância Elétrica	22
2.1.1	Impedância elétrica	22
2.1.2	Problema matemático de TIE	24
2.1.3	Aplicações da TIE	25
2.1.4	Técnicas de Reconstrução de imagens de TIE	27
2.2	A inteligência artificial na saúde	30
2.3	Redes Neurais Artificiais	31
2.3.1	Redes neurais de camada única	34
2.3.2	Rede neural de múltiplas camadas	35
2.3.3	Máquinas de aprendizado extremo	35
3	TRABALHOS RELACIONADOS	39
3.1	Tomografia por Impedância Elétrica	39
3.2	Considerações	44
4	PROPOSTA: ELM E BACKPROJECTION PARA RECONSTRUÇÃO DE IMAGENS DE TIE	47
4.1	Método de reconstrução proposto	47
4.2	Experimentos propostos	48
4.3	Considerações	52
5	RESULTADOS E DISCUSSÃO	54
5.1	Resultados	54
5.2	Discussão	57
5.3	Considerações	59
6	CONCLUSÃO	60
6.1	Dificuldades encontradas	61
6.2	Contribuições	61
6.3	Trabalhos futuros	62

REFERÊNCIAS	64
APÊNDICE A – RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA USANDO EXTREME LEARNING MACHINE DE REGRESSÃO	74
APÊNDICE B – ELECTRICAL IMPEDANCE TOMOGRAPHY IMAGE RE- CONSTRUCTION BASED ON BACKPROJECTION AND EXTREME LEARNING MACHINES	82
APÊNDICE C – RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA BASEADA EM MÁQUI- NAS DE APRENDIZADO EXTREMO E BACKPROJEC- TION	99
APÊNDICE D – ALGORITMO DE EVOLUÇÃO DIFERENCIAL HIBRI- DIZADO E SIMULATED ANNEALING APLICADOS A TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA	104

1 INTRODUÇÃO

Este capítulo trata das principais motivações para o desenvolvimento deste trabalho, apresentando os princípios básicos de funcionamento da Tomografia por impedância elétrica, suas diversas aplicações e desafios. São também descritos os objetivos gerais e específicos e, por fim, o escopo desta dissertação.

1.1 Motivação e Justificativa


Os avanços tecnológicos na saúde tem aumentado a possibilidade de prevenção, diagnósticos precoces e tratamentos de doenças de maneira adequada, através de procedimentos mais rápidos, menos invasivos e com menor tempo de recuperação. Indiretamente, a tecnologia ainda é capaz de beneficiar os pacientes por meio da digitalização de processos e de sistemas de gestão. Como consequência, há uma crescente melhora na qualidade e na expectativa de vida das pessoas, além de um trabalho mais prático e preciso por parte dos profissionais de saúde (BARRA et al., 2006; BANTA, 2003).

Uma das áreas de destaque da medicina é a imagiologia médica (IM), popularmente conhecida como exames de imagem, que tem permitido a visualização anatômica e funcional de diferentes órgãos e tecidos do paciente. A IM está presente em diversas modalidades, podendo-se ressaltar técnicas como a Tomografia computadorizada, a Ressonância magnética nuclear, a ultrassonografia e a mamografia. Porém, apesar dos inquestionáveis benefícios que trazem, muitas dessas técnicas funcionam à base de radiações nocivas à saúde humana, ou possuem equipamentos caros e de grandes dimensões, que restringem seu acesso e utilização. Por conta disso, há lacunas no ramo do diagnóstico médico que vem sendo exploradas por diversos pesquisadores atualmente, como a Tomografia por impedância elétrica (BEUTEL; KUNDEL; METTER, 2000; DOI, 2007).

A Tomografia por Impedância Elétrica (TIE) é uma técnica promissora de imagem do interior de uma seção do corpo através da medição de grandezas elétricas em sua superfície (BARBOSA et al., 2017; EULÁLIO; RIBEIRO; SANTOS, 2012). Eletrodos são posicionados na borda do domínio de forma equidistante, 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. A corrente elétrica injetada por um par de eletrodos 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 e alta frequência (em geral, entre 10kHz e 250kHz) (SINGH et al., 2015). Após a medição dos potenciais elétricos, as informações são enviadas para um sistema de controle e aquisição, que processam e reconstroem os dados de forma a gerar imagens correspondentes ao

domínio em estudo, como mostrado na Figura 1.

Figura 1 – Esquemático do funcionamento básico da Tomografia por impedância elétrica




Fonte: BARBOSA (2017)

Baseado na forma em que as imagens são reconstruídas, há dois tipos de imagens de TIE. Primeiramente, as imagens diferenciais, em que dois conjuntos de dados são medidos em instantes distintos ou sob a aplicação de diferentes frequências de excitação. Nesse caso, os dados são subtraídos e as imagens representam uma variação percentual do parâmetro em estudo. O segundo tipo são as imagens absolutas, que 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, sendo um material bom condutor aquele que permite a passagem de correntes contínuas e alternadas. A permissividade, por sua vez, é a medida da facilidade de cargas elétricas se separarem, ou seja, o material se polarizar, sob a presença de um campo elétrico aplicado. Materiais com alta permissividade apenas permitem a passagem de correntes alternadas. Normalmente, apenas a condutividade, a parte real da impedância, é considerada e reconstruída. O método de imagens absolutas, no qual este trabalho está focado, é tecnicamente mais difícil e computacionalmente mais custoso, sendo, por isso, objetivo de diversas pesquisas (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; ISAACSON; NEWELL, 1999), por exemplo. Na área industrial, como na detecção de vazamentos de tanques e estimação de taxa de parâmetros de fluxo (JORDANA; GASULLA; PALLÁS-ARENY, 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 (ZOU; GUO, 2003), na medição de sangramento intracraniano (DAI et al., 2013) e no diagnóstico de câncer de próstata (WAN et al., 2013). Uma das aplicações mais promissoras na medicina é no monitoramento de ventilação pulmonar imposta por ventilação mecânica, facilitado pelo tamanho e alta resistividade dos pulmões. Equipamentos para este fim já podem ser encontrados em hospitais brasileiros e fazem uso da técnica de imagens diferenciais (Figura 2).

Figura 2 – Tomógrafo por Impedância Elétrica para monitoramento pulmonar desenvolvido pela Timpel




Fonte: PRECISION... (2017)

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; KUMAR et al., 2010). Outra vantagem é a boa resposta temporal da TIE, que permite uma rápida detecção de mudanças no meio em estudo (HERRERA, 2008).

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 (Figura 3). O primeiro consiste na determinação dos potenciais elétricos no interior da seção do corpo e da medição destes 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; KUMAR et al., 2010).

Figura 3 – Esquema dos problemas direto e inverso



Fonte: FEITOSA (2015)

Desse modo, diferentes métodos têm sido estudados e aplicados buscando soluci-

onar esses problemas. Uma das formas de reconstrução é através de métodos iterativos de otimização. Diversos estudos (BARBOSA et al., 2015; RIBEIRO et al., 2014) têm se inspirado em algoritmos evolucionários e bioinspirados da Inteligência Computacional. Em um outro estudo (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; HAUPTMANN, 2018; MARTIN; CHOI, 2016a; MARTIN; CHOI, 2016b) tem proposto o uso das mesmas para a resolução do problema inverso.

1.2 Objetivos

Diante do exposto, este presente trabalho tem como objetivo principal propor e testar um método ainda não descrito na literatura para a reconstrução de imagens de TIE. 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 por *Backprojection* para a geração de imagens de TIE.

Como objetivos específicos ou metas, tem-se:

1. Revisão dos problemas direto e inverso da TIE, bem como seus métodos de reconstrução; revisão de Redes neurais artificiais, Máquinas de aprendizado extremo de regressão e do algoritmo clássico de *Backprojection*;
2. Elaboração de uma ferramenta computacional de reconstrução de imagens de TIE;
3. Obtenção dos resultados da técnica proposta e comparação com os resultados de técnicas do estado da arte;
4. Divulgação dos resultados através de publicações em periódicos e conferências.

1.3 Organização do trabalho

Este trabalho está organizado na forma que se segue: na seção “Fundamentação teórica”, apresentam-se os conceitos teóricos necessários para um bom entendimento deste trabalho, incluindo a base matemática da Tomografia por Impedância Elétrica e princípios de Inteligência Artificial, em especial, Redes Neurais artificiais. Em seguida, na seção "Trabalhos relacionados" é apresentado o estado da arte dos métodos de reconstrução de imagens de TIE. No capítulo seguinte, é feita a proposta deste trabalho, que consiste em apresentar e validar um método inovador de reconstrução de imagens de TIE, baseado no método do *Backprojection* e em Máquinas de aprendizado extremo. No capítulo 5 serão mostrados os resultados experimentais, assim como uma avaliação qualitativa e quantitativa deles. Por fim, na "Conclusão", será feito um sumário da contribuição científica e discutidos possíveis futuros trabalhos.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo é dedicado ao estudo dos conceitos teóricos importantes para orientar a análise e interpretação desta pesquisa.

2.1 Tomografia por Impedância Elétrica

Esta seção trata do ponto visto matemático da Tomografia por impedância elétrica, suas aplicações e principais métodos de reconstrução.

2.1.1 Impedância elétrica

A impedância elétrica (Z) é uma grandeza referente à oposição de um sistema à passagem de corrente elétrica alternada, tendo como unidade de medida o ohm (Ω). Escrita na sua forma retangular, como na equação 2.1, vê-se facilmente que ela possui uma parte real (a resistência elétrica, R) e uma parte imaginária (a reatância X), sendo a última formada pelas reatâncias capacitiva X_C e indutiva X_L (JR; KEMMERLY; DURBIN, 2014).

$$Z = R + jX \quad (2.1)$$

Em um circuito elétrico qualquer, onde há um corpo submetido à passagem de uma corrente elétrica alternada I e a uma diferença de potencial elétrico V , a impedância elétrica é definida matematicamente pela Lei de Ohm (VJ et al., 2007) como na equação 2.2 abaixo:

$$Z = \frac{V}{I}. \quad (2.2)$$

Nesse contexto, a bioimpedância baseia-se no fato de que diferentes tecidos e órgãos opõem a passagem de corrente elétrica de maneira diferente. Ela é o produto dos efeitos das condutâncias, capacitâncias e indutâncias dos tecidos, relacionadas às propriedades elétricas de condutividade σ [$S m^{-1}$], permissividade ε [$F m^{-1}$] e permeabilidade μ [$H m^{-1}$].

Como em sistemas biológicos o fluxo de corrente se dá através dos íons diluídos, a condutividade depende altamente do nível de hidratação tecidual. Tecidos magros, por exemplo, tendem a oferecer menor resistência (parte real da impedância) do que tecidos gordos, ossos e pele, como apontado na Tabela 1. Em se tratando da resistência capacitiva, a oposição ao fluxo de corrente ocorre nas membranas celulares, que por possuírem uma dupla camada proteica condutiva e uma camada lipídica com características isolantes, se

Tabela 1 – Teor de água de vários tecidos e órgãos humanos


Tecidos	Peso % Teor de água	Tecidos	Peso % Teor de água
Osso	44-45	Pulmão	80-83
Medula óssea	8-16	Músculo	73-78
Intestino	60-82	Tecidos oculares	
Cérebro		Coróide	78
Massa branca	68-73	Cornea	75
Massa cinzenta	82-85	Íris	77
Gordura	5-20	Lentes	65
Rim	78-79	Retina	89
Fígado	73-77	Pele	60-76
		Baço	76-81

Fonte: Pethig (1984)

assemelham a um capacitor. Em relação à permeabilidade, como os tecidos biológicos não possuem essencialmente características magnéticas, ela não contém nenhuma informação útil (EICKEMBERG et al., 2011; ZLOCHIVER, 2005).

Como possui uma componente imaginária, a impedância elétrica depende da frequência aplicada. Em baixas frequências ($\sim 1kHz$), a impedância capacitiva das membranas das células é alta, dificultando a penetração da corrente. Em frequências na faixa de $100kHz$, porém, a corrente flui mais facilmente, e a impedância pode ser mensurada. Em outras palavras, a permissividade diminui à medida que a frequência aumenta, enquanto a condutividade se torna maior (Figura 4) (EICKEMBERG et al., 2011; ZLOCHIVER, 2005).

Figura 4 – Variação da condutividade em relação à frequência




Fonte: Sobota (2016)

2.1.2 Problema matemático de TIE

O sistema de Tomografia por impedância elétrica é composto por um *hardware* para aplicação e medição dos parâmetros elétricos, e de um *software*, responsável para resolução do processo matemático, também conhecido como problema de reconstrução. A técnica de TIE consiste na solução dos problemas direto e inverso (BARBOSA et al., 2018; SANTOS et al., 2018a).

Visando diminuir a complexidade do problema, algumas hipóteses e simplificações são adotadas. Assim, considerando o meio como isotrópico, ou seja, que todas as suas propriedades físicas são constantes em todas as direções, e um domínio circular bidimensional Ω , limitado por uma superfície de contorno $\partial\Omega$ como representado na Figura 5, o problema de TIE é determinado matematicamente pela Equação de Poisson, dada pela equação 2.3.

Figura 5 – Domínio da TIE



Fonte: BARBOSA (2017)

$$\Delta \cdot [\sigma(\vec{u}) \Delta \phi(\vec{u})] = 0, \quad \forall \vec{u} \in \Omega, \quad (2.3)$$

Com as condições de contorno dadas pelas equações (2.4) e (2.5):

$$\phi_{ext}(\vec{u}) = \phi(\vec{u}), \quad \forall \vec{u} \in \partial\Omega, \quad (2.4)$$

$$I(\vec{u}) = -\sigma(\vec{u}) \Delta \phi(\vec{u}) \hat{u}, \quad \forall \vec{u} \in \partial\Omega, \quad (2.5)$$

Onde $u = (x, y)$ é a posição do objeto, $\phi(\vec{u})$ a distribuição de potenciais elétricos, $\phi_{ext}(\vec{u})$ a distribuição de potenciais elétricos na superfície do domínio, $I(\vec{u})$ a corrente elétrica alternada, $n(\vec{u})$ o vetor normal à borda e $\sigma(\vec{u})$ a distribuição de condutividade elétrica, ou seja, a imagem de interesse. A unidade no Sistema Internacional de Unidades (SI) para a condutividade é $[\Omega \cdot m]^{-1}$ (HAMILTON; HAUPTMANN, 2018; FREITAS et al., 2018; SANTOS et al., 2018b; RIBEIRO et al., 2014).

Em casos onde a solução do problema inverso é obtida através de um método iterativo, o problema direto é chamado frequentemente, ou ele ainda pode ser usado para

predizer observações. No problema direto de TIE, os potenciais elétricos medidos em seu contorno são determinados a partir do padrão da corrente de excitação e da distribuição da condutividade elétrica, que são dados pela equação de Laplace. O problema é modelado pela equação 2.6 abaixo.

$$\phi_{ext}(\vec{u}) = f(I(\vec{u}), \sigma(\vec{u})), \quad \forall \vec{u} \in \partial\Omega \wedge \vec{u} \in \partial, \quad (2.6)$$

Com as condições de contorno na equação 2.7

$$\sigma \frac{\partial \phi}{\partial \vec{n}} = J, \quad (2.7)$$

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

2.1.3 Aplicações da TIE

A tomografia por impedância elétrica possui inúmeras aplicações em diferentes áreas de estudo. No segmento industrial (YORK, 2001), por exemplo, a técnica pode ser útil na medição de fluxo multifásico (ISMAIL et al., 2005), na investigação da operação de hidrociclones, muito utilizados em mineradoras (WILLIAMS et al., 1999) e em indústrias farmacêuticas, para monitoramento tridimensional da liberação de drogas em função do tempo (RIMPILÄINEN et al., 2010).

Paralelamente, no ramo da geofísica, a TIE pode ser vantajosa no mapeamento de propriedades físicas da terra, permitindo a investigação da poluição em solos e em águas subterrâneas (D'ANTONA et al., 2002). Encontra-se também estudos com aplicações subaquáticas, como no trabalho de (BOUCHETTE et al., 2014), que busca detectar objetos compactos enterrados em várias profundidades de sedimentos. Os autores fizeram experimentos com um tanque coberto de água e de camadas de sedimentos, como mostrado na Figura 6, utilizando um sistema de 64 eletrodos para observar objetos de diferentes propriedades.

Figura 6 – Aplicação da TIE para detectar objetos enterrados em sedimentos




Fonte: Adaptado de Bouchette et al. (2014)

Pode-se ainda citar estudos de construções civis para análise de danos em estruturas (HALLAJI; SEPPÄNEN; POUR-GHAZ, 2014; HOU; LYNCH, 2009), como no desenvolvido

por (RYMARCZYK et al., 2017), que propõe a junção de técnicas de TIE com algoritmos topológicos para otimização. Na Figura 7, pode-se visualizar parte do sistema desenvolvido, composto tanto pelos dispositivos de aquisição quanto de reconstrução de imagens. Acrescenta-se ainda aplicações na área da botânica, para geração de imagens de troncos e análise da deterioração de árvores, através do imageamento de propriedades como umidade e concentração iônica (NICOLOTTI et al., 2003).

Figura 7 – Utilização da TIE para examinar estruturas em construções civis




Fonte: Adaptado de Rymarczyk et al. (2017)

A TIE é ainda uma alternativa com grande potencial no diagnóstico médico, podendo auxiliar em diversos contextos clínicos. Dentre eles, pode-se ressaltar aplicações no monitoramento para guiar ventilação mecânica dos pulmões através do método de formação de imagens diferenciais (WOLF et al., 2013). Esse tipo de aplicação já possui equipamentos comerciais, normalmente utilizados junto aos leitos de Unidades de Terapia Intensiva (UTI). Assim, a TIE é uma alternativa aos convencionais exames de sangue para avaliação dos níveis de oxigenação. Nesse contexto, encontra-se ainda trabalhos para estimativa da perfusão pulmonar através da medição da variação de impedância durante a sístole, permitindo a caracterização de hipertensão arterial pulmonar (HOVNANIAN, 2013).

A técnica de TIE também possui trabalhos relevantes visando o diagnóstico precoce do câncer. O trabalho de (WAN et al., 2013), por exemplo, propõe a detecção de câncer de próstata através da combinação da TIE com a técnica de ultrassonografia transretal, que fornece informações anatômicas que auxiliam as reconstruções tomográficas (WAN et al., 2013). Merece ainda destaque aplicações com foco no câncer de mama, onde também é conhecida por *Electrical Impedance Mammography* (TROKHANOVA; OKHAPKIN; KORJENEVSKY, 2008; HUBER et al., 2010). Dentre elas, encontra-se um modelo de dispositivo de TIE com interface *mobile* com o usuário, permitindo-o realizar avaliações dentro de sua própria casa. Nesse caso, um dispositivo em multi-camadas com formato de sutiã foi desenvolvido, sendo composto por um circuito integrado acoplado à 90 eletrodos (Figura 8). Uma outra abordagem por feita no trabalho de (HONG et al., 2015), permite o imageamento da distribuição de condutividade em três dimensões (3D). Nesse contexto,

desenvolveram um sistema em forma de matriz quadrangular de 12cm cada lado, em que 256 eletrodos estão dispostos. Assim, os eletrodos são pressionados contra a mama, de forma a aumentar a superfície de contato e deixar a camada de tecido analisado mais fina (CHEREPENIN et al., 2001).


Figura 8 – Aplicação da TIE para detecção do câncer de mama



Fonte: Adaptado de Hong et al. (2015)

Outra aplicação encontrada na medicina é para detecção de hematomas subdurais (Figura 9), visando uma detecção precoce de sangramentos intracranianos facilitada pela diferença de resistividade do sangue em relação aos tecidos cerebrais (DAI et al., 2013). Por fim, ressaltam-se ainda estudos para detecção de hemorragias intraventriculares em bebês prematuros, que são as principais causas de mortes de crianças que nascem abaixo do peso (MURPHY et al., 1987), estudos para detecção dos ciclos cardíacos baseada na medição da variação de impedância (HOLDER, 2004) e no monitoramento do funcionamento gástrico (WRIGHT et al., 1993).

Figura 9 – Aplicação da TIE para hematomas subdurais



Fonte: Adaptado de Hong et al. (2015)

2.1.4 Técnicas de Reconstrução de imagens de TIE

Em geral, os algoritmos de reconstrução de TIE podem ser divididos em iterativos e não-iterativos. Os algoritmos não-iterativos tratam o problema inverso de TIE como linear e a distribuição de condutividades elétricas como homogênea, o que conferem a eles rapidez e baixa complexidade computacional (LIMA, 2006). Dentre esses algoritmos, o mais conhecido é o *Backprojection* (SANTOSA; VOGELIUS, 1990; BARBER; BROWN, 1988). Em

contrapartida, os métodos iterativos são mais custosos computacionalmente, já que buscam os resultados com uma série de iterações (FEITOSA et al., 2014). Para isso, assume-se inicialmente uma distribuição de condutividade elétrica e um valor de corrente elétrica para calcular os potenciais de borda do domínio em questão. Em seguida, esses potenciais são comparados com os medidos, e o erro calculado orienta a próxima iteração, buscando aproximação com a distribuição de condutividades real. Nesse segundo grupo, pode-se citar algoritmos baseados no método de Newton-Raphson (YORKEY; WEBSTER; TOMPKINS, 1987).

Na área médica é comum que se deseje analisar alguma estrutura ou órgão interno sem uma intervenção cirúrgica. Além disso, muita vezes é desejável que se obtenha imagens enquanto o paciente ainda se encontra no equipamento médico, evitando, assim, que ele precise retornar à sala de exames. E ainda mesmo que não seja necessária a geração de imagens em tempo-real, métodos de reconstrução rápidos são essenciais para a prática da imagiologia médica (HERMAN, 1995).


Quando se trata da reconstrução de algum objeto, ela pode ser considerada uma distribuição 2D de alguma função. No caso de Tomografia Computadorizada, por exemplo, onde se tem uma fonte e um detector de radiação-X envolvendo o corpo a ser irradiado, pode-se ter uma função que represente os coeficientes de atenuação linear dos objetos internos ao corpo. Em outras palavras, procura-se medir a soma ou integrais de linha dos coeficientes de atenuação ao longo de diferentes caminhos coletados em diferentes angulações. Cada resultado obtido em uma direção é chamado de projeção (HERMAN, 1995; HSIEH, 2009).

Para se ter um entendimento mais claro a cerca de reconstruções de projeções, convém imaginar um experimento. Assumindo uma estrutura semitransparente que se deseja imagear, composta por esferas em seu interior. Ao se analisar o objeto do ponto de vista da Figura 10a, três das cinco esferas totais podem ser observadas, tornando impossível determinar o número, a intensidade e dimensões exatas de todas as esferas. Porém, ao rotacionar toda a estrutura e observá-la em um ângulo diferente (Figura 10b), esferas que antes estavam sobrepostas, podem então ser visualizadas. Em síntese, ao analisar o objeto em múltiplos ângulos, pode-se concluir corretamente a composição do corpo estudado e estimar a sua estrutura interna (HSIEH, 2009).

Substituindo a fonte de luz e os olhos para fonte de radiação-x e pelo sistema de detecção, tem-se um sistema similar ao de CT. No caso de TIE, substitue-se pelos eletrodos posicionados na borda do domínio, que determinam os ângulos e número de projeções, e baseia-se nos diferentes valores de condutividade dos órgãos e tecidos humanos como forma de contraste.

