

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

**Allan Rivalles Souza Feitosa**

**RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR  
IMPEDÂNCIA ELÉTRICA UTILIZANDO O MÉTODO  
DIALÉTICO DE OTIMIZAÇÃO**

Recife  
2015

**Allan Rivalles Souza Feitosa**

**RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR  
IMPEDÂNCIA ELÉTRICA UTILIZANDO O MÉTODO  
DIALÉTICO DE OTIMIZAÇÃO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Biomédica, da Universidade Federal de Pernambuco, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Biomédica.

**ORIENTADOR: WELLINGTON PINHEIRO DOS  
SANTOS, DSC**

Recife  
2015

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

F327r Feitosa, Allan Rivalles Souza.  
Reconstrução de imagens de tomografia por impedância elétrica utilizando o método dialético de otimização / Allan Rivalles Souza Feitosa. - Recife: O Autor, 2015.  
85 folhas, il., gráfs., tabs.

Orientador: Prof. DSc. Wellington Pinheiro dos Santos.  
Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG.  
Programa de Pós-Graduação em Engenharia Biomédica, 2015.  
Inclui Referências.

1. Engenharia Biomédica. 2. Tomografia por impedância elétrica. 3. Otimização dialética. 4. Otimização. 5. Algoritmos genéticos. 6. Otimização por enxame de partículas. 7. Evolução Diferencial. I. Santos, Wellington Pinheiro dos. (Orientador). II. Título.

UFPE

610.28 CDD (22. ed.)

BCTG/2015-97

Allan Rivalles Souza Feitosa

**RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR  
IMPEDÂNCIA ELÉTRICA UTILIZANDO O MÉTODO  
DIALÉTICO DE OTIMIZAÇÃO**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia Biomédica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora.

Aprovado por:

---

Prof. Dr. Wellington Pinheiro dos Santos - Orientador

---

Prof. Dr. Ricardo Emmanuel de Souza – Membro Titular

---

Prof. Dr. Abel Guilhermino da Silva Filho – Membro Titular

Data: 27/02/2015

## **AGRADECIMENTOS**

Ao meu orientador, Dr. Wellington Pinheiro dos Santos pela confiança, paciência e pela sua impecável assistência em cada momento deste curso;

A minha família, em especial aos meus pais, pelo apoio e por todo seu empenho em me incentivar na jornada pelo conhecimento;

A minha esposa Ingrid Moura pelo seu carinho e consolações nos momentos difíceis;

Ao colega de pesquisa e amigo Reiga Ramalho Ribeiro, pelos bons momentos de estudo e pesquisa;

Aos colegas e amigos Carlos André e Wendell Neves pelo apoio e cumplicidade;

A Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco pelo apoio financeiro para a realização desta pesquisa.

## RESUMO

A Tomografia por Impedância Elétrica (TIE) é uma técnica que visa reconstruir imagens do interior de um corpo de forma não invasiva. Esta reconstrução é feita com base nas propriedades elétricas de condutividade do interior deste corpo. Com base na aplicação e medida dos potenciais da borda do corpo, feita através de eletrodos, um algoritmo de reconstrução de imagens gera a imagem do interior deste corpo. Diversos métodos são aplicados para gerar imagens de TIE, porém ainda são geradas imagens de contorno suave. Isto acontece por causa da natureza matemática do problema de reconstrução da TIE como um problema mal posto e mal condicionado. Isto significa que não existe uma distribuição de condutividade interna exata para uma determinada distribuição de potenciais de borda. A TIE é governada matematicamente pela equação de Poisson e a geração da imagem envolve a resolução de um problema direto, que trata da obtenção dos potenciais de borda a partir de uma distribuição interna de condutividade. O problema direto, neste trabalho, foi aplicado através do método dos elementos finitos. Desta forma é possível aplicar técnicas de busca e otimização que objetivam minimizar a distância euclidiana entre os potenciais de borda mensurados no corpo e os potenciais gerados pela resolução do problema direto de um candidato à solução. Devido ao fato deste trabalho ser baseado em simulações, os potenciais de borda buscados foram gerados através da simulação de objetos localizados no centro, borda e entre o centro e a borda e seus respectivos potenciais de borda. Desta forma o objetivo deste trabalho foi construir uma ferramenta computacional baseada em algoritmos de busca e otimização, desde os bioinspirados até os evolucionários, com destaque para o método dialético de otimização, para fazer reconstrução de imagens de Tomografia por impedância elétrica. Para efeitos de comparação também foram utilizados para gerar imagens: Algoritmos Genéticos, Evolução Diferencial e Otimização por Enxame de Partículas. As simulações foram feitas no EIDORS, uma ferramenta MatLab e GNUOctave de código aberto voltada para a comunidade de TIE. Os experimentos foram feitos utilizando três diferentes configurações de objetos de estudo (fantomas). As análises foram feitas de três formas, sendo elas, qualitativa: na forma de o quão as imagens geradas são parecidas com seu respectivo fantoma; quantitativa: com base na evolução do erro relativo calculado pela função objetivo do melhor candidato à solução ao longo das interações; e, ainda, de custo computacional, através da avaliação da evolução do erro relativo ao longo da quantidade de cálculos da função objetivo pelo algoritmo. Foram gerados resultados para Algoritmos Genéticos com busca guiada, cinco versões de Evolução diferencial e duas versões de Otimização por enxame de Partículas. De acordo com os resultados obtidos Método Dialético Objetivo mostrou ter a capacidade de encontrar um valor de erro menor em menos iterações do que as outras técnicas propostas além de ser mais rápido devido ao fato de a quantidade de polos ir diminuindo de acordo com as fases históricas, exigindo menos esforço computacional por iteração. Os resultados desta pesquisa geraram diversas contribuições na forma de artigos publicados em eventos nacionais e internacionais.

**Palavras-chaves:** Tomografia por Impedância Elétrica. Otimização Dialética. Otimização. Algoritmos Genéticos. Otimização por Enxame de Partículas. Evolução Diferencial.

## ABSTRACT

The Electrical Impedance Tomography is a technique that aims to reconstruct images of the inside of a body non-invasively. This reconstruction is based on the electrical properties inside the conductivity of this domain. Based on measurements of the potential edge made through electrodes, an image reconstruction algorithm generates the domain inside the image. Several methods are applied to generate TIE images, but are still generated smooth contour images. This happens because of the mathematical nature of TIE reconstruction problem as an ill-posed and ill-conditioned problem. This means that there is no exact solution to a certain internal conductivity distribution. The TIE is mathematically governed by the Poisson equation and the image generation involves solving a direct problem, which deals with obtaining the edge of potential from an internal distribution of known conductivity. This achievement was made in this study through the finite element method. This way you can apply search and optimization techniques that aim to minimize the Euclidean distance between the edge of potential measured in the body and the potential generated by the resolution of the direct problem of a solution to the candidate. Because this work is based on simulations, the potential of border searches were made by simulating objects located in the center, edge and between the center and the edge and their potential edge respective. Therefore, the objective of this work was to build a computational tool based on search and optimization algorithms, since the bioinspired to the evolutionary, especially the dialectical method optimization, to make reconstruction tomography images by electrical impedance. For comparison, were also used to generate these images: Genetic Algorithms, Differential Evolution and optimization by particle swarm. The simulations were made in EIDORS a MatLab and GNUOctave tool open source toward the TIE community. The experiments were performed using three different configurations of objects of study (phantoms). The analyzes were done in a qualitative way: in the form of how the generated images are similar to their respective phantom; quantitative: based on the evolution of the relative error calculated by the objective function of the best candidate to the solution over the interactions; and also computational cost, by assessing the evolution of the relative error over the amount of computation of the objective function by the algorithm. Results were generated for Genetic Algorithms with guided search, five versions of differential evolution and two versions of Particle Swarm Optimization. According to the results obtained dialectic method showed order to be able to find a smallest error value in fewer iterations than other proposed techniques besides being faster due to the fact that the number of poles tendency to decrease in accordance with the historical phases , requiring less computational effort per iteration. The results of this research have generated several contributions in the form of articles published in national and international events.

**Keywords: Electrical Impedance Tomography. Dialectic optimization. Optimization. Genetic Algorithms. Particle Swarm Optimization. Differential Evolution.**

## LISTA DE ILUSTRAÇÕES

FIGURA 1: ESQUEMATIZAÇÃO DA TIE. ....	12
FIGURA 2: REPRESENTAÇÃO DO PROBLEMA DIRETO. ....	17
FIGURA 3: REPRESENTAÇÃO DO PROBLEMA INVERSO. ....	18
FIGURA 4: DOMÍNIO COM OBJETO CONHECIDO (A) E DOMÍNIO COM OBJETO DESCONHECIDO (B). ....	19
FIGURA 5: ETAPAS DO PROCESSO DO AG. ....	29
FIGURA 6: ETAPAS DO PROCESSO DE ED. ....	31
FIGURA 7: ILUSTRAÇÃO DAS RELAÇÕES NA TOPOLOGIA EM ESTRELA DA OEP. ....	33
FIGURA 8: ILUSTRAÇÃO DAS RELAÇÕES NA TOPOLOGIA EM ANEL DA OEP. ....	33
FIGURA 9: ETAPAS DA OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS. ....	34
FIGURA 10: PSEUDOCÓDIGO DA INICIALIZAÇÃO DOS POLOS E DE SEUS PARES ANTÍTESE. ....	37
FIGURA 11: PSEUDOCÓDIGO DO OPERADOR DE SÍNTESE DAS ALTAS CONTRADIÇÕES. ....	40
FIGURA 12: FLUXOGRAMA DO MÉTODO DIALÉTICO OBJETIVO. ....	43
FIGURA 13: MALHA TRIANGULADA GERADA PELO EIDORS. ....	46
FIGURA 14: DISTRIBUIÇÃO DE CONDUTIVIDADE REPRESENTADA GRAFICAMENTE. ....	47
FIGURA 15: ESQUEMA DA RESOLUÇÃO DA FUNÇÃO OBJETIVO. ....	48
FIGURA 16: PSEUDOCÓDIGO DE ALGORITMO GENÉTICO. ....	49
FIGURA 17: PSEUDOCÓDIGO DE EVOLUÇÃO DIFERENCIAL. ....	50
FIGURA 18: PSEUDOCÓDIGO DE OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS. ....	51
FIGURA 19: PSEUDOCÓDIGO DO MÉTODO DIALÉTICO OBJETIVO. ....	53
FIGURA 20: OBJETOS DE ESTUDO UTILIZADOS COMO FANTOMA NOS EXPERIMENTOS. ....	55
FIGURA 21: IMAGENS RECONSTRUÍDAS NO CENTRO, BORDA E ENTRE O CENTRO E A BORDA, RESPECTIVAMENTE, PARA AG COM BUSCA GUIADA. ....	57
FIGURA 22: ERRO RELATIVO AO LONGO DAS ITERAÇÕES PARA AG COM BUSCA GUIADA. ....	58
FIGURA 23: IMAGENS RECONSTRUÍDAS NO CENTRO, BORDA E ENTRE O CENTRO E A BORDA, RESPECTIVAMENTE, PARA EVOLUÇÃO DIFERENCIAL CLÁSSICA. ....	59
FIGURA 24: IMAGENS RECONSTRUÍDAS NO CENTRO, BORDA E ENTRE O CENTRO E A BORDA, RESPECTIVAMENTE, PARA EVOLUÇÃO DIFERENCIAL 1. ....	60
FIGURA 25: IMAGENS RECONSTRUÍDAS NO CENTRO, BORDA E ENTRE O CENTRO E A BORDA, RESPECTIVAMENTE, PARA EVOLUÇÃO DIFERENCIAL 2. ....	61
FIGURA 26: IMAGENS RECONSTRUÍDAS NO CENTRO, BORDA E ENTRE O CENTRO E A BORDA, RESPECTIVAMENTE, PARA EVOLUÇÃO DIFERENCIAL 3. ....	62
FIGURA 27: IMAGENS RECONSTRUÍDAS NO CENTRO, BORDA E ENTRE O CENTRO E A BORDA, RESPECTIVAMENTE, PARA EVOLUÇÃO DIFERENCIAL MODIFICADA. ....	63
FIGURA 28: ERRO RELATIVO AO LONGO DAS ITERAÇÕES PARA OBJETO LOCALIZADO NO CENTRO PARA DIFERENTES VERSÕES DE EVOLUÇÃO DIFERENCIAL E AG. ....	64
FIGURA 29: ERRO RELATIVO AO LONGO DAS ITERAÇÕES PARA OBJETO LOCALIZADO NA BORDA PARA AS CINCO VERSÕES DE EVOLUÇÃO DIFERENCIAL IMPLEMENTADAS. ....	64
FIGURA 30: ERRO RELATIVO AO LONGO DAS ITERAÇÕES PARA OBJETO LOCALIZADO ENTRE O CENTRO E A BORDA PARA DIFERENTES VERSÕES DE EVOLUÇÃO DIFERENCIAL. ....	65
FIGURA 31: IMAGENS RECONSTRUÍDAS NO CENTRO, BORDA E ENTRE O CENTRO E A BORDA, RESPECTIVAMENTE, PARA OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS CANÔNICO. ....	67
FIGURA 32: IMAGENS RECONSTRUÍDAS NO CENTRO, BORDA E ENTRE O CENTRO E A BORDA, RESPECTIVAMENTE, PARA OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS EM ANEL COM BUSCA GUIADA. ....	68
FIGURA 33: ERRO RELATIVO AO LONGO DAS ITERAÇÕES PARA OBJETO LOCALIZADO NO CENTRO PARA AS DUAS VERSÕES DE OEP E AG. ....	69

FIGURA 34: ERRO RELATIVO AO LONGO DAS ITERAÇÕES PARA OBJETO LOCALIZADO NA BORDA PARA AS DUAS VERSÕES DE OEP E AG.....	69
FIGURA 35: ERRO RELATIVO AO LONGO DAS ITERAÇÕES PARA OBJETO LOCALIZADO ENTRE O CENTRO E A BORDA PARA DUAS VERSÕES DE OEP E AG.....	70
FIGURA 36: IMAGENS RECONSTRUÍDAS NO CENTRO, BORDA E ENTRE O CENTRO E BORDA PARA O MÉTODO DIALÉTICO DE OTIMIZAÇÃO. ....	71
FIGURA 37: ERRO RELATIVO AO LONGO DAS ITERAÇÕES PARA OBJETO LOCALIZADO NO CENTRO PARA O MDO E TODAS AS OUTRAS TÉCNICAS. ....	72
FIGURA 38: ERRO RELATIVO AO LONGO DAS ITERAÇÕES PARA OBJETO LOCALIZADO NA BORDA PARA O MDO E TODAS AS OUTRAS TÉCNICAS. ....	73
FIGURA 39: ERRO RELATIVO AO LONGO DAS ITERAÇÕES PARA OBJETO LOCALIZADO ENTRE O CENTRO E A BORDA PARA O MDO E TODAS AS OUTRAS TÉCNICAS. ....	73
FIGURA 40: ERRO RELATIVO AO LONGO DA QUANTIDADE DE CÁLCULOS DA FUNÇÃO OBJETIVO PARA A BUSCA DE OBJETO LOCALIZADO NO CENTRO DO DOMÍNIO.....	74
FIGURA 41: ERRO RELATIVO AO LONGO DA QUANTIDADE DE CÁLCULOS DA FUNÇÃO OBJETIVO PARA A BUSCA DE OBJETO LOCALIZADO NA BORDA DO DOMÍNIO .....	75
FIGURA 42: ERRO RELATIVO AO LONGO DA QUANTIDADE DE CÁLCULOS DA FUNÇÃO OBJETIVO PARA A BUSCA DE OBJETO LOCALIZADO NA BORDA DO DOMÍNIO .....	75

## LISTA DE TABELAS

TABELA 1: DIFERENTES RESISTIVIDADES DE TECIDOS BIOLÓGICOS. ....	13
TABELA 2: SUMÁRIO TÉCNICO DO SGA. ....	28
TABELA 3: PARÂMETROS UTILIZADOS PARA ALGORITMOS GENÉTICOS .....	49
TABELA 4: PARÂMETROS UTILIZADOS PARA TODAS AS VERSÕES DE ED.....	50
TABELA 5: PARÂMETROS PARA OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS .....	51
TABELA 6: PARÂMETROS UTILIZADOS PARA O MDO .....	54
TABELA 7: PARÂMETROS DO EIDORS UTILIZADOS NOS EXPERIMENTOS.....	56
TABELA 8: CONTRIBUIÇÕES GERADAS PELOS RESULTADOS PARCIAIS DESTA PESQUISA .....	79

## **LISTA DE ABREVIATURAS**

TIE: Tomografia por Impedância Elétrica

TRX: Tomografia por raios X

RM: Ressonância Magnética

EIDORS: Electrical Impedance and Diffuse Optical Tomography Reconstruction Software

AG: Algoritmo Genético

MDO: Método Dialético de Otimização

OEP: Otimização por Enxame de Partículas

OEP-BG: Otimização por Enxame de Partículas com Busca Guiada

ED: Evolução Diferencial

# SUMÁRIO

CAPÍTULO 1: INTRODUÇÃO .....	12
1.1 MOTIVAÇÃO E JUSTIFICATIVA.....	12
1.2 OBJETIVO GERAL.....	14
1.3 OBJETIVOS ESPECÍFICOS .....	14
1.4 ORGANIZAÇÃO DO TRABALHO .....	14
CAPÍTULO 2: TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA.....	16
2.1 RECONSTRUÇÃO DE IMAGENS EM TIE .....	16
2.2 O PROBLEMA DIRETO .....	17
2.4 FUNÇÃO OBJETIVO.....	18
2.5 MÉTODO DE GAUSS-NEWTON .....	20
2.6 APLICAÇÕES DA TIE.....	20
2.6.1 Avaliação da perfusão pulmonar .....	21
2.6.2 Detecção de redistribuição de pressão pulmonar.....	21
2.6.3 Visualizar inclusões pleurais .....	22
2.6.4 Potencial para detectar hematomas subdurais.....	23
2.6.5 Avaliar alterações no volume sistólico .....	24
2.6.6 Auxiliar no diagnóstico de câncer de próstata .....	24
2.6.7 Detectar câncer de mama .....	25
CAPÍTULO 3: OTIMIZAÇÃO POR ALGORITMOS EVOLUCIONÁRIOS .....	26
3.1 COMPUTAÇÃO EVOLUCIONÁRIA.....	26
3.2 ALGORITMOS GENÉTICOS.....	28
3.3 EVOLUÇÃO DIFERENCIAL.....	30
3.4 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS .....	32
3.5 MÉTODO DIALÉTICO OBJETIVO .....	35
3.5.1 O MÉTODO DIALÉTICO APLICADO A PROBLEMAS DE BUSCA E OTIMIZAÇÃO .....	36
3.5.2 ANÁLISE PELO MÉTODO DA MÁXIMA ENTROPIA .....	41
CAPÍTULO 4: RECONSTRUÇÃO DE IMAGENS DE TIE UTILIZANDO O MÉTODO DIALÉTICO OBJETIVO .....	45
4.1 OTIMIZAÇÃO EM TIE .....	45
4.2 INFRAESTRUTURA.....	45
4.3 FUNÇÃO OBJETIVO.....	47
4.4 ALGORITMOS GENÉTICOS.....	48
4.5 EVOLUÇÃO DIFERENCIAL.....	50
4.6 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS .....	51
4.6 MÉTODO DIALÉTICO OBJETIVO .....	52
CAPÍTULO 5: EXPERIMENTOS, RESULTADOS E DISCUSSÃO .....	55
5.1 CARACTERÍSTICAS GERAIS DOS EXPERIMENTOS.....	55
5.2 RESULTADOS DA APLICAÇÃO DOS ALGORITMOS GENÉTICOS .....	56
5.3 DISCUSSÃO DOS RESULTADOS PARA AG'S. ....	58
5.4 RESULTADOS DE EVOLUÇÃO DIFERENCIAL .....	59
5.5 DISCUSSÃO DOS RESULTADOS PARA ED. ....	65
5.6 RESULTADOS DE OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS.....	67
5.7 DISCUSSÃO DOS RESULTADOS PARA OEP .....	70
5.8 RESULTADOS PARA O MÉTODO DIALÉTICO OBJETIVO .....	71

5.9 RESULTADOS DA ANÁLISE DE EVOLUÇÃO DO ERRO RELATIVO AO LONGO DA QUANTIDADE DE CÁLCULOS DA FUNÇÃO OBJETIVO .....	74
5.10 DISCUSSÃO DOS RESULTADOS PARA O MÉTODO DIALÉTICO OBJETIVO .....	76
5.11 DISCUSSÃO GERAL .....	77
CAPÍTULO 6: CONCLUSÃO E TRABALHOS FUTUROS.....	78
6.1 DIFICULDADES APRESENTADAS .....	78
6.2 CONCLUSÕES GERAIS .....	78
6.3 CONTRIBUIÇÕES .....	79
6.4 TRABALHOS FUTUROS .....	81
REFERÊNCIAS .....	82

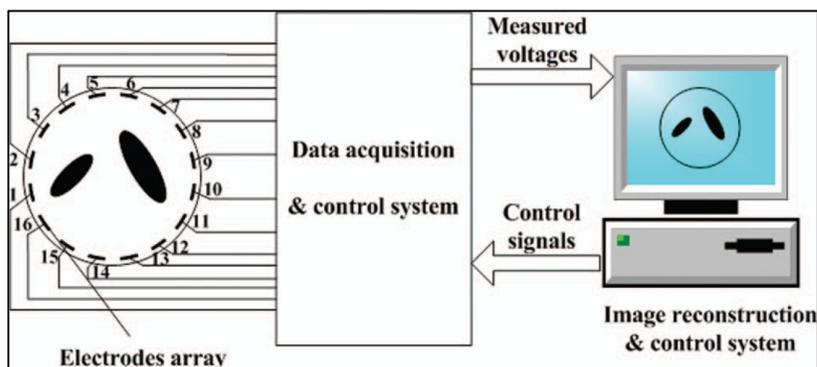
## CAPÍTULO 1: INTRODUÇÃO

### 1.1 Motivação e Justificativa

A Tomografia por Impedância Elétrica (TIE) é uma técnica não invasiva de imagem para diagnóstico que consiste na obtenção de imagens do interior de uma seção de um corpo humano. Estas imagens são reconstruídas através da aplicação e medição de uma corrente elétrica na superfície deste corpo. A reconstrução da imagem em TIE baseia-se nas propriedades elétricas do interior deste domínio. Quando se fala em propriedades elétricas utilizadas pela TIE, refere-se à permissividade elétrica ou condutividade elétrica das estruturas internas a serem analisadas.

A exploração destas propriedades de impedância elétrica na TIE é feita através da aplicação de uma corrente elétrica de baixa amplitude e alta frequência na borda do corpo e da estimação da condutividade interna, através da análise de como estas correntes transpõem o domínio de estudo. A aplicação da corrente, na maioria das vezes, é feita em um eletrodo na superfície do corpo e é mensurada por outros eletrodos também posicionados na borda do volume (GARCIA et al, 2013) como está esquematizado na Figura 1.

**Figura 1: Esquematização da TIE. (Wang et. al. 2012)**



Um fator favorável para se detectar órgãos através da TIE é a diferença relativamente grande entre a resistividade dos diferentes tipos de tecidos que compõem o corpo humano, permitindo assim, uma melhor diferenciação entre eles. A Tabela 1 traz os valores de resistividade de alguns dos tecidos biológicos que compõem o corpo humano (MENIN et al. 2010).

**Tabela 1: Diferentes resistividades de tecidos biológicos. (MENIN et al. 2010)**

Tecido	Resistividade ( $\Omega\text{m}$ )
Osso	150
Músculo	3
Sangue	1.6
Gordura	15

A Tomografia por Impedância Elétrica (TIE) têm se mostrado como uma técnica segura, portátil, de baixo custo e de fácil manipulação (RASTEIRO et. al., 2011). Por não utilizar radiação ionizante, a TIE é uma técnica que não traz riscos de longa exposição, tanto para o operador quanto para o indivíduo estudado. O equipamento de TIE também pode ser levado de um leito para outro, evitando o deslocamento de pacientes, muitas vezes, debilitados. A TIE também é de baixo custo quando comparado a outras técnicas de imageologia como ressonância magnética, tomografia por raios X ou radiografia convencional.

Quando comparada à radiografia convencional (raio X) e tomografia por raios X (TRX), a TIE é uma técnica mais segura pelo fato da não utilização de radiação ionizante, fator que permite um maior tempo de exposição do paciente à técnica, permitindo desta forma fazer, por exemplo, a monitoração contínua de alguma atividade fisiológica.

Quando comparada com a mamografia convencional, a mamografia por impedância elétrica (MIE), possui diversas vantagens, como por exemplo a ausência do desconforto passado pela mulher na mamografia convencional ou a não exposição à radiação ionizante, contudo, as imagens geradas pelos algoritmos de reconstrução em TIE ainda são de baixa resolução e de contorno suave.

Uma das principais dificuldades enfrentadas na reconstrução de imagens em TIE é a sua natureza matemática como um problema mal posto e mal condicionado. Isto significa que não há uma solução única e nem exata para o problema e que o resultado é altamente dependente dos dados de entrada.

Diversos algoritmos são aplicados para resolver o problema da TIE, Este problema tem causado a construção de imagens de contorno suave, sem uma definição clara dos limites da estrutura a ser analisada.

Quando comparada com ressonância magnética (RM) e tomografia por raios X a TIE ainda é inferior com relação à qualidade das imagens geradas. Enquanto as imagens geradas

pela RM e pela TRX são de contorno bem definido, tornando-as muito úteis no diagnóstico médico, as imagens geradas pela TIE ainda são de contorno suave e de baixa resolução.

Pelo fato de ser uma técnica baseada em propriedades elétricas, a TIE é uma técnica altamente sensível a ruídos, podendo um pequeno ruído causar uma diferença na imagem gerada com relação à verdadeira estrutura anatômica analisada.

Devido a estas dificuldades, diversas técnicas têm sido aplicadas na busca de soluções para o problema de TIE que gerem imagens de qualidade e que sejam robustas contra ruídos elétricos e artefatos que possam atrapalhar as medições dos potenciais.

## 1.2 Objetivo geral

O presente trabalho objetiva construir uma ferramenta computacional baseada em algoritmos de busca e otimização, desde os bioinspirados até os evolucionários, com destaque para o método dialético de otimização, para fazer reconstrução de imagens de tomografia por impedância elétrica.

## 1.3 Objetivos específicos

- Revisão dos métodos numéricos de resolução do problema direto da TIE, dos métodos iterativos de resolução do problema inverso da TIE e do Método Dialético de Otimização;
- Estudo do simulador EIDORS (*Electrical Impedance and Diffuse Optical Tomography Reconstruction Software*);
- Elaboração de uma ferramenta computacional de reconstrução de imagens de TIE;
- Obtenção dos resultados da técnica proposta e comparação com os resultados de outras técnicas de busca e otimização aplicadas à TIE;

## 1.4 Organização do trabalho

Este trabalho está organizado da forma que segue: o 1º capítulo traz as características gerais da tomografia por impedância elétrica, o problema encontrado, a motivação para se propor a aplicação de uma nova técnica, e os objetivos.

