



UNIVERSIDADE FEDERAL DO RIO GRANDE

PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM COMPUTACIONAL

JOSÉ ALFREDO DE VILLA TERRA JÚNIOR

**DESENVOLVIMENTO DE UM ALGORITMO UTILIZANDO REDES
NEURAIS ARTIFICIAIS USANDO DADOS DA TOMOGRAFIA POR
IMPEDÂNCIA ELÉTRICA PARA ESTIMATIVA DE VOLUMES**

Rio Grande

2015


JOSÉ ALFREDO DE VILLA TERRA JÚNIOR


"Desenvolvimento de um Algoritmo Utilizando Redes Neurais Artificiais Usando Dados da Tomografia por Impedância Elétrica para Estimativa de Volumes"


Dissertação apresentada ao Programa de Pós Graduação em Modelagem Computacional da Universidade Federal do Rio Grande - FURG, como requisito parcial para obtenção do Grau de Mestre. Área concentração: Modelagem Computacional.


Aprovada em

BANCA EXAMINADORA


Prof. Dr. Renato Glaucio de Souza Rodrigues
Orientador – FURG


Prof.ª Dr.ª Bárbara Demicol Rodriguez
FURG


Prof.ª Dr.ª Maria Eulália Pinto Tabragó
PUCRS


Prof.ª Dr.ª Aline Guerra Dytz
FURG

Rio Grande - RS
2015

JOSÉ ALFREDO DE VILLA TERRA JÚNIOR

**DESENVOLVIMENTO DE UM ALGORITMO UTILIZANDO REDES
NEURAIS ARTIFICIAIS USANDO DADOS DA TOMOGRAFIA POR
IMPEDÂNCIA ELÉTRICA PARA ESTIMATIVA DE VOLUMES**

Dissertação apresentada ao
Programa de Pós-Graduação em
Modelagem Computacional da
Universidade Federal do Rio
Grande – FURG, como
requisito para a obtenção do
título de Mestre em Modelagem
Computacional.

**Orientador: Prof. Dr. Renato
Glauco de Souza Rodrigues**

Rio Grande

2015

AGRADECIMENTOS

À minha noiva Fransuelen C. Retzlaf, por sua paciência e companheirismo nos momentos difíceis.

Aos meus pais José Alfredo e Neida Mara, por terem acreditado em mim e por todo apoio emocional.

Ao meu orientador, professor Dr. Renato Glauco de Souza Rodrigues pela orientação e conhecimentos passados.

Aos professores que foram minha banca, pelas contribuições importantes para o aperfeiçoamento do trabalho.

À CAPES pelo apoio financeiro.

RESUMO

No presente trabalho, desenvolveu-se um sistema capaz de estimar o volume de um corpo qualquer, baseado em dados para Tomografia por Impedância Elétrica (TIE). Mostrou-se, que através de uma Rede Neural Artificial (RNA) o sistema pode ser generalizado, sendo possível aplicá-lo em outros volumes de interesse. Gráficos comparativos mostram que se pode explorar a simetria do sistema sem que ocorram perdas significativas na precisão dos resultados.

Palavras-Chave: **Tomografia por Impedância Elétrica, RNA, EIDORS, Modelagem Computacional.**

ABSTRACT

In this study, we developed a system able to estimate the volume of any body, based on data for Electrical Impedance Tomography (EIT). It has been shown through using an Artificial Neural Network (ANN), the system can be generalized and may be applied to other volumes of interest. Comparative graphs, show it is possible explore the system symmetry without significant losses on the accuracy of results.

Keywords: **Electrical Impedance Tomography, NNA, EIDORS, Computational Modeling.**

LISTA DE FIGURAS

Figura 1: Sistema de estimação de volume da bexiga baseado em dados de Tomografia por Impedância Elétrica.....	11
Figura 2: Representação básica de um exame de TIE.	13
Figura 3: Diagrama da composição das camadas de uma rede MLP.	21
Figura 4: Esquema básico do treinamento de uma rede neural artificial por <i>backpropagation</i>	22
Figura 5: Representação da bexiga urinária	27
Figura 6: Arduino Mega 2560.	29
Figura 7: Malha gerada pelo pacote EIDORS no software MATLAB.	32
Figura 8: Volumes gerados no centro da malha	33
Figura 9: Rede Neural.....	34
Figura 10: Gráfico relativo aos erros de validação.....	36
Figura 11: Gráfico comparativo entre os volumes calculados e os volumes simulados com 208 neurônios na camada de entrada, 6 neurônios na camada oculta e 1 neurônio na camada de saída com 11 volumes simulados.	37
Figura 12: Gráfico do Erro de Validação para uma rede com 104 neurônios na camada de entrada, 15 neurônios na camada oculta e um neurônio na camada de saída com um conjunto de 11 volumes simulados.....	39
Figura 13: Gráfico comparativo entre os volumes calculados e os volumes simulados com 104 neurônios na camada de entrada, 4 neurônios na camada oculta.	39
Figura 14: Imagens dos volumes gerados em posições diferentes.	40
Figura 15: Gráfico do Erro de Validação para uma rede com 208.....	42
Figura 16: Gráfico comparativo entre os volumes calculados e os volumes simulados. Os dados foram obtidos através de uma RNA com 208 neurônios na camada de entrada, 5 neurônios na camada oculta.....	43
Figura 17: Gráfico do Erro de Validação para uma rede com 104 neurônios na camada de entrada, 15 neurônios na camada oculta e um conjunto de saída com 18 volumes...	44
Figura 18: Gráfico comparativo entre os volumes calculados e os volumes simulados com 104 neurônios na camada de entrada, 7 neurônios na camada oculta e 1 conjunto de saída com 18 volumes simulados.	45

LISTA DE EQUAÇÕES

Equação 1: Densidade de Corrente.....	15
Equação 2: Corrente dentro de um condutor.....	16
Equação 3: Impedância Elétrica do meio.....	16
Equação 4: Admitância Elétrica	17
Equação 5: Condutividade Elétrica.....	17
Equação 6: Densidade de Corrente.....	18
Equação 7:Densidade de corrente na TIE.....	18
Equação 8: Divergente da Densidade.....	18
Equação 9: Campo Elétrico.....	18
Equação 10: Equação de Laplace.....	19
Equação 11: Equação de Laplace em duas dimensões.....	19
Equação 12: Equação comum do problema inverso.....	19
Equação 13: Propagação do sinal.....	23
Equação 14: Saída do neurônio j na camada l	23
Equação 15: Ajuste dos pesos sinápticos.....	23
Equação 16: Valor instantâneo da energia total do erro.....	24
Equação 17: Derivada do algoritmo <i>backpropagation</i>	24
Equação 18: Retropropagação do algoritmo.....	24
Equação 19: Atualização dos pesos sinápticos.....	24
Equação 20: Erro Quadrático Médio (MSE, do inglês Mean Square Error).....	25
Equação 21: Atualização dos pesos por Gauss-Newton.....	25
Equação 22:Gradiente da função.....	26
Equação 23: Cálculo da Matriz Hessiana.....	26
Equação 24: Cálculo de S.....	26
Equação 25: Matriz Hessiana.....	26
Equação 26: Atualização dos pesos por Gauss-Newton.....	26
Equação 27: Atualização dos pesos sinápticos com a modificação de Levenberg-Marquadt.....	26

LISTA DE TABELAS

Tabela 1: Comparação entre Resistividade elétrica e o Coeficiente de Atenuação de Raios X	28
Tabela 2: Especificações Técnicas do Arduino Mega 2560	30
Tabela 3: Valores dos erros de validação obtidos na simulação com 208 neurônios na camada de Entrada.....	36
Tabela 4: Valores dos erros de validação obtidos na simulação explorando a simetria do sistema.	38
Tabela 5: Valores dos erros de validação obtidos na simulação com 208 neurônios na camada oculta e 18 volumes variando suas posições.	41
Tabela 6: Valores dos erros de validação obtidos na simulação explorando a simetria do sistema com 18 volumes variando suas posições.	43