Dentre os sistemas desenvolvidos baseados na técnica de TIE, um grupo inglês da Universidade de Sheffield foi pioneiro na obtenção de imagens clínicas. O grupo desenvolveu

Figura 10 – A visualização de objetos opacos em diferentes ângulos permite a predição da sua estrutura interna



Fonte: Hsieh (2009)

um aparelho com 16 eletrodos endereçados por quatro multiplexadores, aplicando corrente elétrica de $5mA$ pico a pico em pares de eletrodos adjacentes. O sistema é capaz de coletar 10 imagens por segundo, sendo adequado para o registro do ciclo cardíaco, e baseia-se no método de *Filtered Back Projection* para reconstrução das imagens tomográficas (BARBER; BROWN, 1988).

O método de retroprojeção (*Backprojection*) é um método somatório simples e rápido. As projeções ou Transformadas de Radon de uma amostra são integrais de linha em ângulos específicos, como mencionado anteriormente. Matematicamente, a técnica de reconstrução pode ser definida como a seguir. Supondo uma função f de duas variáveis polares r e ϕ , com sua integral de linha definida por $[Rf](l, \theta)$, estando a uma distância l da origem e com um ângulo θ com o eixo vertical. Considerando ainda o operador R , correspondente à transformada de Radon, pode-se definir para qualquer função p (HERMAN, 1995; KOSHEV; HELOU; MIQUELES, 2016),

$$[R^{-1}p](r, \phi) = \frac{1}{2\pi^2} \int_0^\pi \int_{-\infty}^{\infty} \frac{1}{r \cos(\theta - \phi) - l} p_1(l, \theta) dl d\theta \quad (2.8)$$

onde $p_1(l, \theta)$ é a derivada parcial de p em relação à l . Assim, é conhecido que (HERMAN, 1995) para todos os pontos (r, ϕ) , satisfazem a equação 2.9 abaixo (HERMAN, 1995; KOSHEV; HELOU; MIQUELES, 2016).

$$[R^{-1}Rf](r, \phi) = f(r, \phi). \quad (2.9)$$

Dessa forma, o método de retroprojeção é um dos métodos numéricos para estimar integrais duplas em um processo de dois passos. Primeiramente, pode-se definir

$$p_c(l, \theta) = \int_{-\infty}^{\infty} p(l', \theta) q(l - l', \theta) dl'. \quad (2.10)$$


Em segundo lugar, a estimativa de f^* de f é obtida pela retroprojeção dada pela equação 2.11:

$$f^*(r, \phi) = \int_0^\pi p_c(r \cos(\theta - \phi) - \theta) d\theta, \quad (2.11)$$

sendo essa segunda fase mais custosa computacionalmente.

Em CT, cada projeção representa a soma de coeficientes de atenuação do objeto irradiado ao longo de um determinado ângulo como mostrado na Figura 11. 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. O nome sinograma tem sua origem no fato de que a Transformada de Radon de um único ponto é uma senoide. Eles 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.

Figura 11 – Funcionamento do algoritmo de Retroprojeção e representação em Sinogramas



Fonte: Hsieh (2009)

2.2 A inteligência artificial na saúde

Nos últimos anos, a Inteligência Artificial (IA) tem ganhado força e popularidade. Diversas empresas a têm incorporado nos seus serviços financeiros, produções e interações com o público através de assistentes pessoais virtuais. Uma das grandes aplicações da IA, porém, é na área médica. Percebe-se um grande potencial para melhorar a efetividade e velocidade de diversos tipos de diagnóstico, auxiliar na gestão dos centros de saúde, realizar procedimentos cirúrgicos com maior precisão e atendimentos automatizados com robôs. Além disso, a IA pode ter o papel de humanizar a saúde. Ao contrário do que o senso comum pensa, afirmando que máquinas poderão substituir humanos eventualmente, a equipe médica poderá se aproximar dos seus pacientes, à medida que otimiza o tempo de diagnóstico e de atualização dos registros dos pacientes (JIANG et al., 2017).

Para que sistemas de IA sejam usados em aplicações médicas, eles precisam ser treinados com dados gerados a partir de atividades clínicas, como de escaneamentos,

diagnósticos, tratamentos, exames clínicos e laboratoriais. Dessa forma, poderão aprender as similaridades entre grupos de dados, associar características ou resultados de interesse. As pesquisas nesse ramo tem se concentrado em alguns tipos de doenças, sendo as principais: câncer, doenças neurológicas e cardiovasculares. Esse fato se dá pelo risco que elas trazem, podendo levar o paciente ao óbito, e necessitando, assim, de diagnósticos precoces.

Muitos tentaram definir a IA, mas até hoje o termo é alvo de discussões. Em 1978, Bellman a definiu como a "automação de atividades que nós associamos com o pensamento humano, atividades como tomadas de decisão, resolução de problemas, aprendizado...". Alguns anos a seguir, em 1990, Kurzweil definiu a IA como "A arte de criar máquinas que realizam funções que exigem inteligência quando realizadas por pessoas". Mais recentemente, Elaine Rich e Kevin Knight explicaram a IA como "o estudo de como fazer os computadores realizarem coisas que, no momento, as pessoas fazem melhor" (RUSSELL; NORVIG, 2016, traduzido pela autora).


As técnicas mais populares de IA atualmente incluem métodos de *Machine learning* para dados estruturados, como Redes Neurais artificiais e Máquinas de Vetor de suporte; e métodos para dados não estruturados como de aprendizado profundo e processamento de linguagem natural (RUSSELL; NORVIG, 2016).

Algoritmos de *Machine Learning* podem ser divididos em duas categorias principais: aprendizado não supervisionado e supervisionado. O primeiro é normalmente usado para extração de atributos e não utiliza as informações de saída durante o treinamento. Pode-se citar como exemplo o algoritmo popular de *Cluster k-means*. Nos algoritmos supervisionados, por outro lado, se tem a presença de um professor no processo de aprendizagem, relacionando as entradas e saídas de interesse para prever o modelo. Nesse último caso, normalmente se têm resultados clínicos mais relevantes e, por isso, é mais usado para aplicações médicas. No contexto específico de imagens médicas, 42% dos casos utilizam Máquinas de vetor de suporte (*Support vector machine, SVM*) e 31% as Redes Neurais Artificiais, como apontado no estudo realizado por (RUSSELL; NORVIG, 2016) mostrado na Figura 12.

2.3 Redes Neurais Artificiais

O sistema nervoso humano é formado por um conjunto de órgãos que compõem os sistemas nervoso central (SNC) e o periférico (SNP). Ele possui um comportamento sofisticado, com a principal função de receber e transmitir informações de diversas partes do corpo, coordenando as respostas a esses estímulos. Pode-se resumir o funcionamento do sistema nervoso através do diagrama de blocos representado na Figura 13. As redes neurais representadas no bloco central, representam o cérebro, que recebem os estímulos


Figura 12 – Distribuição de técnicas de inteligência computacional utilizadas no contexto de imagens médicas



Fonte: Russell e Norvig (2016)

provenientes do ambiente através dos receptores. As mesmas processam as informações e acionam atuadores, que são responsáveis pela geração de uma resposta ou impulso elétrico. Esse sistema possui ainda realimentação, indicada pelas setas no sentido oposto, que convertem os impulsos elétricos em saídas discerníveis (HAYKIN, 2007; RAMESH et al., 2004).

Figura 13 – Funcionamento básico das Redes Neurais Artificiais




Fonte: Adaptado de Haykin (2007)

O neurônio é a unidade básica do sistema nervoso humano, sendo constituído por três partes principais: o corpo celular, os dendritos e os axônios, representados na Figura 14. O corpo celular é constituído por organelas, espalhadas pelo citoplasma, e pelo núcleo, onde estão presentes os cromossomos. Os dendritos, por sua vez, são o terminal de recepção, funcionando como antenas que recebem milhares de informações. Esses dendritos se conectam aos axônios de outros neurônios, sendo estes últimos ramificações responsáveis por enviar informações a diferentes partes do sistema nervoso. Esses pontos de contato entre neurônios chamam-se sinapses, as unidades responsáveis pelas interações neuronais e que, por isso, têm papel fundamental na memorização. 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 ou aprender.

A estrutura e funcionamento do sistema nervoso serviram como inspiração para a criação das Redes Neurais Artificiais (RNA). As RNAs são máquinas baseadas no paralelismo, que buscam modelar a forma como respondemos a determinadas funções.

Figura 14 – Estrutura do neurônio biológico




Fonte: Borges et al. (2015)

Elas se baseiam na ideia de processo de aprendizagem a partir da observação do meio e na conexão neuronal para armazenamento dessas informações (HAYKIN, 2007).

De maneira análoga aos neurônios biológicos, as RNAs são constituídas por unidades básicas de processamentos. Um modelo de neurônio artificial é mostrado na Figura 15 a seguir. A figura representa um conjunto de entradas $x_1 \dots x_n$, que representam os dentritos, e uma única saída y gerada, representando o terminal do axônio. As sinapses nesse contexto são os pesos sinápticos $w_1, \dots, w_n$, que ponderam cada uma das entradas. Em seguida, há a junção somadora, que soma todos os sinais ponderados e o *bias*, produzindo um potencial de ativação u . Finalmente, uma função de ativação $g(u)$ restringe a amplitude do sinal de saída, produzindo uma saída descrita matematicamente pela equação 2.12 (FAVORETTO, 2016; HAYKIN, 2007).

Figura 15 – Modelo de um neurônio artificial




Fonte: Baseado em Favoretto (2016)

$$y = g\left(\sum_{i=1}^n (w_i x_i + \theta)\right) \quad (2.12)$$

Em resumo, os neurônios artificiais emulam a estrutura e o comportamento dos neurônios biológicos, como destacado na Figura 16.

Figura 16 – Comparação entre o neurônio artificial e o biológico



Fonte: Naranjo (2014)

Assim como a criação e modificação das sinapses biológicas permitem ao cérebro humano aprender, o processo de treinamento de uma rede neural artificial confere às mesmas conhecimento e capacidade de aprendizado. Esse processo consiste na modificação dos pesos sinápticos e limiares dos seus neurônios, tendo como objetivo extrair informações dos dados de treinamento, expressando-as em forma de uma matriz de pesos. Então, de maneira recursiva, os pesos são gradualmente modificados e comparados com as entradas, procurando minimizar o erro entre eles. Essa fase de treinamento é normalmente a mais custosa computacionalmente quando se trata de RNAs, dependendo fortemente da arquitetura da rede (NARANJO, 2014).

Dessa forma, devido à essa habilidade, 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. Somado à isso, as RNAs têm capacidade de lidar com dados tanto lineares quanto não-lineares, lidando ainda com informações imprecisas. Esse cenário, torna as RNAs atrativas para o uso em aplicações no campo da medicina (RAMESH et al., 2004).

Existem diversos modelos de RNAs, sendo definidos pelo número de camadas intermediárias de neurônios (redes neurais de camada única ou redes neurais de múltiplas camadas), quantidade de neurônios, função de transferência e pelo algoritmo de aprendizado.

2.3.1 Redes neurais de camada única

As redes neurais de camada única são o tipo mais simples de RNAs. O termo "camada única" refere-se, nesse caso, à camada de saída, alimentada diretamente pelas entradas ponderadas. As RNAs de camada única resolvem apenas problemas mais simples,

que são linearmente separáveis, apresentando, por isso, grandes limitações na sua utilização (SANTOS, 2017).

2.3.2 Rede neural de múltiplas camadas

As redes neurais de múltiplas camadas também possuem uma única camada de entrada e uma única camada de saída, mas diferem das de camada única devido ao número de camadas intermediárias ou escondidas. Por conta disso, elas apresentam poder computacional muito superior, sendo capazes de solucionar problemas que não são linearmente separáveis. Apesar dos grandes benefícios para a resolução de problemas de ordem mais elevada, a rede torna-se, em compensação, mais complexa e mais lenta.

O algoritmo mais conhecido para treinamento dessas redes é baseado no *back-propagation*. O treinamento ocorre em duas fases: fase *forward* e fase *backward*. Na primeira fase, os dados de entrada são inseridos e propagados ao longo das camadas até gerar uma saída. Nesse caso, os pesos e *bias* são calculados durante o processo, porém sem sofrer alterações, e as respostas produzidas são comparadas às desejadas, gerando, assim, erros. Na fase seguinte, a saída calculada anteriormente é utilizada para atualizar os pesos sinápticos e limiares em função dos erros calculados na primeira etapa.

2.3.3 Máquinas de aprendizado extremo

Uma rede neural que tem sido muito utilizada é a Máquina de aprendizado extremo (*Extreme Learning Machine, ELM*) (HUANG, 2015). 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 alta velocidade, menor complexidade computacional e boa capacidade de generalização (HUANG; ZHU; SIEW, 2006) (HUANG et al., 2012).

As ELMs foram originalmente inspiradas pelo processo de aprendizagem biológico, ultrapassando as técnicas convencionais de aprendizado artificial, e movendo-se para um aprendizado próximo ao do cérebro humano. A maneira que o cérebro aprende é sofisticada. Porém, muitas vezes, ele realiza extração de características, regressão e classificação, por exemplo, sem nenhuma intervenção humana, ou seja, sem especificar certos parâmetros. Com inspiração nesse funcionamento, (HUANG, 2014) conjecturou que algumas partes do cérebro devem possuir neurônios aleatórios onde todos os seus parâmetros são independentes do meio ambiente e, mais tarde, essa teoria foi provada com evidências biológicas. O fato é que os neurônios escondidos das ELMs não são apenas independentes do conjunto de treinamento, mas também são independentes uns dos outros, podendo, dessa forma, gerar parâmetros para os neurônios antes mesmo de serem apresentadas ao conjunto de treinamento.

A função de ativação $f(x)$ é utilizada para transformar um conjunto de sinais de entrada em sinais de saída. Ela mapeia os dados de uma dimensão d do espaço para uma dimensão L (espaço dos atributos da ELM), onde os parâmetros dos neurônios da camada escondida são randomicamente gerados de acordo com qualquer distribuição de probabilidade contínua de amostragem. Assim, $f(x)$ é uma função de mapeamento aleatório (HUANG; ZHU; SIEW, 2006; HUANG et al., 2012). No caso das ELMs todas as funções contínuas podem ser usadas como função de ativação, consistindo normalmente de uma função não-linear (ZHANG et al., 2017). Assim, uma rede de camada única pode ser modelada pela equação 2.13 abaixo:

$$\sum_{i=1}^m \beta_i f(a_i x_j + b_i) = y_j, \quad j \in [1, N], \quad (2.13)$$

onde N constitui um conjunto de amostras (x_j, y_j) , $\{x_1, \dots, x_N\}$ o conjunto de treinamento, m o número de neurônios da camada escondida, a_i os pesos de entrada, b_i o bias, β_i os pesos de saída e y_j a saída desejada.

As ELMs tendem não apenas alcançar o menor erro de treinamento, mas também a menor norma dos pesos de saída, o que de acordo com (BARTLETT, 1997), garante uma melhor capacidade de generalização, ou seja

$$\text{Minimizar } \|H\beta - Y\|^2 \text{ e } \|H\|, \quad (2.14)$$

Além disso, os pesos de entrada da camada oculta são determinados aleatoriamente e independentemente do conjunto de treinamento. Por outro lado, os pesos de saída podem ser determinados analiticamente através da equação 2.13, que pode ser escrita de forma mais compacta como $H\beta = Y$, onde

$$H = \begin{pmatrix} f(a_1 x_1 + b_1) & \dots & f(a_m x_1 + b_m) \\ \vdots & \ddots & \vdots \\ f(a_1 x_N + b_1) & \dots & f(a_m x_N + b_m) \end{pmatrix}$$

$$Y = [y_1, \dots, y_N]^T \quad (2.15)$$

$$\beta = (\beta_1^T, \dots, \beta_m^T) \quad (2.16)$$

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. O algoritmo de uma ELM pode ser resumido na Tabela 2, enquanto a Figura 17 propõe um modelo de ELM para este presente trabalho.

Tabela 2 – Pseudocódigo: Algoritmo da ELM

Algoritmo ELM


Passo 1: Estabelecer randomicamente pesos de entrada a_i e um bias b_i , $i = 1, \dots, N$

Passo 2: Calcular a matriz de saída da camada escondida H

Passo 3: Calcular os pesos de saída β . Assim, $\beta = H^\dagger T$, onde $H^\dagger$ é a matriz inversa generaliza de Moore-Penrose da matriz H ($H^\dagger = (H^T H)^{-1} H^T$).

Fonte: A Autora (2018)

Figura 17 – Modelo de Máquina de aprendizado extremo para este trabalho



Fonte: Adaptado de Zhang et al. (2017)

Finalmente, pode-se perceber e concluir que a ELM apresenta características peculiares e importantes que reforçam o porquê de ter sido escolhida para aplicação deste trabalho. Dentre essas características, cita-se:

- Alta velocidade de aprendizado, explicada pelo fato de não apresentarem um processo iterativo para treinamento. (DENG; ZHENG; CHEN, 2009) realizou um estudo comparativo entre Perceptron multicamadas (*Multilayer perceptron*, MLP) treinadas pelo método do *back-propagation* e ELMs, constatando que as últimas são centenas de vezes mais rápidas.

- Boa capacidade de generalização. Os autores das ELMs apontaram no estudo (HUANG; ZHU; SIEW, 2006) que elas possuem desempenho similar ou superior em relação ao *Back-propagation* e Máquinas de vetor de suporte.
- Facilidade de configuração por não necessitar de ajuste de muitos parâmetros iniciais.

Para casos em que a função de ativação $f(x)$ é desconhecida, pode-se definir uma matriz de Kernel para uma ELM. A teoria do Kernel é mais conhecida em aplicações com Máquinas de vetor de suporte. O kernel é usado para transformar os dados de $\{x_i, \dots, x_j\}$ que forem relevantes em um espaço de características, considerando a geometria do conjunto de treino. A escolha dessas características é determinante na capacidade de generalização (BAUDAT; ANOUAR, 2001).

Nesse sentido, a função Kernel recebe dois pontos $\mathbf{x}_i$ e $\mathbf{x}_j$ e computa o produto escalar no espaço de características, como mostrado na equação 2.17 a seguir (LORENA; CARVALHO, 2007; HUANG, 2014):

$$\Omega_{ELM} = HH^T : \Omega_{ELM_{i,j}} = f(\mathbf{x}_i)f(\mathbf{x}_j) = K(\mathbf{x}_i, \mathbf{x}_j). \quad (2.17)$$

Como na maioria dos casos as funções de ativação $f(x)$ assumem formas complexas, o uso do Kernel $K(\mathbf{x}_i, \mathbf{x}_j)$ torna-se útil pela sua simplicidade e capacidade de representar espaços mais abstratos (LORENA; CARVALHO, 2007). Alguns dos Kernels mais utilizados são os polinomiais, os RBF (*RadialBasis Function*) e os Sigmoidais.

Finalmente, a função de saída baseada em kernels pode ser escrita de modo compacto como na equação abaixo (HUANG, 2014):

$$y(\mathbf{x}) = f(\mathbf{x})H^T \left(\frac{I}{C} + HH^T \right)^{-1} T \quad (2.18)$$

$$= \begin{bmatrix} K(\mathbf{x}, \mathbf{x}_1) \\ \vdots \\ K(\mathbf{x}, \mathbf{x}_N) \end{bmatrix}^T \left(\frac{I}{C} + \Omega_{ELM} \right)^{-1} T.$$

3 TRABALHOS RELACIONADOS

Este capítulo é dedicado a revisão de trabalhos relacionados às diferentes técnicas de reconstrução de imagens de Tomografia por impedância elétrica.

3.1 Tomografia por Impedância Elétrica

Um método de reconstrução de Tomografia por Impedância Elétrica foi descrito e testado em um trabalho (LI et al., 2014), que focou na diminuição do custo computacional. Para isso, uma considerável contribuição pode ser o uso de uma malha de elementos finitos (MEF) na obtenção de soluções numéricas, ou seja, na resolução do problema direto de TIE. Nesse tipo de método, a forma que a malha é construída é determinante na acurácia da solução, podendo oscilar entre baixa resolução espacial em malhas grosseiras e um alto custo computacional em malhas altamente refinadas.

Além disso, o alto custo computacional também é advindo da resolução do problema inverso, principalmente quando se deseja a condutividade de um grande número de elementos. Por conta disso, LI et al. (2014) propôs um método iterativo combinando uma técnica de refinamento de malha adaptativo e um método adaptativo Kaczmarz. O primeiro é capaz de refinar a malha de modo automático, procurando a acurácia desejada usando como métrica um erro específico. Dessa forma, o método evita refinamentos desnecessários que não melhoram a acurácia. O segundo método, por sua vez, tem a habilidade de distinguir a distribuição de condutividade com uma estimativa prévia, utilizando a geração de um padrão de correntes ótimo em cada iteração.

Os autores testaram seus métodos com simulações em ambiente EIDORS¹ (*Electrical Impedance Tomography and Diffuse Optical Tomography Reconstruction Software*), fazendo uso de um modelo circular em 2D com 32 eletrodos na superfície do domínio. Observou-se que houve uma melhora na resolução espacial, e comparado com o método iterativo convencional de Gauss-Newton com quatro iterações, o custo de memória foi de um terço. Foram ainda realizados experimentos em *phantoms* dos pulmões e do coração, quantificando a performance com duas métricas, o Erro médio quadrático e a diferença do erro normalizado entre as voltagens obtidas e as desejadas. Porém, os experimentos físicos não consideraram os padrões de corrente ótima, e, assim, o método não pode ser completamente observado.

Um outro trabalho (MIAO; MA; WANG, 2014) propôs uma estratégia para limitar o espectro de condutividade em uma região de interesse (ROI), criando assim um método

¹ Software disponível em: <eidors3d.sourceforge.net>

adaptado do *Linear sensitivity-theorem-based conjugate gradient* (SCG), chamando-o de RROI. A ideia é utilizar todas as informações de borda para reconstruir a imagem dentro uma ROI específica, considerando que, para algumas aplicações, a condutividade varia apenas em determinada região do domínio. Assim, a equação matricial do problema direto tem a sua ordem reduzida e, conseqüentemente, o seu custo computacional. O método foi validado através de simulações e experimentos com *phantoms*. Finalmente, os autores concluíram que o método descrito pode alcançar maior resolução espacial e uma boa acurácia, quando comparado com imagens reconstruídas por SCG aplicado a todo o domínio, mesmo usando um menor número de eletrodos e o mesmo sistema de aquisição. Os resultados qualitativos foram comprovados através de duas métricas, a comparação da resolução espacial e o coeficiente de correlação. Apesar disso, o método proposto é mais sensível a ruídos.

WANG et al.(2016) propôs uma técnica de reconstrução de TIE com o foco na redução do custo computacional, mantendo uma boa resolução de imagem. A ideia é uma abordagem de reconstrução baseada em *compressive sensing* (CS), ou seja, na redução de amostras, de forma a evitar uma redundância dos dados. Porém, a primeira condição para esse método é que os dados necessitam ser esparsos o suficiente. Nesse contexto, desenvolveu-se um algoritmo de reconstrução baseado na representação esparsa de fragmentos (*Patch-based sparse representation*) como um pré-processamento.

Este tipo de representação tem mostrado habilidade na detecção de características locais das imagens, e de remover artefatos e ruídos efetivamente, quando seus parâmetros são escolhidos apropriadamente. Os testes foram realizados tanto em simulações quanto em dados experimentais, utilizando o erro relativo como medida para qualidade de imagem. Concluindo, os autores mostraram que a representação esparsa baseada em fragmentos apresentou resultados melhores dos que os gerados pelos métodos tradicionais de reconstrução, o gradiente conjugado (*conjugate gradient*, CG), esparsidade global (*global sparsity*) e o *K-SVD denoising*. O método também é sensível a ruídos e seu tempo de reconstrução continua longo. Porém, o novo método alcançou maiores taxas de amostragem, reduzindo, ainda assim, o tempo de reconstrução. Como resultado, o tempo efetivo foi reduzido enquanto a resolução final das imagens foi mantida.