No 2º capítulo, é feita uma revisão da literatura sobre TIE bem como é apresentado o problema matemático da TIE.

Já no capítulo 3, são apresentados todos os métodos de busca e otimização utilizados neste trabalho, inclusive o Método Dialético Objetivo.

No 4º capítulo, é mostrado como foi implementada a proposta deste trabalho.

No capítulo 5, são descritos os experimentos, são mostrados todos os resultados e é feita a discussão com base nestes resultados.

No último capítulo (capítulo 6), são apresentadas as conclusões, com as dificuldades encontradas e as perspectivas de trabalhos futuros.

## CAPÍTULO 2: TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA

### 2.1 Reconstrução de imagens em TIE

A TIE consiste em obter imagens de forma não destrutiva e não invasiva do interior de um corpo com base nas propriedades elétricas deste domínio. A principal propriedade explorada pela TIE é a impedância elétrica.

Esta grandeza, dada por  $Z$  obedece à razão entre a voltagem efetiva aplicada no circuito e a corrente elétrica efetiva que o atravessa. Esta razão é dada pela Equação 1.

$$Z = \frac{V_{ef}}{I_{ef}} \quad (1)$$

A impedância, dada no Sistema Internacional em  $\Omega$  (ohm) conceitualmente, responde pela oposição que um dado circuito apresenta à passagem de corrente elétrica (MENIN et al. 2010)

Na TIE, a estimação da impedância do circuito é feita através de uma equação diferencial parcial, denominada de Equação de Poisson, como será mostrado nas expressões vetoriais a seguir.

$$\nabla \cdot [\sigma(\vec{u}) \nabla \phi(\vec{u})] = 0, \quad \forall \vec{u} \in \Omega, \quad (2)$$

$$\phi_{ext}(\vec{u}) = \phi(\vec{u}), \quad \forall \vec{u} \in \partial\Omega, \quad (3)$$

$$I(\vec{u}) = -\sigma(\vec{u}) \nabla \phi(\vec{u}) \cdot \hat{n}(\vec{u}), \quad \forall \vec{u} \in \partial\Omega, \quad (4)$$

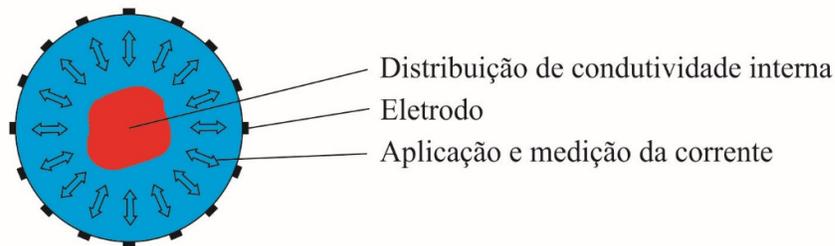
Onde  $\vec{u} = (x, y, z)$  é a posição de um determinado objeto,  $\phi(\vec{u})$  é a distribuição geral dos potenciais,  $\phi_{ext}(\vec{u})$  é a distribuição de potenciais elétricos nos eletrodos de superfície,  $I(\vec{u})$  é a corrente elétrica aplicada,  $\sigma(\vec{u})$  é a distribuição das condutividades elétricas (imagem de interesse),  $\Omega$  é o volume de interesse ou domínio,  $\partial\Omega$  é a borda deste domínio e  $\hat{n}(\vec{u})$  é o vetor normal a borda na posição  $\vec{u} \in \partial\Omega$ .

Um dos meios de se reconstruir a imagem, para a TIE, é a resolução de problema direto. Esta abordagem será explicada a seguir.

## 2.2 O Problema Direto

O problema direto consiste em, dada uma distribuição interna de condutividade em um meio condutivo não homogêneo (corpo humano), estimar qual será a corrente mensurada nos eletrodos de superfície (potenciais de borda) como é mostrado a seguir.

**Figura 2: Representação do problema direto.**



Esta estimação dos potenciais de borda a partir de uma distribuição interna é feita pela equação de Poisson, mostrada a seguir:

$$\nabla(\sigma \nabla \phi) = 0 \quad (5)$$

Onde  $\sigma$  é a distribuição interna de condutividade e  $\phi$  refere-se aos potenciais da borda.

Com as seguintes condições de borda dadas pela seguinte expressão:

$$\sigma \frac{\partial \phi}{\partial \hat{n}} = J \quad (6)$$

Na qual  $\hat{n}$  é o normal externo e utilizam-se valores positivos para a corrente aplicada  $J$  (MARTINS et. al. 2012). Não existem soluções analíticas para (5) e (6) em um domínio  $\Omega$  arbitrário. Contudo, uma solução aproximada para os potenciais de borda pode ser obtida através do Método dos Elementos Finitos (MEF) que transforma o sistema não linear (5) e (6) no seguinte conjunto de sistemas lineares:

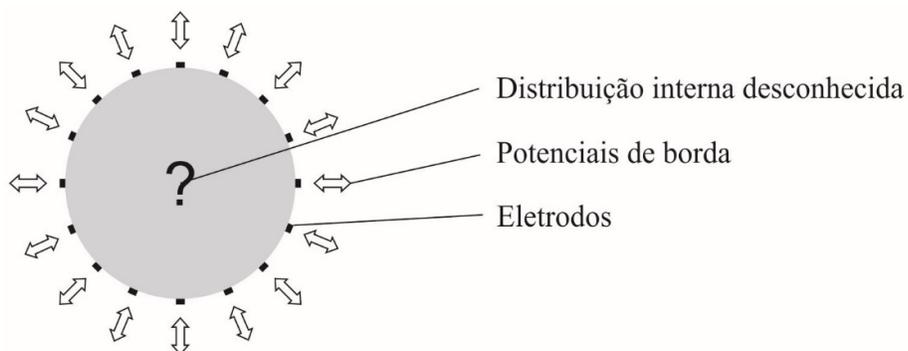
$$K(\sigma) \bullet \Phi - C = 0 \quad (7)$$

No qual e dado uma distribuição de condutividade  $\sigma$  obtém-se uma aproximação para os potenciais de borda  $\Phi$ .

### 2.3 O Problema Inverso

O problema inverso consiste em: a partir de distribuição de potenciais externa  $\Phi$  e de uma corrente aplicada, determinar a distribuição interna de condutividade  $\sigma$  para um domínio  $\Omega$ .

**Figura 3: Representação do problema inverso.**



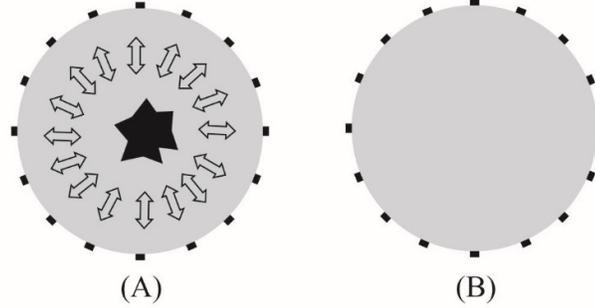
Nas técnicas descritas neste trabalho a resolução do problema direto não será utilizada. De forma que as imagens serão geradas apenas com a resolução do problema direto na forma de tentativa e erro. Este processo será descrito de forma detalhada na próxima secção.

### 2.4 Função Objetivo

Obter os potenciais de borda para uma distribuição de condutividade interna (problema direto), possibilita a reconstrução das imagens na TIE como um problema de busca e otimização. Este problema consiste em minimizar a função objetivo dada pela distância quadrática entre os potenciais de borda mensurados no corpo e os potenciais de borda gerados pela resolução do problema direto para distribuições de condutividade interna aleatórias candidatas à solução. De forma que quanto mais parecidos sejam os potenciais de borda do candidato à solução com os mensurados no corpo, menor será o seu erro relativo e mais parecida a sua distribuição interna de condutividade será com a do corpo analisado.

Pelo fato de nesta pesquisa os dados serem realizados na forma de simulações, os potenciais de borda do corpo foram simulados através de uma distribuição interna de condutividade criada pelo usuário e seu respectivo cálculo do problema direto. A seguir há uma representação desta comparação:

**Figura 4: Domínio com objeto conhecido (A) e domínio com objeto desconhecido (B).**



Onde em (A) é posicionado um objeto com distribuição interna conhecida e gerados seus potenciais de borda através da resolução do problema direto, e estes seriam hipoteticamente, os potenciais de borda medidos no corpo; e em (B) é gerada uma distribuição interna aleatória de condutividade acordo com o método utilizado para otimização, e são gerados seus potenciais de borda através, também, da resolução do problema direto. Assim, para cada candidato à solução, são calculados seus potenciais de borda através da resolução do problema direto e estes potenciais são comparados com os do corpo que a partir de agora passa a ser conhecido como objeto de estudo.

O erro relativo médio (função objetivo) entre os potenciais de borda do objeto procurado e os do candidato à solução é dado pela distância quadrática entre os dois potenciais de borda. Este erro é calculado pela seguinte expressão:

$$f_0(x) = \epsilon(x) = \left[ \frac{\sum_{i=1}^{n_p} (U_i(x) - V_i)^2}{\sum_{i=1}^{n_p} V_i^2} \right]^{1/2} \quad (8)$$

Onde  $n_p$  é o número de eletrodos,  $V_i$  são os potenciais de borda do objeto de estudo e  $U_i(x)$  são os potenciais de borda do candidato à solução.

A expressão (8) será utilizada como função objetivo a ser minimizada por cada técnica apresentada neste trabalho.

## 2.5 Método de Gauss-Newton

O método de Gauss-Newton é um método numérico baseado em gradiente-descendente utilizado para resolver problemas de mínimos quadrados não lineares. É um método desenvolvido para minimizar uma soma de funções quadráticas. Este método tem este nome pelo fato de ser baseado no método de Newton, porém, implementado para eliminar o uso de segundas derivadas (ADLER et. al. 2008).

Para o problema da TIE, o algoritmo de Gauss-Newton é aplicado no sentido de encontrar a distribuição de condutividade  $\sigma_k$  que minimize a expressão:

$$s_k = \frac{1}{2} \sum_{\vec{u} \in \partial\Omega} (\phi_{ext,k}(\vec{u}) - \phi_{ext}(\vec{u}))^2, \quad (9)$$

Onde  $\phi_{ext,k}(\vec{u}) = f(I(\vec{u}), \sigma_k(\vec{v}))$ , para  $\vec{u} \in \partial\Omega$  e  $\vec{v} \in \Omega$  (ADLER et. al. 2008).

Este método é capaz de gerar imagens para TIE, porém não é um método preciso com relação à queda do erro relativo. Não sendo, desta forma um método confiável para se gerar imagens do interior do corpo humano que possivelmente serão utilizadas para o diagnóstico médico. Porém a inclusão de uma solução gerada por este método em um conjunto de candidatos à solução pertinente a um algoritmo de busca e otimização (Busca Guiada), pode guiar a convergência do algoritmo (RIBEIRO et. al., 2014) para valores baixos de erro relativo (neste trabalho foi considerado um erro relativo abaixo de 3% como um erro baixo). Uma das técnicas utilizadas para reconstruir imagens neste trabalho foi implementada utilizando a busca guiada. Esta inclusão está descrita com detalhes no Capítulo 4.

## 2.6 Aplicações da TIE

Na maioria dos estudos encontrados nas bases de dados científicas durante a escrita deste projeto, a Tomografia por Impedância Elétrica é utilizada como método de monitoração respiratória e detecção de problemas relacionados. Todavia também foram encontrados estudos que mostram a TIE relacionada a outras áreas de interesse médico, como por exemplo,

associada à ultrassom e achados patológicos como método de detecção de câncer de próstata, mamografia por impedância elétrica e TIE como uma potencial técnica para detecção de sangramentos intracranianos (Acidente Vascular Cerebral). Alguns destes estudos são descritos a seguir:

#### 2.6.1 Avaliação da perfusão pulmonar

Riera et. al., (2011) Descreveram a Tomografia por Impedância Elétrica como um novo método para monitoração de função pulmonar em pacientes submetidos à ventilação artificial, no entanto com algumas limitações com relação à resolução da imagem obtida. Uma vez que através da TIE seria possível monitorar a distribuição de gás nos pulmões durante a ventilação mecânica de pacientes.

A TIE demonstra interesse em particular no pulmão submetido à ventilação artificial e com lesão pulmonar aguda, fornecendo dados importantes do que acontece em um corte axial da cavidade torácica. Desta forma é possível se ajustar os parâmetros globais da ventilação artificial (precisão e volume, fundamentalmente). A capacidade da TIE para mostrar as características regionais da perfusão e ventilação pulmonares, vem sendo aperfeiçoada ao longo dos últimos anos. Esta técnica é considerada atualmente como uma técnica que pode ajudar na hora de se ajustar os parâmetros do equipamento de ventilação artificial. Mas também pode trazer outros tipos de informações importantes, como a localização de uma inclusão pleural, ou a correta localização de um tubo oro-traqueal (RIERA et. al., 2011).

#### 2.6.2 Detecção de redistribuição de pressão pulmonar

A pressão positiva causada nos pulmões pela ventilação artificial beneficia mais as partes ventrais dos tecidos do pulmonares, causando assim um déficit no suprimento de ar nas regiões dorsais (RADKE et. al. 2012).

A ventilação por suporte de pressão (VSP) foi criada para pacientes de cuidados intensivos e é um equipamento que facilita o processo de respiração do paciente. Nesta técnica, quando o paciente inala o ar, o equipamento cria uma pressão positiva com módulo suficiente para suprir apenas quantidade de ar necessária pela inalação do paciente (RADKE et. al. 2012).

Já a ventilação por pressão controlada (VPC) substitui o processo de respiração, causando uma pressão positiva e removendo esta, a cada ciclo respiratório (RADKE et. al. 2012).

A respiração espontânea, por sua vez, durante a anestesia geral, utilizando apenas uma máscara laríngea, pode prevenir a redistribuição de ventilação. Acredita-se que a VPC pode causar mais redistribuição de ventilação, que é a desigualdade de distribuição de ventilação entre as regiões do tecido pulmonar, do que a VSP, e que a respiração espontânea pode se prevenir a redistribuição de ventilação (RADKE et. al. 2012).

A tomografia por impedância elétrica é uma técnica que permite se avaliar a distribuição interna de ar nos pulmões, bem como sua perfusão nos tecidos alveolares. Esta técnica, no estudo descrito, foi utilizada para mostrar que a respiração espontânea, pode prevenir a redistribuição de pressão, bem como a ventilação por suporte de pressão, causa menor redistribuição de ventilação do que a ventilação por pressão controlada (RADKE et. al. 2012).

O estudo foi realizado através da análise da distribuição da ventilação pulmonar, pela TIE, em 30 pacientes submetidos a: respiração espontânea, ventilação por suporte de pressão e ventilação por pressão controlada (RADKE et. al. 2012).

Para realizar os estudos, foi utilizado um aparelho de TIE pulmonar chamado *Evaluation Kit 2*, produzido pela *Dräger Medical* da Alemanha (RADKE et. al. 2012).

Os autores mostraram que a ventilação por pressão controlada e a ventilação por suporte de pressão podem causar redistribuição de ventilação e que a respiração espontânea pode prevenir este tipo de problema (RADKE et. al. 2012).

### 2.6.3 Visualizar inclusões pleurais

Em seu estudo, Bhatia et. al. (2012), mostraram o potencial da TIE na detecção do pneumotórax e no auxílio de sua drenagem.

O diagnóstico de pneumotórax, que é o acúmulo de ar entre o pulmão e a pleura, é normalmente feito através de sinais e sintomas clínicos e Raio X do tórax. Porém só é possível se detectar este problema com raios X se ele estiver em estágio evoluído, causando, na maioria das vezes, um diagnóstico tardio do pneumotórax (BHATIA et. al. 2012).

O ideal para se detectar este problema e o tratar seria uma técnica que possibilitasse a detecção precoce da inclusão pleural. Os autores, nesta pesquisa objetivaram mostrar que a Tomografia por Impedância Elétrica pode detectar rapidamente um pequeno episódio de pneumotórax (BHATIA et. al. 2012).

Para se realizar o estudo, foram utilizados seis suínos anestesiados. Foram aplicadas alíquotas entre 20 e 30 ml de ar na região pleural, até somar o máximo de 200 ml, e a cada insuflação foram mensurados: o volume intratorácico expiratório final, através da plestimografia indutiva respiratória em conjunto com a TIE; os parâmetros cardíacos e a pressão arterial. Para se gerar as imagens de TIE, eles utilizaram um aparelho de fabricação alemã chamado *Geo MF II EIT system* da *Cardinal Health* (BHATIA et. al. 2012).

Ao longo das inflações foram aparecendo os sintomas fisiológicos, como por exemplo, a taquicardia, que surgiu quando o volume estava em torno de 150 ml. Na imagem formada pela TIE foi possível se visualizar o pneumotórax com uma resolução de 60% mesmo antes de começarem a surgir os sinais fisiológicos. Desta forma os autores concluíram que para os seus experimentos a TIE pode detectar rapidamente pequenos pneumotórax, mesmo antes de começarem a aparecer os sinais clínicos que juntamente com os raios X auxiliam no diagnóstico desta inclusão pleural (BHATIA et. al. 2012).

#### 2.6.4 Potencial para detectar hematomas subdurais

Em sangramentos intracranianos é importante que a detecção seja feita precocemente, para isto é necessário se utilizar uma técnica rápida e de fácil acesso. Dai et al. (2013), mostraram que as características de resistividade elétricas intracranianas mudam quando ocorrem hematomas subdurais. Esta mudança de resistividade aponta para o potencial da TIE como um possível método para detecção rápida de Hematomas subdurais (DAI et al. 2013).

Sangramentos intracranianos podem ocorrer quando um vaso sanguíneo se rompe, deixando surgir um acúmulo patológico de sangue na região extra vascular. A detecção precoce de um sangramento intracraniano é de extrema importância para o prognóstico do paciente e para sua recuperação (DAI et al. 2013).

Este estudo foi realizado através da observação das mudanças na resistividade interna craniana quando ocorre este tipo de problema. Para tanto foram analisados 6 pacientes, sendo 4 homens e duas mulheres, que foram submetidos a cirurgia de drenagem de hematomas na região subdural (DAI et al. 2013).

Através das imagens geradas pela TIE, os autores mostraram que em 100% dos casos em que houve hematoma subdural a condutividade aumentou nas regiões onde havia o sangramento intracraniano. Mostrando, desta forma, que a TIE é uma técnica em potencial para se detectar rapidamente um acidente vascular cerebral deste tipo (DAI et al. 2013).

### 2.6.5 Avaliar alterações no volume sistólico

Em experimentos com suínos Maisch et al. (2011) mostraram que a TIE é uma tecnologia candidata à avaliação das alterações de volume sistólico. Para realizar os experimentos, eles utilizaram o tomógrafo *Enlight*, da *Dixtal*, produzido em São Paulo, Brasil.

A avaliação das alterações no volume sistólico, atualmente são realizadas através da utilização de um cateter, este dispositivo é inserido de forma invasiva no espaço intravascular e é guiado até o coração. A TIE, neste trabalho foi colocada como uma ferramenta em potencial para possibilitar a realização destas avaliações de forma não invasiva (MAISCH et al. 2011).

Seu estudo foi realizado utilizando 8 suínos submetidos a diferentes condições vasculares e os dados foram obtidos através da TIE, que avaliou a sístole aórtica, de uma sonda de fluxo ultrassônico e da análise da onda de pulso arterial. Os dados de TIE dos quatro suínos, juntamente com os dados dos sensores, foram utilizados para se desenvolver um algoritmo de análise de frequência de TIE. E os dados dos outros quatro foram utilizados para testar a performance deste algoritmo (MAISCH et al. 2011).

Os dados de alteração sistólica, visualizados pela TIE, correlacionados com os dados do fluxo ultrassônico e da onda de pulso arterial, consistem em um importante passo para a avaliação, de forma não invasiva, das iterações coração-pulmão (MAISCH et al. 2011).

### 2.6.6 Auxiliar no diagnóstico de câncer de próstata

Wan. et. al. (2013), através de experimentos em glândulas prostáticas extraídas cirurgicamente, mostraram que há uma alteração de condutividade nas regiões cancerígenas do tecido. Fator que coloca a TIE como um potencial método para se detectar câncer de próstata já que a mesma se baseia na condutividade dos tecidos.

O câncer de próstata tem sido um grande problema em saúde pública. Este tipo de câncer é a segunda maior causa de morte por câncer em homens atualmente. O uso da ultrassom transretal para guiar a extração de material para biópsia tem sensibilidade e especificidade limitadas para detectar lesões cancerígenas na próstata (WAN. et. al. 2013).

O estudo propôs um novo método de imageologia para câncer de próstata que combina a ultrassom transretal com tomografia por impedância elétrica. A ultrassom transretal provê informações anatômicas, o que guia a reconstrução de imagens da tomografia por impedância elétrica (WAN. et. al. 2013).

O estudo foi realizado com 50 homens submetidos a prostatectomia total para tratamento de câncer de próstata. O teste estatístico realizado mostrou que há um significativo aumento de condutividade nas regiões afetadas pelo câncer com relação as áreas não afetadas (WAN. et. al. 2013).

#### 2.6.7 Detectar câncer de mama

Em um estudo com 117 pacientes do sexo feminino Pak et. al. (2012) demonstraram que a Mamografia por impedância elétrica com exames adicionais é uma ferramenta não invasiva, confortável, rápida e informativa técnica para o diagnóstico de câncer de mama.

A mortalidade por câncer de mama está crescendo continuamente. Estima-se que surgem, anualmente, um milhão de casos desta doença. O diagnóstico precoce, é um fator que diminui a mortalidade causada por este tipo de problema. Daí a necessidade de cada vez mais melhorar os diagnósticos no sentido de se detectar cada vez mais cedo esta doença. A melhor forma de se prevenir é fazendo exames, pelo menos, a cada dois anos para mulheres maiores de 45 anos (PAK et. al. 2012).

Seu diagnóstico é realizado principalmente pela mamografia, porém esta técnica não é recomendada para mulheres jovens devido à maior densidade do triangulo glandular destas, podendo causar diagnósticos falso-positivos (PAK et. al. 2012).

A mamografia por impedância elétrica atende os requisitos de poder detectar precocemente o câncer de mama e de poder ser realizada por pacientes de qualquer idade. Este tipo de mamografia pode detectar o câncer de mama ainda de forma precoce, através das alterações na impedância da mama afetada (PAK et. al. 2012).

Os experimentos foram feitos através da aplicação da mamografia por impedância elétrica em 117 pacientes do sexo feminino, juntamente com exames de raios X e ultrassom. Estas pacientes estavam divididas entre pacientes com mastopatias, tumores benignos e com câncer de mama (PAK et. al. 2012).

Todos os casos de câncer de mama foram detectados, sendo, 72 casos de câncer de mama com risco de progressão nível III e 3 casos câncer de mama com risco de progressão nível II. Também houveram falsos positivos detectados em 12,61% dos casos. Desta forma, a eficiência do método foi de 87,39% (PAK et. al. 2012).

## CAPÍTULO 3: OTIMIZAÇÃO POR ALGORITMOS EVOLUCIONÁRIOS

A humanidade, no intuito de se relacionar com a natureza e controlar aspectos da vida, tem desenvolvido conhecimento a respeito de tudo que a circunda. Seja sobre o tempo, ou sobre a terra, ou sobre o espaço, entre outros, a construção destes conhecimentos foi e vem sendo feita de forma colaborativa ao longo dos séculos por pesquisadores de diversas áreas.

Um grande avanço no desenvolvimento do conhecimento humano foi o advento dos computadores eletrônicos. Estes possibilitaram inúmeras funcionalidades sob a forma de armazenar e processar dados.

Uma das maiores revoluções do advento do computador foi a capacidade de criar, na forma de programas, seres inteligentes na forma de inteligência artificial e novas formas de vida na forma de vida artificial (MITCHELL, M. 1998). A partir daí foi possível simular os seres e seus sistemas biológicos e aprender sobre seus comportamentos quando ocorrem mudanças no ambiente em que estão inseridos.

A computação baseada em sistemas biológicos e na teoria da evolução natural de Darwin é conhecida nos dias de hoje como Computação Evolucionária e será descrita com mais detalhes na seção a seguir.

### 3.1 Computação Evolucionária

Com o pensamento de utilizar os princípios darwinianos de evolução para resolver problemas de busca, em 1948 Turing propôs a “*genetic or evolutionary computing*”, mas foi em 1962 que Bremerman realizou experimentos em computador em “*optimization through evolution and recombination*”. Durante a década de 60 foram desenvolvidos três modelos de algoritmos evolucionários em três diferentes lugares. Nos Estados Unidos, Fogel, Owens e Walsh introduziram a Programação Evolucionária (FOGEL et. al., 1965; FOGEL et. al., 1966), enquanto na Holland chamou este método de Algoritmos genéticos (DE JONG, 1975; HOLLAND, 1973; HOLLAND, 1975) e na Alemanha as Estratégias evolutivas (RECHEMBERG, 1973; SCHWEFEL, 1995). Mais tarde, no início da década de 90, estes algoritmos foram colocados como parte de uma grande área chamada Computação Evolucionária. Foi também nesta época que surgiu a programação genética como mais uma das técnicas que compõem a Computação Evolucionária (EIBEN & SMITH, 2003).

Computacionalmente, para se implementar a Computação Evolucionária é necessário se construir um algoritmo que corresponda ao sistema biológico no qual será baseado a

evolução do processo. Este algoritmo fará uma simulação, tanto dos indivíduos, quanto das condições ambientais às quais eles serão expostos. Para fazer estes indivíduos interagirem entre si e com o ambiente será necessário que o algoritmo tenha, a princípio, os seguintes componentes, podendo variar de acordo com o algoritmo evolucionário implementado:

- Representação:** é a forma de transcrever a composição dos indivíduos para um formato que possa ser manipulado e avaliado de acordo com o objetivo. A representação real da solução para o problema é chamada de fenótipo, já a forma como ele será tratado pelo algoritmo é chamada de genótipo, esta nomenclatura vem da genética, na qual o material genético puro representa o genótipo e as características que ele gerará após ser transcrito e traduzido são chamadas de fenótipo;
- Função de avaliação:** Também conhecida como função objetivo, esta função, que é a base da seleção, retorna o valor de aptidão (fitness) de cada genótipo a ela submetido. Esta função mostra o quão apto um genótipo está a resolver o problema proposto, pode-se através dela visualizar a convergência do algoritmo ao longo das iterações, no caso da TIE esta função passa a ser a equação (8);
- População:** Conjunto de genótipos candidatos à solução para o problema proposto, geralmente inicializado com indivíduos contendo distribuição aleatória. A função da população é apresentar diferentes candidatos à solução. A diversidade da população é medida de acordo com o quão diferentes seus indivíduos são entre si. Para se ter uma boa exploração do espaço de busca é necessário se ter um bom nível de diversidade;
- Mecanismo de seleção de pais:** Através deste mecanismo serão selecionados os indivíduos que gerarão indivíduos descendentes para a próxima geração. Em alguns casos pode ser relacionado com a aptidão;
- Operadores de variação:** São os operadores que causarão mudanças na composição dos indivíduos. O cruzamento cria um novo indivíduo a partir da composição de dois diferentes indivíduos. A mutação adiciona uma perturbação em algum componente do indivíduo. Ambos são aplicados obedecendo probabilidades;
- Mecanismo de seleção de sobreviventes:** Este mecanismo seleciona os indivíduos que continuarão na população na próxima geração. Quando é baseado nos melhores valores de aptidão diz-se que há um elitismo no algoritmo.