LISTA DE SIGLAS E ABREVIATURAS

TIE	Tomografia por Impedância Elétrica
RNA	Rede Neural Artificial
MATLAB	<i>Matrix Laboratory</i>
EIDORS	<i>Electrical Impedance and Diffuse Optical Tomography Reconstruction Software</i>
WI-FI	<i>Wireless Fidelity</i>
MLP	<i>Multilayer Perceptron</i>
MSE	<i>Mean Square Error</i>
PWM	<i>Pulse Width Modulation</i>
UARTs	<i>Universal Asynchronous Receiver Transmitter</i>
ICSP	<i>In – Circuit Serial Programming</i>
SRAM	<i>Static Random Access Memory</i>
EEPROM	<i>Electrically Erasable Programmable Read only Memory</i>
DOT	<i>Diffuse Optical Tomography</i>

SUMÁRIO

RESUMO	II
ABSTRACT	III
LISTA DE FIGURAS	IV
LISTA DE EQUAÇÕES	V
LISTA DE TABELAS	VI
LISTA DE SIGLAS E ABREVIATURAS	VII
ORGANIZAÇÃO DO TRABALHO	10
1 INTRODUÇÃO	11
2 OBJETIVOS	12
2.1 Geral	12
2.2 Específicos	12
3 JUSTIFICATIVA	12
4 FUNDAMENTAÇÃO TEÓRICA	13
4.1 TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA (TIE)	13
4.2 Aplicações da TIE	14
4.3 Formulação Matemática da TIE	15
4.4 problemas inversos	19
4.5 Redes Neurais Artificiais (RNA)	20
4.5.1 Levenberg- Marquadt	25

4.6	BEXIGA URINÁRIA	27
5	MATERIAIS E MÉTODOS	28
5.1	ARDUINO	28
5.1.1	ARDUINO MEGA 2560	29
5.2	MATLAB	30
5.3	EIDORS	31
6	RESULTADOS E DISCUSSÕES	35
7	CONCLUSÕES	45
	REFERÊNCIAS BIBLIOGRÁFICAS	47

ORGANIZAÇÃO DO TRABALHO

No capítulo 1 está a introdução do trabalho.

No capítulo 2 estão expostos os objetivos, geral e específicos, deste trabalho.

O capítulo 3 apresenta a justificativa para que este estudo seja desenvolvido.

O capítulo 4 é dedicado a fundamentação teórica, onde serão abordados os assuntos: 4.1 Tomografia por Impedância elétrica, 4.2 Aplicações da TIE, 4.3 Formulação Matemática da TIE, 4.4 Problemas Inversos, 4.5 Redes Neurais Artificiais e 4.6 Bexiga Urinária.

No capítulo 5 estão os materiais e métodos utilizados para a obtenção dos resultados, o capítulo está dividido em; 5.1 ARDUINO, 5.2 MATLAB, e 5.3 EIDORS.

No capítulo 6 serão apresentados e discutidos os resultados obtidos durante as simulações.

No capítulo 7 estão as conclusões do trabalho.

E por fim estão as referencias bibliograficas que embasaram este estudo.

1 INTRODUÇÃO

Com o avanço da tecnologia nas últimas décadas, a busca por técnicas de diagnósticos não invasivas tornou-se um dos principais focos dos pesquisadores na área médica.

No presente trabalho a técnica a ser estudada é a Tomografia por Impedância Elétrica (TIE). Esta técnica de monitoração está sendo desenvolvida desde a década de 1980¹. A TIE permite obter imagens que representam um plano transversal de qualquer seção do corpo, onde cada pixel na imagem representa a sua impedância ou resistividade elétrica estimada. Embora a técnica esteja bem desenvolvida e fundamentada, ela ainda permite melhorias.

O foco deste estudo está em desenvolver um algoritmo que, através dos dados para TIE, estime o volume de um corpo qualquer, sem que haja a necessidade de reconstruir a imagem do mesmo. Com isso espera-se diminuir o custo computacional e o tempo de resposta do *software*.

Com base nos dados obtidos neste trabalho, pretende-se desenvolver um sistema que auxilie os cuidadores de pessoas incapazes de ir sozinhas ao banheiro, como tetraplégicos e acamados. O sistema baseado na TIE estimaria o volume da bexiga do paciente e enviaria um sinal para o *smartphone* do cuidador, avisando sobre a necessidade de levar o paciente ao banheiro. A Figura 1 mostra como esta aplicação se daria.




Figura 1: Sistema de estimativa de volume da bexiga baseado em dados de Tomografia por Impedância Elétrica.(Figura adaptada de Thomas Schlebusch et al., 2014).

2 OBJETIVOS

2.1 GERAL

O presente trabalho tem como objetivo principal, a partir de uma aplicação da Tomografia por Impedância Elétrica (TIE), criar e generalizar um algoritmo para estimar o volume de um dado objeto sem que seja necessário a reconstrução da imagem do mesmo.

2.2 ESPECÍFICOS

Como objetivos específicos do presente trabalho, tem-se;

- Análise de aplicações e usos relacionadas a TIE;
- Simulações computacionais para definir o algoritmo de treinamento mais adequado para estimar o volume de um corpo;
- Criação do algoritmo para obtenção, armazenamento e tratamento dos dados;
- Análise dos dados obtidos na simulação.

3 JUSTIFICATIVA

Em geral, os estudos da aplicação da TIE se justificam devido ao método ser não invasivo, possuir um baixo custo e não envolver radiação ionizante.

Os métodos existentes de diagnóstico utilizando TIE são, basicamente, dependentes da reconstrução da imagem da estrutura analisada, o presente trabalho justifica-se por propor uma forma de analisar estruturas anatômicas baseadas em seu volume, sem que haja a necessidade da reconstrução da imagem da mesma. Isso faz com que o tempo de resposta seja diminuído e o custo computacional seja baixo, em relação a métodos que envolvem a reconstrução de imagem, permitindo que o sistema possa ser embarcado em um *hardware* portátil de recursos limitados.

4 FUNDAMENTAÇÃO TEÓRICA

4.1 TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA (TIE)

A TIE é uma técnica não invasiva de obtenção de imagens da estrutura interna de volumes condutores. Ela tem por base explorar as diferenças entre as propriedades elétricas, condutividade e permissividade, dos diferentes tecidos de uma área ou volume de interesse^{2,3,4}.

A produção da imagem na TIE é feita com o posicionamento de eletrodos ao redor do corpo de interesse e quando ocorre um estímulo (injeção de corrente elétrica ou aplicação de diferença de potencial) gera-se uma resposta. Como os parâmetros de condutividade e permissividade variam de um tecido para outro, estima-se a distribuição de condutividades elétricas daquela seção do corpo, a partir da diferença entre o estímulo e a resposta obtida, com isso pode-se reconstruir a imagem deste corpo computacionalmente, através de um algoritmo de reconstrução^{2,3}.




Figura 2: Representação básica de um exame de TIE.

A Figura 2 apresenta um esquema básico montado para obter as informações necessárias para a produção da imagem por meio de Tomografia por Impedância Elétrica. Como pode ser observado os eletrodos são posicionados ao redor do corpo, então uma fonte de corrente aplica um estímulo (corrente elétrica), gerando assim os sinais que serão convertidos pela instrumentação. O multiplexador tem a função de

transmitir a leitura do sinal através de todos eletrodos, com isso os dados são transmitidos para o computador que analisará os dados coletados e fará a reconstrução da imagem através de um algoritmo.

Esta técnica vem sendo desenvolvida desde o início da década de 80¹. Entretanto a literatura aponta Ross P. Henderson e John G. Webster como pioneiros na produção de imagens do corpo humano a partir de suas propriedades elétricas^{2,5,6}. O sistema desenvolvido por Henderson e Webster denominado Câmara de Impedância, utilizava uma fonte de tensão que aplicava uma diferença de potencial elétrico através de eletrodos posicionados ao redor do tórax do paciente. Porém a resolução da imagem obtida era muito baixa, sem muito valor para diagnóstico, devido a algumas aproximações feitas pelo modelo matemático utilizado para a reconstrução da imagem^{2,3,5}.