Um outro tipo de abordagem foi testada recentemente por WANG; REN; DONG (2018), baseado na *Open Electrical Impedance Tomography* (OEIT), um dos ramos da TIE. Enquanto a TIE considera seu domínio como fechado, a OEIT foca no imageamento de uma distribuição de condutividade em um domínio aberto, modelado como um semiplano infinito. Nesse caso, os eletrodos são posicionados em apenas um dos lados do domínio, o que acarreta em desafios adicionais na reconstrução das imagens. Isso pode ser explicado pelo fato de que a densidade de corrente decai à medida que as distâncias dos eletrodos aumentam.

As soluções tradicionais de OEIT assumem um contorno virtual ao invés de resolve-

rem todo o domínio aberto, considerando que a componente normal da corrente elétrica é zero na borda virtual. Assim, a borda virtual juntamente com a borda com os eletrodos, constituem uma borda completa. Esse tipo de abordagem, porém, traz consigo erros de truncamento que influenciam a acurácia dos problemas direto e inverso. Visando solucionar essa questão, o trabalho propôs um método baseado em Transformação Conforme, que transfere o domínio aberto em um simples círculo. Após a transformação, a distribuição de condutividade e os potenciais elétricos continuam satisfazendo a equação de Laplace, que se relaciona com a equação antes da transformação. Nesse contexto, as novas posições e dimensões dos eletrodos também devem ser consideradas, assim como a densidade de corrente em cada um deles. Por fim, aplica-se a transformada inversa para obtenção da distribuição de condutividade no domínio aberto.

Os autores testaram o método no EIDORS, com 16 eletrodos, e resolveram o problema direto com o *Boundary Element method* (BEM), enquanto no problema inverso foram utilizadas MEF com 850 elementos. Também foram realizados experimentos físicos com um tanque retangular e um sistema de aquisição de dados, posicionando um material plástico (não condutor) e um material metálico (condutor) em uma solução salina.

Quatro métricas foram escolhidas para avaliar a qualidade das imagens, sendo aplicadas em segmentações das imagens reconstruídas: *Position Error* (PE), Resolução (RES), Deformação e avaliação dos artefatos em forma de anéis (*Ringing*, RNG). Foram ainda considerados os erros relativos e o coeficiente de correlação entre as imagens reconstruídas e as distribuições verdadeiras. De acordo com os experimentos, o método alcançou uma performance superior em relação aos tradicionais métodos de OEIT, melhorando a resolução espacial na direção de maior profundidade.

O trabalho de WANG et al. (2012), por outro lado, propôs a utilização do método estatístico *Expectation maximization* (EM) para resolver o problema inverso de TIE. Os autores observaram que os tradicionais métodos de regularização introduzem valores negativos na solução, que deveriam ser positivos na imagem real ou distribuição de condutividade, o que resulta em artefatos na reconstrução. Além disso, métodos estatísticos são mais rigorosos e efetivos quando lidam com erros de medição.

O algoritmo EM é normalmente usado para estimar o modelo de Poisson de dados incompletos e tem sido amplamente aplicado para imageamentos "*hard-field*", comumente empregado em CTs e Tomografias por emissão de pósitrons (PET). O princípio básico do *hard-field* é a medição da atenuação da intensidade de radiação, descrita pela lei de Beer-Lambert.

Nesse sentido, considerando como mínimas as variações de condutividade em relação ao plano de fundo, pode-se considerar o problema inverso de TIE como um sistema de equações lineares. Como resultado, os autores aproximaram o problema de TIE ao método de *hard-field*, onde as variações de potenciais medidos (assim como as projeções

originalmente) são um multiplicação matricial entre as mudanças na distribuição de condutividade e uma matriz de sensibilidade. Por fim, as equações puderam ser transformadas em positivos e os elementos da matriz de sensibilidade normalizados.

No estudo foi ainda apontado que a maioria dos métodos estatísticos para reconstrução de imagens requerem minimização da função objetivo. Para isso, o método iterativo de *Gradient projection-reduced Newton* foi utilizado.

Os experimentos abrangeram tanto simulações com fantasmas computacionais no Matlab² quanto físicos. Posicionaram 16 eletrodos na borda e aplicaram uma corrente de cerca de $1mA$, além de introduzirem um ruído gaussiano. Os resultados foram, por fim, avaliados qualitativamente e com o erro relativo (RE), comparando o vetor de condutividade real e calculado. Os autores mostraram uma diminuição na negatividade das imagens, assim como melhores RE em relação às técnicas de Tikhinov e CG, porém com uma perda no tempo total de reconstrução, que se apresentou superior no método proposto.

O próximo trabalho a ser discutido foi proposto por BORSOI et al. (2018). Os pesquisadores se inspiraram na técnica de *Super-Resolution Reconstruction* (SRR), que tem significativamente melhorado a resolução de imagens tomográficas como CT e PET. A SRR reconstrói imagens de alta resolução (*High Resolution*, HR) a partir de outras de baixa resolução (*low resolution*, LR), geradas em movimento, por exemplo, através da extração de informações não redundantes. Apesar de atraente, a técnica foi desenvolvida para sistemas ópticos, que possui princípios diferentes da TIE, especialmente pelas características não lineares e de malhas não uniformes desta última. Recentemente, porém, foi desenvolvido um novo método, o *Penrose Pixels*, focado em hipotéticos pixels não-uniformes. Para adaptar malhas desse tipo, imagens LR passam por um processo de "*upsample*" para formar malhas regulares, chamadas de imagens intermediárias HR (IHR). Por fim, o algoritmo de SRR pode ser aplicado.

A proposta do trabalho visa melhorar a resolução espacial das imagens, sem realizar, entretanto, a resolução do problema inverso de TIE. Ou seja, a ideia é que a metodologia pode ser usada em algoritmos arbitrários. Para testar e provar isso, utilizou-se a técnica de MEF para resolução do problema inverso em ambiente EIDORS, utilizando três diferentes algoritmos: *Gauss-Newton*, *Total Variation* (TV) e Regularização temporal (*Temporal regularization*, TS). Também foram consideradas diferentes configurações dos fantasmas e três métricas para avaliação dos resultados: *Volume overlap fraction* (medição da relativa sobreposição dos volumes reais e das estimativas), *Hausdorff distance* (medição da maior distância entre duas superfícies) e *Mean absolute surface distance* (medição do quanto a média de duas superfícies diferem).

O grupo concluiu que a qualidade das imagens teve uma melhora significativa, assim

² Software disponível em: <www.mathworks.com/products/matlab.html>

como a forma dos objetos reconstruídos se mostraram próximas das imagens HR. Entretanto, o grupo reconheceu a alta complexidade computacional do método e a dificuldade em aplicações em tempo real.

Um método alternativo para encontrar a solução do problema de TIE é tratando-o como problema de otimização, de forma a minimizar o erro relativo entre os potenciais de superfície de um objeto e os potenciais conhecidos, como descrito em (BARBOSA, 2017) e (FREITAS et al., 2018). Foram comparadas diferentes abordagens para solucionar o problema de otimização. A primeira foi Algoritmo Genético, que é inspirado na Teoria Evolucionária e em princípios genéticos, como adaptação de espécies, seleção natural, cruzamento e mutação, onde as possíveis soluções para o problema são representadas por indivíduos. Esse método tem como base operadores de cruzamento e mutação, responsáveis pela variação, ou seja, criação de novos indivíduos ou soluções, além de operadores de seleção, que favorecem a qualidade da solução. Assim, gera-se uma população inicial aleatória, e cada indivíduo é avaliado de acordo com uma função de aptidão. Em seguida, são selecionados randomicamente os pais dentre a população, que são cruzados para geração de novos indivíduos e estes, por sua vez, mutados. Por fim, as funções de aptidão são novamente avaliadas afim de determinar a população sobrevivente para próxima geração ou iteração.

Além de Algoritmos Genéticos, também foi usada pelo grupo de pesquisa a meta-heurística Busca de cardume de peixes (*Fish School Search*, FSS), inspirada no comportamento social dos peixes na busca por alimentos. Nesse caso, os peixes representam uma possível solução do sistema ou um ponto no domínio da função de aptidão. O algoritmo FSS tem operadores baseados na alimentação e no nado, onde o operador de alimentação quantifica o sucesso de um peixe na variação da função de aptidão, dependendo de quão próximo o peixe está da comida, podendo aumentar ou diminuir o seu peso. O segundo operador observa os nados individuais e coletivos dos peixes na sua busca por alimentação, representando no algoritmo o processo de busca em si.

Todos os experimentos foram realizados em ambiente EIDORS, com 16 eletrodos de superfície e uma malha circular com 415 elementos. O objetivo desses trabalhos era a detecção de objetos irregulares posicionados em três diferentes configurações, comparando resultados entre apenas o algoritmo FSS, FSS com Busca Não-cega e apenas Algoritmos genéticos. Por fim, as imagens obtidas com 500 iterações foram anatomicamente consistentes, sendo os algoritmos genéticos que apresentaram menores erros relativos e melhor resolução da imagem.

Por outro lado, os autores MARTIN; CHOI(2016a) utilizou tanto Redes Neurais Artificiais (*Artificial Neural Networks*, ANN) e um algoritmo de otimização por enxames de partículas (*Particle Swarm Optimization*, PSO) para reconstrução de imagens de TIE. Através da combinação de um algoritmo não-linear com um método de otimização, buscaram

obter uma maior convergência local e global enquanto resolvia-se o sistema não-linear com um número limitado de iterações. Nesse caso, foram simulados dados ruidosos através da adição de Ruído Gaussiano branco, e distorções nas bordas dos modelos foram consideradas, visando contornar as dificuldades de dispor os eletrodos de maneira uniforme na prática.

Os experimentos para validação do método foram tanto simulados quanto em *phantoms*, e os resultados foram comparados com o linear *one-step* Gauss-Newton, e com o iterativo não-linear *Primal/dual interior point method* (PDIPM). Finalmente, concluiu-se o método linear suavizou as bordas, que tornaram-se difíceis de serem estimadas. Por outro lado, o método proposto apresentou alta fidelidade visual e pequenos erros de resolução quando comparado com as imagens originais. Assim, os autores acreditam que ANN e PSO podem resolver problemas de TIE de uma forma mais rápida, além de lidar com imperfeições.

FERNÁNDEZ-FUENTES et al.(2018) descreveram uma metodologia para desenvolver um modelo baseado *Machine Learning* (ML), especialmente em RNAs, para resolver o problema inverso de TIE. A escolha se deve ao fato de que as RNAs são capazes de modelar relações extremamente não lineares. Assim, o objetivo principal do trabalho era obter uma acurada distribuição de condutividades elétricas de um corpo através de quatro passos: (1) Desenvolvimento de uma base de 10220 malhas com 844 elementos com adição de artefatos, representando os domínios virtuais; (2) Simulação do problema direto de TIE, na plataforma EIDORS utilizando 16 eletrodos. Um conjunto de 208 medições foi obtido para cada simulação; (3) Desenvolvimento e teste de um modelo de ML de regressão; (4) Algoritmo de pós processamento, onde valores abaixo de determinado *threshold* foram considerados como plano de fundo.

Os resultados foram analisados de forma qualitativa e quantitativa (Erro percentual absoluto médio), sendo comparados com conhecidos métodos de reconstrução, o PDIPM e com o *Improved Gauss-Newton* (IGN). Finalmente, o método proposto obteve índice *kappa* e acurácia relevantes (97, 57% e 94, 60% respectivamente). Apesar disso, os autores reconheceram que o método necessita de aprimoramentos, especialmente para melhor detecção de objetos próximos à borda ou próximos a outros objetos, já que em muitos casos dois objetos eram reconstruídos como apenas um.

3.2 Considerações

Neste capítulo foram abordados diferentes métodos de reconstrução de imagens de TIE que têm sido desenvolvidos nos últimos anos. As propostas de cada um dos trabalhos abordados, assim como suas vantagens e desvantagens, estão resumidos na Tabela 3 a seguir. Na última linha, pode-se ainda observar as características do presente trabalho.

Tabela 3 – Resumo dos trabalhos relacionados

Trabalho	Proposta	Vantagens	Desvantagens
(LI et al., 2014)	Método iterativo para refinamento adaptativo de MEF	Melhora na resolução espacial e redução no custo de memória	Método parcialmente testado nos experimentos físicos e alto custo computacional de métodos iterativos
(MIAO; MA; WANG, 2014)	Limitar o espectro de condutividade em uma ROI	Redução da ordem matricial do problema direto e do custo computacional	Grande sensibilidade à ruídos
(WANG et al., 2016)	Reconstrução baseada na redução de amostras através do CS	Capaz de remover artefatos e ruídos efetivamente	Sensível a ruídos e reconstrução longa
(WANG; REN; DONG, 2018)	Reconstrução de OEIT baseada em transformação conforme	Melhor resolução espacial	Reconstrução pobre das bordas, formas e dimensões dos objetos
(WANG et al., 2012)	Resolução do problema inverso de TIE através do método estatístico <i>Expectation maximization</i>	Imagens com melhor resolução e menor erro relativo comparadas às obtidas com as tradicionais técnicas de Tikhinov e gradiente conjugado	Maior tempo de reconstrução

Tabela 3 – Resumo dos trabalhos relacionados


Trabalho	Proposta	Vantagens	Desvantagens
(BORSOI et al., 2018)	Aumentar a resolução de imagens de TIE com a técnica de <i>Super-Resolution Reconstruction</i>	Melhora na resolução espacial das imagens e reconstrução consistente	Alta complexidade computacional
(BARBOSA, 2017)	Reconstrução tratada como problema de otimização, usando algoritmos genéticos e Busca de cardume de peixes	Imagens consistentes com boa resolução espacial	Experimentos realizados apenas computacionalmente
(MARTIN; 2016a)	CHOI, RNAs e algoritmos de otimização para reconstrução	Alta fidelidade visual em relação à imagens originais	Dificuldade de estimação das bordas
(FERNÁNDEZ-FUENTES et al., 2018)	RNAs para resolução do problema inverso	Boa acurácia e índice Kappa	Dificuldade em detectar objetos próximos e na estimação das bordas
Presente trabalho	Utilização de ELMs de regressão para aproximação de sinogramas e posterior reconstrução por retroprojeção	Alta velocidade e boa capacidade de generalização das ELMs	Baixa resolução do <i>Backprojection</i> e dificuldade de distinguir objetos próximos

Fonte: A Autora (2019)

4 PROPOSTA: ELM e Backprojection para reconstrução de imagens de TIE

A metodologia seguida neste trabalho está esquematicamente descrita na Figura 18 abaixo, incluindo os principais passos realizados durante a pesquisa que serão detalhados futuramente.

Figura 18 – Metodologia geral do trabalho




Fonte: A Autora (2019)

4.1 Método de reconstrução proposto

O presente trabalho tem como proposta um novo método de reconstrução de imagens de Tomografia por Impedância Elétrica. Sugere-se o uso do algoritmo clássico de

Retroprojeção associado a Máquinas de Aprendizado Extremo de Regressão para obtenção de um método rápido e que mantenha uma boa resolução espacial. Nesse sentido, as ELMs são treinadas para gerar sinogramas a partir dos dados de potenciais elétricos medidos na superfície do domínio em estudo. Após essa etapa, esses sinogramas podem gerar imagens de TIE através da Retroprojeção, como apresentado no esquema da Figura 19.

Figura 19 – Método de reconstrução de imagens proposto



Fonte: A Autora (2017)

4.2 Experimentos propostos

Os códigos para geração do banco de imagens tomográficas e para implementação das reconstruções foram desenvolvidos em ambiente GNU/Octave¹, um *software* livre, com muitos *scripts* compatíveis com o Matlab.


Dessa forma, foi gerado um banco de 4000 imagens sintéticas de TIE de tamanho 128x128 pixels em escala de cinza. As imagens são compostas por um domínio circular branco e por objetos interiores a ele, em forma de círculos ou elipses. Os objetos tiveram suas posições, dimensões e tons determinados aleatoriamente pelo código, que possuía como entrada apenas a quantidade de objetos a serem inseridos. Assim, foram geradas imagens com 2 a 6 objetos interiores, como mostrado na Figura 20a.

As imagens geradas possuem intensidades que correspondem aos valores de condutividades elétricas. Visando facilitar o cálculo das diferenças de potenciais elétricos, o negativo das imagens foi obtido (Figura 20b), já que a resistividade é matematicamente o inverso da condutividade. Por fim, conhecendo-se a corrente elétrica injetada, pode-se obter os valores dos potenciais na borda.

Em seguida, foram posicionados 16 eletrodos equidistantes na borda do domínio. De forma a simplificar os cálculos, os valores de resistividades foram aproximados pela soma dos pixels em linha reta entre os eletrodos, mesmo que na prática as correntes elétricas

¹ *Software* disponível em: <www.gnu.org/software/octave/>

Figura 20 – Imagens sintéticas de TIE originais (a) e negativas (b)



Fonte: A Autora (2017)

Tabela 4 – Valores comparativos de resistividade de diferentes tecidos humanos

Tecidos	Média da Resistividade	95% de intervalo de confiança
Bexiga	447	288-693
Sangue	151	120-191
Osso	124×10^6	$91 \times 10^6 - 169 \times 10^6$
Gordura	3850	3046-4868
Coração	175	133-231
Rim	211	160-278
Fígado	342	296-396
Pulmão	157	122-202
Músculo	171	135-216
Pele	329	255-424


Fonte: Faes et al. (1999)

percorram caminhos de menor resistência. Futuramente, as intensidades dos pixels poderão ser aproximados pelos valores reais de resistividades dos tecidos humanos, aperfeiçoando, assim, os experimentos. A tabela 4, por exemplo, mostra a comparação de valores de resistividades de diversos tecidos biológicos. O estudo realizado por (FAES et al., 1999) apontou os valores médios de resistividade em um intervalo de 95% de confiança, de forma que os valores apresentados fossem estatisticamente significativos, já que a resistividade depende grandemente da frequência aplicada.

Além das 4000 imagens geradas, também foi necessária a geração dos 4000 sinogramas correspondentes a elas, que serão aqui chamados de Sinogramas padrão ouro. Eles são a saída desejada das ELMs de Regressão. Os sinogramas padrão ouro também foram reconstruídos por Retroprojeção (Reconstruções padrão ouro), permitindo uma posterior comparação com os resultados obtidos (Figura 21).

As imagens foram finalmente organizadas em arquivos com formato .ARFF (*Attri-*


Figura 21 – Reconstruções padrão ouro das imagens de TIE usando *Backprojection* a partir dos Sinogramas padrão ouro



Fonte: A Autora (2017)

bute Relation File Format), onde cada linha da matriz corresponde a uma única imagem do banco, enquanto as primeiras 240 colunas representam as diferenças de potenciais elétricos medidos pelos eletrodos (15 medições para cada eletrodo), seguidas por 128 colunas correspondentes aos sinogramas que tiveram seus valores dispostos em uma única linha. Totalizaram-se, assim, 16 arquivos preenchidos por matrizes 4000x368, cada um correspondendo a um dos eletrodos, como representado no esquema a seguir (Figura 22).

Figura 22 – Organização dos arquivos .ARFF



Fonte: A Autora (2017)

Dentre o banco de 4000 imagens, 100 imagens foram selecionadas de forma aleatória para um Teste Piloto. O mesmo teve como objetivo a determinação da melhor configuração da ELM para treinamento dos dados, ou seja, a escolha da função de ativação e do número de neurônios da camada escondida. Para isso, foi utilizado como base o código de ELM para Matlab proposto por (HUANG et al., 2012), sendo adaptado para a problemática deste trabalho e para o *software* GNU/Octave.

No teste piloto, foram realizados testes com as funções contínuas Sigmoidal, Senoidal e *Hard Limit*, disponíveis no código original e definidas matematicamente na Tabela 5. Foram ainda testados os Kernels linear, polinomial, RBF e de wavelet, com parâmetros definidos como mostrado na Tabela 6. Neste caso, alguns parâmetros de Kernel foram selecionados baseado em (SOUZA, 2010).

Para cada uma das funções foram realizados testes com 50 a 500 neurônios na camada escondida, variando com passos de 50. Para cada uma dessas configurações foram realizados 30 testes, utilizando tanto Divisão Percentual de $\frac{2}{3}$ quanto Validação cruzada com 10 *folds*, e tendo como medida de acurácia os Erro Médio Quadrático, calculado através da

Tabela 5 – Funções de ativação utilizadas no Teste piloto

Função contínua de ativação	Expressão matemática
Sigmoidal	$f(x) = \frac{1}{1+\exp(-(ax+b))}$
Senoidal	$f(x) = \sin(ax + b)$
Hard Limit	$f(x) = \begin{cases} 1, & \text{se } ax + b \geq 0 \\ 0, & \text{caso contrário} \end{cases}$

Fonte: A Autora (2017)

Tabela 6 – Configurações de Kernel utilizados no Teste Piloto

Kernel	Expressão matemática	Parâmetros
Linear	$K(x) = x \times x^T$	—
Polinomial	$K(x) = (x \times x^T + \alpha)^\beta$	$\beta = 2; 3; 4; 5$
RBF	$K(x) = \exp(-\gamma \ x - x^T\ ^2)$	$\gamma = 0, 2; 0, 05; 0, 02; 0, 0125; 0, 01$
Wavelet	$K(x) = \prod_{i=1}^N h(\frac{x-x^T}{a})$ onde $h(x) = \cos(1,75x)\exp(-\frac{x^2}{2})$	$\alpha = 1; 4$

Fonte: A Autora (2017)

equação 4.1 e o Erro percentual, encontrado realizando a média entre os valores do vetor resultante da equação 4.2.


$$Erro_{MedioQuadratico} = \sqrt{\frac{\sum_{i=1}^N (T_i - Y_i)^2}{N}} \quad (4.1)$$

$$Erro_{percentual} = \frac{(T - Y)}{T} \quad (4.2)$$

onde N é o número de elementos da matriz (*linhas* $\times$ *colunas*), T o conjunto de treinamento e Y a matriz de saída após o treinamento.


Assim, as melhores configurações são aquelas com menor erro possível, ou seja, cujas matrizes, após o treinamento, têm maior aproximação com das matrizes de entrada. Por fim, os melhores resultados obtidos para cada tipo de função de ativação e kernel podem ser resumidos pelo *boxplot* abaixo na Figura 23. Como podem ser observadas, as configurações com 500 neurônios na camada escondida foram selecionadas por apresentarem resultados superiores. Como as métricas usadas não apresentaram variação significativa entre 400 e 500 neurônios, foi mantido o número de 500 neurônios como limite na realização dos testes. Nota-se, ainda, que a função Senoidal apresentou erros muito maiores que as demais funções, sendo as mesmas plotadas novamente para serem melhor analisadas, como na Figura 24.

Figura 23 – Comparação entre diferentes funções contínuas de ativação



Fonte: A Autora (2018)

Figura 24 – Comparação entre as melhores funções contínuas de ativação



Fonte: A Autora (2018)

Por fim, como a função Sigmoidal com 500 neurônios na camada escondida apresentou menores erros além de uma menor dispersão dos resultados, a mesma foi escolhida para futuro treinamento das ELMs com toda a base de imagens sintéticas de TIE.