Para dar movimento ao processo, a execução do algoritmo é dada na forma de iterações, nas quais acontecem as seguintes etapas:

- 1.Criação da população inicial;
- 2.Cálculo da aptidão de todos os indivíduos;
- 3.Aplicação dos operadores de variação (cruzamento, mutação, etc.);
- 4.Selecionar os indivíduos que irão para a próxima geração;
- 5.Verificar se o critério de parada foi atingido (se sim: finalize; se não: volte para o passo 2).

Neste processo, um dado ambiente é preenchido por uma população que luta para sobreviver e reproduzir. A aptidão destes indivíduos, dada pelo ambiente, diz o quão bem eles estão atingindo o objetivo. Suas chances de sobreviver e de reproduzir estão relacionadas com esta aptidão, ou seja, quanto mais apto, mais chances um indivíduo tem de reproduzir e de sobreviver para a próxima geração (EIBEN & SMITH, 2003).

Este trabalho utiliza um método evolucionário baseado na dinâmica das sociedades, sua evolução e suas contradições, chamado Método Dialético de Otimização. Para se realizar as devidas comparações, o problema da TIE também foi implementado em Algoritmos Genéticos, Evolução Diferencial e em Otimização por Enxame de Partículas, estas técnicas serão descritas com mais detalhes a seguir.

### 3.2 Algoritmos Genéticos

Os Algoritmos Genéticos (AG's) foram propostos inicialmente por Holland no seu livro “*Adaptation in natural and artificial systems*”, no entanto eles têm sido muito utilizados como métodos para otimização de funções (EIBEN & SMITH, 2003).

A representação inicial de Holland é conhecida como SGA, sigla do inglês “*Simple Genetic Algorithm*” que obedece às seguintes características:

**Tabela 2: Sumário Técnico do SGA. (EIBEN & SMITH, 2003)**

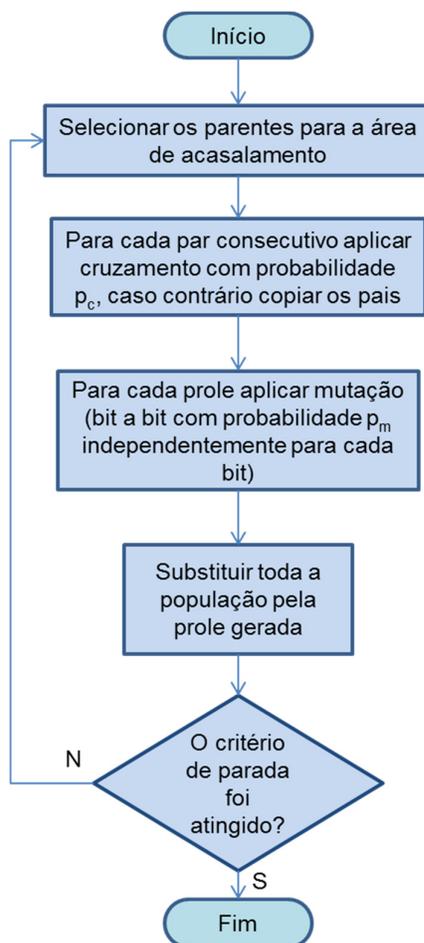
Representação	<i>Strings</i> Binárias
Recombinação	N-pontos ou uniforme
Mutação	Bit a Bit com perturbação e probabilidade fixa
Seleção de Pais	Proporcional à aptidão

Seleção de sobreviventes	Toda a prole substitui os pais
Especialidade	Ênfase no cruzamento

O SGA segue as seguintes etapas com probabilidade de cruzamento  $p_c$ , probabilidade de mutação  $p_m$  e área de acasalamento de tamanho igual ao tamanho da população (EIBEN & SMITH, 2003).

As etapas básicas da execução do Algoritmo Genético (AG) estão esquematizadas a seguir: (Adaptado de EBBEHART & SHI, 2007)

**Figura 5: Etapas do processo do AG.**



Existem outras implementações de AG que são baseadas neste modelo, porém com alterações, na maioria das vezes, nos operadores de mutação e cruzamento. Estes algoritmos atualmente são largamente utilizados na resolução de problemas de otimização envolvendo a minimização ou a maximização de uma determinada função objetivo. Os AG's foram implementados nesta pesquisa para reconstrução de imagens de TIE na forma da minimização da função objetivo dada pela equação (8).

### 3.3 Evolução Diferencial

A Evolução Diferencial (ED) também faz parte da classe dos algoritmos evolucionários aplicados em otimização.

Nesta técnica os operadores básicos de cruzamento e de mutação são sintetizados em um único operador, neste processo a seleção natural é modelada pela substituição do agente pelo seu descendente, caso este seja mais apto (BRAAK, 2006).

Na ED é iniciada uma população com NP candidatos à solução representados por  $X_{i,G}$ ,  $i=1, \dots, NP$ , onde  $i$  é a população e  $G$  é a geração à qual pertence a população. Na versão clássica desta técnica (Equação 10), a aplicação do operador principal ocorre em três agentes selecionados aleatoriamente da população. Abaixo estão as formas mais utilizadas atualmente de ED. (MUSRRAT et. al. 2013)

$$\text{DE/rand/1: } V_{i,G+1} = X_{r1,G} + F \bullet (X_{r2,G} - X_{r3,G}) \quad (10)$$

$$\text{DE/rand/2: } V_{i,G+1} = X_{r1,G} + F \bullet (X_{r2,G} - X_{r3,G}) + F \bullet (X_{r4,G} - X_{r5,G}) \quad (11)$$

$$\text{DE/best/1: } V_{i,G+1} = X_{best,G} + F \bullet (X_{r1,G} - X_{r2,G}) \quad (12)$$

$$\text{DE/best/2: } V_{i,G+1} = X_{best,G} + F \bullet (X_{r1,G} - X_{r2,G}) + F \bullet (X_{r3,G} - X_{r4,G}) \quad (13)$$

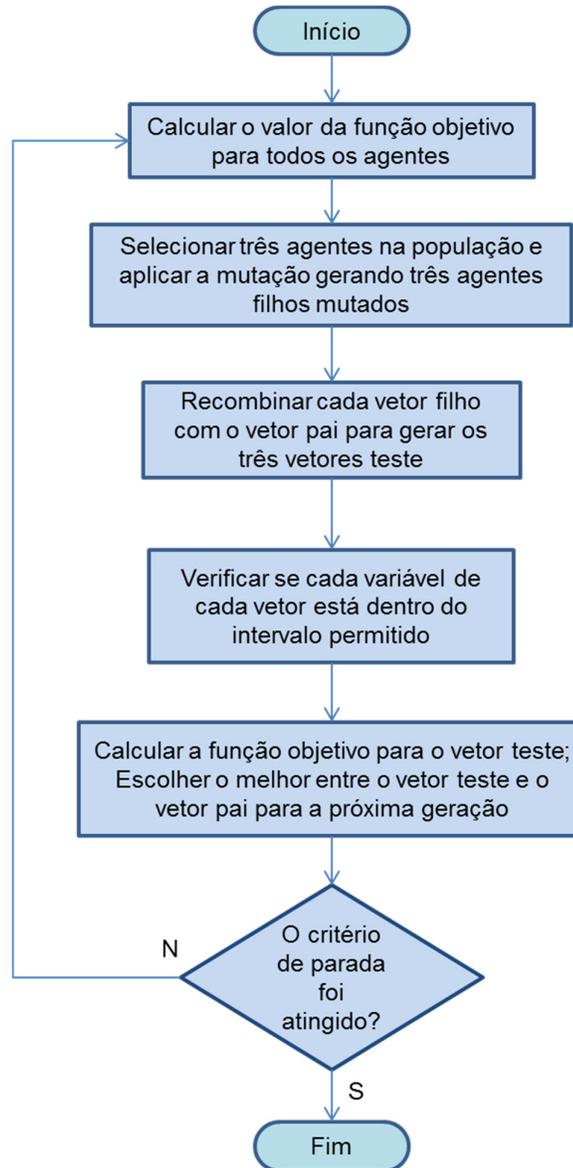
$$\text{DE/rand-to-best/1: } V_{i,G+1} = X_{r1,G} + F \bullet (X_{best,G} - X_{r2,G}) + F \bullet (X_{r3,G} - X_{r4,G}) \quad (14)$$

Onde  $F$  é um número no intervalo  $[0,1]$  chamado de parâmetro de controle.

A seleção de sobreviventes é feita de forma que se o agente gerado tiver melhor avaliação da função de aptidão do que o agente que o gerou ele o substitui, caso contrário, o agente pai continua fazendo parte da população e o gerado é descartado. (MUSRRAT et. al. 2013)

O processo iterativo da ED é baseado nas seguintes etapas:

**Figura 6: Etapas do processo de ED.**



Neste trabalho a ED também foi utilizada como uma técnica para reconstrução de imagens de TIE, na qual a função objetivo foi dada na forma de erro relativo médio pela equação (8).

### 3.4 Otimização por enxame de partículas

A otimização por enxame de partículas (OEP) foi proposta inicialmente pelo psicólogo social James Kennedy e pelo engenheiro eletricitista Russell Eberhart em 1995 (KENNEDY & EBERHART, 1995). Esta técnica é baseada principalmente em alguns conceitos, como vida artificial, bando de pássaros, cardume de peixes e na teoria dos enxames em particular. Ela também está relacionada com a computação evolucionária e tem ligações com algoritmos genéticos e com outra técnica evolucionária chamada programação evolucionária (KENNEDY & EBERHART, 1995).

O movimento das partículas (unidades que evoluem) é dado com base na observação da inteligência de um grupo (que pode ser de pássaros ou de peixes) na qual cada partícula sofre dois tipos de influência na sua trajetória, a influência da partícula líder (partícula melhor avaliada pela função objetivo) e da sua melhor configuração ao longo de toda a história do enxame. Esta influência é modelada nas expressões de atualização das posições (15) e das velocidades (16) mostradas a seguir:

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (15)$$

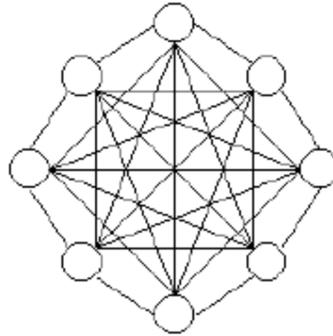
Onde,

$$v_i(t+1) = \omega v_i(t) + c_1 r_1 (p_i - x_i(t)) + c_2 r_2 (p_g - x_i(t)) \quad (16)$$

Em que  $1 \leq i \leq m$ , onde  $m$  é o número de partículas do enxame (tamanho da população);  $\omega$  é o peso de inércia,  $0 < \omega < 1$ ;  $r_1, r_2 \sim U[0,1]$ ;  $c_1, c_2$  são constantes de restrição também conhecidos como coeficientes de aceleração, onde  $c_1 + c_2 \approx 4$  (KENNEDY & EBERHART, 1995), onde  $c_1$  é a influência da consciência individual e  $c_2$  a influência da consciência global;  $x_i$  e  $v_i$  são os vetores de posição e de velocidade, respectivamente para a  $i$ -ésima partícula;  $p_g$  é a melhor posição global (partícula com melhor avaliação durante toda a trajetória do enxame).

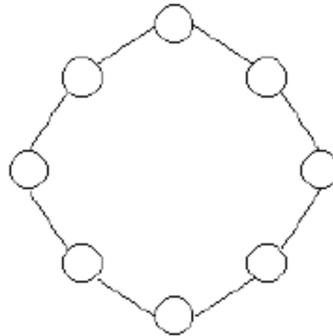
Denomina-se Topologia, a forma como as partículas se relacionam entre si e entre a melhor partícula avaliada. Na versão canônica a topologia é chamada de topologia em estrela, de forma que todas as partículas se relacionam com a melhor posição global como mostra a figura a seguir:

**Figura 7: Ilustração das relações na topologia em estrela da OEP (ZAVALA et. al., 2005).**



Em sua proposta de uma alteração no algoritmo canônico da OEP, Zavala et. al. (2005), utilizaram a topologia em anel, proposta por James Kennedy em 1999 (KENNEDY, 1999) para relacionar de forma diferente as ligações entre as partículas. Na topologia em anel, ao invés das partículas sofrerem influência da influência global e da influência individual, elas sofrem influência do seu melhor vizinho e individual. Como ilustrado na figura a seguir:

**Figura 8: Ilustração das relações na topologia em anel da OEP (ZAVALA et. al., 2005).**



Para achar o melhor vizinho, é utilizada a avaliação da função objetivo da partícula posterior  $x_{i+1}$  versus a anterior  $x_{i-1}$ , a que tiver a melhor aptidão será utilizada como fator de influência sobre a partícula atual  $x_i$ . A Otimização por Enxame de Partículas com topologia em anel é modelada pelas seguintes expressões:

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (17)$$

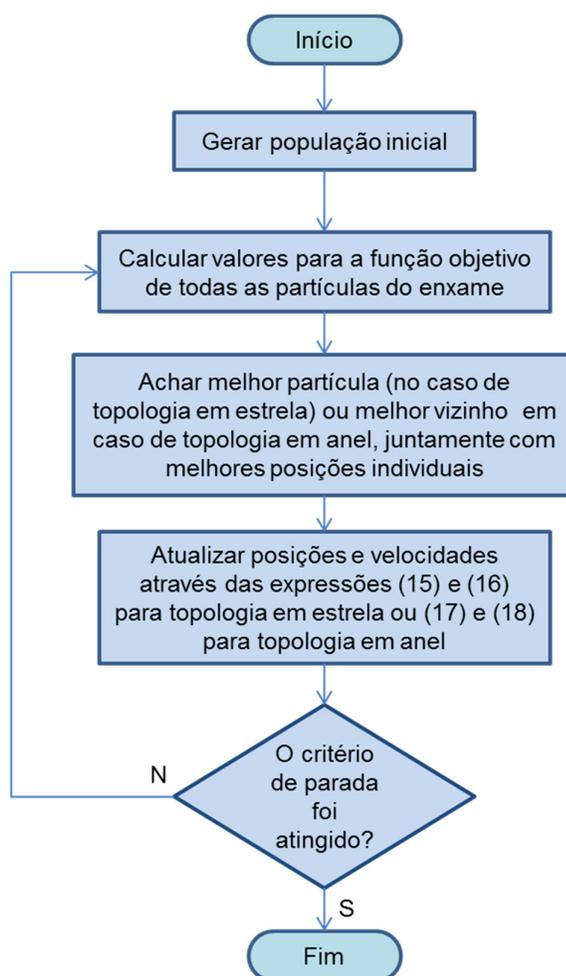
Onde,

$$v_i(t+1) = \omega v_i(t) + c_1 r_1 (p_i - x_i(t)) + c_2 r_2 (p_i - x_i(t)) \quad (18)$$

Que têm os mesmos fatores já descritos na legenda das equações (15) e (16), exceto pelo  $p_i$ , que modela a influência do melhor vizinho sobre a partícula atual, mudando assim, a topologia da OEP. Esta topologia foi criada no sentido de manter a diversidade da configuração das partículas.

O processo iterativo da OEP segue as etapas mostradas a seguir:

**Figura 9: Etapas da Otimização por enxame de partículas.**



Neste trabalho foram implementadas tanto a Otimização por Enxame de Partículas na sua forma canônica, como com a topologia em anel em conjunto com a busca guiada, já citada no capítulo anterior, para resolver o problema de reconstrução de imagens da TIE.

A subsecção a seguir fala sobre a técnica principal aplicada para reconstrução de imagens em TIE implementada neste trabalho. Esta técnica também é derivada das técnicas evolucionárias e é baseada na dinâmica das sociedades, suas contradições e suas crises ao longo das fases históricas.

### 3.5 Método Dialético Objetivo

As origens do termo “dialética” podem ser encontradas na filosofia ocidental. Nos pensamentos de Heráclito, o obscuro, porém a palavra só foi criada na época de Platão, um dos maiores filósofos que já existiu (SANTOS & ASSIS, 2009). Os filósofos socráticos designavam a dialética como “a arte do diálogo”. Neste conceito, a dialética envolve as ideias a respeito de um objeto e a liberdade de interação entre estas através do diálogo. Sendo assim, mais fácil se chegar à uma verdade a respeito deste (SANTOS & ASSIS, 2009).

O conceito moderno de dialética foi proposto entre o final do século XVIII e o início do século XIX pelo filósofo alemão Georg Wilhelm Friedrich Hegel (SANTOS & ASSIS, 2009). Este conceito foi desenvolvido com inspiração nas concepções dialéticas orientais trazidas da China pelos Jesuítas e no pensamento de Heráclito concebendo a realidade como um processo de eterna mudança (SANTOS & ASSIS, 2009).

O Método Dialético Objetivo (MDO), assim como os AG’s e a OEP, pode ser utilizado como uma forma de transformar um conhecimento externo em um sistema discreto e resolver problemas de busca e otimização. A compreensão deste método, envolve alguns termos:

- **Polo:** É um candidato à solução, contendo valores que serão trabalhados pelos operadores da técnica;
- **Pesos:** Corresponde às dimensões do polo. No caso de o polo ser um vetor, que armazena valores numéricos, seriam as posições deste vetor.
- **Polo antítese absoluta:** É um polo gerado contendo uma distribuição de pesos oposta, dentro de um intervalo, a outro polo já existente. A formação deste polo está modelada na segunda parte da expressão (19), mostrada na próxima subsecção;
- **Contradição:** É dada pela distância vetorial calculada entre dois vetores polos;
- **Fase histórica:** É um conjunto de iterações seguido por uma crise revolucionária. Em uma execução do algoritmo pode haver diversas fases históricas;
- **Crise revolucionária:** É a fase na qual são avaliadas as contradições entre os polos;

- **Força social:** Avaliação da função objetivo para um polo. Em outras técnicas como AG, poderia ser chamado de aptidão;
- **Hegemonia contemporânea:** É o polo com melhor força social presente na fase histórica atual;
- **Hegemonia histórica:** É o polo com a melhor força social de todas as fases históricas. Em outras palavras é o melhor polo que o sistema encontrou até o momento.

Este método é inspirado na dinâmica das contradições entre os seus polos. A busca de soluções pelos polos é dada pela aplicação de uma expressão de atualização dos pesos de cada polo e pela avaliação das contradições entre estes. Estas duas fases compõem uma fase histórica (SANTOS et. al., 2009).

### 3.5.1 O método Dialético aplicado a problemas de busca e otimização

O método dialético pode ser utilizado em um problema de busca e otimização (como o da TIE) da forma como é mostrado a seguir, proposto por (SANTOS & ASSIS, 2010):

1) Primeiramente definem-se os parâmetros iniciais, que são:

- Quantidade inicial de polos:  $m(0)$
- Número de fases históricas:  $n_p$  ;
- Duração de cada fase histórica:  $n_H$  ;

Desta forma o sistema iniciará com  $m(0)$  polos e durará  $n_p$  fases históricas, com  $n_H$  gerações em cada fase.

2) Criação do conjunto de polos inicial:

A inicialização dos polos e de seus respectivos pares antítese absoluta acontece como é mostrado a seguir:

**Figura 10: Pseudocódigo da inicialização dos polos e de seus pares antítese**

```

Início
i=1;
Enquanto i for menor que m(0) de faça
    matriz_polos(i) = Inicializar_polo;
    matriz_polos(i+m(0)) = gerar_polo_antitese(matriz_polos(i));
    i = i+1;
Fim Enquanto;
Fim

```

Onde  $m(0)$  é o número inicial de polos. De forma que o conjunto de polos será preenchido por cada polo e seu respectivo par antítese. A inicialização de cada polo e a geração do seu respectivo par antítese é feita de acordo com a expressão a seguir:

$$w_{i,j}(0) = \begin{cases} U(r_j, s_j), & 1 \leq i \leq m(0) \\ \check{w}_{i',j}(0), & 1 + \frac{1}{2}m(0) \leq i \leq m(0) \end{cases} \quad (19)$$

Onde,

$$\check{w}_{i',j} = s_j - w_{i,j} + r_j,$$

Para  $i' = i - \frac{1}{2}m(0)$ ,  $1 \leq i \leq m(0)$  e  $i \leq j \leq n$ , onde  $n$  é a dimensionalidade do problema de otimização,  $U(r_j, s_j)$  é um número aleatório uniformemente distribuído no intervalo  $[r_j, s_j]$  e  $S = [r_1, s_1] \times [r_2, s_2] \times \dots \times [r_n, s_n]$ , desde que  $s_j > r_j$  e  $s_j, r_j \in S$ .

- 3) Inicia-se o processo de evolução, que tem  $n_H$  interações em cada fase histórica. Nesta etapa são atualizados os pesos de cada polo através da expressão:

$$W_i(t+1) = W_i(t) + \Delta W_{C,i}(t) + \Delta W_{H,i}(t), \quad (20)$$

Onde,

$$\Delta W_{C,i}(t) = \eta_C(t)(1 - \mu_{C,i}(t))^2 (W_C(t) - W_i(t)),$$

$$\Delta W_{H,i}(t) = \eta_H(t)(1 - \mu_{H,i}(t))^2 (W_H(t) - W_i(t)),$$

Onde,

$$0 < \eta_C(t) < 1,$$

$$0 < \eta_H(t) < 1,$$

Onde  $\eta_C(0) = \eta_H(0) = \eta_0$  e  $0 < \eta_0 < 1$ . Os termos  $\Delta W_{C,i}(t)$  e  $\Delta W_{H,i}(t)$  estão relacionados com as influências das hegemonias presente e histórica, respectivamente, sobre o polo atual (i), enquanto  $\eta_C(t)$  e  $\eta_H(t)$  são os passos de atualização dos polos atualizados por:

$$\eta_C(t+1) = \alpha \eta_C(t), \quad (21)$$

$$\eta_H(t+1) = \alpha \eta_H(t), \quad (22)$$

Onde  $\alpha$  representa o fator de decrescimento dos passos ao longo das iterações, utilizado para facilitar a convergência.

Na expressão (20),  $\mu_{C,i}(t)$  e  $\mu_{H,i}(t)$  representam as pertinências contemporânea e histórica. Estes fatores, calculados a partir das expressões abaixo, modelam a aproximação da força social do polo atual com a força social das hegemonias contemporânea e histórica, respectivamente.

$$\mu_{C,i}(t) = \left( \frac{\sum_{j=1}^{m(t)} |f(W_i(t)) - f_C(t)|}{\sum_{j=1}^{m(t)} |f(W_j(t)) - f_C(t)|} \right)^{-1}, \quad (23)$$

$$\mu_{H,i}(t) = \left( \frac{\sum_{j=1}^{m(t)} |f(W_i(t)) - f_H(t)|}{\sum_{j=1}^{m(t)} |f(W_j(t)) - f_H(t)|} \right)^{-1}, \quad (24)$$

Nas quais  $1 \leq i \leq m(t)$ . Desta forma quando mais o valor da função objetivo do polo atual  $f(W_i(t))$  se aproxima do valor da função objetivo da hegemonia contemporânea  $f_C(t)$ ,  $\mu_{C,i}(t)$  se aproxima de 1, o que aproxima  $\Delta W_{C,i}(t)$  de 0 e torna a influência deste fator de pertinência contemporânea praticamente nula, evitando alterações no peso pela hegemonia presente. Da mesma forma acontece quando  $f(W_i(t))$  se aproxima de  $f_H(t)$ ,  $\mu_{H,i}(t)$  se aproxima de 1, aproximando  $\Delta W_{H,i}(t)$  de 0.

- 4) No final da fase histórica, após a etapa de evolução acontece a crise revolucionária que consiste nas cinco etapas a seguir:

- 1- **Avaliação das Contradições:** São calculadas as contradições entre todos os polos integrantes do sistema através da seguinte expressão:

$$\delta_{i,j} = \left[ \frac{\sum_{i=1}^{n_p} (W_i - W_j)^2}{\sum_{i=1}^{n_p} W_j^2} \right]^{1/2} \quad (25)$$

Onde  $\delta_{i,j}$  é a contradição entre os polos  $W_i$  e  $W_j$ . Modelando, desta forma, a diferença vetorial entre os dois polos.

- 2- **Fusão das baixas contradições:** As contradições calculadas na etapa anterior são avaliadas para cada par de polos possível no sistema, caso ela seja menor do que uma contradição mínima  $\delta_{\min}$  definida pelo usuário, apenas um dos polos envolvidos continuará no conjunto, desta forma:

$$\begin{aligned} \delta_{i,j}(t) > \delta_{\min} &\Rightarrow W_i(t), W_{j(t)} \in \Omega(t+1), \\ \delta_{i,j}(t) \leq \delta_{\min} &\Rightarrow W_i(t) \in \Omega(t+1). \end{aligned} \quad (26)$$

Onde,  $i \neq j, \forall i, j$  onde  $1 \leq i, j \leq m(t)$  e  $\Omega(t+1)$  representa o novo conjunto de polos.

- 3- **Síntese das altas contradições:** Caso esta seja maior do que uma contradição máxima  $\delta_{\max}$  também definida pelo usuário, é sintetizado um novo polo contendo características herdadas dos dois polos envolvidos através de um operador de cruzamento que seleciona um peso de cada polo em sequência. Esta síntese ocorre de acordo com a seguinte expressão:

$$\delta_{i,j}(t) > \delta_{\max} \Rightarrow g(W_i(t), W_j(t)) \in \Omega(t+1), \quad (27)$$

Para  $i \neq j, \forall i, j$  onde  $1 \leq i, j \leq m(t)$ . E  $g()$  é o operador de cruzamento que gera um novo polo como mostrado a seguir:

**Figura 11: Pseudocódigo do operador de síntese das altas contradições**

```

Início

k=1;
enquanto k<=dimensao_dos_polos
  Se k==dimensao_dos_polos
    novo_polo(1,k) = polos(i,k);
  senão
    novo_polo(1,k) = polos(i,k);
    novo_polo(1,k+1) = polos(j,k+1);
  fim se
  k=k+2;
fim enquanto

Fim

```

Onde *dimensão\_dos\_polos* é a quantidade de pesos de cada vetor polo, e os polos envolvidos no cruzamento são: *polos(i,k)* e *polos(j,k)*. Estes polos continuarão no conjunto juntamente com o polo gerado pelo cruzamento dos mesmos.

- 4- **Crise Revolucionária:** Nesta etapa, dada uma crise máxima  $X_{\max}$ , todos os polos do sistema são acrescidos de uma perturbação nos seus pesos chamada de efeito de crise, dada de acordo com a seguinte expressão:

$$W_{k,i}(t+2) = W_{k,i}(t+1) + X_{\max} G(0,1), \quad (29)$$

Para  $1 \leq k \leq m(t+1)$  e  $1 \leq i \leq n$ , onde  $G(0,1)$  é um número aleatório de distribuição gaussiana com esperança 0 e variância 1.