4.2 APLICAÇÕES DA TIE

Atualmente é possível encontrar diversos estudos de aplicações da Tomografia por Impedância Elétrica, tanto na medicina quanto na área industrial.

Na medicina a TIE se mostra promissora devido ao fato de ser um método de diagnóstico não invasivo, de baixo custo, portátil e que não utiliza radiação ionizante⁴. Artigos publicados recentemente mostram sua versatilidade em termos de aplicação.

Ainda na área médica existem outros trabalhos, considerados tradicionais, publicados aplicando a Tomografia por Impedância Elétrica para, por exemplo, reconstruir as fronteiras de órgãos no tórax humano, determinar a resistividade do pulmão de um adulto, reconstruir tridimensionalmente a próstata, entre outros^{7,8,9}.

Na literatura é possível encontrar diversas aplicações clássicas da Tomografia por Impedância Elétrica na área médica como, por exemplo, a detecção de hemorragia intraventricular em bebês prematuros, monitoramento das funções pulmonares, monitoramento de apneia, detecção de câncer de mama, ventilação forçada dos pulmões, entre outras^{10,11,12,13,14}.

Thomas Schlebusch et al., 2014 propôs um sistema utilizando a TIE para orientar pessoas que tenham algumas estruturas neuronais danificadas, por exemplo os

paraplégicos, e com isso tenham problemas para identificar o momento apropriado de fazer o auto cateterismo. Este sistema estimaria o volume da bexiga do paciente, analisando a condutividade da urina, e enviaria um sinal via *WI-FI* para o celular do cuidador ¹⁵.

Robert Pikkemaat em seu artigo publicado em janeiro de 2014 propõe a TIE como alternativa aos métodos invasivos existentes para o monitoramento do débito cardíaco e do volume sistólico, através da avaliação da frequência cardíaca e da quantificação das mudanças nas configurações do ventilador ¹⁶.

Na área industrial a TIE também possui grande aplicação como, por exemplo, na indústria petrolífera, escoamentos multifásicos em tubulações, aplicações subaquáticas com objetivo de detectar objetos compactos enterrados em sedimentos para diversas profundidades^{17,18,19}.

4.3 FORMULAÇÃO MATEMÁTICA DA TIE

A corrente elétrica alternada transmitida pelos eletrodos depende das características do meio. Associada a ela, a densidade de corrente é uma grandeza vetorial, característica de um ponto interno do condutor.

Devido ao fato do objeto de estudo deste trabalho ser composto de materiais anisotrópicos (as propriedades eletromagnéticas variam com a direção), a densidade de corrente é caracterizada pela direção dos fluxos de corrente e pela forma de condutibilidade da corrente em cada meio condutor.

Para correntes distribuídas uniformemente através da área A de uma seção reta do condutor, o módulo da densidade de corrente J para todos os pontos daquela seção é dado razão entre a corrente aplicada e a área total da superfície, conforme mostra a Equação 1.

Equação 1: Densidade de Corrente.

$$J = \frac{I}{A}$$

Sendo:

J = Densidade de Corrente.

I = Corrente Elétrica Aplicada

A = Área total da superfície

A unidade da densidade de corrente no Sistema Internacional de Unidades é o ampére por metro quadrado ($\frac{A}{m^2}$).

A corrente total que atravessa a superfície de um condutor é dada pela integral do produto da densidade de corrente J e do elemento de superfície dA sobre toda a superfície da seção, como pode ser visto na Equação 2.

Equação 2: Corrente dentro de um condutor.

$$I = \int J \cdot dA$$

A impedância elétrica é uma grandeza que pode ser descrita pela Equação 3.

Equação 3: Impedância Elétrica do meio.

$$Z = \frac{V_{ef}}{I_{ef}}$$

Sendo:

V_{ef} = Voltagem efetiva aplicada ao circuito.

I_{ef} = Corrente elétrica efetiva que atravessa o circuito.

No Sistema Internacional de Unidades (SI), a impedância elétrica é medida em Ohms (Ω).

A impedância elétrica (Z), conceitualmente, mede a oposição total, que um circuito apresenta à passagem da corrente elétrica. A impedância também pode ser expressa como o inverso da admitância (γ), que por sua vez é expressa pela soma de dois termos, uma parte real representando o termo resistivo e uma parte complexa representando o termo capacitivo.

Então para um circuito resistivo e capacitivo de corrente alternada a admitância é expressa pela Equação 4.

Equação 4: Admitância Elétrica

$$\frac{1}{Z} = \gamma(x, \omega) = \sigma(x, \omega) + j\omega\epsilon(x, \omega)$$

Sendo:

Z = Impedância Elétrica

γ = Admitância Elétrica

x = Posição

σ = Condutividade Elétrica

ω = Frequência Angular da corrente elétrica

ϵ = Permissividade elétrica.

Sendo assim, tem-se que na TIE é possível construir uma imagem interna de um corpo de duas formas, a partir de sua condutividade ou a partir de sua permissividade.

Considerando apenas a condutividade σ do meio, temos que;

Equação 5: Condutividade Elétrica.

$$\sigma = \frac{1}{\rho}$$

Sendo:

σ = Condutividade Elétrica.

ρ = Resistividade.

No S.I de unidades, a condutividade é medida em $(\Omega.m)^{-1}$.

Aplicando uma corrente elétrica no meio, gera-se uma densidade de corrente em seu interior. Esse fato é representado na Equação 6.

Equação 6: Densidade de Corrente

$$J = \sigma E + \epsilon \epsilon_0 \frac{\partial E}{\partial t}$$

Sendo:

J = Densidade de Corrente.

σ = Condutividade Elétrica.

E = Campo Elétrico.

ϵ = Permissividade do meio.

ϵ_0 = Permissividade no vácuo.

$\frac{\partial E}{\partial t}$ = Taxa de variação do campo elétrico em um meio.

A TIE utiliza sinais de baixa frequência para que se possa desprezar os efeitos das correntes de deslocamento, sendo assim $\frac{\partial E}{\partial t}$ pode ser desconsiderado. Portanto a densidade de corrente (J) será calculada pelo produto da condutividade elétrica (σ) e do campo elétrico (E), como mostrado na Equação 67.

Equação 7: Densidade de corrente na TIE.

$$J = \sigma E$$

Tomando o divergente da Equação 7, para frequências inferiores a 30 MHz, temos que:

Equação 8: Divergente da Densidade.

$$\nabla \cdot J = 0$$

O campo elétrico (E) pode ser expresso como o negativo do divergente do potencial, como mostra a Equação 9.

Equação 9: Campo Elétrico.

$$E = -\nabla U$$

Sendo:

$U =$ Potencial

Sendo assim, substituindo a Equação 7 na Equação 8 e a Equação 9 na Equação 7, é possível obter a equação de Laplace.

Equação 10: Equação de Laplace.

$$\nabla \cdot (\sigma \nabla U) = 0$$

Em duas dimensões a equação de Laplace pode ser reescrita como:

Equação 11: Equação de Laplace em duas dimensões.

$$\frac{\partial}{\partial x} \left(\sigma \frac{\partial U}{\partial x} \right) + \frac{\partial}{\partial y} \left(\sigma \frac{\partial U}{\partial y} \right) = 0$$

4.4 PROBLEMAS INVERSOS

O primeiro exemplo de problemas inversos que se tem relato foi introduzido por Platão no livro VII do diálogo da república, quando ele propôs o problema filosófico de reconstruir a “realidade” pela observação da imagem de objetos e pessoas através de sombras projetadas na penumbra de uma caverna²⁰.

Nas últimas quatro décadas, pesquisadores de várias áreas do conhecimento se entusiasmaram com a aplicabilidade dos problemas inversos, isto devido à interdisciplinaridade e relevância das aplicações dos mesmos. Dentre estas áreas destacam-se a engenharia, geofísica, inferência estatística, ciências médicas, entre outras^{20,21,22}. No caso da ciência médica dá-se ênfase à reconstrução de imagens.