Os experimentos foram realizados utilizando um computador com sistema operacional Windows 10, processador Intel Core i7-5500U CPU com 2.40GHz e memória RAM de 8GB, com o GNU/Octave versão 4.2.1.

4.3 Considerações

Neste trabalho foram implementados algoritmos de reconstrução de imagens de TIE em ambiente GNU/Octave. Um banco de 4000 imagens sintéticas de TIE foi desenvolvido,

consistindo de imagens com domínios circulares, todas em escala de cinzas e de 128×128 *pixels* de dimensão. Através da soma dos *pixels*, foram determinados os potenciais elétricos em cada um dos 16 eletrodos de borda. Os sinogramas e reconstruções por retroprojeção também foram gerados, ambos funcionando como padrão ouro. As Máquinas de Aprendizado Extremo, por sua vez, foram adaptadas para o *software* e para o problema a partir das implementações propostas por (HUANG, 2015) em Matlab. Neste capítulo ainda foram apresentadas as metodologias e considerações usadas para escolha da melhor configuração de ELM para posterior validação da proposta, sendo escolhida a função Sigmoidal com 500 neurônios na camada escondida.

5 RESULTADOS E DISCUSSÃO


Neste capítulo serão apresentados os resultados das reconstruções de imagens de TIE utilizando o método proposto. Os resultados foram avaliados de forma qualitativa, através da comparação visual com os padrões ouro, assim como quantitativamente, com o cálculo do Índice de Similaridade Estrutural (*Structural Similarity Index, SSIM*) e a Relação sinal-ruído de pico (*Peak Signal-to-Noise ratio, PSNR*) em décibéis.

5.1 Resultados

De acordo com o Teste Piloto realizado, foi escolhida, dentre as testadas, a função contínua de ativação Sigmoidal, ressaltada na Figura 25, com 500 neurônios na camada escondida. Assim, 16 diferentes Redes Neurais do tipo Máquinas de aprendizado extremo de regressão foram treinadas, cada uma tentando modelar um dos 16 eletrodos posicionados na superfície do domínio. Para isso, utilizaram-se as 4000 imagens originais do banco de dados.

Com as ELMs já treinadas, obteve-se, portanto, um método de reconstrução para resolução do problema inverso de TIE pronto, composto pela função que modela os potenciais elétricos de borda em sinogramas e pelo algoritmo de *Backprojection*. Dessa maneira, a técnica proposta tornou-se muito rápida, gerando imagens em poucos segundos, e podendo ser aplicada em diferentes e diversas imagens sem necessidade de novos treinamentos, que mesmo sendo rápidos no caso das ELMs, constituem a fase de maior custo computacional. Por conseguinte, as reconstruções finais foram geradas, como mostrado na Figura 26c.

Figura 25 – Função de ativação contínua Sigmoidal



















Fonte: Zhang et al. (2017)

Como o banco de imagens sintéticas criado consiste apenas de imagens em escala de cinzas, optou-se por representá-las também com uma paleta de cores selecionadas. Para este propósito, existe a função *jet* disponível no Octave, que retorna um mapa de

















cores contendo diferentes intensidades de vermelho, verde e azul, sendo o tamanho do mapa definido pelo usuário. Escolheu-se para este fim 255 tonalidades, gerando, então, as imagens da Figura 27c.

Figura 26 – Comparação das imagens e reconstruções padrão ouro com as reconstruções realizadas com o método proposto a partir do conjunto de treino

Reconstruções de imagens de TIE a partir do conjunto de treino								
Imagens originais (a)								
Reconstrução padrão ouro (b)								
Reconstrução pelo método proposto (c)								
PSNR entre (b) e (c)	38.985 dB	44.554 dB	40.527 dB	41.093 dB	47.164 dB	47.023 dB	44.753 dB	46.693 dB
SSIM entre (b) e (c)	0.93166	0.95131	0.95443	0.92764	0.96484	0.93636	0.89113	0.96262
PSNR entre (a) e (c)	9.5668 dB	10.0543 dB	9.5064 dB	9.2408 dB	9.8509 dB	9.7029 dB	9.4463 dB	9.5697 dB
SSIM entre (a) and (c)	0.030888	0.022824	0.028918	0.030120	0.028063	0.023810	0.027669	0.026667

Fonte: A Autora (2018)

Figura 27 – Representação das reconstruções do conjunto de treino em pseudocores















Reconstruções de imagens de TIE a partir do conjunto de treino								
Imagens originais (a)								
Reconstrução pelo método proposto em escala de cinzas (b)								
Reconstrução pelo método proposto em pseudo-cor (c)								

Fonte: A Autora (2018)

A fim de melhor avaliar o processo de treinamento das redes, um conjunto de novas imagens foi criado, funcionando como um conjunto de teste. Dessa forma, é possível observar a capacidade de generalização das ELMs e garantir elas de fato aprenderam o

















algoritmo e não apenas memorizaram o conjunto a elas apresentado durante o treinamento. Nesse contexto, o resultado dessas reconstruções podem ser observados na Figura 28c.

Figura 28 – Comparação das imagens e reconstruções padrão ouro com as reconstruções realizadas com o método proposto a partir do conjunto de teste

Reconstruções de imagens de TIE a partir do conjunto de teste								
Imagens originais (a)								
Reconstrução padrão ouro (b)								
Reconstrução pelo método proposto (c)								
PSNR entre (b) e (c)	51.434 dB	55.485 dB	36.316 dB	49.472 dB	49.515 dB	44.687 dB	42.688 dB	45.167 dB
SSIM entre (b) e (c)	0.97598	0.98995	0.95813	0.96139	0.96257	0.93634	0.94396	0.92311
PSNR entre (a) e (c)	10.1184 dB	10.4315 dB	9.6230 dB	10.0307 dB	10.1531 dB	10.0401 dB	9.6140 dB	9.3845 dB
SSIM entre (a) and (c)	0.023612	0.018732	0.030955	0.024403	0.022958	0.023325	0.028007	0.028100

Fonte: A Autora (2018)

Figura 29 – Representação das reconstruções do conjunto de treino em pseudocores

Reconstruções de imagens de TIE a partir do conjunto de teste								
Imagens originais (a)								
Reconstrução pelo método proposto em escala de cinzas (b)								
Reconstrução pelo método proposto em pseudo-cor (c)								

Fonte: A Autora (2018)

Como métricas de avaliação das imagens reconstruídas, foram escolhidos a Relação Sinal-Ruído de pico (*Peak Signal-to-noise ratio, PSNR*) e o Índice de Similaridade Estrutural (*Structural similarity index, SSIM*). A PSNR é uma forma de analisar a qualidade da imagem reconstruída, assim como as perdas de informações, em comparação à imagem padrão

ouro, quantificando o quanto a primeira é fiel à segunda (FARDO et al., 2016; SALOMON, 2004; ZIMBICO, 2014). O PSNR pode ser determinado pelas equações 5.1 e 5.2 a seguir:

$$PSNR = 20 \log \frac{MAX_X^2}{MSE}, \quad (5.1)$$

onde

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [X(i, j) - Y(i, j)]^2. \quad (5.2)$$

X e Y representam as imagens a ser comparadas, enquanto MAX_X representa o *pixel* de maior valor da imagem de referência X .

Como ambas as unidades do numerador e do denominador do PSNR são as mesmas, não há dimensão. Porém, por conta do uso do logaritmo, o PSNR é normalmente expresso em décibéis (dB). Pode-se ainda dizer que os valores de PSNR são usados unicamente para comparação de performance de diferentes tipos de reconstruções ou compressões e, por isso, não há um *threshold* estabelecido para se determinar se a imagem é boa ou não (SALOMON, 2004).

O índice de Similaridade estrutural, por outro lado, não estabelece erros absolutos como o PSNR, mas considera informações estruturais, analisando a relação de *pixels* espacialmente próximos. Dessa forma, o SSIM auxilia na detecção dos objetos interiores ao domínio em estudo, assim como a borda desse domínio (WANG et al., 2004). O SSIM entre duas imagens x e y é dado por 5.3:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (5.3)$$


onde μ_x é a média da imagem x , μ_y a média da imagem y , σ_x^2 e σ_y^2 as variâncias, σ_{xy} a covariância entre as imagens. As variáveis $c_1 = (k_1L)^2$ e $c_2 = (k_2L)^2$ estabilizam o denominador e são dependentes da faixa dinâmica dos valores dos *pixels* L e de k_1 e k_2 , escolhidos por padrão como 0,01 e 0,03, respectivamente (ZIMBICO, 2014).

Finalmente, os valores de PSNR e SSIM foram calculados, ainda em ambiente GNU/Octave e apresentados nas Figuras 26 e 28, onde altos valores de PSNR em dB indicam alta proximidade entre as imagens, enquanto os SSIM próximos a 1, correspondem à alta correlação estrutural. Essas métricas são mostradas nas Figuras 26 e 28 e também estão resumidas nos Boxplots das Figura 30 abaixo.

5.2 Discussão

Ao analisar os resultados qualitativamente, pode-se perceber uma significativa similaridade entre as reconstruções (Figura 26c) com as reconstruções padrão ouro (Figura 26b), com a diferença de um leve borramento em (c), o que mostra a efetividade das ELMs

Figura 30 – Boxplots do PSNR e SSIM



Fonte: A Autora (2018)

na geração dos sinogramas. Além disso, os índices de similaridade estrutural entre elas são próximos de 1, indicando alta correlação estrutural entre as imagens. Esses dados apontam que o posicionamento do domínio estudado e dos objetos inseridos nele está adequado, além de que estes objetos foram reconstruídos em sua maioria, mesmo os que possuíam intensidades mais suaves.

A Figura 26 mostra ainda a comparação entre as reconstruções de (c) com as imagens padrão ouro (a). Percebe-se que ambos os parâmetros, PSNR e SSIM, apresentaram considerável diminuição e, conseqüentemente, na qualidade das imagens. Apesar disso, há consistência visual entre as imagens, sendo possível, em grande parte, distinguir as bordas e o tamanho das estruturas presentes. As mesmas conclusões podem ser feitas com os resultados do conjunto de teste (Figura 28), o que leva a crer que as redes foram devidamente treinadas e não que simplesmente decoraram as informações a elas apresentadas na fase de treinamento.

Examinando, desta feita, as imagens em pseudocores apresentadas nas Figuras 27 e 29, é possível ver que este formato não trouxe importante acréscimo de informações a respeito das reconstruções. Em geral, os meios que preenchem os domínios circulares foram representados pelos tons mais quentes, próximos ao vermelho, enquanto objetos internos puderam ser visualizados com tonalidades mais frias, entre o verde e o azul. Apesar das cores manterem o padrão de distribuição dos objetos ainda consistentes com as imagens padrão ouro, nota-se que os de tonalidades mais suaves foram omitidos e camuflados pelos meios que os envolvem.

Por fim, os boxplots dos PSNR e SSIM da Figura 30 apontaram a distribuição e dispersão das métricas de avaliação. No caso do PSNR entre as reconstruções (a), o valor mediano foi de 45dB e dispersão de cerca de 10dB. Comparando as reconstruções com o método proposto e as imagens padrão ouro (b), por outro lado, há uma queda no intervalo de dispersão, assim como na mediana, que está próxima de 9,6dB. Simultaneamente, os SSIM seguem o mesmo caminho, atingindo altos valores em (a), em média 0.9, e caindo para

próximo de zero em (b).

Em suma, as métricas apontam a boa capacidade de generalização e velocidade das máquinas de aprendizado extremo. Elas foram capazes de aproximar os potenciais de borda em sinogramas de maneira bastante eficaz, sendo difícil a distinção visual entre as reconstruções pelo método proposto e as reconstruções padrão ouro. Entretanto, os resultados mostraram ainda que o algoritmo de linearização *Backprojection* não permite uma boa visualização dos contornos, causando leve borramento das imagens e camuflando objetos de baixa intensidade. Tendo isto em vista, acredita-se na importância da aplicação de técnicas de pós-processamento objetivando aprimorar a qualidade final das imagens e atenuar as distorções.

5.3 Considerações

Este capítulo apresentou os resultados obtidos com o algoritmo proposto baseado em máquinas de aprendizado extremo e retroprojeção. A análise foi feita em um banco de 4000 imagens sintéticas de Tomografia por impedância elétrica, todas em escalas de cinza.

As reconstruções foram apresentadas tanto para o conjunto de treino, quanto para um novo conjunto de imagens criado para testes. Com o objetivo de se ter uma melhor investigação visual dos resultados, as imagens também foram mostradas em pseudocores. Paralelamente, a Relação Sinal-Ruído de pico e o Índice de Similaridade Estrutural foram usados como métricas de comparação, englobando características tanto espaciais quanto valores absolutos na análise.

Por fim, as reconstruções indicaram grande semelhança com as reconstruções padrão ouro, alcançando valores de SSIM próximos a 1 e PSNR na faixa de 45dB, indicando que o método proposto se aproxima de uma reconstrução puramente obtida por *Backprojection*. Quando comparadas com as imagens padrão ouro, por sua vez, as métricas tiveram seus valores reduzidos. Apesar disso, as reconstruções indicaram consistência quanto aos formatos e localizações tanto do domínio, quanto dos objetos interiores a ele.

6 CONCLUSÃO

A Tomografia por impedância elétrica é uma técnica promissora que pode contribuir para um diagnóstico médico mais preciso quando combinado com outras técnicas de imageamento. Ela faz uso das propriedades elétricas de um meio para obtenção de imagens e, por isso, pode-se utilizar as consideráveis diferenças de resistividades dos tecidos e órgãos humanos como contraste. A TIE é não invasiva, segura e livre de radiações nocivas à saúde. Seu equipamento pode ainda ser de baixo custo e de pequenas dimensões, facilitando seu uso em diversas aplicações e contextos.

Matematicamente, o processo de reconstrução de TIE é dado pela resolução dos problemas direto e inverso, o qual não possui solução única, além de ser não-linear e mal-posto. Por conta disso, apesar dos seus benefícios da técnica, a TIE é ainda pouco difundida e utilizada, em decorrência da sua baixa resolução espacial e baixa velocidade de reconstrução, necessitando da implementação de um novo método de reconstrução rápido e eficiente.

Assim, neste trabalho foi demonstrada uma proposta inovadora baseada em Máquinas de aprendizado extremo e no clássico algoritmo de retroprojeção. As ELMs são redes neurais artificiais supervisionadas, famosas pela boa capacidade de generalização, alta velocidade e por dispensar a escolha de parâmetros iniciais. Portanto, o trabalho sugeriu o uso das ELMs para criação de sinogramas a partir dos dados de potenciais elétricos do domínio estudado. Em sequência, os sinogramas puderam ser facilmente reconstruídos pela técnica de retroprojeção para geração final de imagens, onde os objetos e o domínio estão representados.

Os experimentos foram realizados por completo em ambiente GNU/Octave e uma base de 4000 imagens sintéticas de TIE foi construída para testar e validar este projeto. As imagens estão em escalas de cinzas, com dimensões de 128×128 *pixels*. As ELMs utilizadas foram baseadas em implementações para Matlab de outros trabalhos disponíveis, sofrendo pequenas modificações para o problema descrito e para o *software* escolhido.

Finalmente, o método foi capaz de reconstruir rapidamente imagens consistentes e razoáveis. Resultados estes comprovados pela inspeção visual e pelas métricas de avaliação — o Índice de Similaridade Estrutural e a Relação sinal-ruído de pico. Por conseguinte, o método tem potencial na obtenção de imagens de TIE e pode contribuir para o estado da arte de técnicas de imagem.

6.1 Dificuldades encontradas

A principal dificuldade encontrada neste trabalho foi a utilização de Máquinas de aprendizado extremo de regressão. Apesar das ELMs terem sido propostas por (HUANG; ZHU; SIEW, 2006) há pouco mais de uma década, sua disseminação e utilização tem sido consolidada nos últimos cinco anos. Além disso, os trabalhos em sua maioria lidam com problemas de classificação, diferentemente da proposta desse trabalho, que é de regressão. Desse modo, a literatura ainda é limitada quanto a sua utilização.

Pode-se ainda salientar que o método descrito é inovador, e, na forma que foi aqui descrita, não há referências similares no estado da arte. Como resultado, muitas decisões sobre a condução do trabalho foram tomadas de forma mais intuitiva pelos pesquisadores, com base nas suas experiências profissionais. Esta questão ainda dificultou o estabelecimento de métricas de avaliação, a seleção de parâmetros e a comparação dos resultados.

6.2 Contribuições

Os resultados parciais da presente pesquisa geraram diversas contribuições para a academia e com grande potencial de crescimento e aperfeiçoamento. Dentre elas, ressaltam-se:

- Revisão do estado da arte da Tomografia por impedância elétrica e Redes neurais Artificiais, em especial máquinas de aprendizado extremo.
- Geração de um banco de imagens sintéticas de TIE, com possibilidade de ser expandido.
- Proposta de um método rápido e inovador de reconstrução de imagens de TIE.
- Adaptação e implementação de algoritmos de máquinas de aprendizado extremo e retroprojeção *open-software* para resolução do problema inverso de TIE.
- Avaliação de diferentes configurações de ELMs para modelar os potenciais elétricos medidos em sinogramas.
- Validação do método proposto através de experimentos computacionais.
- Participação e publicação em eventos nacionais.
- Publicação de um capítulo de um livro internacional.
- Submissão em processo de aprovação para uma revista internacional *Computers and Electrical Engineering*.

Na tabela 7 a seguir detalha-se as principais publicações alcançadas por meio deste trabalho.

Tabela 7 – Contribuições geradas pelos resultados parciais desta pesquisa

Título do artigo/Capítulo	Evento/Periódico/Livro	Ano
Reconstrução de imagens de Tomografia por impedância elétrica usando <i>Extreme Learning Machine</i> de Regressão (GOMES; SOUZA; SANTOS, 2018)	XXII Congresso Brasileiro de Automática	2018
Reconstrução de imagens de Tomografia por impedância elétrica baseada em Máquinas de aprendizado extremo e <i>Backprojection</i> (GOMES et al., 2018)	II Simpósio de inovação em Engenharia Biomédica	2018
Algoritmo de Evolução diferencial hibridizado e <i>Simulated Annealing</i> aplicados a Tomografia por Impedância Elétrica (OGAVA et al., 2017)	I Simpósio de inovação em Engenharia Biomédica	2017
Hybrid Metaheuristics Applied to Image Reconstruction for an Electrical Impedance Tomography Prototype (SANTOS et al., 2018a)	Hybrid Metaheuristics for Image Analysis	2018
Electrical Impedance Tomography Image Reconstruction based on Backprojection and Extreme Learning Machine	Em revisão pela Computers and Electrical Engineering	-

6.3 Trabalhos futuros

Como forma de aprimorar os resultados obtidos, recomenda-se a aplicação de técnicas de pós-processamento de imagens nas reconstruções geradas. Para isso, propõe-se a utilização de algoritmos de classificação não supervisionada para agrupamento de dados (*clustering*), em especial o método de Campos aleatórios condicionais (*Conditional random fields*, CRF). O CRF é um método de modelamento estatístico que pode ser utilizado como classificador. Eles são capazes de prever as estruturas internas de um domínio, tendo como característica importante o fato de considerarem a vizinhança no processo de rotulamento.

Diante disso, planeja-se adicionar esta etapa de pós-processamento na metodologia abordada neste trabalho, considerando os seguintes passos: Para cada pixel da imagem

reconstruída, um vetor de características deve ser gerado, considerando sua posição geométrica e intensidade. Em seguida, os pixels devem ser inicialmente agrupados a partir de um *threshold* de intensidade. Em terceiro lugar, deverá ser aplicado o método CRF de agrupamento na imagem inicialmente rotulada, e, por fim, realizar a reconstrução baseada em *clusters*, forçando o mesmo valor de condutividade para pixels dentro de um mesmo grupo (GONG; KRUEGER-ZIOLEK; MOELLER, 2018).

Em paralelo a este trabalho, o Grupo de Computação Biomédica da UFPE também tem desenvolvido um aparelho *open-hardware* de tomografia por impedância elétrica. Dessa forma, futuramente será possível testar o método de reconstrução proposto não apenas computacionalmente, mas com experimentos físicos, fazendo uso de *phantoms* reais.

Finalmente, pode-se ainda experimentar outras redes neurais artificiais para aproximação de sinogramas, especialmente as de arquiteturas profundas. Além disso, poderá ser implementada uma ferramenta computacional *open-source* para reconstruir imagens de TIE utilizando a abordagem proposta.

Referências

- BANTA, D. The development of health technology assessment. **Health policy**, Elsevier, v. 63, n. 2, p. 121–132, 2003.
- BARBER, D.; BROWN, B. Errors in reconstruction of resistivity images using a linear reconstruction technique. **Clinical Physics and Physiological Measurement**, IOP Publishing, v. 9, n. 4A, p. 101, 1988.
- BARBOSA, V. A.; RIBEIRO, R. R.; FEITOSA, A. R.; SILVA, V. da; ROCHA, A. D.; FREITAS, R. C.; SOUZA, R. E. de; SANTOS, W. P. dos. Reconstrução de imagens de tomografia por impedância elétrica usando cardume de peixes, busca não-cega e algoritmo genético. *In*: CONGRESSO BRASILEIRO DE INTELIGÊNCIA COMPUTACIONAL, 12, 2015, Curitiba, PR. **Anais [...]**. Curitiba, PR: ABRICOM, 2015. p. 1–6.
- BARBOSA, V. A.; RIBEIRO, R. R.; FEITOSA, A. R.; SILVA, V. L.; ROCHA, A. D.; FREITAS, R. C.; SOUZA, R. E.; SANTOS, W. P. Reconstruction of electrical impedance tomography using fish school search, non-blind search, and genetic algorithm. **International Journal of Swarm Intelligence Research**, IGI Global, v. 8, n. 2, p. 17–33, 2017.
- BARBOSA, V. A. d. F. **Reconstrução de imagens de tomografia por impedância elétrica utilizando busca por cardumes de peixes e evolução diferencial**. 2017. Dissertação (Mestrado em Engenharia Biomédica) — Universidade Federal de Pernambuco, Recife, 2017.
- BARBOSA, V. A. de F.; SANTOS, W. P. dos; SOUZA, R. E. de; RIBEIRO, R. R.; FEITOSA, A. R. S.; SILVA, V. L. B. A. da; RIBEIRO, D. E.; FREITAS, R. C.; PASCHOAL, M.; SOARES, N. S. et al. Image reconstruction of electrical impedance tomography using fish school search and differential evolution. *In*: SHI, Y. **Critical Developments and Applications of Swarm Intelligence**. IGI Global, 2018. p. 301–338.
- BARRA, D. C. C.; NASCIMENTO, E. R. P. d.; MARTINS, J. d. J.; ALBUQUERQUE, G. L.; ERDMANN, A. L. Evolução histórica e impacto da tecnologia na área da saúde e da enfermagem. **Revista Eletrônica de Enfermagem**, Directory of Open Access Journals, v. 8, n. 03, p. 422–430, 2006.
- BARTLETT, P. L. For valid generalization the size of the weights is more important than the size of the network. *In*: NEURAL INFORMATION PROCESSING SYSTEMS CONFERENCE, 10, 1997, Denver. **Proceedings [...]**. Denver: 1997. p. 134–140.