- 5- **Geração dos polos antagônicos:** Caso o critério de parada ainda não seja atingido, é acrescido, ao conjunto de polos resultante das etapas anteriores, um novo conjunto de polos com os respectivos polos antítese antagônicos de cada polo presente no conjunto. Esta etapa é dada pela seguinte expressão:

$$W_i(t+2) \in \Omega(t+2) \Rightarrow \tilde{W}(t+2) \in \Omega(t+2), \quad (30)$$

Para  $1 \leq i \leq m(t+2)$ , onde  $m(t+2) = 2m(t+1)$ . De forma que todos os polos atuais do sistema tenham seu par antítese antagônico, repetindo o que acontece na inicialização do algoritmo.

### 3.5.2 Análise pelo método da máxima entropia

Um método de busca e otimização é tão bom quanto boa for sua capacidade de escapar de mínimos locais (encontrando valores melhores do que os antes obtidos) além de ser tão bom quanto for garantida a sua convergência, gerando desta forma duas formas básicas de se avaliar um algoritmo:

- 1- Capacidade de cobertura do espaço de busca (capacidade exploratória);
- 2- Estabilidade e convergência.

Santos & Assis (2013), Propuseram também uma abordagem diferente para o método dialético. Este método é baseado no princípio da máxima entropia para gerar uma versão modificada do algoritmo canônico do MDO.

Para se descrever o método da máxima entropia aplicado ao MDO é necessário se partir da expressão de atualização dos pesos supracitada na equação 19 do presente trabalho, com base na qual, para o algoritmo convergir é necessário que o processo minimize as seguintes quantidades:

$$E_H = \sum_{i=1}^m \mu_{H,i} |f(W_i) - f_H|, \quad (31)$$

$$E_C = \sum_{i=1}^m \mu_{C,i} |f(W_i) - f_C|. \quad (32)$$

As pertinências histórica e contemporânea obedecem às seguintes expressões:

$$\sum_{i=1}^m \mu_{H,i} = 1, \quad (33)$$

$$0 \leq \mu_{H,i} = 1, \quad (34)$$

$$\sum_{i=1}^m \mu_{C,i} = 1, \quad (35)$$

$$0 \leq \mu_{C,i} = 1, \quad (36)$$

Devido ao fato de as medidas de incerteza expressas por estas expressões serem probabilísticas, pode-se definir uma entropia histórica  $H(\mu_H)$  e uma entropia contemporânea  $H(\mu_C)$  que podem ser maximizadas de forma paralela, aumentando assim a capacidade do algoritmo de cobrir mais espaço de busca:

$$H(\mu_H) = - \sum_{i=1}^m \mu_{H,i} \ln \mu_{H,i}, \quad (37)$$

$$H(\mu_C) = - \sum_{i=1}^m \mu_{C,i} \ln \mu_{C,i}. \quad (38)$$

De forma que a resolução destas duas funções se assemelha à construção de um algoritmo *fuzzi* c-médias utilizando o princípio da máxima entropia e o Método dos Multiplicadores de Langrage. Assim as funções de pertinência histórica e contemporânea são reescritas da seguinte forma:

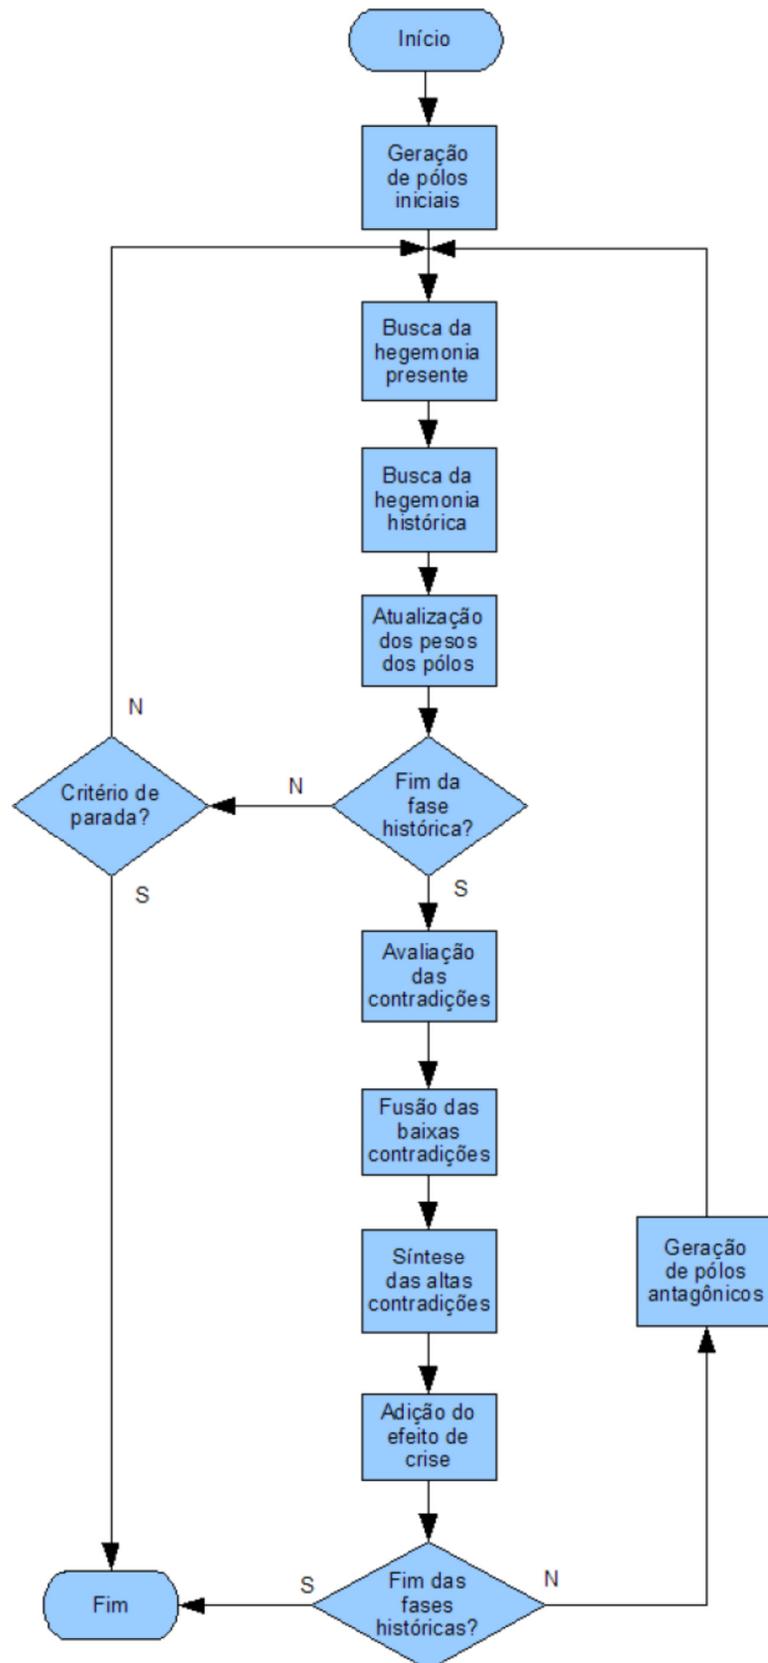
$$\mu_{H,i}(t) = \frac{\exp\left(-\frac{1}{m(t)}|f(\mathbf{w}_i(t)) - f_H(t)|\right)}{\sum_{j=1}^{m(t)} \exp\left(-\frac{1}{m(t)}|f(\mathbf{w}_j(t)) - f_H(t)|\right)}, \quad (39)$$

$$\mu_{C,i}(t) = \frac{\exp\left(-\frac{1}{m(t)}|f(\mathbf{w}_i(t)) - f_C(t)|\right)}{\sum_{j=1}^{m(t)} \exp\left(-\frac{1}{m(t)}|f(\mathbf{w}_j(t)) - f_C(t)|\right)}. \quad (40)$$

Onde, para se utilizar o Método Dialético Objetivo com a máxima entropia as equações 38 e 39 substituem as equações 23 e 24 na forma canônica do algoritmo.

A seguir está representado um fluxograma das etapas da OD:

Figura 12: Fluxograma do Método Dialético Objetivo (SANTOS & ASSIS, 2010)



No qual as etapas de busca das hegemônias e atualização dos pesos dos polos compõem a fase da evolução dos polos. Estas etapas modelam as interações entre os polos componentes e sua troca de informações ao longo do tempo.

Já as etapas de avaliação, fusão e síntese das contradições, crise revolucionária e geração dos pares antítese, compõem a fase de crise. Na qual a fusão das baixas contradições modela a junção das partes que têm pensamento parecido nos tempos de crise, a síntese das antas contradições modela a aparência de grupos que são moderados entre dois extremos ideológicos durante a crise e a geração dos polos antagônicos modela o surgimento de grupos com ideias totalmente contrárias às do grupo atual.

Neste trabalho, a função objetivo, que calcula a força social de cada polo deste método foi aplicada para TIE na forma de minimização do erro relativo médio dado pela expressão (8).

## **CAPÍTULO 4: RECONSTRUÇÃO DE IMAGENS DE TIE UTILIZANDO O MÉTODO DIALÉTICO OBJETIVO**

### 4.1 Otimização em TIE

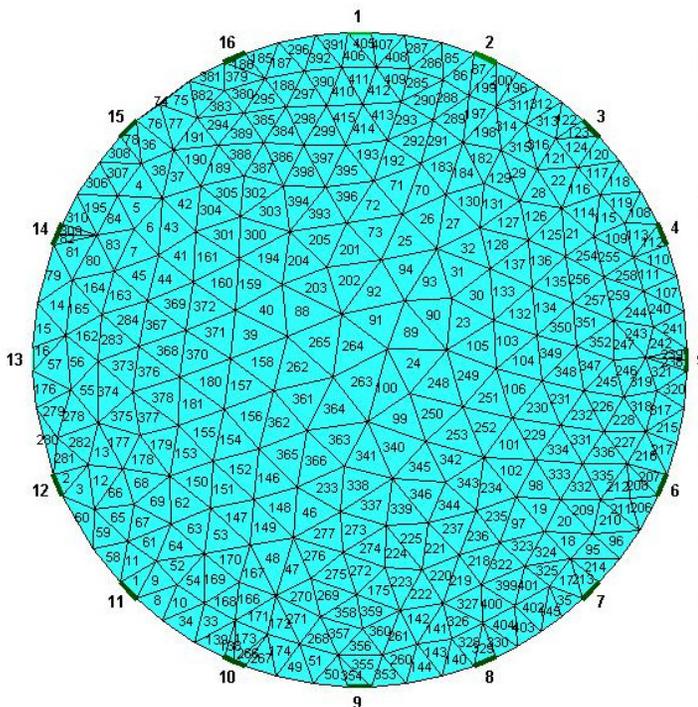
A proposta principal do presente trabalho foi implementar o problema direto da TIE na forma de um problema de busca e otimização do erro relativo entre a distribuição de potenciais de borda de uma distribuição criada pelo autor (na plataforma EIDORS) e a distribuição de borda dos candidatos à solução gerados pelos métodos de busca e otimização. Neste capítulo será descrita a implementação para cada uma das técnicas aplicadas para este problema.

### 4.2 Infraestrutura

Para se realizar os experimentos foi utilizada a plataforma EIDORS - “*Electrical Impedance Tomography and Diffuse Optical Tomography Reconstruction Software*”, uma ferramenta de código aberto, voltada para a TIE, desenvolvida para plataformas MatLab e Octave. Esta ferramenta possibilita realizar algumas tarefas relativas à TIE que não são triviais, como a resolução do problema direto para determinada distribuição, ou a representação gráfica de um vetor candidato à solução em uma malha a fim de se avaliar visualmente sua distribuição de condutividade.

Os vetores candidatos à solução representam, em cada elemento seu, a condutividade de cada um dos elementos finitos (triângulos) do domínio. Abaixo segue uma malha gerada pelo EIDORS. Nesta malha, cada triângulo representa graficamente um elemento finito, e seu respectivo número corresponde à dimensão do vetor que contém o valor de condutividade deste elemento.

**Figura 13: Malha triangulada gerada pelo EIDORS**



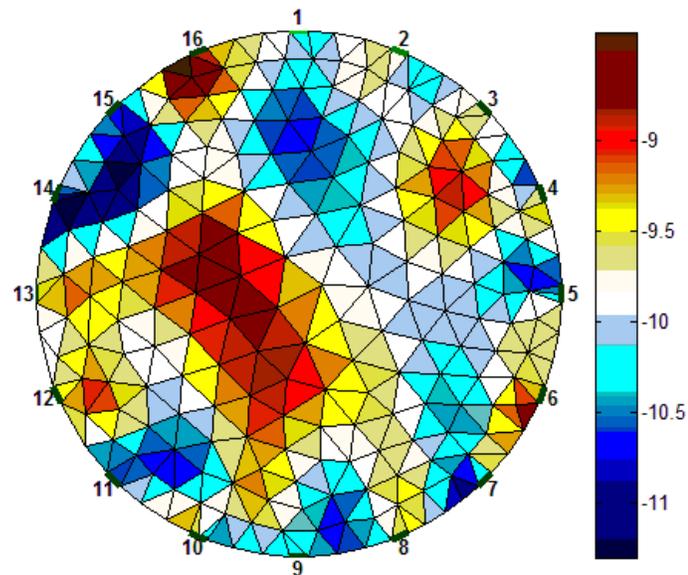
Na qual cada triângulo representa uma posição no vetor candidato à solução. Os números em cada triângulo representam os índices de sua posição no vetor. E nesta posição por sua vez é armazenado um número real contendo um valor de condutividade correspondente a este elemento.

Na configuração do EIDORS utilizada nesta pesquisa a malha gerada contém 415 elementos, ou seja, cada vetor candidato à solução tem 415 posições, das quais cada uma representa a condutividade de um elemento da malha.

A conversão de um vetor candidato à solução em uma imagem de distribuição de condutividade é feita pelo EIDORS e só é realizada quando é necessário se avaliar visualmente a distribuição de condutividade de um candidato à solução. De forma que os algoritmos de busca e otimização trabalham apenas com os vetores numéricos contendo representações das condutividades internas em suas dimensões.

A representação gráfica de um dos candidatos à solução contendo uma distribuição interna de condutividade está representada a seguir:

**Figura 14: Distribuição de condutividade representada graficamente.**



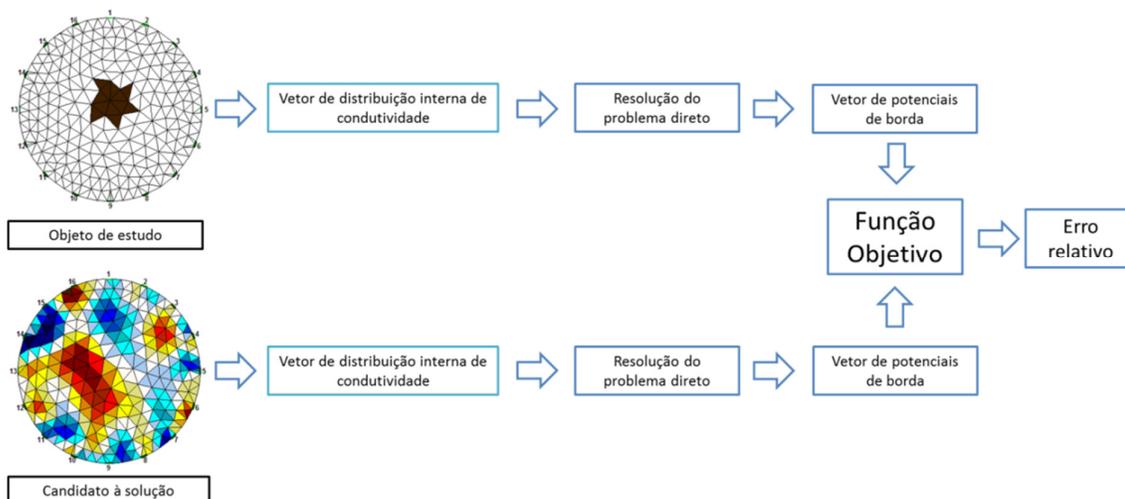
Na qual a cor vermelho escuro representa uma baixa condutividade, e azul escuro uma alta condutividade. As transições entre baixa e alta condutividade sob o ponto de vista numérico são representadas pelas cores intermediárias (amarelo, cinza, etc.);

#### 4.3 Função Objetivo

A função objetivo para todas as técnicas recebe como entrada dois vetores candidatos à solução e retorna o erro relativo entre eles como mostrado na equação (8). Nos experimentos realizados nesta pesquisa foram utilizados dados simulados. De forma que foram criados pelo autor objetos isolantes (de baixa condutividade) posicionados no centro, na borda e entre o centro e a borda do domínio e foram gerados os potenciais de borda para estas distribuições. Estes potenciais de borda simulam os potenciais de um corpo real contendo os objetos colocados pelo autor. Estes objetos são mostrados na figura (13), no próximo capítulo.

A seguir está um esquema de como é feito o cálculo da função objetivo para um candidato à solução.

**Figura 15: Esquema da resolução da função objetivo**



Na qual, através da resolução do problema direto, um vetor contendo uma distribuição interna de condutividade é transformado em um vetor de potenciais de borda. E utilizando a função objetivo é calculado o erro relativo entre os dois vetores de potenciais.

Na prática a resolução do problema direto para o objeto de estudo é feita apenas uma vez por execução do algoritmo, devido ao fato de os potenciais de borda procurados não mudarem ao longo das iterações da técnica.

Desta forma, quanto mais próximos forem os valores dos potenciais de borda calculados para o candidato à solução forem dos potenciais de borda ideais, menor será o erro relativo. Esta característica configura o problema da TIE como um problema de minimização do erro relativo que pode ser aplicado utilizando as seguintes técnicas.

#### 4.4 Algoritmos Genéticos

Para se implementar o problema de reconstrução de imagens em TIE na forma de AG's, os indivíduos da técnica foram representados pelos vetores de distribuição de condutividade interna. E os genes foram representados pelas posições do vetor.

Na aplicação desta técnica foram utilizados os seguintes parâmetros:

**Tabela 3: Parâmetros utilizados para Algoritmos Genéticos**

<b>Parâmetro</b>	<b>Valor</b>
População Inicial	100 indivíduos
Seleção	10 indivíduos melhores avaliados
Probabilidade de Cruzamento	100%
Probabilidade de mutação	100% da prole

Estes parâmetros foram obtidos de forma analítica com base nas simulações realizadas e os menores valores de erro encontrados por elas. Para AG as simulações foram feitas com a inclusão de um indivíduo contendo uma solução Gauss-Newton, a fim de se guiar a busca e melhorar a convergência. Abaixo está descrita a forma pela qual foi implementado o Algoritmo Genético para reconstrução de imagens de Tomografia por Impedância Elétrica.

**Figura 16: Pseudocódigo de Algoritmo Genético**

```

Início

Gere o objeto de busca;
Gere a população inicial;
Inclua um indivíduo (solução) gerado pelo método Gauss-Newton na população;

Enquanto o critério de parada não for atingido faça:
    Calcule a aptidão de todos os indivíduos com relação ao objeto de busca;
    Retorne a aptidão do melhor indivíduo;
    Selecione os indivíduos que irão participar do cruzamento;
    Faça o cruzamento dos indivíduos selecionados com probabilidade  $P_c$ ;
    Aplique a mutação em todos os indivíduos com probabilidade  $P_m$ ;
Fim Enquanto

Retorne o melhor indivíduo encontrado;
Gere a imagem para o melhor indivíduo encontrado;

Fim.

```

Como critério de parada foi utilizado o número máximo de gerações, que foi de 500 gerações, sendo gerada a imagem e computado o erro do indivíduo mais apto presente na população a cada 50 gerações bem como nesta última.

#### 4.5 Evolução Diferencial

Para esta técnica foram realizados experimentos em cada uma das quatro versões encontradas na literatura bem como para uma versão modificada proposta em coautoria pelo autor deste trabalho (RIBEIRO et. al. 2014). Nestas implementações, os agentes são representados por vetores numéricos que representam, em suas dimensões, cada um, as condutividades internas de um candidato à solução para os potenciais de borda do objeto de estudo utilizado. Nas versões de ED Foram utilizados os seguintes parâmetros:

**Tabela 4: Parâmetros utilizados para todas as versões de ED.**

Número Inicial de Agentes	100
Probabilidade de mutação	90%

Abaixo segue uma ilustração do como foi implementado o algoritmo a ED para o problema de geração das imagens de TIE.

**Figura 17: Pseudocódigo de Evolução Diferencial**

```

Início

Gere o objeto de busca;
Gere os agentes iniciais;

Enquanto o critério de parada não for atingido faça:

    Calcule o erro relativo de todos os agentes com relação ao objeto de busca;
    Retorne a aptidão do melhor agente;
    Selecione, de forma aleatória, três agentes;
    Aplique a mutação nos agentes selecionados;
    Cruzar os vetores gerados pela mutação com seus respectivos pais para gerar três vetores teste;
    Verifique se os valores dos vetores agentes estão dentro do intervalo permitido;
    Calcular o erro relativo para os vetores teste;

    De i=1 até o numero de vetores teste
        Se o erro relativo do vetor teste > erro relativo do vetor pai
            O vetor teste substitui o vetor pai;
        Senão
            O vetor teste é descartado;
        Fim se
    Fim de

Fim Enquanto

Retorne o melhor agente encontrado;
Gere a imagem para o melhor agente encontrado;

Fim.

```

No qual variam, de acordo com a versão implementada, o número de agentes selecionados, e a expressão de mutação, que gera o vetor teste.

#### 4.6 Otimização por Enxame de Partículas

Na OEP, cada partícula foi representada por um vetor contendo uma distribuição interna de condutividade. Na atualização das posições pela expressão já descrita, estes vetores têm sua distribuição variada. Desta forma acontece a busca por um candidato à solução que contenha um valor baixo de erro relativo (neste trabalho, considerado abaixo de 3%).

Os parâmetros utilizados para OEP estão descritos na tabela a seguir:

**Tabela 5: Parâmetros para Otimização por enxame de partículas**

Partículas Iniciais	100
Peso de inércia	8.5
C1	2.0992
C2	1.9008

A implementação da otimização por Enxame de Partículas foi feita de acordo com o pseudocódigo representado a seguir:

**Figura 18: Pseudocódigo de Otimização por Enxame de Partículas**

```

Início

Gere o objeto de busca;
Gere o enxame inicial;

Enquanto o critério de parada não for atingido faça:
    Calcule o erro relativo de todas as partículas com relação ao objeto de busca;
    Retorne a aptidão da melhor partícula;
    Aplique as expressões de atualização das velocidades e dos pesos;
Fim Enquanto

Retorne a melhor partícula encontrada;
Gere a imagem para a melhor partícula encontrada;

Fim.

```

As expressões de atualização das posições e velocidades são dependentes da topologia como descrito no capítulo anterior. Esta técnica também foi implementada com a Busca guiada, que é a inclusão de uma partícula com os valores de condutividade solucionados pelo método de Gauss Newton, no enxame inicial.

#### 4.6 Método Dialético Objetivo

Para o MDO os polos foram representados por vetores numéricos contendo em suas dimensões os valores de condutividade interna. O conjunto inicial de polos contém vetores polo com distribuições de condutividade randômicas, porém com valores pertinentes ao intervalo entre a condutividade máxima e a mínima, utilizadas para os experimentos realizados nesta pesquisa. No método dialético, como já descrito, metade dos polos é criada constituindo seus valores de forma randômica e a outra metade é gerada pelos polos antagônicos à primeira metade de polos já inicializada.

A atualização dos pesos dos polos foi feita através das expressões contidas na equação (20), de forma que os pesos dos polos (valores contidos nos vetores numéricos) variem com relação a seus valores de aptidão e as hegemonias histórica e contemporânea, no sentido de encontrar melhores forças sociais. Os valores de aptidão são obtidos pela aplicação da expressão (8) como função de aptidão que retorna o erro relativo entre os potenciais de borda do polo atual e os potenciais de borda do objeto de estudo. Este erro, nesta técnica é conhecido como força social.

Na fusão das baixas contradições são avaliadas todas as contradições presentes no conjunto. Nesta fase cada polo é confrontado com cada um dos outros polos do conjunto e caso a contradição calculada seja menor do que a contradição mínima, definida pelo usuário, um destes polos é eliminado do grupo, como mostrado na expressão (26), de forma a evitar duplicidade ou proximidade de distribuições.

Já na síntese das altas contradições é uma etapa que visa criar polos em uma área do espaço de busca que está sem cobertura. Aqui também cada polo é confrontado com todos os outros polos e desta vez, quando a contradição encontrada (distância vetorial) é maior do que uma contradição máxima, definida pelo usuário, é gerado um novo polo contendo valores pertinentes ao par de polos envolvido na contradição.

Na crise revolucionária foram adicionados ruídos, na forma de soma de um valor gaussiano com esperança 0 e variância 1, em cada peso de cada polo do sistema.

Na geração dos pares antagônicos são gerados os pares antítese absolutos dos polos remanescentes das duas tapas anteriores (fusão das baixas contradições e síntese das altas contradições). Abaixo encontra-se uma representação em pseudocódigo das etapas do Método Dialético Objetivo.

**Figura 19: Pseudocódigo do Método dialético Objetivo**

```

Início

Gere o objeto de busca;
Gere os polos iniciais e seus pares antagônicos;

Enquanto o fase < np faça:

    Enquanto geração < nH faça
        Calcule a força social de todos os polos;
        Encontre a hegemonia contemporânea e a histórica;
        Atualize os pesos de cada polo;
    Fim Enquanto

    Calcule as contradições entre todos os pares de polos;
    Faça a fusão das baixas contradições;
    Faça a síntese das altas contradições;
    Aplique a crise revolucionária;
    Gere os pares antítese dos polos;

Fim Enquanto

Retorne o melhor polo encontrado;
Gere a imagem para o melhor polo encontrado;

Fim.

```

A seguir estão os parâmetros utilizados para a implementação do Método Dialético Objetivo para a reconstrução de imagens de Tomografia por Impedância Elétrica.

**Tabela 6: Parâmetros Utilizados para o MDO**

Quantidade inicial de polos	100
Número de Fases Históricas	50
Duração de cada Fase Histórica	10
Range Superior	0.2
Range Inferior	0.002
Alfa	0.999
Eta L	0.999
Eta H	1.001
Contradição Máxima	0.0005
Contradição Mínima	0.001
Efeito de Crise Máximo	0.005

Os parâmetros utilizados para esta técnica foram obtidos através de sucessivas execuções do algoritmo variando os parâmetros e, desta forma, guardando os valores de parâmetros que conseguiram achar um menor valor de erro relativo no final de cada execução. Abaixo são mostrados os parâmetros que foram utilizados nesta técnica.

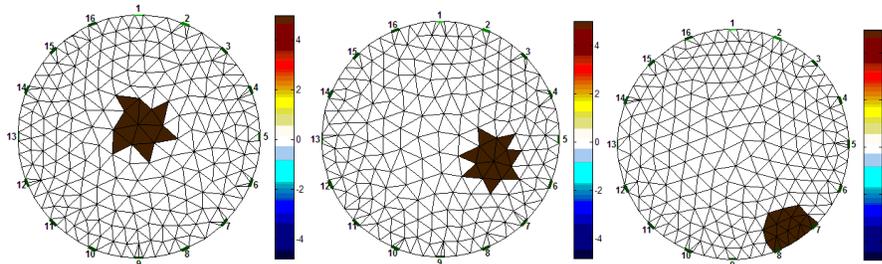
## CAPÍTULO 5: EXPERIMENTOS, RESULTADOS E DISCUSSÃO

Os experimentos foram realizados a fim de se avaliar o desempenho das técnicas descritas no capítulo 3, estas técnicas foram aplicadas para reconstruir imagens de TIE baseando-se na minimização da função objetivo. Primeiramente serão mostradas as características gerais dos experimentos que foram comuns para todas as abordagens e posteriormente, serão mostrados os resultados da reconstrução de imagens de TIE para cada técnica em particular.