O problema direto ocorre quando dada uma causa determinamos o efeito. Já o problema inverso é aquele em que temos o efeito, ou resultado, e tentamos determinar a causa^{21,22}. Dois problemas são inversos um do outro se a formulação de um envolve, pelo menos, parte do conhecimento da solução do outro^{21,23}.

O problema inverso pode ser representado pela

Equação 12: Equação comum do problema inverso.

$$F(\mathbf{u}) = \mathbf{y}$$

ou seja, para um dado efeito y há uma causa u a ser determinada que pertence a um conjunto de dados U . Tal equação é gerada a partir de um modelo matematicamente determinado, ou a determinar, F , o qual geralmente é definido entre espaços de Hilbert X e Y ²⁴.

Problemas inversos são ditos mal postos, ou seja, a solução não satisfaz alguma ou todas as condições de Hadamard^{20,21,22}.

- i. $\forall u \in U, \exists y \in Y$ (condição de existência);
- ii. u é univocamente determinado a partir de y (condição de unicidade);
- iii. O problema é estável nos espaços (X, Y) (estabilidade da solução).

Para resolver problemas, como o descrito pela Equação 12, é comum aplicar o operador inverso da função F , ou seja, F^{-1} . Porém, por vezes, encontram-se problemas que não possuem operador inverso ou se possuem este é ilimitado ^{20,21,22}.

Para resolver problemas inversos existem alguns métodos matemáticos clássicos, como por exemplo, o método de regularização de Tikhonov e a regularização por métodos iterativos, dentre eles o método de Landweber, entre outros^{21,22,24}.

Os métodos de regularização determinam uma solução aproximada para o problema mal-posto, utilizando soluções de um conjunto de problemas bem-postos, convergindo assim para a solução do problema inverso considerado^{21,22,24}.

4.5 REDES NEURAIAS ARTIFICIAIS (RNA)

As redes perceptron de múltiplas camadas (MLP, *multilayer perceptron*) são uma classe muito importante das Redes Neurais Artificiais²⁵. Nessas redes existe um conjunto de nós de fonte, formando uma ou mais camadas ocultas e uma camada de saída de nós computacionais^{25,26,27}.

A Figura 3 mostra um diagrama de como fica a composição das camadas de uma rede do tipo MLP.




Figura 3: Diagrama da composição das camadas de uma rede MLP, com n neurônios fonte na camada de entrada, 2 camadas ocultas com n neurônios computacionais e 1 camada de saída com 2 neurônios (Figura adaptada de De Souza, 2012).

Uma rede MLP pode ser totalmente conectada ou parcialmente conectada²⁷.

Nas RNA's Totalmente Conectadas, um neurônio de qualquer camada está conectado a todos os neurônios das camadas anterior e posterior, como visto na Figura 3.

Nas RNA's Parcialmente Conectadas, como o próprio nome sugere, algumas conexões entre neurônios não ocorrem. Recentemente têm-se estudado a utilização das MLP parcialmente conectadas para reconstrução de imagens tomográficas, através do treinamento supervisionado com o algoritmo de retropropagação do erro (do inglês, *backpropagation*)^{25,26,27}.

O treinamento de retropropagação consiste, basicamente, em um passo para frente, que é a propagação da entrada da rede às camadas posteriores e um para trás, que é a retropropagação do erro que ocorre em sentido contrário da camada de saída.

A Figura 4 apresenta um diagrama básico do treinamento por retropropagação de erro.




Figura 4: Esquema básico do treinamento de uma rede neural artificial por retropropagação (*backpropagation*).

O algoritmo *backpropagation* é um exemplo de aprendizagem supervisionada, aplicado por um processo iterativo. Neste processo a saída produzida pela rede é comparada a resposta desejada e melhorada a cada iteração^{25,26,27,28}.

Após ser feito o cálculo do erro, é realizada a retropropagação deste erro, com o intuito de atualizar os pesos sinápticos das camadas ocultas. Isso faz com que os pesos sinápticos sejam ajustados e assim o erro entre a saída produzida e a desejada seja diminuído^{25,26,27,28}.

Segundo Haykin (2001), o algoritmo pode ser resumido como segue:

1. Inicialização: é quando os pesos e as bias da RNA são inicializados. A bias é o valor aplicado externamente a cada neurônio e tem o efeito de aumentar ou diminuir a entrada líquida. Considerando uma função de ativação sigmoidal, pode-se usar aleatoriamente valores de uma distribuição uniforme no intervalo entre 0 e 1.
2. Apresentação dos padrões de treinamento: nesta etapa é apresentado à rede o conjunto de padrões de treinamento.
3. *Forward*: nesse passo o padrão de entrada é propagado pela RNA, camada a camada com o auxílio da Equação 13.

Equação 13: Propagação do sinal.

$$u_j^l(n) = \sum_{i=0}^{m^{l-1}} w'_{ji}(n) y_i^{l-1}(n)$$

sendo,

$$l = 0, 1, 2, \dots;$$

L = índice das camadas da RNA;

$y_i^{l-1}(n)$ = função de saída do neurônio “ i ” na camada anterior ($l-1$);

$w'_{ji}(n)$ = peso sináptico do neurônio “ j ” na camada “ l ”;

m^l = número de neurônios na camada “ l ”.

$l=0$ representa a camada de entrada e $l = L$ a camada de saída. Quando $i = 0$, temos $y_0^{l-1} = 1$ e $w_{j0}^l(n)$ representa o bias aplicado ao neurônio j da camada l .

A saída do neurônio j na camada l é dada por:

Equação 14: Saída do neurônio j na camada l .

$$y_j^l(n) = \varphi_j(u_j^l(n))$$

sendo,

φ_j = função de ativação de j .

Durante o processo deve ser realizado um ajuste nos pesos sinápticos, este ajuste é descrito pela Equação 15. ^{25,26,27,28}.

Equação 15: Ajuste dos pesos sinápticos.

$$e_j(n) = d_j(n) - y_j(n)$$

Onde $e_j(n)$ é o sinal de erro da saída que é dado pela diferença entre o valor desejado para determinada entrada $d_j(n)$ e o valor de saída $y_j(n)$ gerado pela rede ^{25,27,28,29}.

O valor instantâneo da energia total do erro é obtido através da Equação 16.

Equação 16: Valor instantâneo da energia total do erro.

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n)$$

onde $\varepsilon(n)$ é o valor instantâneo do erro e C é o conjunto de todos os neurônios pertencentes a camada de saída^{25,28,30}.

4. *Backward*: aqui inicia-se a derivação do algoritmo backpropagation, a partir da camada de saída.

Equação 17: Derivada do algoritmo *backpropagation*.

$$\delta_j^l = \varphi_j'(u_j^l(n)) e_j^l(n)$$

Retropropagando a partir da camada de saída L e variando j de 0 à m^{l-1} , calcula-se:

Equação 18: Retropropagação do algoritmo.

$$\delta_j^{l-1}(n) = \varphi_j'(u_j^{l-1}(n)) \sum_{i=1}^{m^l} w_{ji}^l(n) * \delta_j^l(n)$$

onde j varia de 0 à m^{l-1} .

Assim é possível atualizar os pesos sinápticos da seguinte forma:

Equação 19: Atualização dos pesos sinápticos.

$$w_{j,i}^l(n+1) = w_{j,i}^l(n) - \alpha \delta_j^{l-1}(n) y_i^l(n)$$

Onde, α é o tamanho do passo de aprendizagem.

5. Nesta etapa, repete-se os passos *Forward* e *Backward* para todos os padrões de treinamento.
6. Então retorna-se ao terceiro passo até que o critério de parada seja satisfeito.

Para este trabalho foi levado em consideração o resultado da validação cruzada, como critério de parada. A validação cruzada evita o *overfitting*, ou seja, a memorização que a rede faz dos padrões de treinamento, em vez de extrair características gerais.

Neste critério de parada, o conjunto de padrões é dividido em conjunto de validação e treinamento. No conjunto de validação calcula-se a capacidade de generalização da rede durante o processo de aprendizagem. Já o conjunto de treinamento é utilizado para treinar a rede, esse processo é interrompido quando o erro de validação começa a aumentar. Tal erro pode ser calculado pela Equação 20.