- BAUDAT, G.; ANOUAR, F. Kernel-based methods and function approximation. *In*: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2001. **Proceedings [...]**. IJCNN'01, 2001. v. 2, p. 1244–1249.
- BERA, T. K.; BISWAS, S. K.; RAJAN, K.; NAGARAJU, J. Improving image quality in electrical impedance tomography (eit) using projection error propagation-based regularization (pepr) technique: a simulation study. **Journal of Electrical Bioimpedance**, v. 2, n. 1, p. 2–12, 2011.
- BEUTEL, J.; KUNDEL, H. L.; METTER, R. L. V. **Handbook of medical imaging**. Spie Press, 2000. v. 1.
- BORGES, R. R.; IAROSZ, K. C.; BATISTA, A. M.; CALDAS, I. L.; BORGES, F. S.; LAMEU, E. L. Sincronização de disparos em redes neuronais com plasticidade sináptica. **Caderno Brasileiro de Ensino de Física**, v. 37, n. 2, 2015.
- BORSOI, R. A.; AYA, J. C. C.; COSTA, G. H.; BERMUDEZ, J. C. M. Super-resolution reconstruction of electrical impedance tomography images. **Computers & Electrical Engineering**, Elsevier, v. 69, p. 1–13, 2018.
- BOUCHETTE, G.; CHURCH, P.; MCFEE, J. E.; ADLER, A. Imaging of compact objects buried in underwater sediments using electrical impedance tomography. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 52, n. 2, p. 1407–1417, 2014.
- BRASIL, S. D. *Bíblia De Estudo Genebra*. **Sociedade Bíblica**, 1999. ISBN 9788531102974. Disponível em: <https://books.google.com.br/books?id=PSHXPgAACAAJ>.
- CHENEY, M.; ISAACSON, D.; NEWELL, J. C. Electrical impedance tomography. **SIAM review**, SIAM, v. 41, n. 1, p. 85–101, 1999.
- CHEREPENIN, V.; KARPOV, A.; KORJENEVSKY, A.; KORNIENKO, V.; MAZALETSKAYA, A.; MAZOUROV, D.; MEISTER, D. A 3d electrical impedance tomography (eit) system for breast cancer detection. **Physiological measurement**, IOP Publishing, v. 22, n. 1, p. 9, 2001.
- DAI, M.; LI, B.; HU, S.; XU, C.; YANG, B.; LI, J.; FU, F.; FEI, Z.; DONG, X. In vivo imaging of twist drill drainage for subdural hematoma: a clinical feasibility study on electrical impedance tomography for measuring intracranial bleeding in humans. **PloS one**, Public Library of Science, v. 8, n. 1, p. e55020, 2013.
- D'ANTONA, G.; FERRERO, A.; LAZZARONI, M.; OTTOBONI, R.; SAMARANI, E. Active monitoring apparatus for underground pollutant detection based on electrical impedance tomography. *In*: INSTRUMENTATION AND MEASUREMENT CONFERENCE, 19, 2002. **Proceedings [...]**. IMTC, 2002. v. 1, p. 577–579.

DENG, W.; ZHENG, Q.; CHEN, L. Regularized extreme learning machine. *In: SYMPOSIUM ON COMPUTATIONAL INTELLIGENCE AND DATA MINING*, 2009. **Proceedings [...]**. CIDM'09, 2009. p. 389–395.

DOI, K. Computer-aided diagnosis in medical imaging: historical review, current status and future potential. **Computerized medical imaging and graphics**, Elsevier, v. 31, n. 4-5, p. 198–211, 2007.

EICKEMBERG, M.; OLIVEIRA, C. C. de; CARNEIRO, R. A. K.; SAMPAIO, L. R. Bioimpedância elétrica e sua aplicação em avaliação nutricional. **Revista de Nutrição**, Directory of Open Access Journals, v. 24, n. 6, p. 873–882, 2011.

EULÁLIO, A.; RIBEIRO, L. R.; SANTOS, W. P. dos. Electrical impedance tomography imaging: Principles and reconstruction algorithms. **Medical Imaging: Procedures, Techniques and Applications**, Nova Science Publishers, v. 1, p. 83–98, 2012.

FAES, T.; MEIJ, H. Van der; MUNCK, J. D.; HEETHAAR, R. The electric resistivity of human tissues (100 hz-10 mhz): a meta-analysis of review studies. **Physiological measurement**, IOP Publishing, v. 20, n. 4, p. R1, 1999.

FARDO, F. A.; CONFORTO, V. H.; OLIVEIRA, F. C. de; RODRIGUES, P. S. A formal evaluation of psnr as quality measurement parameter for image segmentation algorithms. **arXiv preprint arXiv:1605.07116**, 2016.

FAVORETTO, S. **Máquinas de aprendizado extremo aplicadas à identificação de pessoas através de eletrocardiograma (ECG)**. 2016. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Tecnológica Federal do Paraná, 2016.

FEITOSA, A. R.; RIBEIRO, R. R.; BARBOSA, V. A.; SOUZA, R. E. de; SANTOS, W. P. dos. Reconstruction of electrical impedance tomography images using chaotic ring-topology particle swarm optimization and non-blind search. *In: IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN AND CYBERNETICS*, 2014. p. 2618–2623.

FEITOSA, A. R. S. **Reconstrução de imagens de tomografia por impedância elétrica utilizando o método dialético de otimização**. 2015. Dissertação (Mestrado em Engenharia Biomédica) — Universidade Federal de Pernambuco, Recife, 2015.

FERNÁNDEZ-FUENTES, X.; MERA, D.; GÓMEZ, A.; VIDAL-FRANCO, I. Towards a fast and accurate eit inverse problem solver: A machine learning approach. **Electronics**, Multidisciplinary Digital Publishing Institute, v. 7, n. 12, p. 422, 2018.

FILIPOWICZ, S. F.; RYMARCZYK, T. Measurement methods and image reconstruction in electrical impedance tomography. **Przegląd Elektrotechniczny**, v. 88, n. 6, p. 247–250, 2012.

FREITAS, R. C. de; RIBEIRO, D. E.; SILVA, V. L. B. A. da; BARBOSA, V. A. de F.; FEITOSA, A. R. S.; RIBEIRO, R. R.; SOUZA, R. E. de; SANTOS, W. P. dos. Electrical impedance tomography using evolutionary computing: A review. *In: ACHARJYA, D. P.; SANTHI, V. Bio-Inspired Computing for Image and Video Processing*. Chapman and Hall/CRC, 2018. p. 93–128.

GOMES, J. C.; OGAVA, R.; SOUZA, R. E. de; SANTOS, W. P. dos. Reconstrução de imagens de tomografia por impedância elétrica baseada em máquinas de aprendizado extremo e backprojection. *In: SIMPÓSIO DE INOVAÇÃO EM ENGENHARIA BIOMÉDICA*, 2, 2018, Recife, PE. **Anais [...]**. Recife, PE: SABIO - Universidade Federal de Pernambuco, 2018. p. 27–30. Disponível em: <https://drive.google.com/file/d/1A05SHzlzltmqRasaYkvkz32Q6p34F4Jo/view>.

GOMES, J. C.; SOUZA, R. E. de; SANTOS, W. P. dos. Reconstrução de imagens de tomografia por impedância elétrica usando extreme learning machine de regressão. *In: CONGRESSO BRASILEIRO DE AUTOMÁTICA*, 22, 2018, João Pessoa, PB. **Anais [...]**. João Pessoa, PB: 2018. Disponível em: <https://ssl4799.websiteseuro.com/swge5/PROCEEDINGS/PDF/CBA2018-0306.pdf>.

GONG, B.; KRUEGER-ZIOLEK, S.; MOELLER, K. An efficient classification-reconstruction method for 3d eit imaging. **IFAC-PapersOnLine**, Elsevier, v. 51, n. 27, p. 36–40, 2018.

HALLAJI, M.; SEPPÄNEN, A.; POUR-GHAZ, M. Electrical impedance tomography-based sensing skin for quantitative imaging of damage in concrete. **Smart Materials and Structures**, IOP Publishing, v. 23, n. 8, p. 085001, 2014.

HAMILTON, S. J.; HAUPTMANN, A. Deep d-bar: Real time electrical impedance tomography imaging with deep neural networks. **IEEE Transactions on Medical Imaging**, IEEE, 2018.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. São Paulo: Bookman Editora, 2007.

HERMAN, G. T. Image reconstruction from projections. **Real-Time Imaging**, Elsevier, v. 1, n. 1, p. 3–18, 1995.

HERRERA, C. N. L. **Algoritmo de tomografia por impedância elétrica baseado em Simulated Annealing**. 2008. Dissertação (Mestrado em Engenharia Mecânica) — Universidade de São Paulo, 2008.

HOLDER, D. S. **Electrical impedance tomography: methods, history and applications**. Londres: CRC Press, 2004.

HONG, S.; LEE, K.; HA, U.; KIM, H.; LEE, Y.; KIM, Y.; YOO, H.-J. A 4.9 mW-sensitivity mobile electrical impedance tomography ic for early breast-cancer detection system. **IEEE Journal of Solid-State Circuits**, IEEE, v. 50, n. 1, p. 245–257, 2015.

HOU, T.-C.; LYNCH, J. P. Electrical impedance tomographic methods for sensing strain fields and crack damage in cementitious structures. **Journal of Intelligent Material Systems and Structures**, Sage Publications Sage UK: London, England, v. 20, n. 11, p. 1363–1379, 2009.

HOVNANIAN, A. L. D. **Papel da tomografia de impedância elétrica em pacientes portadores de hipertensão arterial pulmonar**. 2013. Tese (Doutorado em Ciências) — Universidade de São Paulo, 2013.

HSIEH, J. **Computed tomography**: principles, design, artifacts, and recent advances. *In*: SPIE BELLINGHAM, WA. 2009.

HUANG, G.-B. An insight into extreme learning machines: random neurons, random features and kernels. **Cognitive Computation**, Springer, v. 6, n. 3, p. 376–390, 2014.

HUANG, G.-B. What are extreme learning machines? filling the gap between frank rosenblatt's dream and john von neumann's puzzle. **Cognitive Computation**, Springer, v. 7, n. 3, p. 263–278, 2015.

HUANG, G.-B.; ZHOU, H.; DING, X.; ZHANG, R. Extreme learning machine for regression and multiclass classification. **IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)**, IEEE, v. 42, n. 2, p. 513–529, 2012.

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: theory and applications. **Neurocomputing**, Elsevier, v. 70, n. 1-3, p. 489–501, 2006.

HUBER, N.; BÉGO, N.; ADAMS, C.; SZE, G.; TUNSTALL, B.; QIAO, G.; WANG, W. Further investigation of a contactless patient-electrode interface of an electrical impedance mammography system. *In*: IOP PUBLISHING. **Journal of Physics: Conference Series**. [S.l.], 2010. v. 224, n. 1, p. 012166.

ISMAIL, I.; GAMIO, J.; BUKHARI, S. A.; YANG, W. Tomography for multi-phase flow measurement in the oil industry. **Flow Measurement and Instrumentation**, Elsevier, v. 16, n. 2-3, p. 145–155, 2005.

JIANG, F.; JIANG, Y.; ZHI, H.; DONG, Y.; LI, H.; MA, S.; WANG, Y.; DONG, Q.; SHEN, H.; WANG, Y. Artificial intelligence in healthcare: past, present and future. **Stroke and vascular neurology**, BMJ Specialist Journals, v. 2, n. 4, p. 230–243, 2017.

JORDANA, J.; GASULLA, M.; PALLÁS-ARENY, R. Leakage detection in buried pipes by electrical resistance imaging. *In*: WORLD CONGRESS ON INDUSTRIAL PROCESS TOMOGRAPHY, 1999. **Proceedings [...]**. Buxton, 1999, v. 5, p. 28–34.

JR, W. H. H.; KEMMERLY, J. E.; DURBIN, S. M. **Análise de Circuitos em Engenharia-8**. AMGH Editora, 2014.

- KOSHEV, N.; HELOU, E. S.; MIQUELES, E. X. Fast backprojection techniques for high resolution tomography. **arXiv preprint arXiv:1608.03589**, 2016.
- KUMAR, S. P.; SRIRAAM, N.; BENAKOP, P.; JINAGA, B. Reconstruction of brain electrical impedance tomography images using particle swarm optimization. *In*: INTERNATIONAL CONFERENCE ON INDUSTRIAL AND INFORMATION SYSTEMS, 2010. **Proceedings [...]**. ICIIIS, 2010. p. 339–342.
- LI, T.; ISAACSON, D.; NEWELL, J. C.; SAULNIER, G. J. Adaptive techniques in electrical impedance tomography reconstruction. **Physiological measurement**, IOP Publishing, v. 35, n. 6, p. 1111, 2014.
- LIMA, C. R. d. **Estudo da obtenção de imagens de tomografia de impedância elétrica do pulmão pelo método de otimização topológica**. 2006. Tese (Doutorado em Engenharia Mecânica) — Universidade de São Paulo, 2006.
- LORENA, A. C.; CARVALHO, A. Introdução às support vector machines. **Revista de Informática Teórica e Aplicada**, v. 14, 2007. p. 43–67.
- MARTIN, S.; CHOI, C. T. Nonlinear electrical impedance tomography reconstruction using artificial neural networks and particle swarm optimization. **IEEE Transactions on Magnetism**, IEEE, v. 52, n. 3, p. 1–4, 2016.
- MARTIN, S.; CHOI, C. T. On the influence of spread constant in radial basis networks for electrical impedance tomography. **Physiological measurement**, IOP Publishing, v. 37, n. 6, p. 801, 2016.
- MIAO, L.; MA, Y.; WANG, J. Roi-based image reconstruction of electrical impedance tomography used to detect regional conductivity variation. **IEEE Transactions on Instrumentation and Measurement**, IEEE, v. 63, n. 12, p. 2903–2910, 2014.
- MURPHY, D.; BURTON, P.; COOMBS, R.; TARASSENKO, L.; ROLFE, P. Impedance imaging in the newborn. **Clinical Physics and Physiological Measurement**, IOP Publishing, v. 8, n. 4A, p. 131, 1987.
- NARANJO, J. F. L. **Inteligência computacional aplicada na geração de respostas impulsivas bi-auriculares e em aurilização de salas**. 2014. Tese (Doutorado em Modelagem Computacional) — Universidade do Estado do Rio de Janeiro, 2014.
- NICOLOTTI, G.; SOCCO, L.; MARTINIS, R.; GODIO, A.; SAMBUELLI, L. Application and comparison of three tomographic techniques for detection of decay in trees. **Journal of arboriculture**, International Society of Arboriculture, v. 29, n. 2, p. 66–78, 2003.
- OGAVA, R.; SOARES, N.; GOMES, J.; BARBOSA, V.; RIBEIRO, R.; SOUZA, E. de; SANTOS, W. dos. Algoritmo de evolução diferencial hibridizado e simulated annealing

aplicados a tomografia por impedância elétrica. *In: SIMPÓSIO DE INOVAÇÃO EM ENGENHARIA BIOMÉDICA*, 2017, Recife, PE. **Anais [...]**. Recife, PE: SABIO, 2017.

PETHIG, R. Dielectric properties of biological materials: Biophysical and medical applications. **IEEE Transactions on Electrical Insulation**, IEEE, n. 5, p. 453–474, 1984.

PRECISION MEDICINE IS FINALLY A REALITY AT THE BEDSIDE. 2017. Disponível em: <http://www.timpel.com.br/>. Acesso em: 20/06/2017.

RAMESH, A.; KAMBHAMPATI, C.; MONSON, J. R.; DREW, P. Artificial intelligence in medicine. *In: THE ROYAL COLLEGE OF SURGEONS OF ENGLAND*, 2004. **Proceedings [...]**. 2004, v. 86, n. 5, p. 334

RIBEIRO, R. R.; FEITOSA, A. R.; SOUZA, R. E. de; SANTOS, W. P. dos. Reconstruction of electrical impedance tomography images using genetic algorithms and non-blind search. *In: INTERNATIONAL SYMPOSIUM ON BIOMEDICAL IMAGING*, 11, 2014. ISBI, 2014. p. 153–156.

RIMPILÄINEN, V.; KUOSMANEN, M.; KETOLAINEN, J.; JÄRVINEN, K.; VAUHKONEN, M.; HEIKKINEN, L. M. Electrical impedance tomography for three-dimensional drug release monitoring. **European Journal of Pharmaceutical Sciences**, Elsevier, v. 41, n. 2, p. 407–413, 2010.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach**. [S.l.]: Malaysia; Pearson Education Limited, 2016.

RYMARCZYK, T.; TCHÓRZEWSKI, P.; ADAMKIEWICZ, P.; DUDA, K.; SZUMOWSKI, J.; SIKORA, J. Practical implementation of electrical tomography in a distributed system to examine the condition of objects. **IEEE Sensors Journal**, IEEE, v. 17, n. 24, p. 8166–8186, 2017.

SALOMON, D. **Data compression: the complete reference**. 3. ed. California: Springer Science & Business Media, 2004.

SANTOS, A. R. **Abordagens de aprendizado de máquina aplicadas à classificação de dados provenientes de equipamento eletroencefalográfico não-invasivo**. 2017. Dissertação (Mestrado em Engenharia Elétrica), 2017.

SANTOS, W. P. dos; SOUZA, R. E. de; BARBOSA, V. A. de F.; RIBEIRO, R. R.; FEITOSA, A. R. S.; SILVA, V. L. B. A. da; RIBEIRO, D. E.; FREITAS, R. C.; GOMES, J. C.; SOARES, N. S. et al. Hybrid metaheuristics applied to image reconstruction for an electrical impedance tomography prototype. *In: Hybrid Metaheuristics for Image Analysis*. Springer, 2018. p. 209–251.

SANTOS, W. P. dos; SOUZA, R. E. de; FREITAS, R. C. de; RIBEIRO, D. E.; SILVA, V. L. B. A. da; BARBOSA, V. A. de F.; FEITOSA, A. R. S.; RIBEIRO, R. R.; GOMES, J. C.; SOARES, N. S.; LIMA, M. P. d. M. L.; VALENÇA, R. B.; OGAVA, R. L. T.; DIAS, t. J. d. N. S. A. Hybrid metaheuristics applied to image reconstruction for an electrical impedance tomography prototype. *In: BHATTACHARYYA, S. **Hybrid Metaheuristics for Image Analysis***. Springer, Cham, 2018. p. 209–251.

SANTOSA, F.; VOGELIUS, M. A backprojection algorithm for electrical impedance imaging. **SIAM Journal on Applied Mathematics**, SIAM, v. 50, n. 1, p. 216–243, 1990.

SINGH, G.; ANAND, S.; LALL, B.; SRIVASTAVA, A.; SINGH, V. Development of a microcontroller based electrical impedance tomography system. *In: SYSTEMS, APPLICATIONS AND TECHNOLOGY CONFERENCE, 2015, Long Island. **Proceedings** [...]*. Long Island: LISAT, 2015. p. 1–4.

SOBOTA, V. **Novel approaches in evaluation of lung ventilation distribution using electrical impedance tomography**. 2016. Dissertação (Mestrado em Engenharia Biomédica) — CZECH TECHNICAL UNIVERSITY IN PRAGUE, 2016.

SOUZA, C. R. Kernel functions for machine learning applications. **Creative Commons Attribution-Noncommercial-Share Alike**, v. 3, p. 29, 2010.

TEHRANI, J. N.; JIN, C.; MCEWAN, A.; SCHAIK, A. van. A comparison between compressed sensing algorithms in electrical impedance tomography. *In: INTERNATIONAL CONFERENCE OF THE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 2010. **Proceedings** [...]*. EMBC, 2010. p. 3109–3112.

TROKHANOVA, O.; OKHAPKIN, M.; KORJENEVSKY, A. Dual-frequency electrical impedance mammography for the diagnosis of non-malignant breast disease. **Physiological measurement**, IOP Publishing, v. 29, n. 6, p. S331, 2008.

VJ, B.; SI, R.; MIL, M.; RRJ, G. Comportamento da impedância elétrica dos tecidos biológicos durante estimulação elétrica transcutânea. **Revista Brasileira de fisioterapia**, SciELO Brasil, v. 11, n. 2, p. 153–159, 2007.

WAN, Y.; BORSIC, A.; HEANEY, J.; SEIGNE, J.; SCHNED, A.; BAKER, M.; WASON, S.; HARTOV, A.; HALTER, R. Transrectal electrical impedance tomography of the prostate: Spatially coregistered pathological findings for prostate cancer detection. **Medical physics**, Wiley Online Library, v. 40, n. 6Part1, 2013.

WANG, H.; XU, G.; ZHANG, S.; YAN, W. An implementation of generalized back projection algorithm for the 2-d anisotropic eit problem. **IEEE Transactions on Magnetics**, IEEE, v. 51, n. 3, p. 1–4, 2015.

WANG, Q.; LIAN, Z.; WANG, J.; CHEN, Q.; SUN, Y.; LI, X.; DUAN, X.; CUI, Z.; WANG, H. Accelerated reconstruction of electrical impedance tomography images via patch based sparse representation. **Review of Scientific Instruments**, AIP Publishing, v. 87, n. 11, p. 114707, 2016.

WANG, Q.; WANG, H.; CUI, Z.; YANG, C. Reconstruction of electrical impedance tomography (eit) images based on the expectation maximum (em) method. **ISA transactions**, Elsevier, v. 51, n. 6, p. 808–820, 2012.

WANG, Y.; REN, S.; DONG, F. A transformation-domain image reconstruction method for open electrical impedance tomography based on conformal mapping. **IEEE Sensors Journal**, IEEE, 2018.

WANG, Z.; BOVIK, A. C.; SHEIKH, H. R.; SIMONCELLI, E. P. Image quality assessment: from error visibility to structural similarity. **IEEE transactions on image processing**, IEEE, v. 13, n. 4, p. 600–612, 2004.

WILLIAMS, R.; JIA, X.; WEST, R.; WANG, M.; CULLIVAN, J.; BOND, J.; FAULKS, I.; DYAKOWSKI, T.; WANG, S.; CLIMPSON, N. et al. Industrial monitoring of hydrocyclone operation using electrical resistance tomography. **Minerals Engineering**, Elsevier, v. 12, n. 10, p. 1245–1252, 1999.

WOLF, G. K.; GÓMEZ-LABERGE, C.; RETTIG, J. S.; VARGAS, S. O.; SMALLWOOD, C. D.; PRABHU, S. P.; VITALI, S. H.; ZURAKOWSKI, D.; ARNOLD, J. H. Mechanical ventilation guided by electrical impedance tomography in experimental acute lung injury. **Critical care medicine**, LWW, v. 41, n. 5, p. 1296–1304, 2013.

WRIGHT, J.; BUSH, D.; LEDINGHAM, S.; EVANS, D. The effect of nutrient and nonnutrient testmeals on gastric-emptying (ge) measured by electrical-impedance tomography. *In*: WB SAUNDERS CO INDEPENDENCE SQUARE WEST CURTIS CENTER, STE 300, PHILADELPHIA GASTROENTEROLOGY. 1993. v. 104, n. 4, p. A604–A604.

YORK, T. A. Status of electrical tomography in industrial applications. **Journal of Electronic Imaging**, International Society for Optics and Photonics, v. 10, n. 3, p. 608–620, 2001.

YORKEY, T. J.; WEBSTER, J. G.; TOMPKINS, W. J. Comparing reconstruction algorithms for electrical impedance tomography. **IEEE Transactions on Biomedical Engineering**, IEEE, n. 11, p. 843–852, 1987.

ZHANG, C.; LIU, Q.; WU, Q.; ZHENG, Y.; ZHOU, J.; TU, Z.; CHAN, S. H. Modelling of solid oxide electrolyser cell using extreme learning machine. **Electrochimica Acta**, Elsevier, v. 251, p. 137–144, 2017.