### 5.1 Características gerais dos experimentos

Para todos os experimentos foram utilizadas como objetos de comparação três tipos de distribuição, criadas pelo usuário, com objetos posicionados no centro, na borda e entre o centro e a borda do domínio circular. A avaliação foi realizada de três maneiras: quantitativa, através do cálculo do erro feito pela função objetivo (8) do melhor candidato à solução, encontrado pelo algoritmo no final da trajetória; qualitativa: através da avaliação de o quão parecida a melhor distribuição encontrada é com a distribuição procurada (objeto de estudo); e de custo computacional, através da busca da técnica que encontra um menor valor de erro em um menor número de avaliações da função objetivo. A função objetivo é etapa mais computacionalmente custosa em todas as técnicas devido ao fato da resolução do problema direto para cada candidato à solução. Abaixo estão as três distribuições procuradas, criadas pelo usuário.

**Figura 20: Objetos de estudo utilizados como fantoma nos experimentos**



Onde a área em marrom é uma área de menor condutividade, definida como 5 S/m, e a área branca, uma maior condutividade, definida como 0.2 S/m. As figuras representam objetos localizados no centro, entre o centro e a borda e na borda, respectivamente.

Para os resultados serem comparáveis alguns parâmetros também foram os mesmos para todos os experimentos realizados, como os seguintes parâmetros do EIDORS:

**Tabela 7: Parâmetros do EIDORS utilizados nos experimentos**

Número de Eletrodos	16
Densidade da malha	“b”
Refinamento da malha	“2”
Dimensão dos candidatos a solução	415 elementos

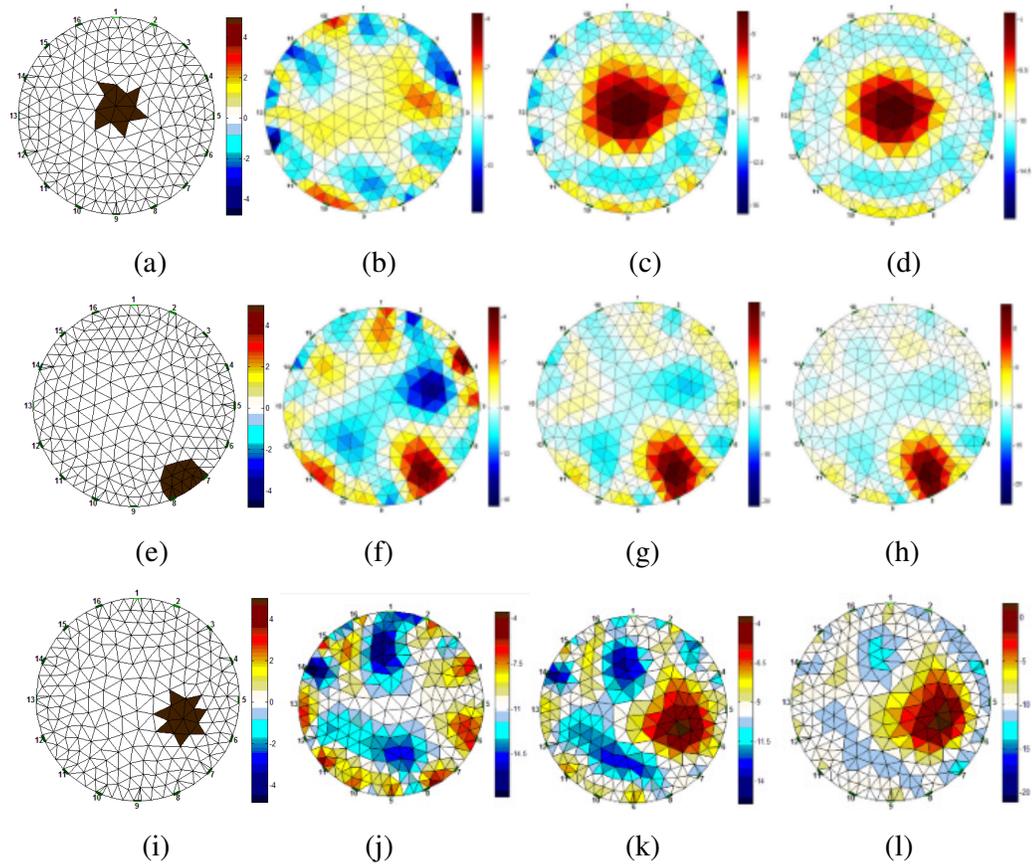
A quantidade de candidatos à solução também foi um fator comum para todos os algoritmos implementados, sendo de 100 candidatos iniciais à solução. Estes candidatos tiveram suas distribuições de condutividade preenchidas de forma aleatória, exceto para os casos de busca guiada, nos quais um dos candidatos à solução é uma distribuição encontrada pelo método determinístico de Gauss-newton, neste caso são criados 99 candidatos à solução com distribuições aleatórias em adição com um Gauss-newton.

Todos os experimentos foram feitos em um computador com processador Intel Core i7 com 8 GB de memória RAM e vídeo dedicado de 2 GB.

## 5.2 Resultados da aplicação dos Algoritmos Genéticos

A seguir são mostrados os resultados para AG com busca guiada para objeto localizado no centro, na borda e entre o centro e a borda, respectivamente:

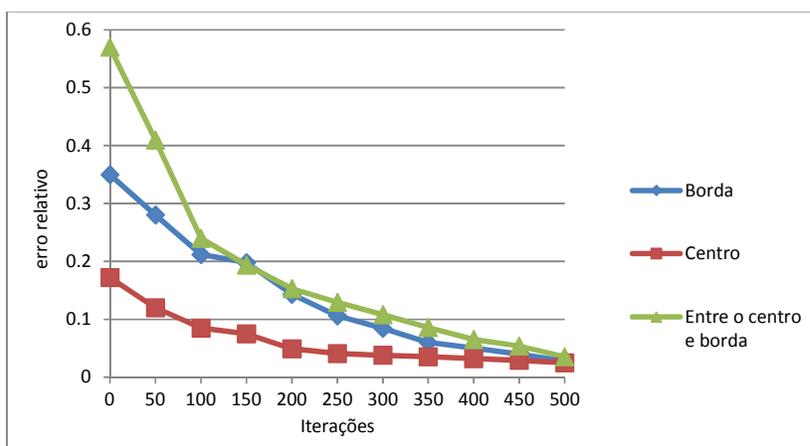
**Figura 21: Imagens reconstruídas no centro, borda e entre o centro e a borda, respectivamente, para AG com Busca Guiada.**



Onde, (a), (e) e (i) representam os objetos de estudo posicionados no centro, borda e entre o centro e a borda, respectivamente. (b), (c) e (d) representam a imagem do melhor candidato à solução para o centro em 100, 300 e 500 iterações, respectivamente; (f), (g) e (h) representam a imagem do melhor candidato à solução para a borda em 100, 300 e 500 iterações, respectivamente; e (j), (k) e (l) representam a imagem do melhor candidato à solução para o objeto de estudo localizado entre o centro e a borda em 100, 300 e 500 iterações, respectivamente.

A seguir são mostrados os resultados quantitativos, através da evolução do erro relativo do melhor indivíduo presente na população ao longo das iterações.

**Figura 22: Erro relativo ao longo das iterações para AG com busca guiada.**



Onde a linha azul representa a evolução do erro para o objeto localizado na borda, a linha vermelha para o objeto localizado no centro do domínio e a verde para objeto localizado entre o centro e a borda.

### 5.3 Discussão dos resultados para AG's.

Qualitativamente, a partir da figura (21) é possível ver que o AG com busca guiada conseguiu gerar imagens anatomicamente consistentes, ou seja, encontrou o isolante procurado mostrado na figura (21) imagens (a) e (e), para o centro e para a borda em 300 iterações (imagens (c) e (g)). Mostrado ser capaz de encontrar uma imagem consistente em um número razoável de iterações.

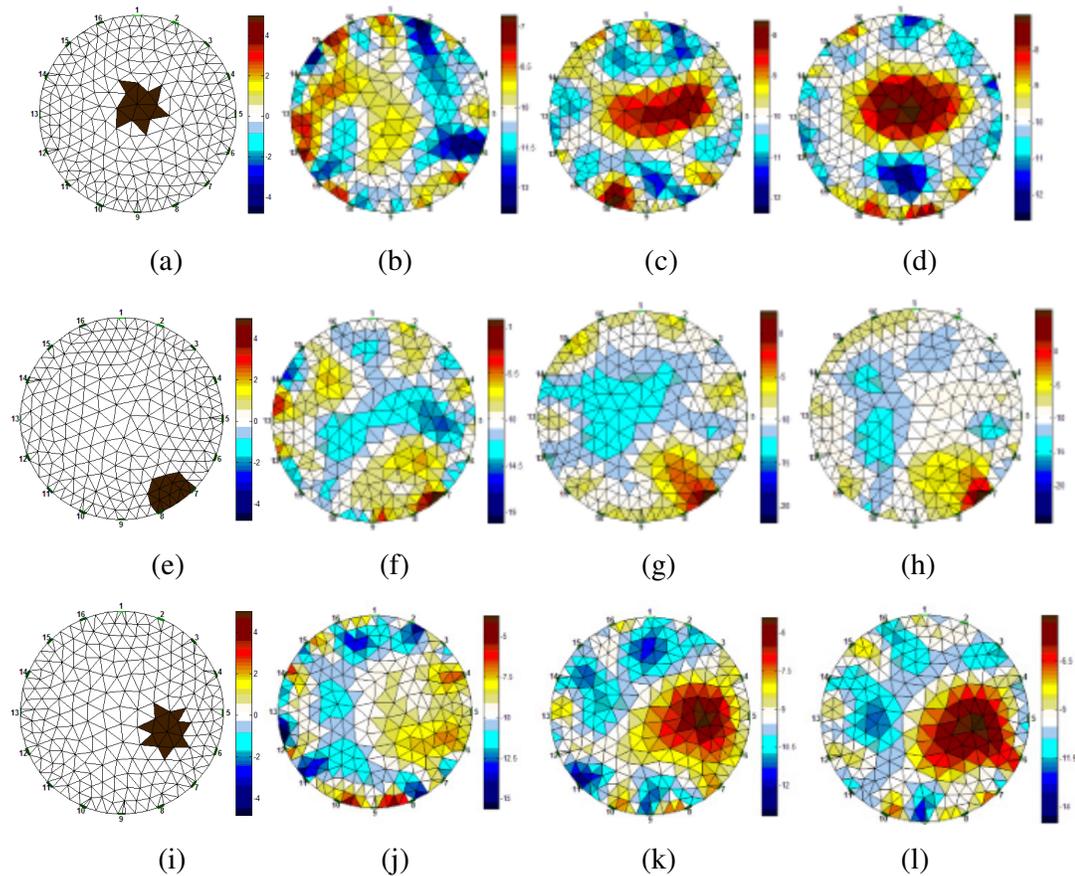
Quantitativamente, a partir da figura (22) é possível observar que o AG mostrou uma queda de erro inicial mais rápida para a reconstrução do objeto posicionado no centro.

O AG se mostrou como uma técnica capaz de fazer boas reconstruções de imagens de TIE, porém nos experimentos realizados neste trabalho o AG mostrou ser a técnica mais demorada com relação ao tempo de iteração, chegando a levar até três dias para se realizar as 500 iterações de cada experimento.

## 5.4 Resultados de evolução diferencial

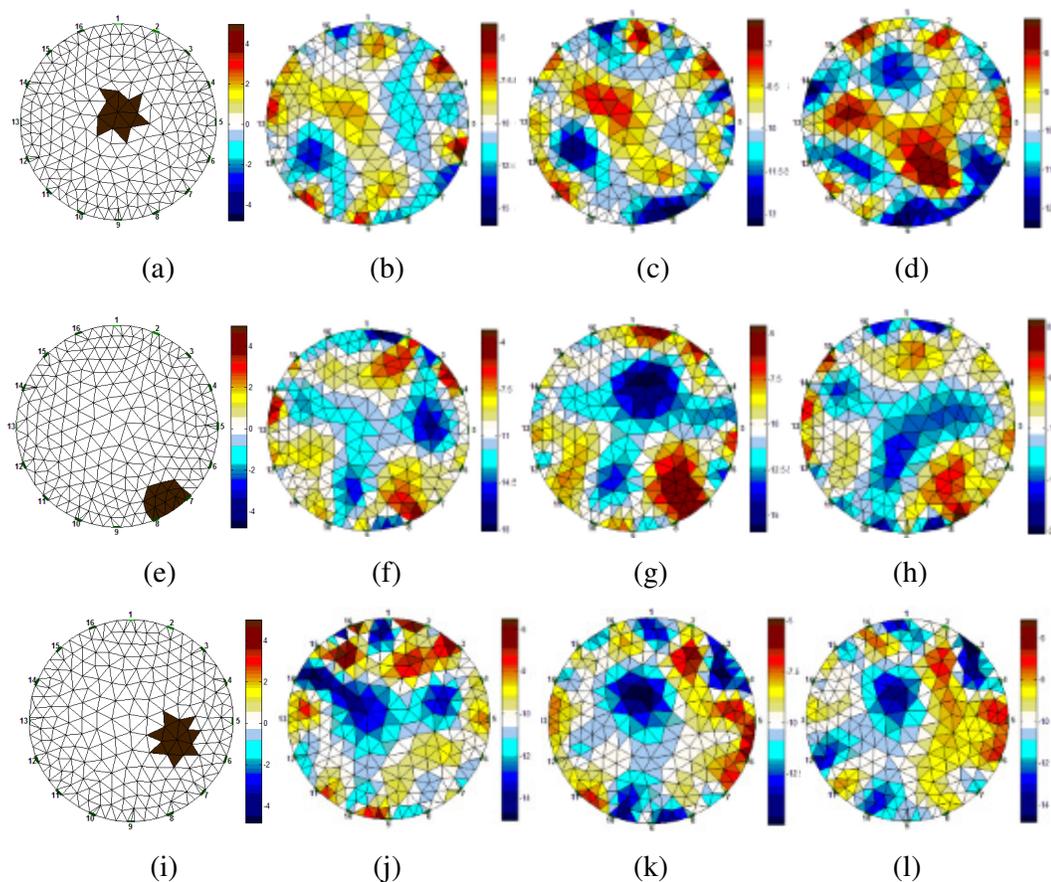
Na evolução diferencial foram feitas simulações em diversas versões a fim de se encontrar a versão da ED que apresentasse o melhor desempenho para reconstrução de imagens de TIE. A seguir são mostrados os resultados das versões da Evolução Diferencial já descritas neste trabalho além de uma versão modificada (ED-M) proposta em (RIBEIRO et. al., 2014).

**Figura 23: Imagens reconstruídas no centro, borda e entre o centro e a borda, respectivamente, para Evolução Diferencial clássica**



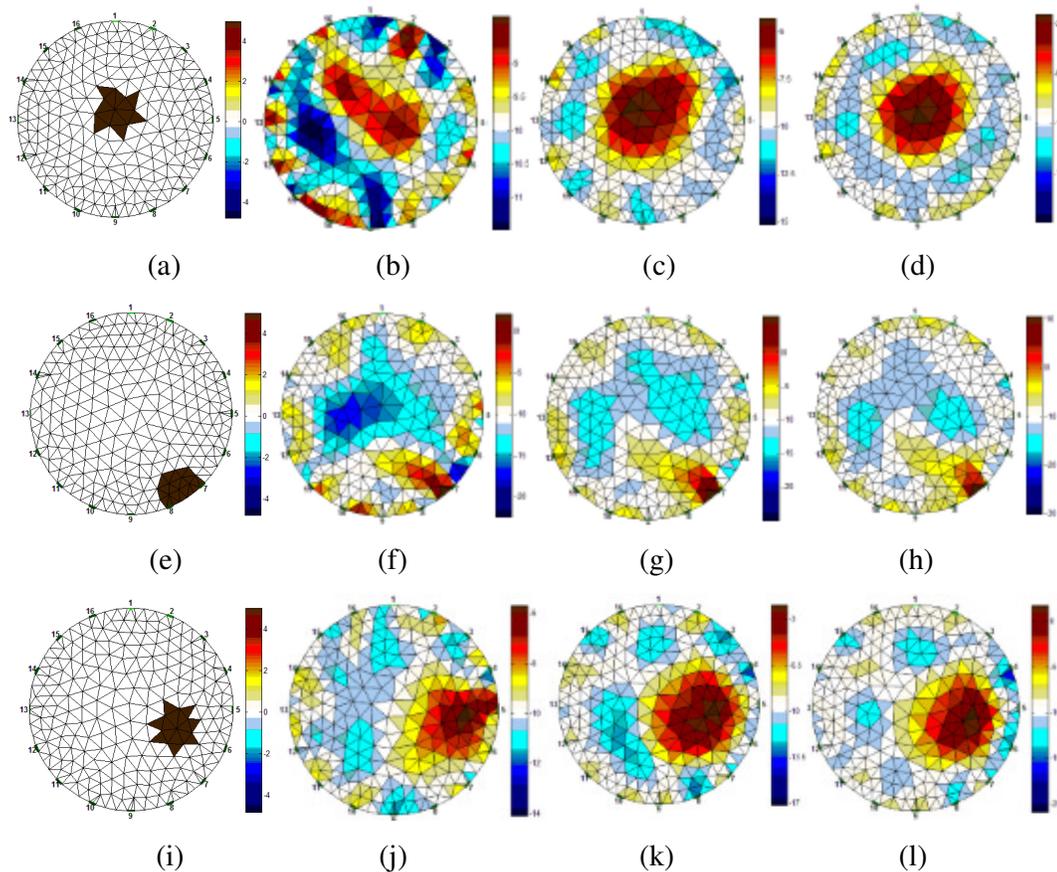
Onde, (a), (e) e (i) representam os objetos de estudo posicionados no centro, borda e entre o centro e a borda, respectivamente. (b), (c) e (d) representam a imagem do melhor candidato à solução para o centro em 100, 300 e 500 iterações, respectivamente; (f), (g) e (h) representam a imagem do melhor candidato à solução para a borda em 100, 300 e 500 iterações, respectivamente; e (j), (k) e (l) representam a imagem do melhor candidato à solução para o objeto de estudo localizado entre o centro e a borda em 100, 300 e 500 iterações, respectivamente.

**Figura 24: Imagens reconstruídas no centro, borda e entre o centro e a borda, respectivamente, para Evolução Diferencial 1.**



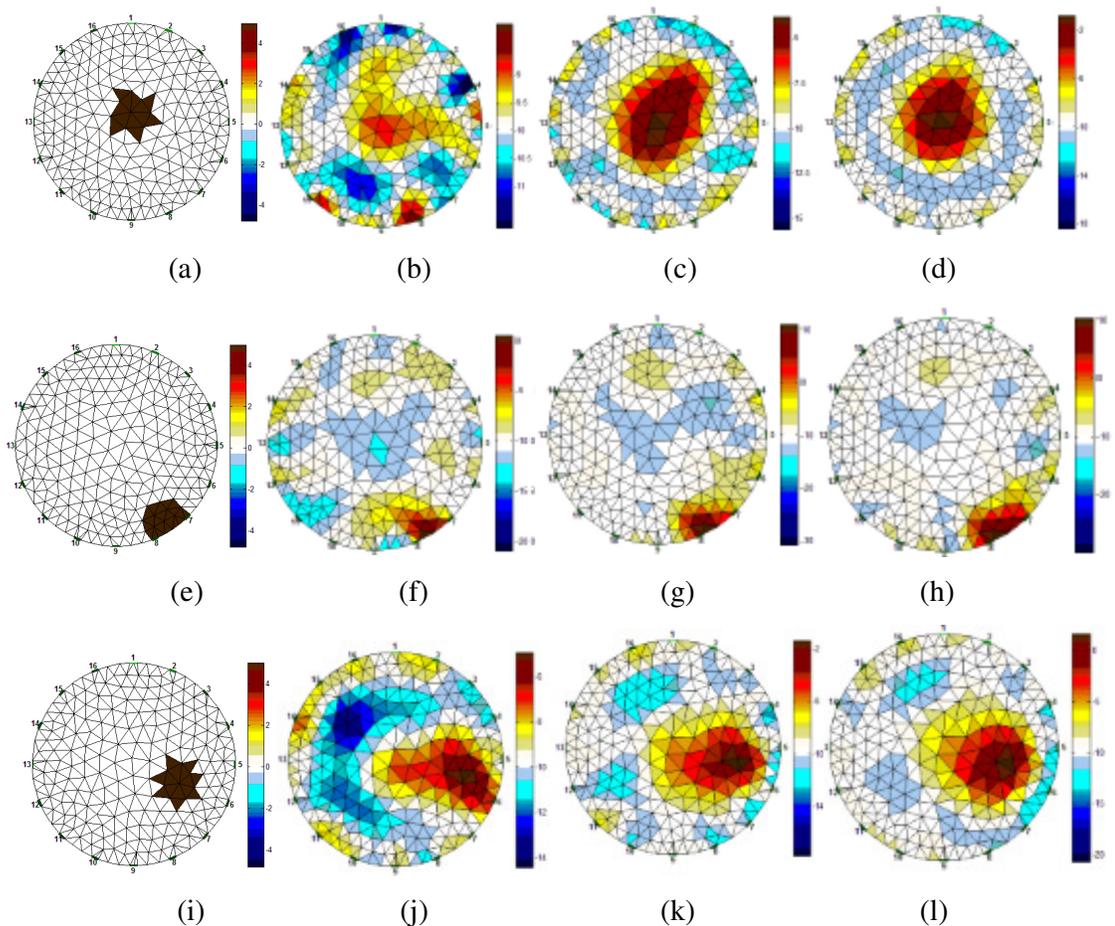
Onde, (a), (e) e (i) representam os objetos de estudo posicionados no centro, borda e entre o centro e a borda, respectivamente. (b), (c) e (d) representam a imagem do melhor candidato à solução para o centro em 100, 300 e 500 iterações, respectivamente; (f), (g) e (h) representam a imagem do melhor candidato à solução para a borda em 100, 300 e 500 iterações, respectivamente; e (j), (k) e (l) representam a imagem do melhor candidato à solução para o objeto de estudo localizado entre o centro e a borda em 100, 300 e 500 iterações, respectivamente.

**Figura 25: Imagens reconstruídas no centro, borda e entre o centro e a borda, respectivamente, para Evolução Diferencial 2.**



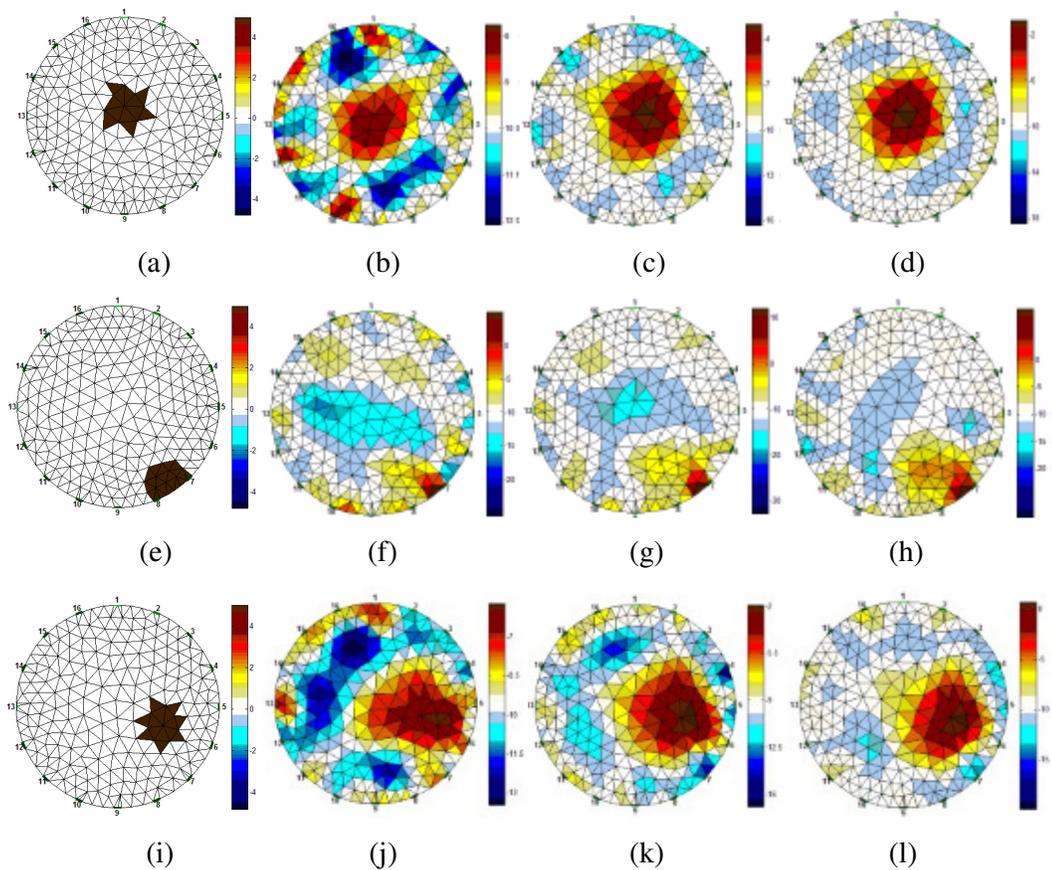
Onde, (a), (e) e (i) representam os objetos de estudo posicionados no centro, borda e entre o centro e a borda, respectivamente. (b), (c) e (d) representam a imagem do melhor candidato à solução para o centro em 100, 300 e 500 iterações, respectivamente; (f), (g) e (h) representam a imagem do melhor candidato à solução para a borda em 100, 300 e 500 iterações, respectivamente; e (j), (k) e (l) representam a imagem do melhor candidato à solução para o objeto de estudo localizado entre o centro e a borda em 100, 300 e 500 iterações, respectivamente.

**Figura 26: Imagens reconstruídas no centro, borda e entre o centro e a borda, respectivamente, para Evolução Diferencial 3.**



Onde, (a), (e) e (i) representam os objetos de estudo posicionados no centro, borda e entre o centro e a borda, respectivamente. (b), (c) e (d) representam a imagem do melhor candidato à solução para o centro em 100, 300 e 500 iterações, respectivamente; (f), (g) e (h) representam a imagem do melhor candidato à solução para a borda em 100, 300 e 500 iterações, respectivamente; e (j), (k) e (l) representam a imagem do melhor candidato à solução para o objeto de estudo localizado entre o centro e a borda em 100, 300 e 500 iterações, respectivamente.