Equação 20: Erro Quadrático Médio (MSE, do inglês Mean Square Error).

$$MSE = \frac{1}{n} \mathbf{e}^T \mathbf{e}$$

sendo,

n = número de padrões de entrada;

$\mathbf{e}$ = vetor que armazena o erro de todos os padrões de entrada.

$\mathbf{e}^T$ = transposta de $\mathbf{e}$.

4.5.1 LEVENBERG- MARQUADT

O algoritmo Levenberg – Marquadt é um método de otimização geral que pode ser aplicado ao algoritmo *backpropagation* para minimizar a função de erro. Ele propõe uma solução de compromisso entre o algoritmo do gradiente descendente e o método iterativo de Gauss-Newton.

A atualização dos pesos da RNA usada no método Gauss-Newton é dada pela Equação 21.

Equação 21: Atualização dos pesos por Gauss-Newton.

$$w_{i+1} = w_1 - H^{-1} \nabla f(w)$$

Onde, o gradiente $\nabla f(w)$ é representado por:

Equação 22: Gradiente da função.

$$\nabla f(w) = J^T e$$

Equação 23: Cálculo da Matriz Hessiana.

$$\nabla^2 f(w) = J^T J + S$$

Sendo, J a matriz Jacobiana e J^T sua transposta.

A Equação 24, mostra o cálculo de S .

Equação 24: Cálculo de S .

$$S = \sum_{i=1}^n e_i \nabla^2 e_i$$

Se comparado ao produto da matriz Jacobiana, pode-se supor que S é um valor muito pequeno. Sendo assim, a matriz Hessiana pode ser representada pela Equação 25.

Equação 25: Matriz Hessiana.

$$\nabla^2 f(w) \approx J^T J$$

Assim a atualização dos pesos sinápticos, representada anteriormente pela Equação 21, fica:

Equação 26: Atualização dos pesos por Gauss-Newton.

$$w_{i+1} = w_i - (J^T J)^{-1} J^T e$$

O algoritmo Levenberg- Marquadt, faz uma modificação na Equação 26, com isso a equação da atualização dos pesos é calculada pela Equação 27.

Equação 27: Atualização dos pesos sinápticos com a modificação de Levenberg-Marquadt.

$$w = w_i - (J^T J + \mu I)^{-1} J^T e$$

Sendo,

I = Matriz Identidade;

μ = parâmetro que define a matriz Hessiana positiva.

Essa modificação é feita, devido ao fato de que uma matriz Hessiana simplificada não pode ser invertida.

4.6 BEXIGA URINÁRIA

A bexiga urinária é um órgão muscular oco situado na cavidade pélvica, posteriormente à sínfise púbica. Nos homens ela está localizada diretamente na frente do reto e nas mulheres ela situa-se à frente da vagina e abaixo do útero ³¹.

Quando vazia, a bexiga tem a forma de um balão vazio, conforme o volume urinário aumenta ela vai assumindo uma morfologia esférica até assumir a forma de pêra, conforme mostrado na Figura 5, ascendendo na cavidade abdominal. A bexiga de um indivíduo adulto pode armazenar de 700ml a 800 ml ³¹.




Figura 5: A) Representação de uma bexiga urinária vazia. B) Representação de uma bexiga urinária cheia. (figura adaptada de: <http://www.lookfordiagnosis.com/>).

A expectativa de que os dados de Tomografia por Impedância Elétrica possam trazer informações das estruturas internas do corpo humano, através da distribuição da resistividade ou condutividade, auxiliando em um diagnóstico médico pode ser fortalecida ao visualizar a comparação apresentada na Tabela 1 ^{2,32}.

Tabela 1: Comparação entre Resistividade elétrica e o Coeficiente de Atenuação de Raios X [Barber & Brown,1984].

Tecido	Resistividade ($\Omega.m$)	Coeficiente de Atenuação de Raios X (m^{-1})
Osso	150	35,0
Músculo	1,0	20,4
Sangue	1,6	20,4
Gordura	15,0	18,5

A Tabela 1 mostra que a diferença da resistividade entre alguns tecidos é muito maior se comparada a diferença existente entre os mesmos tecidos com relação ao coeficiente de atenuação de Raios X ^{2,32}.

Para o caso de estimativa de volumes, estudado no presente trabalho, a técnica se mostra-se ainda mais promissora, devido ao fato de não haver a reconstrução da imagem^{2,32}.

5 MATERIAIS E MÉTODOS

5.1 ARDUINO

O Arduino é uma placa de controle de entrada e saída de dados, onde as informações podem ser transmitidas de um computador para a placa via *bluetooth*, *wireless*, USB, infravermelho, entre outras.

Existem diversos motivos que tornaram o Arduino uma ferramenta popular entre os pesquisadores, dentre eles pode-se citar o baixo custo, software compatível com *Microsoft Windows*, *Mac OS X* e *Linux*, ser *software* e *hardware* livres e diversidade nas versões do *hardware*, o que permite que o usuário possa adquirir o produto que se adapte a sua necessidade^{33,34}.

O Arduino possui diversos modelos, os mais conhecidos são:

7. Arduino Uno;
8. Arduino 2009;
9. Arduino Mega 2560 e
10. Arduino Nano.

As simulações realizadas neste trabalho foram conduzidas considerando a implementação do sistema em um Arduino Mega 2560.

5.1.1 ARDUINO MEGA 2560

O Arduino mega 2560 é uma placa de microcontrolador baseado no ATmega2560 (folha de dados). Ele possui 54 pinos digitais de entrada / saída (dos quais 14 podem ser usados como saídas PWM), 16 entradas analógicas, 4 UARTs (portas seriais de *hardware*), um cristal oscilador de 16 MHz, uma conexão USB, um cabeçalho ICSP e um botão de *reset* ^{33,34}.

A Figura 6 mostra a placa de microcontrolador Arduino Mega 2560.




Figura 6: Arduino Mega 2560. [Figura adaptada do manual do Arduino Mega 2560].

A Tabela 2 apresenta as especificações técnicas do Arduino Mega 2560.

Tabela 2: Especificações Técnicas do Arduino Mega 2560 [Manual Arduino Mega 2560].

Especificações Técnicas do Arduino Mega 2560	
Microcontrolador	ATmega2560
Voltagem de alimentação	5V
Voltagem de entrada (recomendada)	7-12V
Voltagem de entrada (limites)	6-20V
Pinos digitais I/O	54 (dos quais 15 oferecem saída PWM)
Pinos de entrada analógica	16
Corrente contínua por pino I/O	40 mA
Corrente contínua para o pino 3.3V	50 mA
Memória Flash	256 KB dos quais 8 KB usados pelo bootloader
SRAM	8 KB
EEPROM	4 KB
Velocidade de Clock	16 MHz

5.2 MATLAB

O MATLAB (*Matrix Laboratory*) é um *software* interativo dedicado a cálculos numéricos e gráficos científicos. Ele é capaz de realizar operações matriciais, construir gráficos em duas ou três dimensões, auxilia no processamento de sinais, além de manipular outras funções especializadas.

Enquanto professor de matemática na Universidade do Novo México Cleve Moler desenvolveu, junto com Jack Dangarra, Pete Stewart e Jim Banch, em 1978 os pacotes EISPACK e LINPACK para Fortran. Usando o Fortran e porções dos dois pacotes, Moler desenvolveu a primeira versão do MATLAB ^{35,36}.

O *software* tem funções de tratamento numérico de alto desempenho, capazes de resolver problemas numéricos de maneira mais eficiente do que em outros tipos de linguagens tradicionais de programação. Com uma interface de fácil manipulação o MATLAB, além de ser usado por cientistas de diversas áreas é também usado na área da educação, porém sua principal utilização continua sendo no processamento de imagens ^{35,36}.