ZIMBICO, A. J. *Análise comparativa de técnicas de compressão aplicadas a imagens médicas usando ultrassom*. 2014. Dissertação (Mestrado em Engenharia Elétrica e Informática) — Universidade Tecnológica Federal do Paraná, 2014.

ZLOCHIVER, S. **Induced Current Electrical Impedance Tomography For Medical Applications: A Theoretical Study**. 2005. Tese (Doutorado em Engenharia) — University of Tel Aviv, 2005.

ZOU, Y.; GUO, Z. A review of electrical impedance techniques for breast cancer detection. **Medical engineering & physics**, Elsevier, v. 25, n. 2, p. 79–90, 2003.

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

Trabalho submetido e aprovado para apresentação e publicação nos Anais do XXII Congresso Brasileiro de Automática, realizado na cidade de João Pessoa (PB), durante o período de 9 a 12 de setembro de 2018.

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.

XXII CBA 2018

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 SOUZA¹¹DEPARTAMENTO 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

XXII CBA 2018

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 esse 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 $\vec{u} = (x, y, z)$ 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:

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

XXII CBA 2018

Onde J é a densidade de corrente elétrica (Ogava 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

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

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

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

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

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

XXII CBA 2018




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 $\mathbf{X} = \{(x_i, t_i) | x_i \in R^n, t_i \in R^m, i = 1, \dots, N\}$, 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 estimação 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

XXII CBA 2018

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.

XXII CBA 2018

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

XXII CBA 2018

- 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*.

APÊNDICE B – ELECTRICAL IMPEDANCE TOMOGRAPHY IMAGE RECONSTRUCTION BASED ON BACKPROJECTION AND EXTREME LEARNING MACHINES

Trabalho submetido para a revista internacional *Computers and Electrical Engineering* da editora Elsevier.

Abstract: *Electrical Impedance Tomography (EIT) is an image technique based on the application of an alternating electrical current on electrodes placed on the surface of the domain, which are also responsible for measuring the resulting electrical potentials. EIT main advantages are portability, low cost and non-use of ionizing radiation. EIT image reconstruction depends on the resolution of the direct and inverse problems, which is non-linear and ill-posed. Several reconstruction methods have been used to solve EIT inverse problem, from Newton-based methods to bio- and social-inspired metaheuristics. In this work we propose a new approach: the use of random-weighted neural networks, speci-*

ally Extreme Learning Machines (ELM), to approximate sinograms from electrical potential data and, therefore, use the classical Backprojection algorithm for image reconstruction. We generated a database of 4000 synthetic 128 128 images. We trained 16 ELMs corresponding to a 16-electrode EIT system placed on a circular domain. Results were evaluated according to Peak-to-Noise ratio (PSNR) and Structural Similarity Index (SSIM), as well as visual inspection. Results are fair and similar to image reconstructions obtained by the direct application of the Backprojection algorithm, in case this reconstruction problem would be a classic tomographic reconstruction.

Electrical Impedance Tomography Image Reconstruction based on Backprojection and Extreme Learning Machines

Juliana C. Gomes, Rodrigo B. Valença, Rodrigo L. T. Ogava,
Natália S. Soares, Valter A. F. Barbosa, David E. Ribeiro,
Wellington P. dos Santos, and Ricardo E. de Souza^a

^a*Departament of Biomedical Engineering, Federal University of Pernambuco, Recife,
Pernambuco, Brazil, e-mail: jucarneirog@hotmail.com, wellington.santos@ufpe.br*

Abstract

Electrical Impedance Tomography (EIT) is an image technique based on the application of an alternating electrical current on electrodes placed on the surface of the domain, which are also responsible for measuring the resulting electrical potentials. EIT main advantages are portability, low cost and non-use of ionizing radiation. EIT image reconstruction depends on the resolution of the direct and inverse problems, which is non-linear and ill-posed. Several reconstruction methods have been used to solve EIT inverse problem, from Newton-based methods to bio- and social-inspired metaheuristics. In this work we propose a new approach: the use of random-weighted neural networks, specifically Extreme Learning Machines (ELM), to approximate sinograms from electrical potential data and, therefore, use the classical Backprojection algorithm for image reconstruction. We generated a database of 4000 synthetic 128×128 images. We trained 16 ELMs corresponding to a 16-electrode EIT system placed on a circular domain. Results were evaluated according to Peak-to-Noise ratio (PSNR) and Structural Similarity Index (SSIM), as well as visual inspection. Results are fair and similar to image reconstructions obtained by the direct application of the Backprojection algorithm, in case this reconstruction problem would be a classic tomographic reconstruction.

Keywords: Electrical Impedance Tomography, Image Reconstruction,

Submissão para Computers and Electrical Engineering

modified Backprojection, Artificial Neural Networks, Extreme Learning
Machines

1. Introduction

Electrical Impedance Tomography (EIT) is a low cost, noninvasive imaging technique to acquire an imaging of a body section based on the application of an alternating, low amplitude and high frequency electric current to pairs of surface electrodes. Then, the resulting electrical potentials are measured. The images are obtained from the resolution of the inverse problem, and may correspond to the estimation of electrical conductivity or to the permittivity distribution of the interior of the domain. Conductivity can be understood as the possibility of the medium in allowing the displacement of electric charges. Permittivity measures the ease of polarization of the material. Normally, only the conductivity, the real part of the impedance, is considered and reconstructed [1, 2, 3].

Electrical Impedance Tomography has applications in geophysics, industrial processes, botany and medicine. In the medical applications we can mention the detection of breast cancer [4], the diagnosis of prostate cancer [5], the monitoring of mechanically ventilated lung ventilation [6, 7], and the measurement of intracranial bleeding [8].

EIT is a technique that has several advantages, among them being non-invasive, portable and low cost. In addition, it is a safe technique, which does not use ionizing radiation, which in turn can be harmful to human health. However, when compared with other imaging techniques, such as CT and NMR, it has low spatial resolution and high computational cost of reconstruction, which means that it has not yet been strongly established [1, 3].

The objective of this work is to propose an innovative method for the reconstruction of EIT images: the use of the classical Backprojection algorithm to obtain EIT images from approximate sinograms by Artificial Neural Networks (ANN) of the Extreme Learning Machine (ELM) type. The sinograms are constructed from the mapping of the electrical potentials measured on the surface of

Submissão para Computers and Electrical Engineering

the section in the sinograms obtained through the classic Backprojection. The ELM neural network is used to approximate these sinograms using nonlinear regression.

The proposal was validated through a training set consisting of synthetic phantoms. Since the ELM network is a fast training machine, the proposed reconstruction method is also very fast, producing reconstructed images with good quality, as the experimental results attest.

This work is organized as following: in section 2 we present a brief of the state-of-the-art of EIT image reconstruction methods; in section 3 we present our methodology, the theoretical methods, and the description of the synthetic image database we created; we also present our proposal; in section 4 we provide our experiments results and make qualitative and quantitative analyses of them; finally, in section 5 we summarize the scientific contribution of this work and discusses the potential future work.

2. Related Works

One reconstruction method was described and tested in [9]. They use the finite element model (FEM), which is widely used to reconstruct EIT images, specially to obtain numerical solutions for the forward problem. However, it can require a large computational cost to generate the mesh, mainly for inverse problem resolution. Furthermore, conventional iterative methods, as Gauss-Newton, can also takes a large amount of computational power because of large-dimensional matrices. Because of this, [9] proposed an iterative algorithm combining an adaptative mesh refinement and an adaptive Kaczmarz method. The first one is able to refine the mesh, searching a desired accuracy using a specific error measure. In this way, it can avoid unnecessary refinement that does not improve solution's accuracy. The second one has the ability of distinguish the conductivity distribution with an prior estimation. For this, it uses an optimal current pattern generation. The authors tested their method with simulations in EIDORS environment, using a 2D circular model with 32 electrodes on the

Submissão para Computers and Electrical Engineering

surface domain. They observed that the spatial resolution was improved and compared with the Gauss-Newton method using four iterations, showing that the proposed method requires one third of memory cost. They also performed
 60 experiments on lung and heart phantoms and quantified the performance with two error metrics, the mean squared error and the normalized norm difference between the obtained voltages and the desired ones. However, the experiments on phantoms did not use the optimal current patterns, and the performance could not be fully observed.

65 The work [10] proposed a strategy to limit the conductivity spectrum to a region of interest (ROI), creating an adapted method from the linear sensitivity-theorem-based conjugate gradient (SCG), namely RROI. The idea is to use all boundary informations to reconstruct image within a specific ROI, considering that for some applications the conductivity varies only in a determined region
 70 of the domain. Thereby, the matricial equation from direct problem decreases its order, and consequently, the computational load. The method was validated by simulation and experiments with phantoms. Finally, the authors concluded that the described method can obtain higher spatial resolution and a good accuracy, when compared with images from SCG applied to the entire domain,
 75 even using a fewer number of electrodes and the same data acquisition system. The qualitative results were proved by two metrics, the spatial resolution comparison and the correlation coefficient. Despite of this, the proposed method is more sensitive to noise.

[11] proposed an EIT reconstruction technique focus on reducing computa-
 80 tional cost, maintaining a good image resolution. Their idea is a reconstruction approach based on compressive sensing (CS), which means the reduction of samples, avoiding data redundancy. However, the prior condition to this method is that the data needs to be sparse enough. In this context, they developed a reconstruction algorithm based on patch-based sparse representation
 85 as a pre-processing step. The patch-based has shown ability to detect local image features and also effectivity to remove artifacts and noisy data, when its parameters are chosen appropriately. Tests were performed on both simulated

Submissão para Computers and Electrical Engineering

and experimental data, using the relative error as a metric of image quality. In conclusion, the authors showed that patch-based sparsity method has better
 90 results compared with traditional conjugate gradient (CG), global sparsity and
 KSVD denoising reconstruction methods, at image quality. It is also not sensitive to noise. Besides that, its computational time is still long. In addition, the new method based on CS theory achieved higher sampling rates, reducing in this way the computational time. As a result, the effective reconstruction time
 95 is reduced and high image resolution maintained.

An alternative way of finding a solution to EIT problem is treating it as a optimization problem, by trying to minimize the relative error between the surface potentials of an object and known surface potentials, as described by our research group in [12] and [13]. We compared different approaches to solve
 100 the optimization problem. The first one was Genetic Algorithm (GA). It is inspired by the Evolution Theory and genetic principals, as species adaptation and natural selection. This method randomly selects two individuals and the one with best fitness is chosen for crossover with occasional mutation to generate new individuals. We also used the meta-heuristic Fish School Search (FSS) in
 105 this optimization problem, where each fish represents a possible solution to the system or a point on fitness function domain. The FSS algorithm has operators based on food and swimming. The food operator quantifies how successful is a fish in its fitness function variation, depending on how close a fish is from food, being able to increase or decrease its own weight. The swimming operator
 110 is responsible for the fish movements in their seek for food. All experiments were performed using EIDORS environment, 16 surface electrodes and circular mesh grids with 415 elements. We aimed to detect irregular objects in three different configurations, and also compare results between only FSS algorithm, FSS with Non-blind search and only GA. We showed that with 500 iterations,
 115 images were anatomically consistent, but with GA we got lower relative errors and better image quality.

On the other hand, the work [14] used both ANN and Particle Swarm Optimization (PSO) to reconstruct EIT images. By combining a Nonlinear algo-

Submissão para Computers and Electrical Engineering

rithm with an Optimization method, they aimed to achieve a higher local and
 120 global convergence while solving a nonlinear system with a limited number of
 iterations. In this case, they simulated noisy data by adding White Gaussian
 Noise and also considered distortions on the models boundary to approximate
 real-life problems. The method was validated by simulated experiments and use
 of phantoms, and results were compared with One-step Gauss-Newton, a linear
 125 inverse solver, and with a nonlinear iterative solver, the primal/dual interior
 point method (PDIPM). The authors concluded that the linear solver presented
 a large smoothness, making difficult to estimate boundaries. In addition, the
 described method showed higher visual fidelity and lower resolution error when
 compared with original images. Finally, they believe that ANN and PSO can
 130 solve EIT problems in a faster manner and it can also deal with imperfections.
 In this paper, a novel method is proposed to EIT reconstruction, improving
 image quality and computational cost. The proposed method combines both a
 linear solver, the classical Backprojection algorithm, and nonlinear algorithms
 via ANNs. The idea is to approximate sinograms from electrical potential data
 135 using Extreme Learning Machines, considering its low computational complex-
 ity and good generalization performance. These sinograms can be reconstructed
 through Backprojection and generate EIT images. Experiments were performed
 with our own synthetic images database, that we developed on GNU/Octave en-
 vironment. The effectiveness of this method is measured by Peak-to-Noise ratio
 140 (PSNR) and Structural Similairity Index (SSIM), as well as visual inspection.

3. Materials and Methods

3.1. Electrical Impedance Tomography problems and reconstruction

The EIT technique is based on the solution of direct and inverse problems
 [1, 3]. The inverse problem is the estimation of the electrical conductivity dis-
 145 tribution and permittivity of the interior of the domain. However, besides the
 function that represents the potentials does not vary linearly with the applied
 current, there is no single distribution corresponding to a determined set of

Submissão para Computers and Electrical Engineering

measured electrical potentials. Therefore, the solution may be unstable, with high sensitivity to numerical errors and experimental noise.

150 From the mathematical point of view, the EIT problem is determined by the Poisson Equation, given in (1):

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

with the boundary conditions in Equations (2) and (3):

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

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

where $u = (x, y, z)$ is the position of the object, $\phi(\vec{u})$ the potentials distribution, $\phi_{ext}(\vec{u})$ the potentials distribution on the surface of the domain, $I(\vec{u})$ the alternating electrical current, $\sigma(\vec{u})$ the electrical conductivity distribution, that is, the image of interest, Ω the domain, $\partial\Omega$ the edge and $n(\vec{u})$ the normal vector to the edge [15, 13, 16, 17].

For the direct problem, the electrical potentials measured in its contour are determined from the current excitation pattern and the conductivity distribution, which is given by Laplace's equation. It is modeled by the relation given in (4):

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

with the boundary conditions in Equation (5):

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

where J is the density of electrical current [18].

165 3.2. Backprojection Reconstruction

Projections or the Radon Transform of a sample are sets of line integrals at specific angles. When projections of different angles are organized in rows of a matrix, they are called sinograms, a graphical representation in which the vertical axis is the distance from the origin to the electrode selected on the

Submissão para Computers and Electrical Engineering

170 surface of the domain, and horizontal axis represents the angle at which the slice is measured. The name sinogram is originated from the fact that the Radon Transform of a single point outside the center is a sinusoid. Thereby, with all information from a sinogram, it is possible to reconstruct an image by the Backprojection process or the application of the Inverse Radon Transform.

175 The Backprojection reconstruction is a simple and fast summation method, commonly used in Computerized Tomography image reconstruction [19, 20, 21]. In our proposal, the projections angles are defined by the number of electrodes. Additionally, each projection represents the sum of resistivities or conductivities.

3.3. Extreme Learning Machines

180 Artificial Neural Networks (ANN) are machines inspired by human brain functioning. They were originally designed to model the way we respond to certain functions. ANNs are endowed of parallelism, being able to be linear or non-linear, with learning ability through the observation of the environment. ANNs are composed by basic processing units, the neurons, interacting with each other through synapses, similarly to their biological precedents. The modification of these communication gives the brain plasticity and learning ability. Thus, the neural networks modify their synaptic weights in order to achieve their desired outputs. Consequently, they have the capacity to learn and to generalize, i.e. they can generate appropriate outputs for conditions or situations that were not present in the learning Stage, being able to solve many complex problems [15].

195 Canonical Extreme Learning Machines are supervised artificial neural networks with a single hidden layer, known by their high speed, low computational complexity and good generalization performance by simply changing hidden neurons kernels. This single layer network can be modeled as (6):

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

where N is the set of samples (x_i, t_i) , N_h the number of neurons in the hidden layer, $f(x)$ the activation function, w_i the input weights, b_i the bias, β_i the

Submissão para Computers and Electrical Engineering

output weights and t_i the target output. The input weights of the hidden layer are determined randomly and independently of the training set, whereas the output weights can be determined analytically.




Figure 1: Flow diagram of the calculation of the output weights of an ELM (Elaborated by the author).

200

By using the algorithm shown in the diagram of Figure 1, we can get the smallest training error and the lowest weight norm among possible solutions through a simple operation of generalized inverse of the output matrices of the hidden layer [22, 23, 24, 25].

205 3.4. Proposed reconstruction method

This work proposes an innovative method for the reconstruction of EIT images. We propose the use of the Backprojection algorithm to reconstruct sinograms artificially reconstructed by Regression ELMs. After being trained, these ELMs are able to map the surface electrical potential into sinograms. This method is graphically resumed in Figure 2.

210




Figure 2: Proposed reconstruction method: Backprojection from approximate sinograms using ELMs (Elaborated by the author).

Submissão para Computers and Electrical Engineering

3.5. Proposed experiments

We adopted GNU/Octave, an open software with a mostly Matlab-compatible programming language. In order to train the ELMs, we generated a 4000 synthetic 128×128 pixels grayscale images. Circular objects and ellipses were
 215 placed inside a circular domain, in different quantities, sizes and gray-level intensities. In addition, 16 equidistant electrodes were positioned at the edge of the domain. To calculate the electrical potentials, the electrical currents were considered following paths in straight lines between the electrodes. Therefore, by summing the intensities of the pixels, we can obtain the sum of the resistivi-
 220 ties (inverse of the conductivity) between the electrodes, knowing the current of excitation. Given the excitation current, we can calculate the surface electrical potentials.

From this database we randomly selected 100 synthetic images for a pilot test, to find the activation function that best models the problem, as well as
 225 finding the right amount of hidden layer neurons. We employed the functions Sigmoidal, Sine and Hard Limit. We varied the number of neurons from 50 to 500, with steps of 50 as well. In addition, we included ELMs based on Wavelet, RBF, Polynomial and Linear kernels. We tested all cases using percentage split of 2/3 and 10-fold cross validation. As a measure of performance, we
 230 considered the best configuration as the one with the lowest Percentage Error when compared the Training with Testing set.

4. Results and Discussions

Finally, we trained 16 ANNs corresponding to a 16-electrode EIT system placed on a circular domain. Based on previous results, we used the Sigmoidal
 235 activation function, 500 neurons in the hidden layer, and all 4000 images of the synthetic database we previously generated. Thus, the sinograms could be reconstructed by Backprojection. Results can be visualized in the left side (1) of Figure 3.

Submissão para Computers and Electrical Engineering

	Reconstruction with images from the Training set (1)					Reconstruction with images from the Testing set (2)				
Original images (a)										
Reconstruction of original sinograms (b)										
Reconstruction of original sinograms after ELM (c)										
PSNR between (b) and (c)	44.554 dB	47.164 dB	47.023 dB	44.753 dB	46.693 dB	51.434 dB	55.485 dB	49.472 dB	49.515 dB	44.687 dB
SSIM between (b) and (c)	0.95131	0.96484	0.93636	0.89113	0.96262	0.97598	0.98995	0.96139	0.96257	0.93634
PSNR between (a) and (c)	10.0543 dB	9.8509 dB	9.7029 dB	9.4463 dB	9.5697 dB	10.1184 dB	10.4315 dB	10.0307 dB	10.1531 dB	10.0401 dB
SSIM between (a) and (c)	0.022824	0.028063	0.023810	0.027669	0.026667	0.023612	0.018732	0.024403	0.022958	0.023325

Figure 3: Reconstruction of EIT images using Backprojection algorithm. PSNR and SSIM metrics were used for comparison.

As can be seen in Figure 3, the original sinograms were reconstructed, i.e. those obtained directly from the images of the database (b), as well as the sinograms generated from the training of the ELMs (c) were reconstructed. When comparing these results, a great similarity between these two reconstructions is observed qualitatively, presenting slightly greater blurry in (c), showing that the ELMs were effective in the generation of the sinograms. By analyzing the Peak Signal-to-Noise Ratio (PSNR) in decibels (dB), high-quality reconstructions can be observed, as can also be seen in Figure 4a. Furthermore, the Structural Similarity Index close to one indicates high correlation between images, not only in absolute values but also in the structure of the objects present in the image.

Figure 3 also shows comparisons between the original images (a) and the reconstructions by Backprojection (c) using our proposal. Both PSNR and SSIM showed a significant decrease in image quality. Nevertheless, we can see consistency between the images, indicating the presence of objects in regions and formats similar to the originals. Post-processing techniques can be applied in a way that softens these distortions and improves image quality.

Submissão para Computers and Electrical Engineering

255 In order to evaluate the training of the ELMs, we additionally generated more
 100 new images. Thereby, they could also be reconstructed by Backprojection,
 as shown in the right side (2) of the Figure 3. The results show the efficiency
 of ELMs in EIT image reconstruction. The networks were able to reconstruct
 images that were not present in the training set with consistency, without a
 260 significant decrease in the PSNR and SSIM indexes. This shows that the ELMs
 did not memorize, but actually learned in the training process. Furthermore,
 in this last case, Boxplots of PSNR and SSIM indexes using all 100 images are
 shown in Figure 4.




Figure 4: Boxplots of PSNR (dB) and SSIM

5. Conclusion

265 Electrical Impedance Tomography is a promising technique that may con-
 tribute for more precise medical diagnoses when combined with other imaging
 techniques. Therefore, the implementation of a fast and efficient reconstruction
 method is necessary. We demonstrated that our proposal was able to reduce the
 time of EIT reconstruction, mainly due to the high speed of the ELMs, and ob-
 270 taining reasonable and consistent images. In this way, our method is promising
 and can contribute to the state-of-the-art of this imaging technique.

Submissão para Computers and Electrical Engineering

The use of Artificial Neural Networks, in particular ELMs for regression, as well as the reconstruction with Backprojection algorithm has shown an interesting potential for obtaining EIT images. In future tests, post-processing techniques may be applied to improve image quality. Furthermore, other fast-ANNs can also be tested in sinogram approximation, specially deep random-weighted neural architectures. In addition, an open-source computational tool can be implemented to reconstruct EIT images using the proposed approach.

Acknowledgements

The authors are grateful to the Brazilian research agencies CAPES, CNPq and Facepe, for the partial financial support of this research.

References

- [1] J. N. Tehrani, C. Jin, A. McEwan, A. van Schaik, A comparison between compressed sensing algorithms in electrical impedance tomography, in: Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE, IEEE, 2010, pp. 3109–3112.
- [2] T. K. Bera, S. K. Biswas, K. Rajan, J. Nagaraju, 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) (2011) 2–12.
- [3] S. P. Kumar, N. Sriraam, P. Benakop, B. Jinaga, Reconstruction of brain electrical impedance tomography images using particle swarm optimization, in: Industrial and Information Systems (ICIIS), 2010 International Conference on, IEEE, 2010, pp. 339–342.
- [4] D. Pak, N. Rozhkova, M. Kireeva, M. Ermoshchenkova, A. Nazarov, D. Fomin, N. Rubtsova, Diagnosis of breast cancer using electrical impedance tomography, Biomedical Engineering 46 (4) (2012) 154–157.