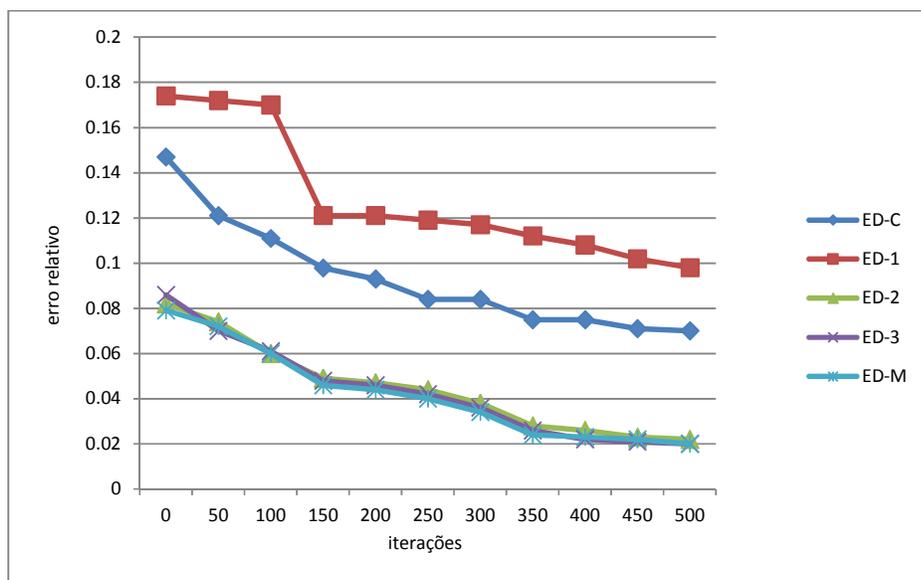
**Figura 27: Imagens reconstruídas no centro, borda e entre o centro e a borda, respectivamente, para Evolução Diferencial modificada.**



Onde, (a), (e) e (i) representam os objetos de estudo posicionados no centro, borda e entre o centro e a borda, respectivamente. (b), (c) e (d) representam a imagem do melhor candidato à solução para o centro em 100, 300 e 500 iterações, respectivamente; (f), (g) e (h) representam a imagem do melhor candidato à solução para a borda em 100, 300 e 500 iterações, respectivamente; e (j), (k) e (l) representam a imagem do melhor candidato à solução para o objeto de estudo localizado entre o centro e a borda em 100, 300 e 500 iterações, respectivamente.

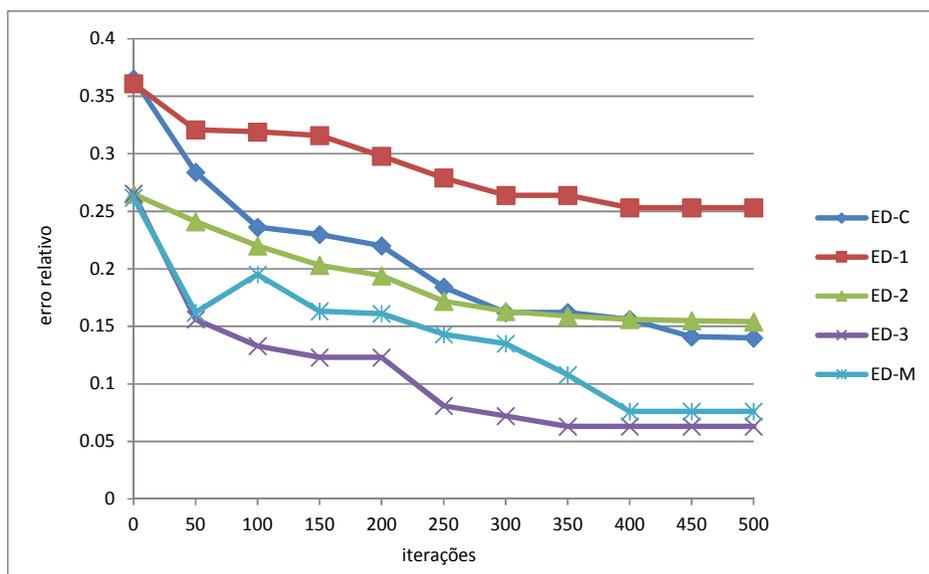
A seguir estão os resultados quantitativos para as versões de ED implementadas para o objeto localizado no centro, na borda e entre o centro e a borda, respectivamente. O gráfico abaixo representa o erro relativo do melhor agente presente no conjunto ao longo das iterações.

**Figura 28: Erro relativo ao longo das iterações para objeto localizado no centro para diferentes versões de Evolução Diferencial e AG.**



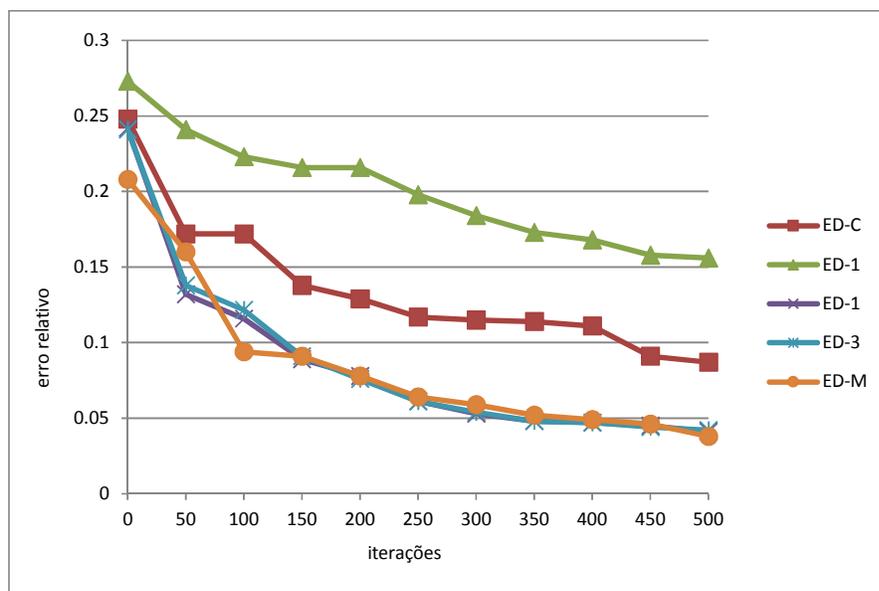
Onde estão representadas as quatro versões de ED e a versão modificada proposta em (RIBEIRO et. al., 2014) para a busca do objeto de estudo posicionado no centro do domínio.

**Figura 29: Erro relativo ao longo das iterações para objeto localizado na borda para as cinco versões de Evolução Diferencial implementadas.**



Onde, estão representados os erros relativos dos melhores agentes presentes no conjunto a cada 50 iterações do algoritmo para as cinco versões de ED implementadas para o problema de reconstrução de imagens de TIE.

**Figura 30: Erro relativo ao longo das iterações para objeto localizado entre o centro e a borda para diferentes versões de Evolução Diferencial.**



Onde, estão representados os resultados quantitativos para quatro versões de ED e para a versão modificada proposta em (RIBEIRO et. al., 2014) para busca de objeto de estudo localizado entre o centro e a borda do domínio.

### 5.5 Discussão dos resultados para ED.

Qualitativamente a Evolução Diferencial Clássica apresentou um desempenho inferior ao AG, a partir da observação da figura (23), imagem (d), é possível ver que para 300 iterações para objeto no centro a ED-C mostrou uma imagem borrada e sem o formato anatômico do isolante procurado, representado pela figura (23), imagem (a). Além disso, para a borda não foram encontrados resultados consistentes anatomicamente nem para 500 iterações, que foi o máximo de iterações de todos os experimentos.

Da mesma forma, para a primeira alteração da Evolução Diferencial (ED-1), mostrada na figura (24), qualitativamente, não foram encontrados resultados anatomicamente consistentes para nenhuma das duas configurações utilizadas. O fato de para a borda a imagem ter se configurado para 300 iterações (figura (24), imagem (g)) e ter sido desfeita para 500 iterações (figura (24), imagem (h)) explica-se pela área condutiva presente na imagem de 100 iterações (figura (24), imagem (f)). Esta inclusão condutiva faz com que o erro relativo seja maior do que o da imagem (figura (24), imagem (g)), devido ao fato da imagem (figura (24), imagem (h)) conter menos artefatos do que a imagem (figura (24), imagem (g)).

Já na 2ª alteração da Evolução Diferencial (ED-2) aplicada, para 300 iterações, de forma semelhante ao AG, foram mostrados resultados qualitativos coerentes com os isolantes procurados, tanto para o objeto localizado no centro quanto para o objeto na borda do domínio. Este fator é, possivelmente, pelo fato de, nesta versão do algoritmo (Equação 13), o agente base, ser o agente melhor avaliado. Ou seja, o agente atual é atualizado pelo melhor agente e por duas diferenças.

Na Evolução Diferencial 3 (ED-3) as imagens para 300 iterações (Figura 26, imagens (d), (h) e (l)) também são anatomicamente consistentes, ou seja, foi encontrado o isolante para os três objetos de estudo, porém as imagens nesta versão estão mais limpas nos arredores do objeto do que na ED-2, mostrada anteriormente. Isto mostra um potencial para limpar a imagem de artefatos.

Na figura (27) podem ser vistos as imagens geradas para a Evolução Diferencial Modificada, proposta por (RIBEIRO et. al., 2014). As imagens mostraram que esta versão da ED encontrou o isolante no centro do domínio em apenas 50 iterações, diminuindo consideravelmente o número de avaliações de função objetivo chamadas pelo algoritmo, mostrando um potencial para se diminuir o custo computacional da reconstrução das imagens de TIE. Porém para o objeto na borda e ED-2 (figura (25), imagem (h)) mostrou uma imagem melhor do que a ED-M (figura (26), imagem (h)).

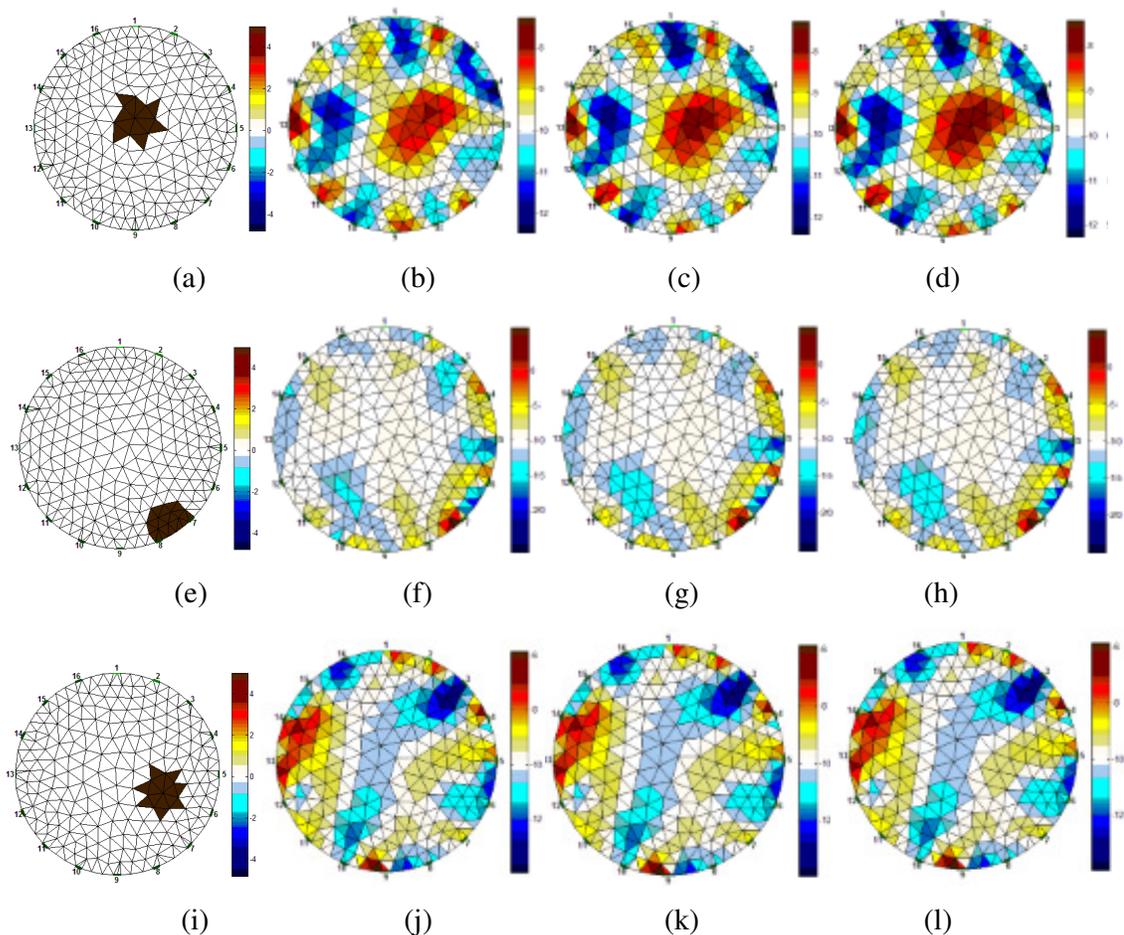
Os resultados quantitativos são mostrados pelas figuras (28), (29) e (30) e mostram a evolução do erro relativo ao longo das iterações, respectivamente. Com base nestes gráficos pode-se observar que as versões da ED que envolvem o melhor agente (agente com menor erro relativo), que são ED-2, ED-3 e ED-M, além de iniciar a trajetória do algoritmo com valores de erro menores, conseguem um valor de erro menor em menos iterações do que as outras abordagens de ED e AG, para centro, borda e entre o centro e borda. Mostrando-se como potenciais técnicas para se diminuir o custo computacional da reconstrução de imagens em TIE.

Nos experimentos realizados neste trabalho para as abordagens em ED, destacou-se a versão modificada DE-M proposta por (RIBEIRO et. al.,2014) que apesar de ter desempenho quantitativo parecido com ED-2 e ED-3, utilizando apenas a inversão dos fatores da primeira diferença na ED-3 (Equação 13), conseguiu encontrar o objeto de estudo em apenas 50 iterações para o objeto localizado centro do domínio.

### 5.6 Resultados de Otimização por Enxame de Partículas

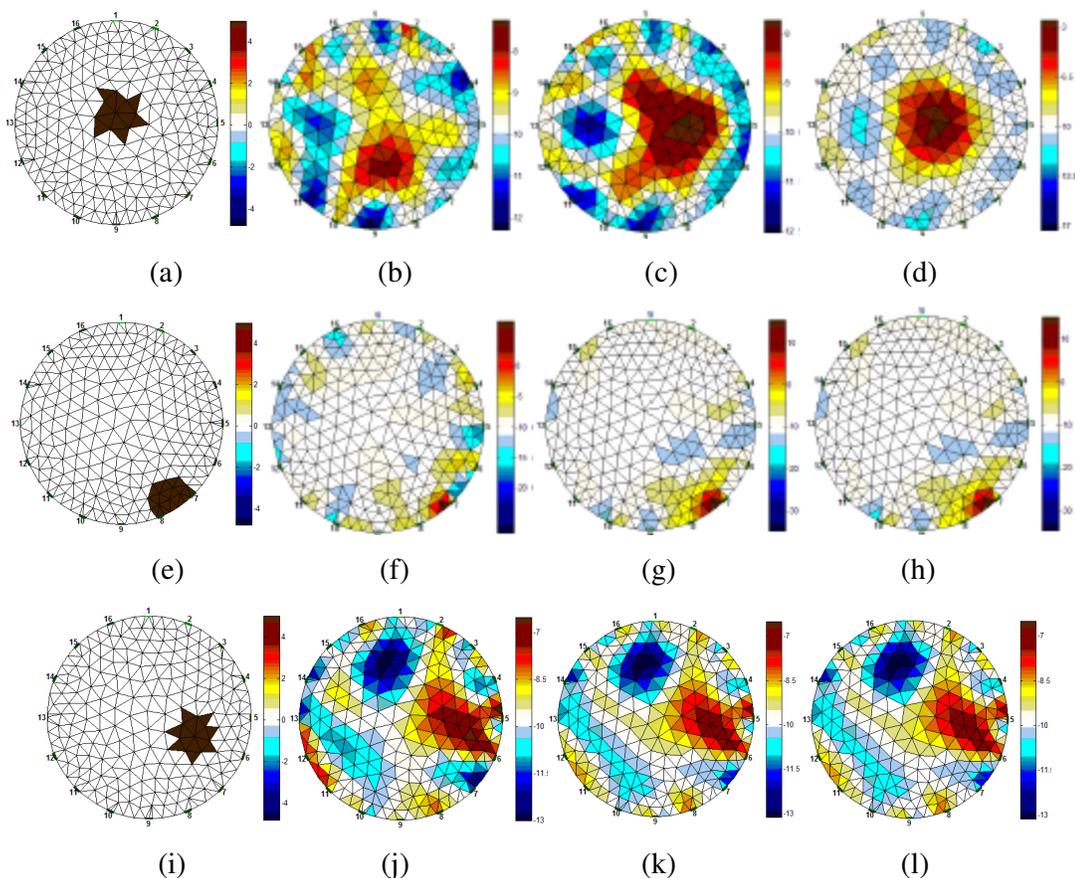
Abaixo estão representados e descritos os resultados para OEP canônico bem como para uma versão de OEP com topologia em anel e busca guiada proposta por (FEITOSA et. al., 2014).

**Figura 31: Imagens reconstruídas no centro, borda e entre o centro e a borda, respectivamente, para Otimização por enxame de partículas canônico.**



Onde, (a), (e) e (i) representam os objetos de estudo posicionados no centro, borda e entre o centro e a borda, respectivamente. (b), (c) e (d) representam a imagem do melhor candidato à solução para o centro em 100, 300 e 500 iterações, respectivamente; (f), (g) e (h) representam a imagem do melhor candidato à solução para a borda em 100, 300 e 500 iterações, respectivamente; e (j), (k) e (l) representam a imagem do melhor candidato à solução para o objeto de estudo localizado entre o centro e a borda em 100, 300 e 500 iterações, respectivamente.

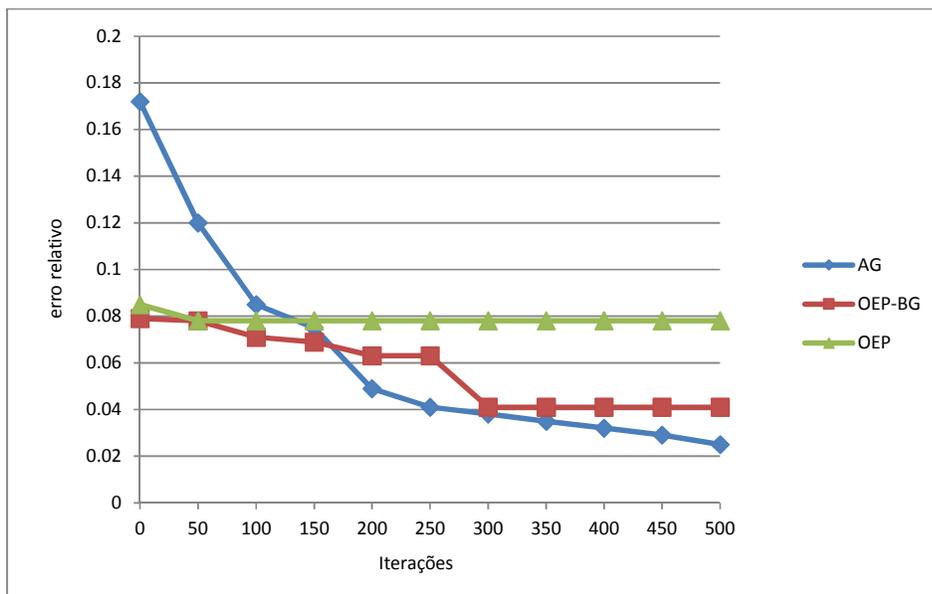
**Figura 32: Imagens reconstruídas no centro, borda e entre o centro e a borda, respectivamente, para Otimização por Enxame de Partículas em anel com busca guiada.**



Onde, (a), (e) e (i) representam os objetos de estudo posicionados no centro, borda e entre o centro e a borda, respectivamente. (b), (c) e (d) representam a imagem do melhor candidato à solução para o centro em 100, 300 e 500 iterações, respectivamente; (f), (g) e (h) representam a imagem do melhor candidato à solução para a borda em 100, 300 e 500 iterações, respectivamente; e (j), (k) e (l) representam a imagem do melhor candidato à solução para o objeto de estudo localizado entre o centro e a borda em 100, 300 e 500 iterações, respectivamente.

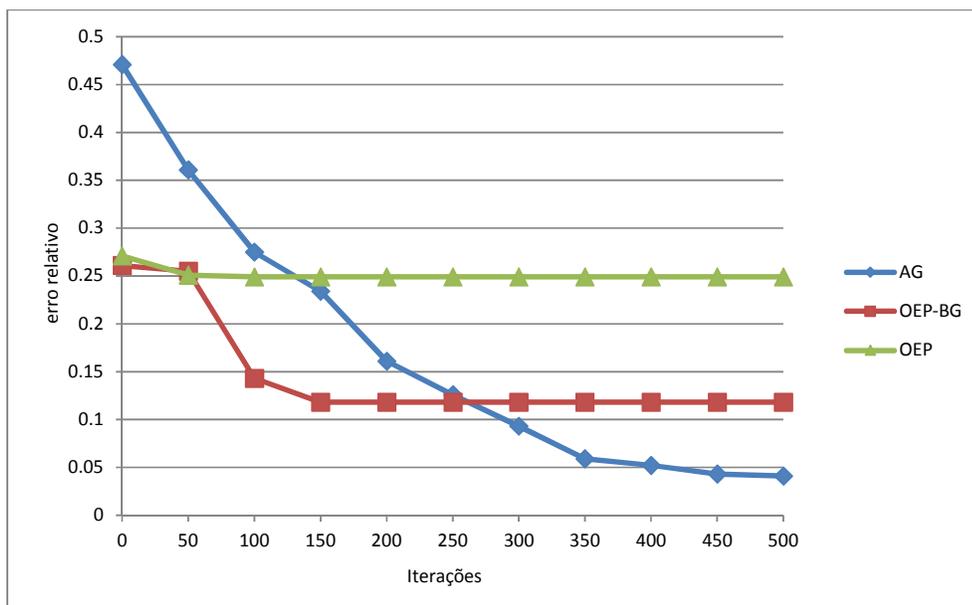
A seguir estão representados os resultados quantitativos, na forma da evolução do erro relativo da melhor partícula presente no enxame ao longo das iterações do algoritmo.

**Figura 33: Erro relativo ao longo das iterações para objeto localizado no centro para as duas versões de OEP e AG.**



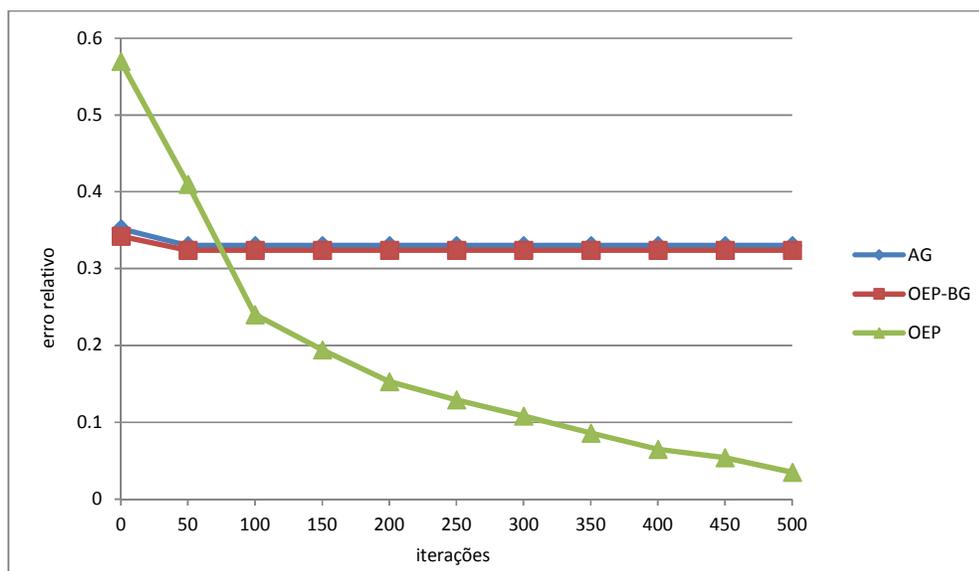
Onde estão representados em azul, Algoritmos Genéticos, em verde OEP e em vermelho OEP-BG.

**Figura 34: Erro relativo ao longo das iterações para objeto localizado na borda para as duas versões de OEP e AG.**



Onde estão representados em azul, Algoritmos Genéticos, em verde OEP canônico e em vermelho OEP em anel com busca guiada.

**Figura 35: Erro relativo ao longo das iterações para objeto localizado entre o centro e a borda para duas versões de OEP e AG.**



Onde estão representados em azul, Algoritmos Genéticos, em verde OEP canônico e em vermelho OEP em anel com busca guiada e fator caótico.

### 5.7 Discussão dos resultados para OEP

A OEP canônica conseguiu gerar resultados anatomicamente consistentes a partir de 300 iterações para o centro, porém as imagens geradas para o objeto na borda não foram anatomicamente consistentes, uma vez que conseguiram apenas localizar o objeto sem desenhá-lo. Estes resultados podem ser vistos na figura 17.

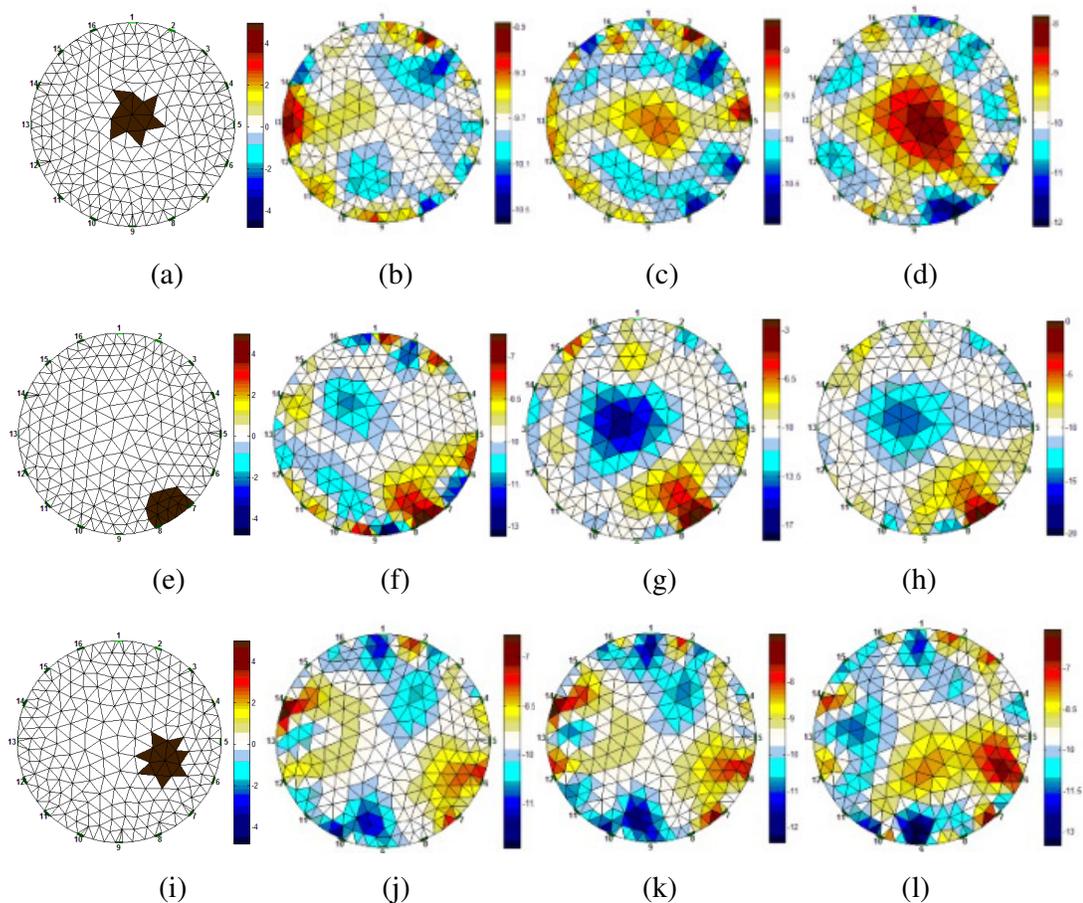
Qualitativamente, quando comparada com a OEP canônica, a OEP com busca guiada e fator caótico mostrou uma capacidade de gerar imagens mais limpas para 300 iterações na borda e para 500 iterações no centro, mostrando-se como uma potencial técnica contra artefatos de imagens.