5.3 EIDORS

O EIDORS (*Electrical Impedance and Diffuse Optical Tomography Reconstruction Software*) é um pacote de código aberto para reconstrução de imagens em TIE e Tomografia por Difusão Ótica (**DOT**)³⁷. Este *software* pode ser implementado no MATLAB, onde é dividido em três fases ^{37, 38}:

11. Geração de Malhas;
12. Problema Direto;
13. Problema Inverso.

No problema direto, tem-se o volume e se quer saber quais os potenciais medidos na malha. Já no problema inverso, conhecendo os potenciais, deseja-se saber qual o volume gerado.

O EIDORS resolve o problema direto usando o método dos elementos finitos, enquanto o problema inverso é resolvido utilizando técnicas de regularização³⁹.

Na primeira etapa de coleta de dados, foi desenvolvido um algoritmo com a finalidade de gerar um conjunto de saída com 11 volumes dispostos em uma malha triangular, representada na Figura 7, gerada pelo pacote EIDORS.




Figura 7: Malha gerada pelo pacote EIDORS no software MATLAB. Os números que variam de -1 a 1, tanto no eixo X quanto no Y representam a diferença de potencial em cada ponto da malha. Os números de 1 a 16 são as posições dos eletrodos dispostos ao redor do corpo de provas, cada triângulo possui um número de identificação. Na junção de cada triângulo (nós) é onde são calculados as diferenças de potencial.

Nesta fase os 11 volumes gerados variam seu tamanho no centro da malha, como mostrado na Figura 8.




Figura 8: Volumes gerados no centro da malha gerada pelo EIDORS.

Esses volumes foram calculados através de uma função inserida no algoritmo utilizado para gerar as figuras. Essa função calcula a área de cada triângulo que forma a figura, assim ao somar essas áreas obtém-se o volume das mesmas. Para obter os dados finais da simulação são retiradas 3 colunas da amplitude calculada, referentes aos eletrodos de aplicação e seus adjacentes. Com isso gera-se um conjunto de 11 padrões com 208 elementos na camada de entrada, representando 13 pares de eletrodos lidos em 16 posições diferentes em torno do corpo e uma saída com 11 volumes calculados.

Na fase de treinamento, primeiramente foi realizada uma simulação com diversos algoritmos de treinamento, a fim de identificar qual daria a melhor contribuição para o problema proposto. Cada algoritmo foi treinado 30 vezes com 5 neurônios na camada oculta. Os algoritmos testados foram:

14. *Levenberg- Marquardt backpropagation;*
15. *BFGS quasi-Newton backpropagation;*
16. *Conjugate gradient backpropagation with Powell-Beale restarts;*
17. *Conjugate gradient backpropagation with Fletcher-Reeves updates;*
18. *Conjugate gradient backpropagation with Polak-Ribiere updates;*
19. *Gradient descent backpropagation;*
20. *Gradient descent with adaptive lr backpropagation;*
21. *Gradient descent with momentum;*
22. *Gradient descent w/momentum & adaptive lr backpropagation;*
23. *One step secant backpropagation;*
24. *RPROP backpropagation; e*
25. *Scaled conjugate gradient backpropagation.*

Fazendo uso deste algoritmo, foi montada uma primeira rede neural com 208 dados de entrada, 15 neurônios na camada oculta e uma saída com 11 padrões de volumes. Como representado na Figura 9.




Figura 9: Rede Neural com 208 neurônios na camada de entrada, 15 neurônios na camada oculta, 1 neurônio na camada de saída e um conjunto de saída com 11 volumes calculados (figura gerada pelo MATLAB).

O Matlab fornece como padrão na camada de saída uma função de transferência do tipo linear. Entretanto foi realizado outro teste a fim de definir qual a função de

transferência daria a melhor resposta para o problema proposto. Sendo assim criou-se uma rede neural com 208 neurônios na camada de entrada, 15 neurônios na camada oculta, um neurônio na camada de saída com 11 padrões de volumes calculados e tendo como algoritmo de treinamento o Levenberg-Marquadt *backpropagation*, as funções de transferência testadas foram:

- 26. Logsig (função de transferência sigmoide logarítmica);
- 27. Tansig (função de transferência sigmoide simétrica);
- 28. Purelin (função de transferência linear).

A rede foi treinada 100 vezes, com o número de neurônios na camada oculta variando de 3 a 15.

6 RESULTADOS E DISCUSSÕES

No teste que envolveu a escolha do algoritmo de treinamento mais adequado para o problema proposto, o que apresentou melhor performance, ou seja, teve o menor erro de validação durante o teste, foi o Levenberg-Marquadt *backpropagation*.

No teste realizado para definir a função de transferência mais adequada para o problema proposto neste trabalho, foi variado o número de neurônios da camada oculta de 3 a 15, após ser observado que a contribuição com um número inferior a 3 e acima de 15 neurônios era irrelevante para tal problema. Com isso foi possível determinar que a função de transferência mais adequada para o problema abordado nesse trabalho foi a função linear (Purelin).

Após a escolha do algoritmo de treinamento e da função de transferência foi possível montar o programa base para os treinamentos e simulações. O programa base final ficou com 208 neurônios na camada de entrada, 15 neurônios na camada oculta, 1 neurônio na camada de saída e um conjunto de saída com 11 volumes.

Com o programa base pronto o próximo passo foi definir com quantos neurônios na camada oculta a rede neural apresentaria o melhor resultado. Para isso a rede foi treinada 100 vezes para cada neurônio na camada oculta, variando os mesmos de 3 até 15.

Então foi feita a média dos erros relativos a validação do treinamento para cada neurônio testado, com isso foi possível determinar a quantidade de neurônios que apresentou o menor erro de validação, que neste caso foram 6 neurônios na camada escondida. Conforme mostrado na Tabela 3.

Tabela 3: Valores dos erros de validação obtidos na simulação com 208 neurônios na camada de Entrada.

Número de Neurônios na Camada Oculta	Valor do Erro
3	0,0654
4	0,0697
5	0,1784
6	0,0383
7	0,0704
8	0,0925
9	0,1222
10	0,0879
11	0,2557
12	0,0645
13	0,0856
14	0,1589
15	0,0901

A Figura 10 ilustra os valores obtidos durante a simulação e que são apresentados na Tabela 3.




Figura 10: Gráfico relativo aos erros de validação.

Na fase de simulação a rede foi treinada 100 vezes com os 6 neurônios na camada escondida, número que apresentou o melhor resultado para os padrões de entrada fornecidos à rede, conforme pode ser visto na Tabela 3. Feito isso, calculou-se o erro quadrático médio desses treinamentos e armazenou-se o melhor resultado de rede treinada, ou seja, a rede que apresentou o menor erro quando comparada a saída desejada com a saída obtida na simulação.

A Figura 11 mostra a comparação entre os volumes calculados e os volumes obtidos na simulação.




Figura 11: Gráfico comparativo entre os volumes calculados e os volumes simulados. Os dados foram obtidos através de uma RNA com 208 neurônios na camada de entrada, 6 neurônios na camada oculta e 1 neurônio na camada de saída com 11 volumes simulados.

Analisando o gráfico pode-se observar que os resultados obtidos foram satisfatórios, porém para o caso de um sistema que irá estimar o volume de uma bexiga e que terá o intuito de avisar ao cuidador quando a mesma estiver cheia, deseja-se uma melhor precisão em volumes maiores.

Um impecílio encontrado para implementação do algoritmo no Arduino Mega 2560, é sua capacidade de armazenamento. O limite de memória deste microcontrolador é de 8 Kbits, porém o resultado obtido para o caso de 208 neurônios na camada de

entrada exige 10 Kbits de memória, para os testes usando ponto flutuante de dupla precisão. Para solucionar este problema optou-se por explorar a simetria do sistema, sendo assim montou-se uma rede neural com 104 neurônios na camada de entrada, os mesmos 15 neurônios na camada oculta e 1 neurônio na camada de saída. Então todos os passos realizados na rede com 208 neurônios na camada entrada foram repetidos para esta nova rede.