Submissão para Computers and Electrical Engineering

- [5] Y. Wan, A. Borsic, J. Heaney, J. Seigne, A. Schned, M. Baker, S. Wason, A. Hartov, R. Halter, Transrectal electrical impedance tomography of the prostate: Spatially coregistered pathological findings for prostate cancer detection, *Medical physics* 40 (6Part1).
300
- [6] S. H. Alves, M. B. Amato, R. M. Terra, F. S. Vargas, P. Caruso, Lung reaeration and reventilation after aspiration of pleural effusions. a study using electrical impedance tomography, *Annals of the American Thoracic Society* 11 (2) (2014) 186–191.
305
- [7] A. Adler, J. H. Arnold, R. Bayford, A. Borsic, B. Brown, P. Dixon, T. J. Faes, I. Frerichs, H. Gagnon, Y. Gärber, et al., Greit: a unified approach to 2d linear eit reconstruction of lung images, *Physiological measurement* 30 (6) (2009) S35.
- [8] M. Dai, B. Li, S. Hu, C. Xu, B. Yang, J. Li, F. Fu, Z. Fei, X. Dong, In vivo imaging of twist drill drainage for subdural hematoma: a clinical feasibility study on electrical impedance tomography for measuring intracranial bleeding in humans, *PloS one* 8 (1) (2013) e55020.
310
- [9] T. Li, D. Isaacson, J. C. Newell, G. J. Saulnier, Adaptive techniques in electrical impedance tomography reconstruction, *Physiological measurement* 35 (6) (2014) 1111.
315
- [10] L. Miao, Y. Ma, J. Wang, Roi-based image reconstruction of electrical impedance tomography used to detect regional conductivity variation, *IEEE Transactions on Instrumentation and Measurement* 63 (12) (2014) 2903–2910.
320
- [11] Q. Wang, Z. Lian, J. Wang, Q. Chen, Y. Sun, X. Li, X. Duan, Z. Cui, H. Wang, Accelerated reconstruction of electrical impedance tomography images via patch based sparse representation, *Review of Scientific Instruments* 87 (11) (2016) 114707.

Submissão para Computers and Electrical Engineering

- [12] V. A. Barbosa, R. R. Ribeiro, A. R. Feitosa, V. L. Silva, A. D. Rocha, R. C. Freitas, R. E. Souza, W. P. Santos, Reconstruction of electrical impedance tomography using fish school search, non-blind search, and genetic algorithm, *International Journal of Swarm Intelligence Research (IJSIR)* 8 (2) (2017) 17–33.
- [13] R. C. de Freitas, D. E. Ribeiro, V. L. B. A. da Silva, V. A. de Freitas Barbosa, A. R. S. Feitosa, R. R. Ribeiro, R. E. de Souza, W. P. dos Santos, Electrical impedance tomography using evolutionary computing: A review, in: *Bio-Inspired Computing for Image and Video Processing*, Chapman and Hall/CRC, 2018, pp. 93–128.
- [14] S. Martin, C. T. Choi, Nonlinear electrical impedance tomography reconstruction using artificial neural networks and particle swarm optimization, *IEEE Transactions on Magnetics* 52 (3) (2016) 1–4.
- [15] S. J. Hamilton, A. Hauptmann, Deep d-bar: Real time electrical impedance tomography imaging with deep neural networks, *IEEE Transactions on Medical Imaging*.
- [16] W. P. dos Santos, R. E. de Souza, R. C. de Freitas, D. E. Ribeiro, V. L. B. A. da Silva, V. A. de Freitas Barbosa, A. R. S. Feitosa, R. R. Ribeiro, J. C. Gomes, N. S. Soares, M. P. d. M. L. Lima, R. B. Valena, R. L. T. Ogava, . J. d. N. S. A. Dias, Hybrid metaheuristics applied to image reconstruction for an electrical impedance tomography prototype, in: *Bhattacharyya S. (eds) Hybrid Metaheuristics for Image Analysis*, Springer, Cham, 2018, pp. 209–251.
- [17] R. R. Ribeiro, A. R. Feitosa, R. E. de Souza, W. P. dos Santos, Reconstruction of electrical impedance tomography images using genetic algorithms and non-blind search, in: *Biomedical Imaging (ISBI), 2014 IEEE 11th International Symposium on*, IEEE, 2014, pp. 153–156.
- [18] R. Ogava, N. Soares, J. Gomes, V. Barbosa, R. Ribeiro, E. de Souza, W. dos Santos, Algoritmo de evolução diferencial hibridizado e simulated

Submissão para Computers and Electrical Engineering

- annealing aplicados a tomografia por impedância elétrica, I Symposium of
 355 Innovation in Biomedical Engineering (SABIO).
- [19] J. Hsieh, Computed tomography: principles, design, artifacts, and recent
 advances, SPIE Bellingham, WA, 2009.
- [20] H. Wang, G. Xu, S. Zhang, W. Yan, An implementation of generalized back
 projection algorithm for the 2-d anisotropic eit problem, IEEE Transactions
 360 on Magnetism 51 (3) (2015) 1–4.
- [21] R. Guardo, C. Boulay, B. Murray, M. Bertrand, An experimental study
 in electrical impedance tomography using backprojection reconstruction,
 IEEE transactions on biomedical engineering 38 (7) (1991) 617–627.
- [22] G.-B. Huang, H. Zhou, X. Ding, R. Zhang, Extreme learning machine for re-
 365 gression and multiclass classification, IEEE Transactions on Systems, Man,
 and Cybernetics, Part B (Cybernetics) 42 (2) (2012) 513–529.
- [23] G.-B. Huang, Q.-Y. Zhu, C.-K. Siew, Extreme learning machine: theory
 and applications, Neurocomputing 70 (1-3) (2006) 489–501.
- [24] Q. Li, T. Zhao, L. Zhang, W. Sun, X. Zhao, Ferrography wear particles
 370 image recognition based on extreme learning machine, Journal of Electrical
 and Computer Engineering 2017.
- [25] J. Lei, H. Mu, Q. Liu, X. Wang, S. Liu, Data-driven reconstruction method
 for electrical capacitance tomography, Neurocomputing 273 (2018) 333–
 345.

APÊNDICE C – RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA BASEADA EM MÁQUINAS DE APRENDIZADO EXTREMO E BACKPROJECTION

Trabalho submetido e aprovado para apresentação e publicação nos Anais do II Simpósio de Inovação em Engenharia Biomédica, realizado em 2018 no Campus Recife da Universidade Federal de Pernambuco.

Abstract: *Electrical Impedance Tomography (EIT) is an imaging technique through the measurement of electrical properties through electrodes placed around the domain of study. Its main advantages are the portability, low cost and non-use of ionizing radiation. However, the reconstruction of EIT images depends on the resolution of the direct and inverse problems, which is non-linear and ill-posed. Therefore, the technique is not yet well established because of its low reconstruction speed and low spatial resolution. This work proposes the use of the classic algorithm of Backprojection for the reconstruction of Sinograms obtained from electrical potential data. For this, it is suggested the use of Artificial Neural Networks (ANN) of the type of Extreme Learning Machine (ELM) of Regression in order to generate the sinograms.*

Reconstrução de imagens de Tomografia por Impedância Elétrica baseada em Máquinas de aprendizado extremo e *Backprojection*

Juliana Gomes
Dept. de Eng. Biomédica
UFPE

Recife, Brasil
jucarneirog@hotmail.com

Rodrigo Ogava
Dept. de Eng. Biomédica
UFPE

Recife, Brasil
rodrigo.ogava@gmail.com

Ricardo E. de Souza
Dept. de Eng. Biomédica
UFPE

Recife, Brasil
res.ufpe@gmail.com

Wellington P. dos Santos
Dept. de Eng. Biomédica
UFPE

Recife, Brasil
wellington.santos@ufpe.br

Abstract—Electrical Impedance Tomography (EIT) is an imaging technique through the measurement of electrical properties through electrodes placed around the domain of study. Its main advantages are the portability, low cost and non-use of ionizing radiation. However, the reconstruction of EIT images depends on the resolution of the direct and inverse problems, which is non-linear and ill-posed. Therefore, the technique is not yet well established because of its low reconstruction speed and low spatial resolution. This work proposes the use of the classic algorithm of Backprojection for the reconstruction of Sinograms obtained from electrical potential data. For this, it is suggested the use of Artificial Neural Networks (ANN) of the type of Extreme Learning Machine (ELM) of Regression in order to generate the sinograms.

Index Terms—Electrical Impedance Tomography, Image reconstruction algorithm, Sinogram, Backprojection, Artificial Neural Networks, Extreme Learning Machine.

I. INTRODUÇÃO

A Tomografia por Impedância Elétrica (TIE) é uma técnica de imagem do interior de uma seção do corpo baseada na aplicação de uma corrente elétrica alternada, de baixa amplitude e alta frequência. Para isso, eletrodos são posicionados na superfície desse corpo, e são responsáveis por enviar esse estímulo, assim como pela medição dos potenciais elétricos resultantes. Dessa forma, pode-se obter imagens com estimativas das condutividades ou permissividades elétricas do interior de um domínio. Pode-se entender condutividade como a possibilidade do meio em permitir o deslocamento de cargas elétricas, enquanto a permissividade a medida da facilidade de polarização do material [1]–[3].

A TIE possui aplicações em diversas áreas: na geofísica, em processos industriais, na botânica e na medicina, por exemplo. Na última, pode-se citar aplicações na detecção de câncer de mama [4], no diagnóstico de câncer de próstata [5], no monitoramento de ventilação pulmonar imposta por ventilação mecânica [6], [7] e na medição de sangramento intracraniano [8].

A TIE é uma técnica que possui diversas vantagens, dentre elas o fato de não ser invasiva, ser portátil, e de baixo custo associado. Além disso, a TIE é uma técnica segura, que

não utiliza radiação ionizante, que é nociva à saúde humana. Apesar disso, a técnica ainda possui baixa resolução espacial e um alto custo computacional na reconstrução de suas imagens, se comparada a outras técnicas de imagem médicas, como a Tomografia Computadorizada (CT) e a Ressonância Magnética Nuclear (RMN), e, por isso, ainda não foi fortemente estabelecida. Desse modo, diversos métodos tem sido estudados e aplicados buscando solucionar esses problemas [1], [3].

Diante do exposto, este presente trabalho, visa propor um método inovador na reconstrução de imagens de TIE. Sugere-se a utilização do clássico algoritmo de Retroprojeção (*Backprojection*) para obtenção de imagens de TIE a partir de Sinogramas. Os sinogramas, por sua vez, serão construídos a partir dos dados de diferenças de potenciais elétricos medidos na superfície do domínio estudado, utilizando para isto Redes Neurais Artificiais (RNAs) do tipo Máquinas de aprendizado extremo (*Extreme Learning Machine – ELM*) de Regressão. Assim, acredita-se que se poderá obter um método rápido de reconstrução devido à alta velocidade de ambos os algoritmos escolhidos com ainda uma boa qualidade de imagem.

II. MATERIAIS E MÉTODOS

A. Fundamentação teórica

1) *Reconstrução de imagens de TIE*: A técnica de TIE consiste na solução dos problemas direto e inverso [1], [3]. O problema inverso é a estimativa da distribuição de condutividade e permissividade elétrica do interior do domínio. Porém, além da função que representa os potenciais não variar de forma linear com a corrente aplicada, não há uma única distribuição de condutividades e permissividades correspondente a um determinado conjunto de potenciais elétricos medidos. A solução do problema pode ainda ser instável, apresentando grande sensibilidade a erros numéricos e a ruídos experimentais. Do ponto de vista matemático, o problema de TIE é determinado pela Equação de Poisson dada em (1):

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

Com as condições de contorno em (2) e (3):

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

II Simpósio de inovação em Engenharia Biomédica

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

Onde $u = (x, y, z)$ é a posição do objeto, $\phi(\vec{u})$ a distribuição de potenciais, $\phi_{ext}(\vec{u})$ a distribuição de potenciais na superfície do domínio, $I(\vec{u})$ a corrente elétrica alternada, $\sigma(\vec{u})$ a distribuição de condutividade elétrica, ou seja, a imagem de interesse, Ω o domínio, $\partial\Omega$ a borda e $n(\vec{u})$ o vetor normal à borda [9], [10].

Quando se trata do problema direto, determina-se os potenciais elétricos medidos em seu contorno a partir do padrão de excitação de corrente e da distribuição de condutividade, sendo essa relação dada pela Equação de LaPlace. Assim, o mesmo é modelado pela relação dada em (4):

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

Com as condições de contorno em (5):

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


Onde J é a densidade de corrente elétrica [11].

2) *Transformada de Radon e Sinogramas*: A transformada de Radon (TR) é uma integral de linha e, assim, a TR de uma distribuição $f(x, y)$ é dada por (6):

$$p(\xi, \phi) = \int f(x, y) \delta(x \cos(\phi) + y \sin(\phi) - \xi) dx dy \quad (6)$$

Onde δ é a função delta de Dirac, ξ é o vetor perpendicular à orientação da corrente elétrica injetada, considerando de forma simplificada que a corrente percorre uma trajetória em linha reta entre os eletrodos. ϕ , por outro lado, é o ângulo formado entre o vetor ξ e o eixo x [12]. A função $p(\xi, \phi)$ é conhecida como Sinograma, já que a transformada de Radon de um ponto fora do centro é uma senoide [13]. O sinograma representa o alinhamento de todas as projeções de uma fatia ao longo de uma matriz. Dessa forma, a transformada de Radon modela as projeções do objeto em estudo. Em contraste, a Transformada Inversa de Radon modela as retroprojeções, sendo a reconstrução das imagens o somatório das mesmas. Em outras palavras, a reconstrução por *Backprojection* tem como objetivo encontrar a função $f(x, y)$ dado um sinograma $p(\xi, \phi)$ como mostrado na Fig. 1.

Fig. 1. Exemplo de reconstrução de imagens de Tomografia Computadorizada por Backprojection a partir de sinogramas [13]



3) *Reconstrução de imagens por Backprojection*: O método de retroprojeção (*Backprojection*) é um método somatório simples e rápido, comumente utilizado em reconstruções de imagens de CT [13]–[15]. O mesmo requer a coleção de dados que representam o somatório de regiões igualmente espaçadas em 360 graus, e geometricamente falando, ele transforma o

sinograma de volta em uma imagem. Sua operação é definida por (7):

$$f(x, y) = \int_0^\pi p(x \cos(\phi) + y \sin(\phi), \phi) d\phi \quad (7)$$

4) *Extreme Learning Machines de Regressão*: As Redes Neurais Artificiais (RNA) são máquinas inspiradas no funcionamento cerebral humano que buscam modelar a forma como respondemos a determinadas funções. São sistemas dotados de paralelismo, podendo ser lineares ou não-lineares, com habilidade de aprendizagem através da observação do meio. Devido à isto, elas possuem capacidade de generalização, ou seja, de gerar saídas apropriadas para situações que não estavam presentes no processo ou algoritmo de aprendizagem, o que torna possível a resolução de problemas complexos [16]. Uma rede neural que tem sido muito utilizada atualmente é a Máquina de Aprendizado Extremo (ELM). A mesma trata-se de uma rede supervisionada e de única camada oculta, 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 (8).


$$\sum_{i=1}^{N_h} \beta_i f(w_i x_j + b_i) = t_i, j \in [1, N] \quad (8)$$

onde N constitui um conjunto de amostras (x_i, t_i) , N_h 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. Assim, os pesos de entrada da camada oculta são determinados de forma aleatória e independente do conjunto de treinamento, enquanto, os pesos de saída podem ser determinados de forma analítica [17]–[20].

B. Métodos propostos

Este presente trabalho propõe um método inovador para obtenção de imagens de TIE a partir da reconstrução de Sinogramas por *Backprojection*. Para a geração dos sinogramas, deseja-se treinar ELMs de Regressão para encontrar uma função que modele os dados a partir dos potenciais elétricos medidos na superfície do domínio, como resumido no esquema da Fig. 2.

Fig. 2. Reconstrução de imagens de TIE a partir de sinogramas




Para o desenvolvimento de um teste piloto, desenvolveu-se imagens de TIE sintéticas e códigos para a reconstrução em ambiente GNU/Octave. Um banco de imagens (128x128)

II Simpósio de inovação em Engenharia Biomédica

em escala de cinzas foi gerado, com domínios circulares, de forma que objetos internos ao domínio foram representados por círculos e elipses de diferentes tamanhos e intensidades. Por fim, simulou-se 16 eletrodos equidistantes na borda do objeto desenhado, e o percurso das correntes elétricas entre os eletrodos foi considerado como em linha reta. Assim, realizando a soma das intensidades dos pixels, pode-se obter a soma das resistividades (inverso da condutividade) entre os eletrodos. Conhecendo-se a corrente elétrica de excitação, se obteve, dessa forma, os valores de potenciais elétricos na superfície do domínio em estudo.

Dentre o banco de dados, escolheu-se de forma aleatória 100 imagens sintéticas. O programa gerou sinogramas dessas imagens, bem como reconstruiu os mesmos por *Backprojection*. As reconstruções, portanto, servem como imagens de referências para as futuras reconstruções através do método proposto, enquanto os sinogramas para o treinamento das RNAs.

No caso das RNAs, utilizou-se a ELM proposta por [18] na versão para Matlab/Octave. De forma a encontrar a melhor configuração da ELM para reconstrução das imagens, realizou-se uma varredura entre diferentes configurações. Foram testadas as funções de ativação Sigmoidal, Senoidal e Hard Limit com o número de neurônios da camada escondida variando entre 50 e 500, com passos de 50. Além das citadas, ELMs utilizando Kernel Wavelet, RBF, Polinomial e linear também foram incluídas. Todos os casos foram testados com os métodos de amostragem e validação de algoritmo com Divisão percentual de 2/3 e Validação cruzada (*Cross Validation*) com 10 *folds*. Dessa maneira, os melhores resultados apresentados foram com maior número de neurônios, bem como utilizando o *Cross-Validation*, sendo considerados melhores os testes após treinamento com menor Erro percentual. Uma síntese desses resultados pode ser observada no gráfico da Fig. 3.




Portanto, observou-se que os erros decrescem à medida que o número de neurônios da camada escondida cresce. Além disso, como visto no gráfico, a função de ativação Sigmoidal apresentou um melhor desempenho, constituindo a provável melhor configuração de ELM para obtenção dos sinogramas.

III. RESULTADOS E DISCUSSÕES

De forma a obter os sinogramas, 16 RNAs foram treinadas correspondentes aos 16 eletrodos posicionados na superfície. Utilizou-se a função de ativação Sigmoidal e os potenciais elétricos medidos nas 100 imagens de TIE selecionadas como amostra, ou seja, como de conjunto de entrada, enquanto os sinogramas das imagens originais eram as saídas esperadas. Por fim, as 16 RNAs treinadas geraram os parâmetros pesos de entrada, pesos de saída e bias, que foram salvos para posterior obtenção de cada uma das colunas dos sinogramas. Finalmente, os sinogramas foram reconstruídos por *Backprojection* e o resultado pode ser visualizado na Fig. 4 a seguir.

Fig. 4. Reconstrução de imagens por *Backprojection* com diferentes quantidades de neurônios na camada escondida e diferentes objetos interiores ao domínio em estudo



Finalmente, pode-se perceber que as imagens com maior número de neurônios na camada escondida apresentaram maior qualidade na reconstrução, de forma a visualizar melhor o domínio em estudo, como pode ser visto nas imagens com 400 ou 500 neurônios. Além disso, todas as imagens obtidas apresentaram consistência em relação à imagem original de referência, indicando a presença de objetos em regiões semelhantes. Apesar disso, não é possível a definição do número de objetos presentes. Sugere-se ainda que os elementos mais escuros que são interiores ao domínio puderam ser mais facilmente reconstruídos, em contraste de alguns de intensidade mais clara que passaram despercebidos. Por conta disso, observa-se na terceira imagem, por exemplo, que o objeto de maior intensidade apresentou-se maior em dimensões do que o objeto mais claro, apesar da imagem original indicar o oposto.

Em trabalhos futuros, planeja-se utilizar um maior número de imagens para o treinamento das ELMs, pois, assim, acredita-se que a rede irá apresentar uma melhor capacidade de generalização do problema. Neste presente trabalho também foram escolhidos 16 eletrodos de modo a reduzir o

II Simpósio de inovação em Engenharia Biomédica

tempo de aquisição e reconstrução dos dados, de forma à simplificar os resultados preliminares. Porém, deseja-se ainda realizar reconstruções obtidas com maior número de eletrodos posicionados na superfície, preferencialmente 32 eletrodos, de modo a obter um melhor *sampling* angular e possível melhor resolução da imagem. Por fim, acredita-se que o presente método proposto apresentou resultados preliminares satisfatórios e consistentes, constituindo de método promissor. O mesmo será poderá reduzir de modo considerável o tempo de reconstrução de imagens de TIE, devido principalmente à alta velocidade das Máquinas de Aprendizado Extremo (ELM) e do algoritmo de *Backprojection*, bem como proporcionar uma razoável qualidade de imagem.

AGRADECIMENTOS

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

REFERENCES

- [1] J.N. Tehrani; C. Jin; A. McEwan; A. Schaik. A comparison between compressed sensing algorithms in Electrical Impedance Tomography. 32nd Annual Conference of IEEE EMBS, 2010.
- [2] K. Bera; S. K. Biswas; K. Rajan; J. Nagaraju. Improving image quality in electrical impedance tomography (eit) using projection error propagation-based regularization (pepr) technique: a simulation study. Journal of Electrical Bioimpedance, 2011.
- [3] S.P. Kumar; N. Sriram; P.G. Benakop; B.C. Jinaga. Reconstruction of brain electrical impedance tomography images using Particle Swarm Optimization. 5th International Conference of Industrial and Information Systems, 2010.
- [4] Pak, NI Rozhkova, MN Kireeva, MV Ermoshchenkova, AA Nazarov, DK Fomin, and NA Rubtsova. Diagnosis of breast cancer using electrical impedance tomography. Biomedical Engineering, 46(4):154157, 2012.
- [5] Y. Wan; A. Borsic; J. Heaney; J. Seignec; A. Schned; M. Baker; S. Watson; A. Hartov; R. Halter. Transrectal electrical impedance tomography of the prostate: Spatially coregistered pathological findings for prostate cancer detection. Medical physics, Volume: 40, Junho 2013.
- [6] S. H. Alves; M. B. Amato; R. M. Terra; F. S. Vargas; CARUSO, P. Lung reoperation and reventilation after aspiration of pleural effusions. A study using electrical impedance tomography. Annals of the American Thoracic Society, Am Thoracic Soc, v. 11, n. 2, p.186–191, 2014.
- [7] A. Adler; J. H. Arnold; R. Bayford; A. Borsic; B. Brown; P. Dixon; T. J. Faes; I. Frerichs; H. Gagnon, H.; Y. Gaeber, Y. et al. GREIT: A unified approach to 2D linear EIT reconstruction of lung images. Physiological measurement, IOP Publishing, v. 30,n. 6, p. S35, 2009.
- [8] M. Dai; B. Li; S. Hu; C. Xu; B. Yang; J. Li; F. Fu; Z. Fei; Z. Dong. In vivo imaging of twist drill drainage for subdural hematoma: a clinical feasibility study on electrical impedance tomography for measuring intracranial bleeding in humans. PloS one, Public Library of Science, v. 8, n. 1, p. e55020, 2013.
- [9] S. J. Hamilton; A. Hauptmann. Deep D-bar: Real time Electrical Impedance Tomography Imaging with Deep Neural Networks. 2017
- [10] W. Pinheiro dos Santos, R. Ribeiro, R. Feitosa, A. Barbosa, V. da Silva, et al. Electrical Impedance Tomography Using Evolutionary Computing: A Review. Bio-inspired computing for Image and video processing, v.1, p.93-128, 2017.
- [11] R. Ogava, J. Gomes, N. Soares, V. Barbosa, W. Santos, et al. Algoritmo de Evolução Diferencial hibridizado e Simulated Annealing aplicados a Tomografia por Impedância Elétrica. I Simpósio de inovação em Engenharia Biomédica (SABIO), 2017.
- [12] M. P. V. Leão, V. G. Macedo. Comparação entre os métodos de analítico e iterativo na reconstrução de imagens tomográficas. XXIV Congresso Brasileiro de Engenharia Biomédica (CBEB), 2014.
- [13] J. Hiesh. Computed Tomography: Principles, Design, Artifacts and Recent Advances. 2nd Edition. SPIE Press, Wiley Inter-Science, 2009.
- [14] H. Wang, G. Xu, S. Zhang, and W. Yan. An implementation of generalized backprojection algorithm for the 2-D anisotropic EIT problem. IEEE Transactions on Magnetism, Volume: 51, Issue: 3, Março 2015.
- [15] R. Guardo; C. Boulay; B. Murray; M. Bertrand. An Experimental Study in Electrical Impedance Tomography using Backprojection Reconstruction. IEEE Transactions on Biomedical Engineering, Vol 38, no. 7, Julho 1991.
- [16] S. Haykin. Redes Neurais Princípios e prática. São Paulo: Bookman, 2001
- [17] G. Huang; H. Zhou; Z. Ding; R. Zhang. Extreme Learning Machine for Regression and Multiclass Classification. IEEE Transactions on Systems, Man, and Cybernetics – Part B: Cybernetics, Vol. 42, no. 2, Abril 2012.
- [18] G. Huang; Q. Zhu; C. Siew. Extreme learning machine: Theory and applications. Neurocomputing, Vol.70, pp.489-501, 2006.
- [19] L. Qiong; Z. Tingting; Z. Lingchao; S. Wenhui; X. Zhao. Ferrography Wear Particles Image Recognition Based on Extreme Learning Machine. Journal of Electrical and Computer Engineering, Volume 2017.
- [20] J. Lei; H.P. Mua; Q.B. Liub; X.Y. Wang b; S. Liua. Data-driven reconstruction method for electrical capacitance tomography. Neurocomputing, 2017.