Através do decaimento do erro ao longo do tempo mostrado nas figuras (33), (34) e (35) para centro e borda e entre o centro e a borda, respectivamente, a análise quantitativa a OEP com busca guiada fator caótico mostrou duas principais vantagens quando comparada com a OEP canônica.

A primeira é a capacidade de escapar de mínimos locais, fator que causa estagnação da queda do erro como aconteceu com a OEP comum, em verde nos gráficos citados. Este fator é devido à inclusão de uma partícula com uma distribuição gerada pelo algoritmo Gauss-Newton, a fim de guiar a convergência do enxame e garantir a exploração de outras áreas do espaço de busca. A segunda vantagem é a capacidade de se iniciar com valores de erro menores. Este fator é devido também a inclusão de uma partícula com um conhecimento a priori da solução procurada.

## 5.8 Resultados para o Método Dialético Objetivo

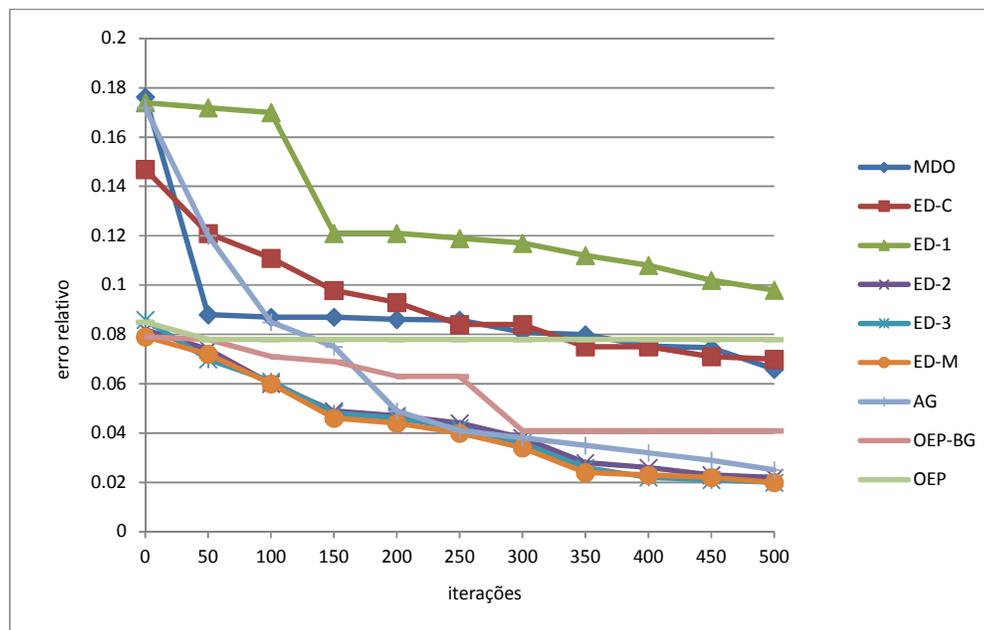
**Figura 36: Imagens reconstruídas no centro, borda e entre o centro e borda para o Método dialético de Otimização.**



Onde, (a), (e) e (i) representam os objetos de estudo posicionados no centro, borda e entre o centro e a borda, respectivamente. (b), (c) e (d) representam a imagem do melhor candidato à solução para o centro em 100, 300 e 500 iterações, respectivamente; (f), (g) e (h) representam a imagem do melhor candidato à solução para a borda em 100, 300 e 500 iterações, respectivamente; e (j), (k) e (l) representam a imagem do melhor candidato à solução para o objeto de estudo localizado entre o centro e a borda em 100, 300 e 500 iterações, respectivamente.

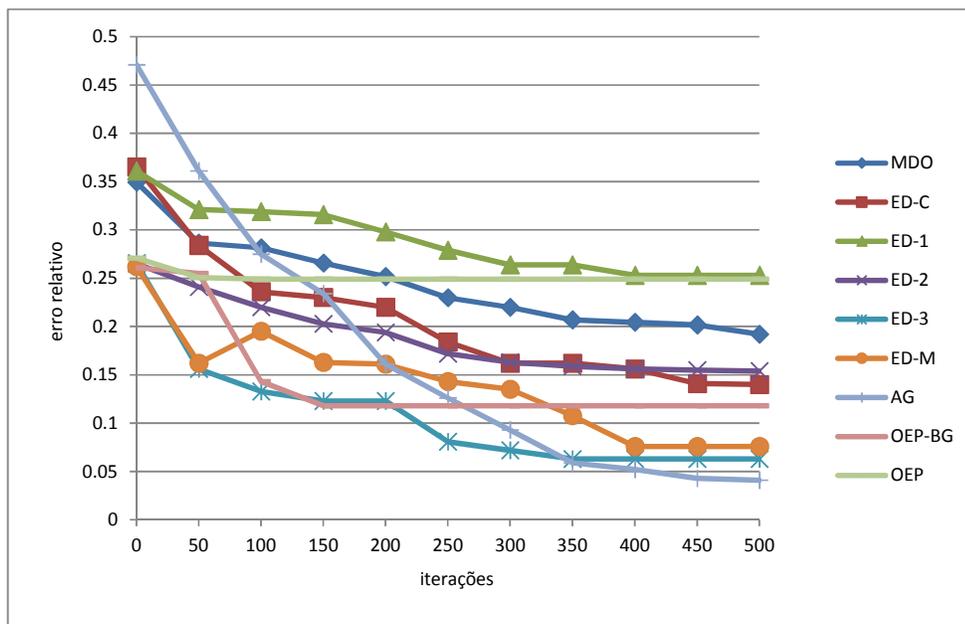
A seguir estão representados os resultados quantitativos, na forma de queda do erro relativo ao longo das iterações para o centro e borda e entre o centro e a borda, respectivamente.

**Figura 37: Erro relativo ao longo das iterações para objeto localizado no centro para o MDO e todas as outras técnicas.**



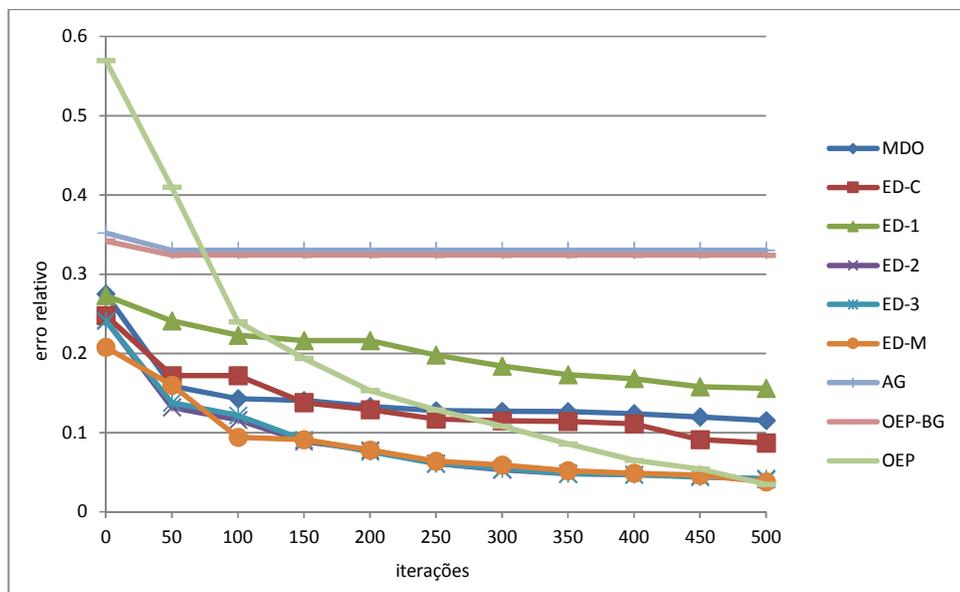
Onde estão representados, além de todas as versões de ED e de OEP, o AG e o MDO em azul para a busca do objeto localizado no centro do domínio

**Figura 38: Erro relativo ao longo das iterações para objeto localizado na borda para o MDO e todas as outras técnicas.**



Onde estão representados, além de todas as versões de ED e de OEP, o AG e a Método Dialético Objetivo em azul para a busca do objeto localizado na borda do domínio.

**Figura 39: Erro relativo ao longo das iterações para objeto localizado entre o centro e a borda para o MDO e todas as outras técnicas.**

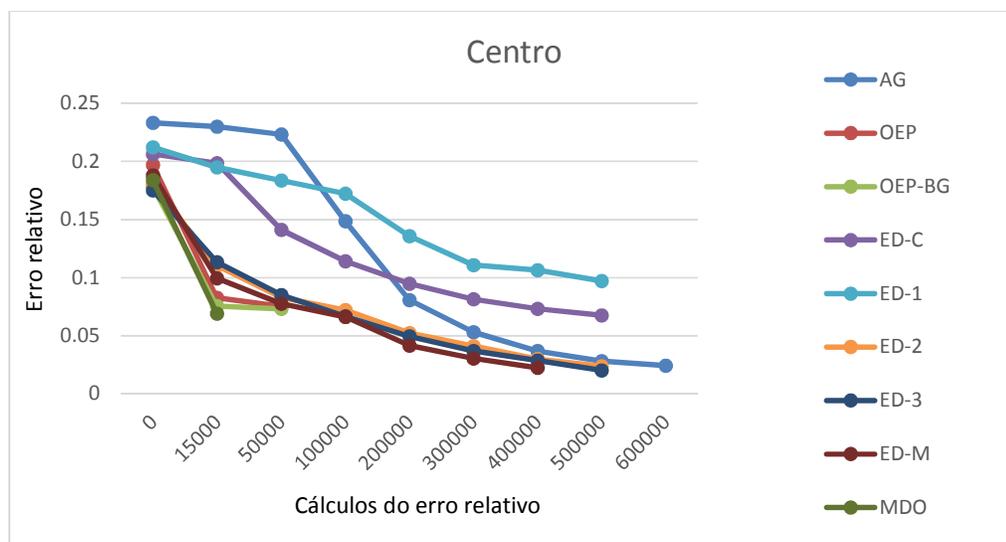


Onde estão representados, além de todas as versões de ED e de OEP, o AG e a Método Dialético Objetivo em azul para a busca do objeto localizado entre o centro e a borda do domínio.

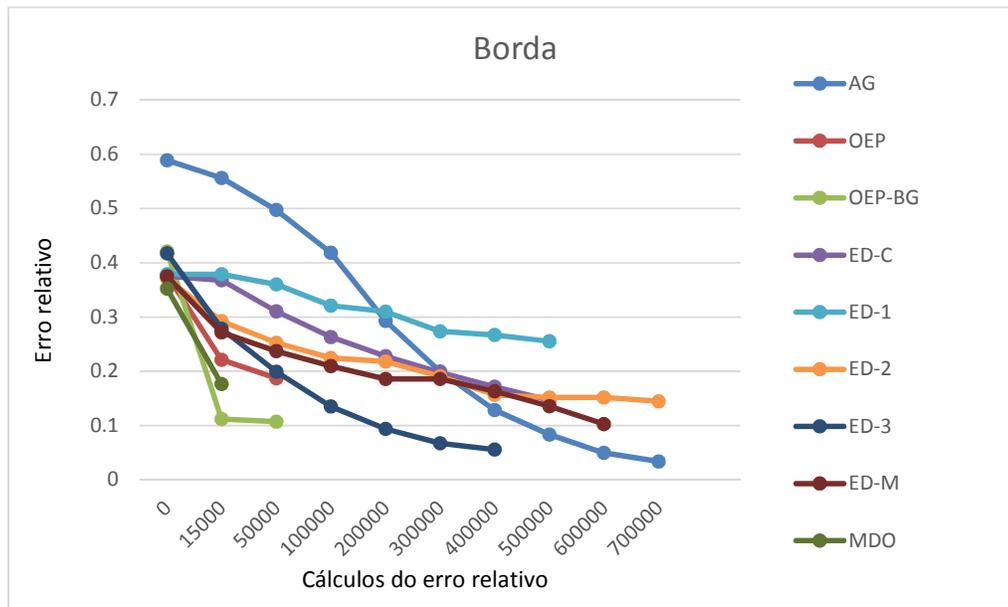
5.9 Resultados da análise de evolução do erro relativo ao longo da quantidade de cálculos da função objetivo.

Apesar de nas figuras (37), (38) e (39) o MDO ter mostrado uma evolução do erro relativo equivalente a algumas das outras técnicas ao longo das iterações, Suas iterações foram ficando mais rápidas ao longo do tempo devido à diminuição dos polos e, conseqüentemente, a diminuição da quantidade de cálculo de erro relativo necessária para cada iteração. A seguir estão os gráficos representando a queda do erro relativo ao longo da quantidade de cálculos da função objetivo para todas as técnicas aplicadas para o problema da TIE neste trabalho para os objetos de estudo localizados no centro, borda e entre o centro e a borda.

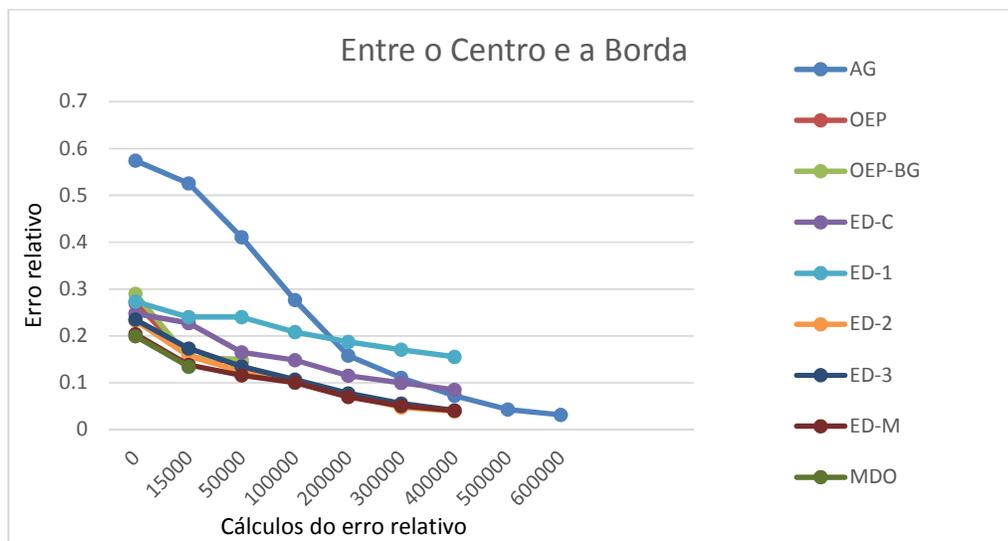
**Figura 40: Erro relativo ao longo da quantidade de cálculos da função objetivo para a busca de objeto localizado no centro do domínio**



**Figura 41: Erro relativo ao longo da quantidade de cálculos da função objetivo para a busca de objeto localizado na borda do domínio**



**Figura 42: Erro relativo ao longo da quantidade de cálculos da função objetivo para a busca de objeto localizado entre o centro e a borda do domínio**



Onde são mostradas as técnicas que têm a capacidade de encontrar um valor menor de erro relativo utilizando um número menor de cálculos da função objetivo. Estes cálculos são a etapa mais onerosa, computacionalmente falando, para todas as técnicas, sendo irrelevantes, em termos de custo computacional, as outras etapas das técnicas.

### 5.10 Discussão dos resultados para o Método Dialético Objetivo

Esta técnica mostrou uma capacidade de encontrar uma imagem mais limpa (com menos interferentes), do que as outras técnicas aqui aplicadas, em uma quantidade mínima de iterações e, principalmente em uma quantidade mínima de cálculos da função objetivo.

Uma vantagem observada foi que com o passar das fases históricas a quantidade de polos tende a diminuir. Este fator ocorre devido à ação do operador de fusão das baixas contradições, e também tem a capacidade de aumentar a velocidade de cada iteração através da diminuição da quantidade de cálculos de função objetivo.

Esta diminuição resulta na redução do esforço computacional a cada fase histórica e isto torna a técnica menos onerosa computacionalmente e mais rápida do que as outras técnicas.

Através da análise das figuras (40), (41) e (42) é possível se constatar que o MDO consegue encontrar um valor de erro mais baixo do que a maioria das técnicas em um número muito menor de cálculos da função objetivo. Isto o torna mais rápido porque, apesar de ter a mesma quantidade de iterações do que as outras técnicas, como mostrado nos gráficos contidos nas figuras (37), (38) e (39), o MDO tende a utilizar uma quantidade menor de cálculos da função objetivo ao longo de suas fases históricas e, conseqüentemente, sua convergência se torna mais rápida do que a das outras técnicas apresentadas.

Ainda para os cálculos da função objetivo, no caso da borda (Gráfico da Figura 41), a Otimização por Enxame de Partículas com Busca Guiada mostrou conseguir um erro menor do que o MDO em apenas 15.000 cálculos da função objetivo, porém, quando são confrontadas as imagens geradas por estes métodos (Figura 32, imagem (h) para OEP-BG e Figura 36, imagem (h) para MDO), a imagem da borda gerada pelo Método Dialético Objetivo tende a ser mais definida, de forma que suas áreas de baixa condutividade (em vermelho) são mais parecidas com as áreas de baixa condutividade do objeto procurado (Figura 36, imagem (e)).

A análise quantitativa, realizada de acordo com a queda do erro relativo ao longo das iterações, mostrou que como as técnicas implementadas sem a busca guiada, ou seja, sem a inclusão de um candidato à solução gerado pelo método Gauss-Newton, começa com um valor de erro maior do que as que contêm a busca guiada.

### 5.11 Discussão Geral

O AG se mostrou uma técnica capaz de encontrar valores de erro muito baixo, porém cada iteração desta técnica foi muito demorada, atrasando o processo de convergência além de formar uma queda de erro que a longo prazo tende a parar, caracterizando que o algoritmo encontrou um mínimo local.

A Otimização por Enxame de Partículas só se mostrou capaz de formar imagens de TIE quando foi implementada com a busca guiada, a inclusão de uma partícula gerada pelo método determinístico de Gauss-newton, foi capaz de guiar a convergência das outras partículas iniciais do enxame para um menor valor de erro e uma imagem anatomicamente consistente com o objeto procurado.

Nas versões da Evolução diferencial que não envolvem o conhecimento do melhor agente (best), não houve formação de boas imagens, nem de valores baixos de erro. Porém nas versões que o envolvem e na versão proposta pelos autores deste trabalho, houve um rápido decaimento de erro e a formação de uma imagem consistente em menos de 50 iterações do algoritmo.

O Método Dialético Objetivo se mostrou ser mais rápido e menos oneroso computacionalmente do que as outras técnicas propostas. Este fator se deu pela redução, ao longo das fases históricas, do número de polos, e, conseqüentemente, da redução na quantidade necessária de cálculos da função objetivo.

Qualitativamente, o MDO conseguiu localizar os objetos de busca, mas não conseguiu os definir anatomicamente, de acordo com as respectivas formas do objeto de estudo de cada um. Sua redução do erro relativo foi equivalente às técnicas que não envolvem nenhum tipo de conhecimento a priori e seu algoritmo não convergiu para um valor baixo de erro quando comparado com as outras técnicas. Porém esta técnica se mostrou como uma técnica promissora, devido ao fato de ter sua convergência mais rápida do que as outras.

## **CAPÍTULO 6: CONCLUSÃO E TRABALHOS FUTUROS**

### **6.1 Dificuldades apresentadas**

As principais dificuldades encontradas na realização desta pesquisa estão relacionadas com a seleção de parâmetros e o tempo de processamento.

A seleção dos parâmetros teve de ser feita de forma empírica devido ao fato de uma execução do algoritmo levar muito tempo, como no caso do AG que chegou a levar 3 dias para se realizar apenas uma execução. Inviabilizando o uso de técnicas de variação de parâmetros que necessitam de várias execuções do algoritmo para encontrar os melhores parâmetros.

Outra consequência relacionada ao tempo de uma execução do algoritmo computacional foi a não aplicação de um teste estatístico para se fazer comparações mais profundas entre as diversas abordagens, uma vez que, baseado nos trabalhos do estado da arte seriam necessárias no mínimo 30 execuções do algoritmo para cada técnica para se poder aplicar um teste estatístico.

### **6.2 Conclusões Gerais**

Os experimentos realizados neste trabalho mostraram que o Método Dialético de Otimização tem a capacidade de convergir mais rapidamente do que as outras técnicas. Esta aceleração ocorre devido a fatores já citados. Porém ainda é necessário se ajustar os parâmetros desta técnica a fim de encontrar uma imagem mais bem definida.

Acredita-se que a dificuldade de encontrar imagens definidas esteja relacionada ao ajuste de parâmetros desta técnica. Pois, quando se trata do MDO, a complexidade da tarefa de ajustar os parâmetros aumenta devido ao grande número de operadores envolvidos e a necessidade de encontrar a combinação certa entre eles para se haver um equilíbrio adequado entre exploração e exploração no espaço de busca.

## 6.3 Contribuições

Os resultados parciais da presente pesquisa geraram diversas contribuições publicadas em eventos nacionais e internacionais, estes artigos estão listados a seguir:

**Tabela 8: Contribuições geradas pelos resultados parciais desta pesquisa**

Nome do Artigo	Evento/Cidade de publicação	Ano de publicação
RECONSTRUCTION OF ELECTRICAL IMPEDANCE TOMOGRAPHY IMAGES USING GENETIC ALGORITHMS AND NON-BLIND SEARCH. (RIBEIRO et. al. 2014)	INTERNATIONAL SYMPOSIUM ON BIOMEDICAL IMAGING/ BEIJING - CHINA	2014
RECONSTRUCTION OF ELECTRICAL IMPEDANCE TOMOGRAPHY IMAGES USING PARTICLE SWARM OPTIMIZATION, GENETIC ALGORITHMS AND NON-BLIND SEARCH (FEITOSA et. al. 2014)	IEEE BIOSIGNALS AND BIOROBOTICS CONFERENCE / SALVADOR - BRASIL	2014
A MODIFIED DIFFERENTIAL EVOLUTION ALGORITHM FOR THE RECONSTRUCTION OF ELECTRICAL IMPEDANCE TOMOGRAPHY IMAGES (RIBEIRO et. al. 2014)	IEEE BIOSIGNALS AND BIOROBOTICS CONFERENCE / SALVADOR / BRASIL	2014
RECONSTRUCTION OF ELECTRICAL IMPEDANCE TOMOGRAPHY IMAGES USING CHAOTIC RING-TOPOLOGY PARTICLE SWARM OPTIMIZATION AND NON-BLIND SEARCH (FEITOSA et. al. 2014)	IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN, AND CYBERNETICS / SAN DIEGO - EUA	2014

RECONSTRUCTION OF ELECTRICAL IMPEDANCE TOMOGRAPHY IMAGES USING CHAOTIC SELF-ADAPTIVE RING-TOPOLOGY DIFFERENTIAL EVOLUTION AND GENETIC ALGORITHMS (RIBEIRO et. al. 2014)	IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN, AND CYBERNETICS / SAN DIEGO - EUA	2014
RECONSTRUÇÃO DE IMAGENS DE TIE UTILIZANDO PSO EM ANEL, BUSCA GUIADA E FATOR CAÓTICO (FEITOSA et. al. 2014)	XXIV CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA / UBERLÂNDIA - BRASIL	2014
RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA USANDO EVOLUÇÃO DIFERENCIAL MODIFICADA (RIBEIRO et. al. 2014)	XXIV CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA / UBERLÂNDIA - BRASIL	2014
UM ALGORITMO DE EVOLUÇÃO DIFERENCIAL MODIFICADO COM BUSCA NÃO-CEGA PARA TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA (RIBEIRO et. al. 2014)	XXIV CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA / UBERLÂNDIA - BRASIL	2014
APLICAÇÃO DE ALGORITMOS GENÉTICOS E EVOLUÇÃO DIFERENCIAL PARA RECONSTRUÇÃO DE IMAGENS DE TIE (FEITOSA et. al. 2014)	XXIV CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA / UBERLÂNDIA - BRASIL	2014

#### 6.4 Trabalhos Futuros

Como pesquisas futuras recomenda-se o uso de arquiteturas paralelas, de forma que, com esta tecnologia é possível se obter um número de iterações em um menor espaço de tempo. Isto possibilitaria, além do aumento de velocidade, fazer mais execuções do algoritmo e trabalhar algumas técnicas de análise estatística;

Recomenda-se também um estudo mais profundo da seleção de parâmetros para esta técnica, na forma de execuções do algoritmo variando os parâmetros e encontrar o menor valor de erro e capacidade de manter a diversidade dos polos;

Também se coloca a necessidade de estudar a quantidade inicial de polos do algoritmo e se ela interfere na convergência ou na velocidade da técnica;

Recomenda-se a aplicação da busca-guiada, empregada em algumas técnicas deste trabalho, na MDO, para guiar o processo de convergência do algoritmo;

Observou-se também a necessidade de se realizar um estudo para se desenvolver métricas de qualidade para experimentos envolvendo computação evolucionária e TIE;

A normalização das imagens em vetores contendo valores que representem suas distribuições pode ser válida para se fazer a comparação das imagens de forma quantitativa.