Neste formato, o menor erro de validação durante os treinamentos ocorreu na rede com 4 neurônios na camada escondida, diminuindo assim a exigência de memória para armazenamento para 3,4 Kbits. Este resultado é ilustrado na Tabela 4.

Tabela 4: Valores dos erros de validação obtidos na simulação explorando a simetria do sistema.

Número de Neurônios na Camada Oculta	Valor do Erro
3	0,1832
4	0,0507
5	0,0575
6	0,0562
7	0,0679
8	0,0556
9	0,1900
10	0,0932
11	0,0596
12	0,0608
13	0,1197
14	0,0954
15	0,1415

O gráfico mostrado na Figura 12 ilustra os valores obtidos durante a simulação e que são apresentados na Tabela 4.




Figura 12: Gráfico do Erro de Validação para uma rede com 104 neurônios na camada de entrada, 15 neurônios na camada oculta e um neurônio na camada de saída com um conjunto de 11 volumes simulados.

A Figura 13 mostra o gráfico comparativo entre os volumes calculados e os simulados para 104 neurônios na camada de entrada e 4 neurônios na camada oculta.




Figura 13: Gráfico comparativo entre os volumes calculados e os volumes simulados. Os dados foram obtidos através de uma RNA com 104 neurônios na camada de entrada, 4 neurônios na camada oculta e 1 neurônio na camada de saída com conjunto de saída com 11 volumes simulados.

Ao comparar a Figura 11 com a Figura 13, é possível observar que o gráfico da Figura 13 apresenta melhores resultados para os volumes maiores, adequando-se assim melhor ao objetivo proposto. Além de diminuir a memória a ser ocupada no Arduino Mega de 10 Kbits para 3,4 Kbits.

O próximo passo deste estudo foi desenvolver um sistema em que um volume genérico fosse alternando sua posição na malha e aumentando seu tamanho, para que o objetivo de generalizar o sistema para qualquer volume fosse alcançado. Esta variação pode ser observada na Figura 14.




Figura 14: Imagens dos volumes gerados em posições diferentes. A) e B) possuem volumes próximos, o mesmo ocorre com C) e D).

A diferença nas formas das figuras é devido aos triângulos possuírem tamanhos diferentes, tornando impossível manter o mesmo desenho em todos os pontos. Então foram escolhidos triângulos que calculassem volumes parecidos mesmo quando a posição variasse. Com isso foram obtidos 18 volumes em três posições diferentes.

Com os volumes calculados passou-se para os treinamentos e simulações. Seguiu-se o programa base já testado anteriormente, com 208 neurônios na camada de entrada, 15 neurônios na camada escondida, 1 neurônio na camada de saída e um conjunto de saída com 18 volumes.

No treinamento, o menor erro de validação ocorreu com 5 neurônios na camada oculta, como pode ser visto na Tabela 5.

Tabela 5: Valores dos erros de validação obtidos na simulação com 208 neurônios na camada oculta e 18 volumes variando suas posições.

Número de Neurônios na Camada Oculta	Valor do Erro
3	0,00864
4	0,01006
5	0,00828
6	0,00952
7	0,01082
8	0,01189
9	0,01191
10	0,01223
11	0,01637
12	0,01591
13	0,01914
14	0,02238
15	0,01836

O gráfico referente a Tabela 5 é apresentado na Figura 15.




Figura 15: Gráfico do Erro de Validação para uma rede com 208 neurônios na camada de entrada, 15 neurônios na camada oculta e um conjunto de saída com 18 volumes.

Na fase de simulação foi montada uma rede com 208 neurônios na camada de entrada, 15 neurônios na camada oculta, um neurônio na camada de saída e um conjunto de saída com 18 volumes. O resultado obtido na simulação foi comparado com os volumes calculados, essa comparação é ilustrada na Figura 16.




Figura 16: Gráfico comparativo entre os volumes calculados e os volumes simulados. Os dados foram obtidos através de uma RNA com 208 neurônios na camada de entrada, 5 neurônios na camada oculta e 1 conjunto de saída com 18 volumes simulados.

Ao analisar a

Figura 16 pode-se observar que a rede com 208 neurônios, para este caso, não apresentou resultados entusiasmantes, uma vez que sua melhor aproximação entre os volumes calculados e os simulados ocorreu nos menores volumes e como já dito anteriormente, o foco deste trabalho está nos volumes maiores.

Para o teste envolvendo simetria foi montada uma rede com 104 neurônios na camada de entrada, 15 neurônios na camada oculta, um neurônio na camada de saída e um conjunto de 18 volumes calculados.

Observou-se então que a rede que gerou os melhores resultados foi a que possuía 7 neurônios na camada oculta, conforme mostra a

Tabela 6.

Tabela 6: Valores dos erros de validação obtidos na simulação explorando a simetria do sistema com 18 volumes variando suas posições.

Número de Neurônios na Camada Oculta	Valor do Erro
3	0,0109
4	0,0127
5	0,0093
6	0,0121
7	0,0091
8	0,0136
9	0,0111
10	0,0129
11	0,0150
12	0,0184
13	0,0241
14	0,0198
15	0,0152

O gráfico apresentado na Figura 17 ilustra os dados obtidos durante a simulação e apresentados na

Tabela 6.




Figura 17: Gráfico do Erro de Validação para uma rede com 104 neurônios na camada de entrada, 15 neurônios na camada oculta e um conjunto de saída com 18 volumes.

Figura 18 mostra o resultado comparativo entre a saída desejada e saída obtida na simulação da rede neural com 7 neurônios na camada oculta.




Figura 18: Gráfico comparativo entre os volumes calculados e os volumes simulados. Os dados foram obtidos através de uma RNA com 104 neurônios na camada de entrada, 7 neurônios na camada oculta e 1 conjunto de saída com 18 volumes simulados.

Ao comparar os resultados das simulações com 208 e 104 neurônios na camada de entrada, é possível observar através da comparação entre a

Figura 16 e Figura 18 que quando utilizada a simetria para gerar os resultados, o sistema apresenta melhor resposta quando são analisados os volumes maiores, ou seja, quando a bexiga estiver cheia.

7 CONCLUSÕES

Após a análise das aplicações da TIE, tanto na área médica quanto na área industrial, a pesquisa seguiu o caminho da estimativa de volume de um certo corpo, com base no trabalho publicado em 2014 por T. Schlebusch et al.

Foram realizados diversos testes e simulações para definir qual configuração de rede seria a mais adequada ao problema proposto. Assim pode-se chegar a um programa base constituído por uma RNA com 208 neurônios na camada de entrada, 15 neurônios na camada oculta, 1 neurônio na camada de saída e um conjunto com 11 volumes calculados. Esse programa foi a base para todas as outras variações que envolveram simetria, variação de posição e variação de volume do objeto estudado.

Também foram realizados testes para saber quais funções de ativação seriam as mais eficientes para tal problema, chegando assim a conclusão que as mais indicadas seriam uma função sigmoideal na camada de entrada, uma função linear na camada de saída e o algoritmo de treinamento mais adequado para o problema, após algumas simulações, foi definido como sendo o Levenberg-Marquadt *backpropagation*.

Os objetivos de coleta, armazenamento e comparação dos dados foram alcançados. Através de testes utilizando simetria para a coleta de dados, descobriu-se uma maneira mais rápida, com menor custo computacional e mais precisa para adquirir os resultados de volume no intervalo de valores de interesse.

Com isso, foi possível criar um programa base para o *software* idealizado no começo das pesquisas. Ao fazer a análise dos dados obtidos nas simulações foi possível observar que explorando a simetria do sistema, tanto na fase onde os volumes foram gerados centralizados quanto na fase onde os mesmos foram variando sua posição na malha, foi obtida uma melhor precisão nos resultados relativos aos volumes maiores, ou seja, que representam a bexiga cheia.

Futuramente, pretende-se desenvolver um sistema de *hardware*, que possa ter uma aplicação prática, através do grupo de pesquisa sobre a Tomografia por Impedância Elétrica da Universidade Federal do Rio Grande – FURG.