APÊNDICE D – ALGORITMO DE EVOLUÇÃO DIFERENCIAL HIBRIDIZADO E SIMULATED ANNEALING APLICADOS A TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA

Trabalho submetido e aprovado para apresentação e publicação nos Anais do I Simpósio de Inovação em Engenharia Biomédica, realizado em 2017 no Campus Recife da Universidade Federal de Pernambuco.

Resumo: A Tomografia por Impedância Elétrica (TIE) é um método de diagnóstico por imagem não-invasivo, não-destrutivo, de baixo custo e portátil que possui diversas aplicações hoje em dia. Tal método baseia-se na aplicação de uma corrente alternada de alta frequência e baixa amplitude em eletrodos posicionados, equidistantemente, ao redor da superfície do domínio em análise, visando a reconstrução do mapa de condutividade ou resistividade elétrica de seu interior. A reconstrução de imagens de TIE, entretanto, não é algo trivial, pois trata-se de um problema inverso, mal-posto, governado pela Equação de Poisson. Neste trabalho, apresentam-se algoritmos para a reconstrução de TIE baseados no algoritmo de Evolução Diferencial (ED), fazendo um comparativo deste com os métodos de *Simulated Annealing* (SA) e Evolução Diferencial com *Simulated Annealing* para análises qualitativas e quantitativas.

I Simpósio de inovação em Engenharia Biomédica

I Simpósio de Inovação em Engenharia Biomédica – SABIO 2017

ALGORITMO DE EVOLUÇÃO DIFERENCIAL HIBRIDIZADO E SIMULATED ANNEALING APLICADOS A TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA

R. L. T. Ogava*, N. S. Soares*, J. C. Gomes*, V. A. F. Barbosa*, R. R. Ribeiro*, D. E. Ribeiro*,
R. E. de Souza*, W. P. dos Santos*

*Universidade Federal de Pernambuco, Recife, Brasil
e-mail: rodrigo.ogava@gmail.com.com

Resumo: A Tomografia por Impedância Elétrica (TIE) é um método de diagnóstico por imagem não-invasivo, não-destrutivo, de baixo custo e portátil que possui diversas aplicações hoje em dia. Tal método baseia-se na aplicação de uma corrente alternada de alta frequência e baixa amplitude em eletrodos posicionados, equidistantes, ao redor da superfície do domínio em análise, visando a reconstrução do mapa de condutividade ou resistividade elétrica de seu interior. A reconstrução das imagens de TIE, entretanto, não é algo trivial, pois trata-se de um problema inverso, mal-posto, governado pela Equação de Poisson. Neste trabalho apresentam-se algoritmos para a reconstrução de TIE baseados no algoritmo de Evolução Diferencial (ED), fazendo um comparativo deste com os métodos de *Simulated Annealing* (SA) e Evolução Diferencial com *Simulated Annealing* (EDSA) para análises qualitativas e quantitativas.

Palavras-chave: Tomografia por Impedância Elétrica, reconstrução de imagem, algoritmos de reconstrução, Evolução Diferencial, *Simulated Annealing*.

Abstract: *Electrical Impedance Tomography (EIT) is a non-invasive, non-destructive, low cost and portable imaging method that has several applications nowadays. This method is based on the application of an alternating current of high frequency and low amplitude in electrodes positioned, equidistantly, around the surface of the domain in analysis aiming at the reconstruction of the map of conductivity or electrical resistivity of its interior. The reconstruction of EIT images, however, is not trivial, because it is an inverse, misplaced problem governed by the Poisson equation. In this work we present algorithms for the reconstruction of EIT based on algorithm of Differential Evolution (DE), making a comparison between this method, Simulated Annealing (SA) and Differential Evolution with Simulated Annealing (DESA) for qualitative and quantitative analyzes.*

Keywords: *Electrical Impedance Tomography, Image Reconstruction, Reconstruction Algorithms, Differential Evolution, Simulated Annealing.*

Introdução

O câncer é doença de grande complexidade e com altos índices de mortalidade, sendo o câncer de mama o

segundo mais frequente no mundo atualmente. No Brasil, em média 60 mil pessoas, por ano, são diagnosticadas com a doença, sendo a maioria mulheres. Como agravante, tem-se que 60% dos casos são diagnosticados já em estado avançado, o que prejudica demasiadamente o tratamento. Devido a tais circunstâncias, a Tomografia por Impedância Elétrica (TIE) se mostra um método de imageamento alternativo de grande ajuda, pois é não-invasivo, não contém radiação ionizante, possui um baixo custo relativo, além de ser portátil e de fácil manipulação.

A TIE baseia-se na resolução de um problema inverso, por onde uma corrente alternada de alta frequência e baixa amplitude é aplicada em eletrodos conectados à superfície do domínio estudado e os potenciais elétricos resultantes são medidos com o intuito de reconstruir graficamente um mapa de condutividade ou resistividade elétrica do interior do volume sob análise.

Contudo, a reconstrução de TIE não é tão simples, pois trata-se de um problema mal-posto governado pela Equação de Poisson, ou seja, dado um conjunto de potenciais elétricos, não existe uma única distribuição de condutividade ou resistividade elétrica no interior do domínio em estudo.

A TIE é bastante dependente do algoritmo de reconstrução utilizado, sendo diferentes técnicas de otimização testadas e comparadas por pesquisadores do mundo inteiro. Os algoritmos evolutivos têm se mostrado como uma ótima alternativa para a resolução do problema inverso, por tal motivo, neste trabalho, apresenta-se uma comparação do algoritmo de Evolução Diferencial (ED) com o *Simulated Annealing* (SA), e a técnica híbrida, Evolução Diferencial com *Simulated Annealing* (EDSA).

Materiais e Métodos

I Simpósio de Inovação em Engenharia Biomédica

I Simpósio de Inovação em Engenharia Biomédica – SABIO 2017

Tomografia por Impedância Elétrica – Do ponto de vista experimental, um circuito eletrônico se encarrega de distribuir as correntes pelos 16 eletrodos dispostos na superfície do domínio estudado e medir as diferenças de potencial relacionadas. Os dados das medidas são passados a um computador que, utilizando um algoritmo adequado, pode fazer a estimativa da distribuição de condutividade (ou resistividade) no plano avaliado. A cada ponto da região medida é associado um pixel, o qual corresponde ao valor da condutividade estimada [1], tal esquema pode estar representado na Figura 1.




Figura 1: Diagrama de Blocos da TIE.

Do ponto de vista matemático, o problema de TIE é regido pelas Equação de Poisson (1) e duas condições de contorno (2) e (3).

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

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

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

Onde $\vec{u} = (x, y, z)$ é a posição do voxel, $\phi(\vec{u})$ é a distribuição de potenciais elétricos, $\phi_{ext}(\vec{u})$ é a distribuição de potenciais elétricos nos eletrodos de superfície, $I(\vec{u})$ é a corrente elétrica, periódica com frequência ω_0 para evitar os efeitos de superfície, $\sigma(\vec{u})$ é a distribuição de condutividade elétrica, Ω é o volume de interesse (domínio), e $\partial\Omega$ é a borda do domínio (superfície), $\hat{n}(\vec{u})$ é o vetor normal de superfície na posição $\vec{u} \in \partial\Omega$ [2] [3].

Tal problema pode ser direto, quando se quer determinar os potenciais elétricos dos eletrodos de superfície dados corrente e distribuição de condutividade. Sendo este modelado pela seguinte relação:

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

Ou pode ser um problema inverso, quando, a partir da corrente e distribuição de potenciais elétricos nos eletrodos de superfície, deseja-se determinar a distribuição de condutividade (imagem de TIE). Sendo este modelado da seguinte forma:

$$\sigma(\vec{u}) = f^{-1}(I(\vec{v}), \phi_{ext}(\vec{v})), \forall \vec{v} \in \partial\Omega \wedge \vec{u} \in \Omega \quad (5)$$

Evolução Diferencial – É uma técnica que pretende minimizar a função objetivo no espaço de busca. Utilizando os operadores básicos de cruzamento e mutação, esse algoritmo evolucionário de otimização cria um processo de seleção natural, onde os operadores são modelados através da substituição pelo seus descendentes mais adaptados [2]. Este processo está detalhado no algoritmo seguinte, concebido para a minimização da função objetivo $f: R^n \rightarrow R$, onde P_{CR} é a probabilidade de cruzamento [4]:

Algoritmo ED

- 1) Gerar a população inicial (S) com dimensão d , cada um representado por um vetor $x_{j,i,G}$, onde $j = 1, 2, \dots, d$, $i = 1, 2, \dots, n$ e G corresponde a geração corrente;
- 2) Repetir até que seja atingido o critério de parada:
 - a) Para $i = 1, 2, \dots, n$ faça
 - i) Gerar agente mutado $v_{j,i,G+1}$;
 - ii) Gerar agente cruzado $\tilde{x}_{j,i,G+1}$;
 - iii) Se $f(\tilde{x}_{j,i,G+1}) < f(x_{j,i,G})$, então

$$x_{j,i,G} \leftarrow \tilde{x}_{j,i,G+1} \text{ (minimização);}$$

A versão da evolução diferencial usada neste trabalho contém o i -ésimo agente mutado, comumente conhecido como *trial vector*, definido como se segue:

$$v_{j,i,G+1} = x_{j,i,G} + \eta_i (x_{j,i_{best},G} - x_{j,i,G}) + \eta_i (x_{j,i_1,G} - x_{j,i_2,G}) \quad (6)$$

Onde $\eta_i \text{rand}_i$, $i_1 \neq i_2 \neq i$ e i_{best} corresponde ao agente mais apto na geração corrente. O i -ésimo agente cruzado é definido como se segue:

$$\tilde{x}_{j,i,G+1} = \begin{cases} v_{j,i,G+1}, & \text{se } (\text{rand}_j \leq P_{CR}) \text{ ou } j = \text{rnbr}(i) \\ x_{j,i,G}, & \text{se } (\text{rand}_j > P_{CR}) \text{ ou } j \neq \text{rnbr}(i) \end{cases} \quad (7)$$

Onde, $P_{CR} = 0,9$ é a taxa de cruzamento, rand_j é a j -ésima avaliação de um gerador de número aleatório uniforme com resultado $[0,1]$, $\text{rnbr}(i) \in 1, 2, \dots, d$ é um índice escolhido aleatoriamente, o que assegura que $\tilde{x}_{j,i,G+1}$ recebe pelo menos um parâmetro $v_{j,G+1}$ [4].

Simulated Annealing – É uma analogia entre um processo metalúrgico, o *Annealing*, e um método de solução para um problema de otimização. O *Annealing* é o processo de resfriamento lento e gradual de um sólido até o estado de menor energia. Se o resfriamento não for gradual, o material fica preso em um estado de “menor energia local”, com a estrutura atômica irregular e fraca [5]. Assim, o *Simulated Annealing* é uma meta-heurística de otimização por busca local de escalada do monte, que pode pular mínimos locais. A movimentação no espaço de busca é feita pela aplicação sequencial de modificações aleatórias no ponto de avaliação da função objetivo, buscando manter o menor custo. Um custo

I Simpósio de Inovação em Engenharia Biomédica

I Simpósio de Inovação em Engenharia Biomédica – SABIO 2017

maior pode ser mantido de acordo com uma probabilidade. Ao longo prazo, converge para o mínimo global [3].

Algoritmo SA

- 1) $S^{\square} \leftarrow S$ // Solução inicial;
- 2) $T \leftarrow T_0$ // Temperatura inicial;
- 3) k // Parâmetro de processo;
- 4) γ // Constante aleatória $\in [0,1]$;
- 5) SA_{max} // Número máximo de iterações antes da queda da temperatura T ;
- 6) Enquanto o critério de parada não for satisfeito:
 - a) $IterT \leftarrow 0$ // Iterações da temperatura T ;
 - b) Enquanto $IterT < SA_{max}$ faça:
 - i) $IterT \leftarrow IterT + 1$;
 - ii) $S' \leftarrow GerarVizinhoQualquer(S)$;
 - iii) $\Delta E \leftarrow f(S') - f(S)$ // mudança da função objetivo;
 - iv) Se $\Delta E < 0$, então: $S \leftarrow S'$;
 - v) Senão se $f(S') < f(S^{\square})$, então: $S^{\square} \leftarrow S'$;
 - (1) Senão tome aleatoriamente $P \in [0,1]$;
 - (2) Se $\left(P < e^{\frac{-\Delta E}{kT}}\right)$ então $S \leftarrow S'$;
- 7) Fim-enquanto;
- 8) $T \leftarrow \frac{T}{1 + \gamma \sqrt{T}}$;// onde $\gamma \in [0,1]$
- 9) $IterT \leftarrow 0$; Fim-enquanto;
- 10) $S \leftarrow S^{\square}$; Retorne $S^{\square}$; fim Simulated Annealing;

A função $GerarVizinhoQualquer(S)$ obtém uma solução vizinha no espaço de busca da solução corrente “S” através da adição de um ruído aleatório máximo de 5% sobre um elemento interno escolhido aleatoriamente. A geração de uma solução vizinha pior, isto é, $\Delta E > 0$, o algoritmo evita a modificação desse elemento durante as demais iterações até a convergência.

Evolução Diferencial Híbrida com Simulated Annealing – Essa técnica (EDSA) consiste na implementação da ED, como detalhado em “Algoritmo ED”, no entanto adicionado o *Simulated Annealing* dentro do operador de seleção para melhorar a capacidade de busca global da ED. Esta técnica encontra-se explicada no algoritmo seguinte:

Algoritmo EDSA

- 1) Inicialização: Gerar a população inicial de agentes aleatórios, cada um representado por um

vetor, a temperatura atual é a temperatura inicial escolhida;

- 2) A avaliação da aptidão dos agentes da população;
- 3) Mutaç o da população: É baseada na estratégia ED/rand-to-best/2/bin. Como mostrada pela Eq. (6);
- 4) Cruzamento da população: É baseado na operação de cruzamento da ED. Como mostrada pela Eq. (7);
- 5) Avaliação da aptidão de acordo com a função objetivo;
- 6) A seleção da população é processada comparando o vetor alvo com o vetor de julgamento da população. Além disso, *Simulated Annealing* é adicionado dentro do operador de seleção;
- 7) Parar se o crit rio de parada for satisfeito; Casos contrário, voltar a Etapa 3.

Função Objetivo para Reconstrução-TIE – O problema da TIE é tratado como um problema de otimização, assim diferentes técnicas podem ser usadas. A função objetivo é:

$$f(s) = \left[\frac{\sum_{i=1}^{n_p} (U_i(s) - V_i)^2}{\sum_{i=1}^{n_p} (V_i)^2} \right]^{1/2} \quad (8)$$

$$V = (V_1, V_2, \dots, V_{n_p})^t \quad (9)$$

$$U(s) = (U(s)_1, U(s)_2, \dots, U(s)_{n_p})^t \quad (10)$$

onde V é a distribuição de potenciais elétricos medidos na borda, e $U(s)$ é a distribuição de potenciais elétricos calculados na borda. Sendo n_p o número de eletrodos na borda e $f(s)$ o erro médio quadrático relativo.

Reconstrução de Imagem usando EIDORS – O software EIDORS é uma ferramenta em código livre para MATLAB/Octave utilizada para modelagem direta e inversa de TIE e Tomografia Óptica baseada em Difusão, a fim de compartilhar dados e promover a colaboração entre grupos de trabalho nestes campos [3], [4]. Ele simula uma malha de elementos finitos que representa computacionalmente uma secção transversal de um corpo bem como sua distribuição de condutividade interna na forma de cores [4].

Métodos e Experimentos Propostos – Para a avaliação, projetamos experimentos para 16 eletrodos, 415 elementos da malha da grade circular 2D com nível de densidade 'b' e nível de refinamento '2' (parâmetros do EIDORS). Os problemas estudados consistem em detectar objetos irregulares isolados em três configurações: (a) no centro, (b) entre o centro e a borda e (c) perto da borda do domínio. Utilizou-se o erro relativo entre as distribuições de potenciais elétricos medidos e calculados na borda como a função objetivo para todos os métodos de otimização que usamos neste trabalho. Candidatos a solução são vetores reais usados

I Simpósio de Inovação em Engenharia Biomédica

I Simpósio de Inovação em Engenharia Biomédica – SABIO 2017

como abstrações teóricas para distribuições de condutividade possíveis, onde cada dimensão corresponde a um determinado elemento finito da grade.

Para o método SA, utilizou-se $T_0=200.000$ (temperatura inicial), $k=1$ (parâmetro de processo),

$SA_{max}=10.000$ (número máximo de iterações antes da queda da temperatura T), como solução inicial (S)

um agente foi definido com distribuição de condutividade interna aleatória entre 0 e 1. Tanto para o método ED quanto para EDSA foi utilizado $P_{CR} = 0,9$, trabalhou-se com $n = 100$ (número de agentes da população), ou seja, candidatos a solução, e foi feito experimentos para critério de parada como 500 iterações. É importante enfatizar que, todas as técnicas aqui mencionadas foram implementadas no software MATLAB versão R2008a. Sendo usado o software EIDORS versão 3.7.1 para resolução do problema direto da TIE.

Resultados

A Figura 2 mostra as distribuições de condutividade elétrica originais simuladas com o objeto isolado eletricamente no centro (a), entre o centro e a borda (b) e na borda (c) do domínio circular.

As Figuras 3, 4 e 5 apresentam os resultados das reconstruções obtidas com as técnicas ED, SA e EDSA, conforme discutidas neste trabalho.

A Figuras 6 apresenta o comportamento do erro quadrático relativo de acordo com o número de cálculos da função objetivo para o objeto em cada uma das posições propostas.




Figura 2: Objetos de estudo criados com o software EIDORS com isolante no centro, entre o centro e a borda e na borda.




Figura 3: Resultados obtidos com as simulações usando ED para objetos colocados no centro (a1,a2,a3), entre o centro e a borda (b1,b2,b3) e na borda (c1,c2,c3) do domínio circular, para 50, 300 e 500 iterações, respectivamente.




Figura 4: Resultados obtidos com as simulações usando SA para objetos colocados no centro (a1,a2,a3), entre o centro e a borda (b1,b2,b3) e na borda (c1,c2,c3) do domínio circular, para 50, 300 e 500 iterações, respectivamente.




Figura 5: Resultados obtidos com as simulações usando EDSA para objetos colocados no centro (a1,a2,a3), entre o centro e a borda (b1,b2,b3) e na borda (c1,c2,c3) do domínio circular, para 50, 300 e 500 iterações, respectivamente.

I Simpósio de Inovação em Engenharia Biomédica

I Simpósio de Inovação em Engenharia Biomédica – SABIO 2017




Figura 6: Erro de acordo com o número de cálculos da função objetivo para o objeto nas três configurações.

Discussão

Analisando quantitativamente as Figuras 3, 4 e 5, pode-se perceber visualmente que as técnicas apresentadas foram eficazes na reconstrução dos objetos em estudo. As mesmas são consistentes anatomicamente, considerando a baixa resolução das imagens de TIE, e com resultados conclusivos com o número máximo de iterações propostas. Comparado com o método SA, a Evolução Diferencial mostrou-se mais eficiente nas reconstruções, pois logo nas primeiras 50 iterações apresentou resultados consistentes e com baixo nível de ruído relativo. É importante, porém, ressaltar, que as reconstruções obtidas com a técnica EDSA apresentaram uma maior definição de borda.

A partir do gráfico da Figura 6, observa-se que a técnica híbrida proposta gera valores mais baixos de erro relativo nas primeiras iterações, além de apresentar uma queda rápida do erro relativo ao longo do processo de convergência, mantendo os valores quase sempre abaixo dos obtidos com a técnica ED. Esses resultados podem ser explicados pela alta diversidade da população candidata obtida pela técnica ED, acoplada à capacidade de se evitar mínimos locais com a técnica SA.

Conclusão

Ambas as análises quantitativa e qualitativa mostraram que a técnica híbrida avaliada, utilizando ED e SA, obteve melhores resultados em comparação com a reconstrução apenas com ED ou com SA. Além disso, observa-se que o custo computacional pode ser reduzido de maneira eficaz através da hibridização da Evolução Diferencial com técnicas de busca local.

Agradecimentos

Os autores agradecem ao CNPq e à FACEPE pelo financiamento parcial da pesquisa.

Referências

- [1] de Lima, C. R. (2006). *Estudo da obtenção de imagens de tomografia de impedância elétrica do pulmão pelo método de otimização topológica* (Doctoral dissertation, Universidade de São Paulo).
- [2] Ribeiro, R. R., Feitosa, A. R., Barbosa, V. A., da Silva, V. L., Rocha, A. D., Freitas, R. C., ... & dos Santos, W. P. Reconstrução de Imagens de TIE usando Simulated Annealing, Evolução Diferencial e Algoritmos Genéticos.
- [3] Ribeiro, R. R., Feitosa, A. R. S., Souza, R. E., & Santos, W. P. (2014). Um algoritmo de evolução diferencial modificado com busca não-cega para tomografia por impedância elétrica. In *Proceedings of the XXIV Congresso Brasileiro de Engenharia Biomédica*.
- [4] Ribeiro, R. R., Barbosa, V. A. F., Mendonça, P. D., da Silva, V. L. B. A., de Souza, R. E., dos Santos, W. P. (2016). Evolução diferencial híbrida para reconstrução de imagens de tomografia por impedância elétrica.
- [5] Herrera, C. N. L., Vallejo, M. F. M., Moura, F. S., Aya, J. C. C., & Lima, R. G. (2007). Electrical impedance tomography algorithm using simulated annealing search method. In *Proc COBEM* (Vol. 2007).