REFERÊNCIAS BIBLIOGRÁFICAS

-
- ¹ BARBER, D.; BROWN, B, FREESTON, I. *Imaging spatial distributions of resistivity using potential tomography*. Electronic Letters 19, p. 993-935, 1983.
- ² Menin, Olavo H. *Método dos Elementos de Contorno para Tomografia de Impedância Elétrica* / Olavo Henrique Menin; orientador Prof. Dr. Alexandre Souto Martinez. – Ribeirão Preto/SP, 2009. 71 p. Dissertação (Mestrado – Programa de Pós-Graduação em Física Aplicada à Medicina e Biologia) – Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto da Universidade de São Paulo.
- ³ Olavo H. Menin, Vanessa Rolnik Artioli. “*Tomografia de Impedância Elétrica: uma nova técnica de imageamento em medicina*”. Revista Iluminart – ISSN : 1984-8625 – Número 5 – Agosto de 2010 - IFSP – Campus Sertãozinho.
- ⁴ Dalvi-Garcia F, Souza MN, Pino AV. “*Algoritmo de reconstrução de imagens para um sistema de Tomografia por Impedância Elétrica (TIE) baseado em configuração multiterminais*” . Rev. Bras. Eng. Biom., v. 29, n. 2, p. 133-143, jun. 2013.
- ⁵ Henderson, R. P.; Webster, J. G. (1978). *An impedance camera for spatially specific measurements of the thorax*. IEEE Transactions on Biomedical Engineering, v.25 p.250–254.
- ⁶ Lima, Cícero Ribeiro de. *Estudo da Obtenção de Imagens de Tomografia de Impedância Elétrica do Pulmão pelo Método de Otimização Topológica* – ed. rev. – São Paulo, 2006. 188 p. Tese (Doutorado) — Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia Mecatrônica e de Sistemas Mecânicos.
- ⁷ Rashid A, Kim B S, Khambampati A K, Kim S and Kim K Y 2011 “*An oppositional biogeography-based optimization technique to reconstruct organ boundaries in the human thorax using electrical impedance tomography*”. Physiol. Meas. 32 767–96.
- ⁸ Zhang J and Patterson R 2010. “*Non-invasive determination of absolute lung resistivity in adults using electrical impedance tomography*”. Physiol. Meas. 31 S45–56.
- ⁹ Borsic A, Halter R, Wan Y, Hartov A and Paulsen K D 2010. “*Electrical impedance tomography reconstruction for three-dimensional imaging of the prostate*”. Physiol. Meas. 31 S1–16.
- ¹⁰ MURPHY, D.; BURTON, P.; COOMBS, R.; TARASSENKO, L.; ROLFE, P. *Impedance imaging in the newborn*. Clin. Phys. Physiol. Meas., v. 8, p. 131–140, 1987. Suppl. A.
- ¹¹ HARRIS, N.; SUGGETT, A.; BARBER, D.; BROWN, B. *Applied potential tomography: A new technique for monitoring pulmonary function*. Clin. Phys. Physiol. Meas., v. 9, p. 79–85, 1988. Suppl. A.
- ¹² WOO, E. J.; HUA, P.; WEBSTER, J. G.; TOMPKINS, W. J. *Measuring lung resistivity using electrical impedance tomography*. IEEE Transactions on Biomedical Engineering, v. 39, n. 7, p. 756–760, 1992.
- ¹³ MURUGAN, R. M. *An improved electrical impedance tomography (EIT) algorithm for the detection and diagnosis of early stages of breast cancer*. — Dept. of Electrical and Computer Engineering, University of Manitoba, Winnipeg, Manitoba, 1999.
- ¹⁴ AMATO, M. B. P.; BARBAS, C. S.; MEDEIROS, D. M.; ET al. *Effect of a protective-ventilation strategy on mortality in the acute respiratory distress syndrome*. Journal of Medicine, v. 338, n. 6, p. 347–354, 1998.
- ¹⁵ T Schleich et al 2014 Physiol. “*Bladder volume estimation from electrical impedance tomography*”. Meas. 35 1813 doi:10.1088/0967-3334/35/9/1813

-
- ¹⁶ Pikkemaat R, Lundin S, Stenqvist O, Hilgers RD, Leonhardt S. “Recent advances in and limitations of cardiac output monitoring by means of electrical impedance tomography”. *Anesth Analg*. 2014 Jul;119(1):76-83. doi: 10.1213/ANE.0000000000000241.
- ¹⁷ R. Thorn, G.A. Johansen, B.T. Hjertaker. “Three-phase flow measurement in the petroleum industry”. *Meas. Sci. Technol.*, 24 (1) (2013), p. 012003.
- ¹⁸ Rolnik, V. P.; Seleglim, P. Jr. (2006). “A specialized genetic algorithm for the electrical impedance tomography of two phase flows”. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, v.28 p.378–390.
- ¹⁹ Bouchette, G. Neptec Design Group, Kanata, ON, Canada 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*, VOL. 52, NO. 2, FEBRUARY 2014.
- ²⁰ De Cezaro, *Problemas Inversos em Tomografia*. SBMAC, São Carlos- SP, Brasil 2012.
- ²¹ De Cezaro, *Métodos de Regularização Tipo Level Set para Problemas Inversos*. Florianópolis, Fevereiro de 2006.
- ²² Leonardo Silveira Borges. *Métodos para problemas mal-postos discretos de grande porte* – Campinas, SP : [s.n.], 2013.
- ²³ A. Kirsch, *An Introduction to the Mathematical Theory of Inverse Problems*, Springer, Karlsruhe, (1996).
- ²⁴ J. Margotti, *Métodos Tipo Newton Inexatos para Problemas Inversos*. Florianópolis, Abril de 2011.
- ²⁵ Haykin, Simon (2001), *Redes Neurais: Princípios e Práticas*, 2 ed., BOOKMAN.
- ²⁶ RODRIGUES, R.G.S. *Desenvolvimento e Aplicação de um Algoritmo de Reconstrução Tomográfica com Base em Redes Neurais Artificiais*. Ribeirão Preto, 2000. Tese (Doutorado) - Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto-USP.
- ²⁷ Souza, Francisco Ary Alves de. “Análise de desempenho da rede neural artificial do tipo multilayer perceptron na era multicore” – Natal, RN, 2012.
- ²⁸ N. Silva, Juliana Mendes. *Redes Neurais Artificiais: Rede Hopfield e Redes Estocásticas*, Niterói/RJ - Julho de 2003.
- ²⁹ J. P. Kerr and E. B. Bartlett, “SPECT Reconstruction Using a Backpropagation Neural Network Implemented on a Massively Parallel SIMD Computer”, *IEEE Computer-Based Medical System – Proceedings of the Fifth Annual Symposium* (IEEE, New York, 1992), p. 616.
- ³⁰ P. Knoll et. al, “An artificial neural net and error backpropagation to reconstruct single photon emission computerized tomography data”, *Med. Phys.*, 26(2):244-8 (1999).
- ³¹ Tortora, Gerard J. *Corpo Humano - Fundamentos de Anatomia e Fisiologia* - 8ª Ed. 2012.
- ³² D C Barber and B H Brown 1984 J. “Applied potential tomography”. *Phys. E: Sci. Instrum.* 17 723.
- ³³ Manual Arduino Mega 2560.
- ³⁴ <http://arduino.cc/>
- ³⁵ An interview with CLEVE MOLER Conducted by Thomas Haigh On 8 and 9 March, 2004 Santa Barbara, California.
- ³⁶ <http://www.mathworks.com/company/newsletters/articles/the-origins-of-matlab.html>

³⁷ Adler A. and Lionheart W. R. B. , "*Uses and abuses of EIDORS: An extensible software base for EIT*", ISSN 1749-9097 May 2006.

³⁸ Vidya Sarode, Priya M Chimurkar and Alice N Cheeran. Article: *Electrical Impedance Tomography using EIDORS in a Closed Phantom*. International Journal of Computer Applications 48(19):48-52, June 2012. Full text available.

³⁹ J. Aguilar. "*Estudos numericos para o problema da tomografia por impedância elétrica*", Tese de Doutorado, IME-USP, 2009.