## REFERÊNCIAS

- ADLER, A.; BORSIC, A.; POLYDORIDES, N.; LIONHEART, W. R. B.; “Simple FEMs aren’t as good as we thought: experiences developing EIDORS v3. 3,” Report of The University of Manchester. 2008;
- BHATIA, R.; SCHMOLZER, G.M.; DAVIS, P.G.; TINGAY, D.G.; Electrical impedance tomography can rapidly detect small pneumothoraces in surfactant-depleted piglets; *Intensive Care Med* 38:308– 315. 2012;
- BRAAK C.J.F.T.; A Markov Chain Monte Carlo version of the genetic algorithm Differential Evolution: easy Bayesian computing for real parameter spaces. *Statistics and Computing* - vol. 16, no. 3.; 1(1): 239–249. 2006;
- DAI M; LI B; HU S; XU C; YANG B; et al.44; 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): e55020. doi:10.1371/journal.pone.0055020. 2013;
- DE JONG, K.A. An Analysis of the behavior of a class of genetic adaptative systems. PhD thesis, University of Michigan. 1975;
- EBERHART, R.; SHI, Y. *Computational Intelligence: concepts to implementations*, Morgan Kaufmann, United States. 2007;
- EIBEN, A. E.; SMITH J. E. *Introduction to Evolutionary Computing*. Ed1. Amsterdam, Bristol, Budapest: Springer. 2003;
- FEITOSA, A.R.S.; RIBEIRO, R.R.; BARBOSA, V.A.F.; SOUZA, R.E.; SANTOS, W.P. Reconstruction of electrical impedance tomography images using particle swarm optimization, genetic algorithms and non-blind search. *Biosignals and Biorobotics Conference*, Salvador – Brazil, San Diego, EUA. 2014;
- FEITOSA, A.R.S.; RIBEIRO, R.R.; BARBOSA, V.A.F.; SOUZA, R.E.; SANTOS, W. P. Reconstruction of electrical impedance tomography images using chaotic ring-topology particle swarm optimization and non-blind search; *IEEE International Conference on Systems, Man and Cybernetics*. 2014;
- FEITOSA, A.R.S.; RIBEIRO, R.R.; BARBOSA, V.A.F.; SOUZA, R.E.; SANTOS, W.P.; Reconstrução de imagens de TIE utilizando PSO em anel, busca guiada e fator caótico; *Congresso Brasileiro de Engenharia Biomédica*; Uberlândia, Brasil. 2014;
- FEITOSA, A.R.S.; RIBEIRO, R.R.; BARBOSA, V.A.F.; de Souza, R.E.; SANTOS, W.P.; Aplicação de Algoritmos Genéticos e Evolução Diferencial para reconstrução de imagens de TIE; *Congresso Brasileiro de Engenharia Biomédica*; Uberlândia, Brasil. 2014;
- FOGEL, L. J.; OWENS, A. J.; WALSH, M.J.; *Artificial intelligence though a simulation of evolution*. *Biophysicsand Cybernetic Systems*. Spartan, Washington DC, pp. 131-156. 1965;

FOGEL, L. J.; OWENS, A. J.; WALSH, M.J.; Artificial intelligence through simulated evolution, Wiley, Chichester, UK. 1966;

GARCIA, F.D.; SOUZA, M.N.; PINO, A.V.; 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. 2013;

HOLLAND, J.H.; Genetic algorithms and the optimal allocation of trials. SIAM J. of Computing, 2 pp.88-105. 1973;

HOLLAND, J.H.; Adaptation in natural and Artificial Systems. MIT Press. Cambridge, M. 1975;

KENNEDY, J.; Small Worlds and mega minds: Effects of neighborhood topology on particle swarm performance. Proceedings of the 6 Congress on Evolutionary Computation, Washington, DC. 1999;

KENNEDY, J.; EBERHART, R.; Particle Swarm Optimization. Purdue School of Engineering and Technology. Indianapolis. 1995;

MAISCH, S.; BOHM, S. H.; SOLA, J.; GOEPFE, R.T.; MATTHIAS, S.; KUBITZ, J. C.; RICHTER, H.P.; RIDDER, J.; GOE, T.Z.; ALWIN, E.; REUTER D.A.; Heart-lung interactions measured by electrical impedance tomography; Crit Care Med Vol. 39, No. 9. 2011;

MARTINS, T.C.; CAMARGO, E.D.L.B.; LIMA, R.G.; AMATO, M.B.P.; TSUZUKI, M.S.G.; Image Reconstruction Using Interval Simulated Annealing in Electrical Impedance Tomography; Ieee Transactions on Biomedical Engineering, vol. 59, no. 7. 2012;

MENIN, O.H.; ARTIOLI. ROLNIK, V.; Tomografia de Impedância Elétrica: uma nova técnica de imageamento em medicina, Revista Iluminart – ISSN : 1984-8625 – Número 5. 2010;

MITCHELL, M.; An Introduction to Genetic Algorithms; First MIT Press paperback edition; Cambridge, Massachusetts/London, England. 1998;

MUSRRAT, A.; MILLIE, P.; AJITH, A.; Unconventional initialization methods for differential evolution. Applied Mathematics and Computation, 219, 4474–4494. 2013;

PAK, D. D.; ROZHKOVA, N. I.; KIREEVA, M. N.; ERM OSHCHENKOVA, M. V.; NAZAROV, A. A.; FOMIN, D. K.; RUBTSOVA; Diagnosis of Breast Cancer Using Electrical Impedance Tomography; Biomedical Engineering, Vol. 46, No. 4, pp. 154-157; November. 2012;

RADKE, O. C.; SCHNEIDER, T.; HELLER, A. R.; KOCH, T.; Spontaneous Breathing during General Anesthesia prevents the Ventral Redistribution of Ventilation as detected by Electrical Impedance Tomography, Anesthesiology, V 116, No 6. 2012;

- RASTEIRO, M. G.; SILVA, R.; GARCIA, F. A. P.; FAIA, P. Electrical Tomography: a review of configurations and Applications to Particulate Processes. *KONA Powder and Particle Journal*, no. 29, pp. 67–80. 2011;
- RECHEMBERG, I.; *Evolutionarystrategie: Optimierung Technischer Systeme nach Prinzipien des Biologischen Evolution*. Fromman-Hozlboog Verlag, Stuttgart, Germany. 1973;
- RIBEIRO, R.R.; FEITOSA, A.R.S.; SOUZA, R.E.; SANTOS, W.P.; A modified differential evolution algorithm for the reconstruction of electrical impedance tomography images. *Biosignals and Biorobotics Conference*, Salvador – Brazil. 2014;
- RIBEIRO, R.R.; FEITOSA, A.R.S.; SOUZA, R.E.; SANTOS, W.P.; Reconstruction of electrical impedance tomography images using genetic algorithms and non-blind search. *IEEE 11th International Symposium on Biomedical Imaging (ISBI)*, Beijing, China. 2014;
- RIBEIRO, R.R.; FEITOSA, A.R.S.; SOUZA, R.E.; SANTOS, W.P.; Reconstruction of electrical impedance tomography images using chaotic self-adaptive ring-topology differential evolution and genetic algorithms; *IEEE International Conference on Systems, Man and Cybernetics*, San Diego, EUA. 2014;
- RIBEIRO, R.R.; FEITOSA, A.R.S.; SOUZA, R.E.; SANTOS, W.P.; Um algoritmo de Evolução Diferencial Modificado com busca não cega para Tomografia por Impedância Elétrica; *Congresso Brasileiro de Engenharia Biomédica*; Uberlândia, Brasil. 2014;
- RIBEIRO, R.R.; FEITOSA, A.R.S.; SOUZA, R.E.; SANTOS, W.P.; Reconstrução de imagens de Tomografia por Impedância Elétrica usando Evolução Diferencial Modificada; *Congresso Brasileiro de Engenharia Biomédica*; Uberlândia, Brasil. 2014;
- RIERA J.; RIU, P.J.; CASANC, P.; MASCLANSA, J.R.; Tomografía de impedancia eléctrica en la lesión pulmonar aguda; *Med Intensiva*. 35(8):509---517. 2011;
- SANTOS, W. P.; ASSIS, F. M.; *Algoritmos dialéticos para inteligência computacional*. Editora Universitária da UFPE. Recife – PE. 2013;
- SANTOS, W. P.; ASSIS, F. M.; Avaliação do Método Dialético na quantização de imagens multiespectrais. *Revista da Sociedade Brasileira de Redes Neurais. Learning and Nonlinear Models (L&NLM) – Journal of the Brazilian Neural Network Society*, Vol. 8, Iss. 4, pp. 174–201. 2010;
- SANTOS, W. P.; ASSIS, F. M. Optimization based on Dialectics. *Proceedings of International Joint Conference on Neural Networks*, Atlanta, Georgia, USA. 2009;
- SANTOS, W. P.; ASSIS, F. M.; SOUZA, R. E.; MENDES, P. B.; MONTEIRO, H. S. S.; ALVES, H. D.; *Dialectical Non-Supervised Image Classification.*, 9 IEEE Congress on Evolutionary Computation. Trondheim, Noruega. 2009;
- SCHWEFEL, H.P.; *Evolution and Optimum seeking*. Wiley, New York, 1995;

WANG, Q.; WANG, H.; ZHANG, R.; WANG, J.; ZHENG, Y.; CUI, Z.; YANG, C.; Image reconstruction based on L1 regularization and projection methods for electrical impedance tomography; Review of Scientific Instruments 83, 104707. 2012;

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 prostatecancer detection; Medical Physics 40, 063102. 2013;

ZAVALA, A. E. M.; AGUIRRE, A. H.; DIHARCE, E. R. V. Particle Evolutionary Swarm Optimization Algorithm (PESO). Proceedings of the Sixth Mexican International Conference on Computer Science. 26-30 September, Puebla, Mexico. 2005;

# Reconstruction of electrical impedance tomography images using particle swarm optimization, genetic algorithms and non-blind search

Allan R. S. Feitosa<sup>1</sup>, Reiga R. Ribeiro<sup>1</sup>, Valter A. F. Barbosa<sup>1</sup>,  
Ricardo E. de Souza<sup>1</sup>, and Wellington P. dos Santos<sup>1</sup>

<sup>1</sup>Departamento de Engenharia Biomédica, Universidade Federal de Pernambuco, Brazil

Email: wellington.santos@ufpe.br

**Abstract**—The fields of non-invasive imaging and e-health have been increasing in the last decades, due to the need of avoiding to exposure living tissues to ionizing radiation, increasing monitoring levels of critical patients, and promoting the increasing of quality life. Furthermore, the use of image-reconstruction devices based on ionizing radiation can result on several health problems for patients in case non-calibrated apparatus is employed. These needs have been strengthening the efforts to improve non-invasive methods like Electrical Impedance Tomography (EIT), a low-cost, non-invasive, portable, and safe of handling imaging technique. However, EIT image reconstruction is still an open problem, due to its nature as an ill-posed problem governed by the Equation of Poisson. Several numerical methods are used in order to solve this equation without generating anatomically inconsistent results. Evolutionary methods can be used as alternatives to Gauss-Newton and Backprojection well-known approaches, which frequently generate low-resolution blurred images. Herein this work we present an EIT reconstruction method based on the optimization of the relative error of reconstruction using particle swarm optimization with non-blind search. We studied two forms of initialization: totally random and including an imperfect but anatomically consistent solution based on Gauss-Newton reconstruction method, according to Saha and Bandyopadhyay’s criterion for non-blind initial search in optimization algorithms, in order to guide the iterative process to avoid anatomically inconsistent solutions. Our approach was compared with genetic algorithms. Results were quantitatively evaluated with ground-truth images using the relative mean squared error, showing that our results reached low error magnitudes. Qualitative evaluation also indicated that our results were morphologically consistent.

**Index Terms**—electrical impedance tomography, image reconstruction, reconstruction algorithms, particle swarm optimization, genetic algorithms.

## I. INTRODUCTION

The development and application of non-invasive imaging techniques in Medicine and Biology have being quantitative and qualitatively improved by efforts performed by academy and industry in the last decades, looking for more portable and safer technologies [1]. The continuous use of imaging devices based on ionizing radiation can provide several health problems for exposed patients, mainly if non-calibrated devices are used. The exposure of living tissues to ionizing radiation can result on some forms of cancer, which has become perhaps the most important public health issue, independently of social and economic differences among the nations of the globe

[1]–[3]. Electrical Impedance Tomography (EIT) consists of a non-invasive imaging technique that does not employ ionizing radiation, offering a relative vast set of opportunities because of its low cost, portability and, its most important aspect, safety of handling [4]. EIT is based on applying electrical currents to arrangements of electrodes placed on the surface of the volume under study [1], [4]–[6]. The resulting electrical potentials are measured and, afterwards, submitted to a reconstruction system that deals with these voltages as contour conditions of a boundary value problem, where the main interest is finding the distribution of electrical conductivities inside the volume under study [1], [6].

Once EIT image reconstruction is boundary value problem governed by the Equation of Poisson, it is an ill-posed problem, i.e. there is no unique conductivity distribution for a given set of electrical potentials on surface electrodes [1], [4]. Solution candidates are probable conductivity distributions. The error of reconstruction is defined as the error between the given and calculated distributions of electric potentials at the edge. Herein this work we present an EIT reconstruction method based on the optimization of the relative error of reconstruction using particle swarm optimization [7] and Saha and Bandyopadhyay’s criterion for non-blind initial search in optimization algorithms [8]. The initial set of solutions used by the particle swarm is varied according two approaches: (a) totally random set of individuals, and (b) inclusion of a noisy version of the solution obtained from the Gauss-Newton reconstruction algorithm. Our hypothesis is that this approach could aid to accelerate and guarantee particle swarm convergence to morphologically consistent solutions. We performed simulations where we evaluate the use of elitist genetic algorithms and particle swarm optimization, with and without non-blind search. These results are compared with ground-truth images using the relative squared error. Quantitative and qualitative analysis demonstrate that our results are anatomically consistent and relatively easy to generate, once differential evolution does not need a large set of initialization parameters.

This work is organized as following: in section II we present a brief on Electrical Impedance Tomography and related image reconstruction problems, definition of particle swarm optimization and genetic algorithms, the use of software EIDORS

for the reconstruction of electrical impedance tomography images based on finite element methods, and our propose particle swarm initialized by including a noisy version of the solution obtained by using Gauss-Newton classical method; in the same section we also present the methodology of the proposed experiments; in section III we present the results we obtained from the experiments described on previous section; finally, in section IV we make general and specific comments on results.

## II. MATERIALS AND METHODS

### A. Electrical Impedance Tomography

Electrical Impedance Tomography (EIT) is an imaging method mathematically governed by the Equation of Poisson, according to the following general vectorial expressions [1], [6]:

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

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

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

where  $\vec{u} = (x, y, z)$  is the position of a determined voxel,  $\phi(\vec{u})$  is the general distribution of electrical potentials,  $\phi_{\text{ext}}(\vec{u})$  is the distribution of electric potentials on surface electrodes,  $I(\vec{u})$  is the electrical current, periodical with frequency  $\omega_0$  due to avoid surface electrical effects,  $\sigma(\vec{u})$  is the distribution of electrical conductivities, i.e. the image of interest,  $\Omega$  is the volume of interest, also known as domain, and  $\partial\Omega$  is the border of the domain  $\Omega$ , i.e. the surface.  $\hat{n}(\vec{u})$  is the normal surface vector in position  $\vec{u} \in \partial\Omega$ .

The EIT direct problem consists of determining the electrical potentials of the surface electrodes  $\phi_{\text{ext}}(\vec{u})$  given currents  $I(\vec{u})$  and conductivity distribution  $\sigma(\vec{u})$ , according to the following mathematical relation:

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

whilst the problem of determining the conductivity distribution  $\sigma(\vec{u})$ , i.e. the tomographic image, given  $I(\vec{u})$  and  $\phi_{\text{ext}}(\vec{u})$ , is known as the EIT inverse problem, modeled by the following expression:

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

### B. Gauss-Newton algorithm

The Gauss-Newton algorithm is a based numerical method based on gradient-descent commonly used to solve non-linear least squared problems. It was designed to minimize a sum of squared function values based on a modification of Newton's method, implemented to eliminate the use of the second derivatives [9], [10].

Given a real function  $g : \mathbb{R}^n \rightarrow \mathbb{R}$  composed by a sum of  $m$  squared functions  $r_i : \mathbb{R}^n \rightarrow \mathbb{R}$ , where  $i = 1, 2, \dots, m$ , as shown:

$$g(\mathbf{x}) = \sum_{i=1}^m r_i^2(\mathbf{x}), \quad (6)$$

where  $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$ , the Gauss-Newton algorithm iteratively finds  $\mathbf{x} \in \mathbb{R}^n$  that minimizes  $g : \mathbb{R}^n \rightarrow \mathbb{R}$  by calculating the iterations

$$\mathbf{x}_{k+1} = \mathbf{x}_k - (\mathbf{J}_r^T \mathbf{J}_r)^{-1} \mathbf{J}_r^T \mathbf{r}(\mathbf{x}), \quad (7)$$

where  $\mathbf{r}(\mathbf{x}) = (r_1(\mathbf{x}), r_2(\mathbf{x}), \dots, r_n(\mathbf{x}))^T$ , and

$$\mathbf{J}_r = \left[ \frac{\partial r_i(\mathbf{x})}{\partial x_j} \right]_{m \times n} \quad (8)$$

is the Jacobian matrix of  $\mathbf{r}$  at  $\mathbf{x} \in \mathbb{R}^n$  [9]–[11].

In the context of Electrical Impedance Tomography, the Gauss-Newton algorithm is employed to find the distribution of electrical conductivities  $\sigma_k$  that minimizes

$$\mathbf{s}_k = \frac{1}{2} \sum_{\vec{u} \in \partial\Omega} (\phi_{\text{ext},k}(\vec{u}) - \phi_{\text{ext}}(\vec{u}))^2, \quad (9)$$

where

$$\phi_{\text{ext},k}(\vec{u}) = f(I(\vec{u}), \sigma_k(\vec{v})), \quad (10)$$

for  $\vec{u} \in \partial\Omega$  and  $\vec{v} \in \Omega$  [11], [12].

### C. EIT image reconstruction as an optimization problem

The problem domain  $\Omega$  is a discretized closed region. Therefore,  $\Omega$  and  $\partial\Omega$  have finite amounts of elements. Considering  $n_e$  as the amount of elements of the grid of  $\Omega$ , i.e.  $n_e = \#\Omega$ , and  $n_p$  as the number of elements at the edge, i.e.  $n_p = \#\partial\Omega$ , the error function can be rewritten as follows:

$$\mathbf{r}_k = \sum_{i=1}^{n_p} (U_i(\mathbf{x}_k) - V_i)^2, \quad (11)$$

where

$$\mathbf{V} = (V_1, V_2, \dots, V_{n_p})^T$$

is the measured distribution of electrical potentials at the border of the domain, and

$$\mathbf{U}(\mathbf{x}_k) = (U_1(\mathbf{x}_k), U_2(\mathbf{x}_k), \dots, U_{n_p}(\mathbf{x}_k))^T$$

is the calculated distribution of electrical potentials at the border, given the vectorized version

$$\mathbf{x}_k = (x_{1,k}, x_{2,k}, \dots, x_{n_e,k})^T$$

of the calculated distribution of electrical conductivities  $\sigma_k$  [11], [12]. Therefore

$$r_i(\mathbf{x}_k) = U_i(\mathbf{x}_k) - V_i,$$

where  $U_i(\mathbf{x}_k) = f(I(\vec{u}), \sigma_k)$  and  $\vec{u} \leftrightarrow i$  [11], [12].

In order to adequate evolutionary algorithms to solve the indirect problem of EIT, we defined the objective function as the relative squared error as following:

$$f_o(\mathbf{x}) = \epsilon(\mathbf{x}) = \left[ \frac{\sum_{i=1}^{n_p} (U_i(\mathbf{x}) - V_i)^2}{\sum_{i=1}^{n_p} V_i^2} \right]^{1/2}. \quad (12)$$

#### D. Genetic Algorithms

Genetic Algorithms (GA) consist basically of heuristic iterative processes for search and optimization composed by metaphors inspired by the Theory of Evolution and the principles of Genetics [13]. A typical GA can be defined as following [13]:

- 1) Generate the initial population;
- 2) Repeat until the maximum of iterations is reached:
  - a) Evaluate objective function (also known as fitness function) for each individual;
  - b) Natural selection: Individuals with best fitness are selected for the stage of crossover;
  - c) Crossover: Given a defined mask (coordinates of interest in vectors), descendant individuals are generated by combining genes of two ancestors;
  - d) Mutation: genes of descendants are randomly selected and modified. The strategy of selecting a determined quantity of the best ancestors to pass to the next generation is called elitism [13].

#### E. Particle Swarm Optimization

Particle Swarm Optimization (PSO) algorithms were created by James Kennedy and Russel Eberhart in 1995 [14]. These algorithms are based on movements and behavior of flocks of animals, like fishes and birds [14], [15]. Similarly to genetic algorithms, PSO algorithms are initialized with a population of random individuals. Associated to each individual (or particle) there is a pair of vectors used to represent position and velocity. There is neither mutation nor crossover. Just position and velocity vectors are adjusted using the best global and individual or local position, according to a determined objective function, as described by the following canonical expression [13], [16], [17]:

$$\mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \mathbf{v}_i(t+1), \quad (13)$$

where

$$\mathbf{v}_i(t+1) = w\mathbf{v}_i(t) + c_1r_1(\mathbf{p}_i - \mathbf{x}_i(t)) + c_2r_2(\mathbf{p}_g - \mathbf{x}_i(t)), \quad (14)$$

for  $1 \leq i \leq m$ , where  $m$  is the number of particles of the flock, i.e. the size of the population of solution candidates;  $w$  is the inertia factor,  $0 < w < 1$ ;  $r_1, r_2 \sim U[0, 1]$ ;  $c_1$  and  $c_2$  are constriction constants, also known as acceleration coefficients, where  $c_1 + c_2 \approx 4$ , where  $c_1$  is the weight of individual conscience, whilst  $c_2$  is the weight of global conscience;  $\mathbf{x}_i$  and  $\mathbf{v}_i$  are position and velocity vectors, respectively, for the  $i$ -th particle;  $\mathbf{p}_g$  is the best global position, i.e.

$$f_o(\mathbf{p}_g) = \min_{1 \leq j \leq m} f_o(\mathbf{x}_j), \quad (15)$$

whilst  $\mathbf{p}_i$  is the best individual or local position of the  $i$ -th particle. For the best individual position:

$$f_o(\mathbf{x}_i(t'')) = \min_{0 \leq t' \leq t} f_o(\mathbf{x}_i(t')) \Rightarrow \mathbf{p}_i = \mathbf{x}_i(t''). \quad (16)$$

However, in case of using the best local position, considering the neighborhood  $N_i$  of the  $i$ -th particle:

$$f_o(\mathbf{p}_i) = \min_{j \in N_i} f_o(\mathbf{x}_j), \quad (17)$$

where  $f_o : S \rightarrow \mathbb{R}$  is the objective function to be minimized, since  $S \subseteq \mathbb{R}^n$ ,  $n$  is the dimensionality of the optimization problem.  $\mathbf{p}_i$  can also be the best individual position of the  $i$ -th particle, as following:

$$f(\mathbf{p}_i(t)) = \max_{0 \leq t' \leq t} f(\mathbf{x}_i(t')). \quad (18)$$

#### F. Image reconstruction using EIDORS

EIDORS is a project whose goal is to provide free software algorithms implemented in MATLAB/Octave for forward and inverse modeling for Electrical Impedance Tomography (EIT) and Diffusion based Optical Tomography, in medical and industrial settings, and to share data and promote collaboration between groups working these fields [18]. Several algorithms were implemented in EIDORS, like Backprojection and Gauss-Newton algorithms [9], [10], [18]. Backprojection is the same algorithm used to reconstruct x-ray computerized tomography images, considering that electrical current use a direct way to move from an application electrode to the grounded one, whilst Gauss-Newton is an iterative linear reconstruction method based on gradient descent [9], [10].

#### G. Non-blind search

Saha and Bandyopadhyay affirm that, in order to avoid totally random searches and accelerate optimization algorithms convergence, we should set the initial population of candidate solutions using non-precise solutions obtained from simpler and imprecise direct methods [8]. Our hypothesis is that the use of particle swarm optimization to solve the EIT inverse problem can get reasonable solutions using a non-prohibitive number of iterations when the first population set involves one solution candidate built using noisy versions of the solution obtained by using the Gauss-Newton method.

#### H. Proposed methods and experiments

In order to evaluate our proposal, we designed experiments for 16 electrodes, 415-element circular 2D mesh grids with density level 'b' and refining level '2' (EIDORS parameters). The studied problems consist of detecting irregular isolating objects positioned in three configurations: (a) in the center of the domain, (b) between center and border, and (c) near the border of the domain. We used the relative error between the distributions of measured and calculated electrical potentials at the edge as the objective function for all evolutionary optimization methods we used herein this work. Solution candidates are real vectors used as theoretical abstractions for possible conductivity distributions, where each dimension corresponds to a determined finite element of the grid. We worked with population sizes of 100 individuals, i.e. solution candidates. We ran experiments for 50, 100, 150, 200, 250, 300, 350, 400, 450, and 500 generations.

For the use of genetic algorithms, we worked with population sizes of 100 individuals. The algorithm was performed using elitism: for each iteration, 10 individuals with the best performance are selected to compose the next generation. Individuals, i.e. solution candidates, are theoretical abstractions for possible conductivity distributions. Each gen on

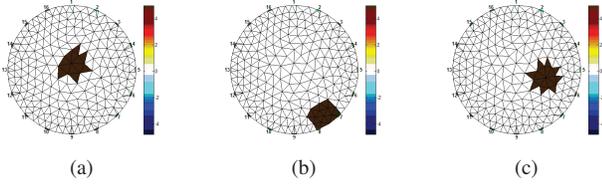


Figure 1. Original simulated conductivity distributions for electrical isolating objects placed in the center (a), near the border (b), and between the center and the border (c) of the circular domain.

chromosomes corresponds to a determined finite element of the grid. Crossover was performed changing 100 random conductivity elements for each pair of chromosomes, the best individuals provided by the previous generation, resulting 90 descendant individuals plus 10 antecessors. All descendants suffered mutation, by the addition of a maximum noise of 5%.

For particle swarm optimization, we used 100-individuals sized populations. Additionally, for particle swarm optimization with non-blind search, the initial population was composed by 99 random solutions and a noisy version of the solution obtained with the classical Gauss-Newton method as implement in EIDORS, adding 5%-magnitude destructive noise. We also used  $w = 0.85$ ,  $c_1 = 2.0992$  and  $c_2 = 1.9008$  for all PSO experiments. These values were empirically determined.

Performance was measured by the evaluation of the relative squared error between measured electric potentials on electrodes and calculated electric potentials. These electric potentials were evaluated solving the EIT direct problem.

### III. RESULTS

Figure 1 shows the ground-truth simulated conductivity distributions for electrical isolating objects placed in the center (a), near the border (b), and between the center and the border (c) of the circular domain. Figures 2, 3, and 4 show the reconstruction results obtained by using genetic algorithms (GA), particle-swarm optimization with totally random initialization (PSO)), and our new proposal, PSO with non-blind search, where one of the solution candidates consists of an imprecise solution but anatomically consistent solution generated with Gauss-Newton reconstruction method (PSO-NSB), respectively, for objects placed in the center (a), near the border (b), and between the center and the border (c) of the circular domain, for 50 (1), 100 (2), 150 (3), 200 (4), 300 (5), 400 (6), and 500 (7) iterations.

Figures 5, 6 and 7 present the evolution of relative error with the number of iterations for the isolating object placed in the center, near the border, and between center and border of the domain.

### IV. DISCUSSION AND CONCLUSION

The behavior of the reconstruction algorithms can be observed by the analysis of visual results shown by images 2, 3, and 4. GA-based reconstruction demonstrated an interesting behavior because, although the results obtained for the first 50 iterations are still neither conclusive nor anatomically

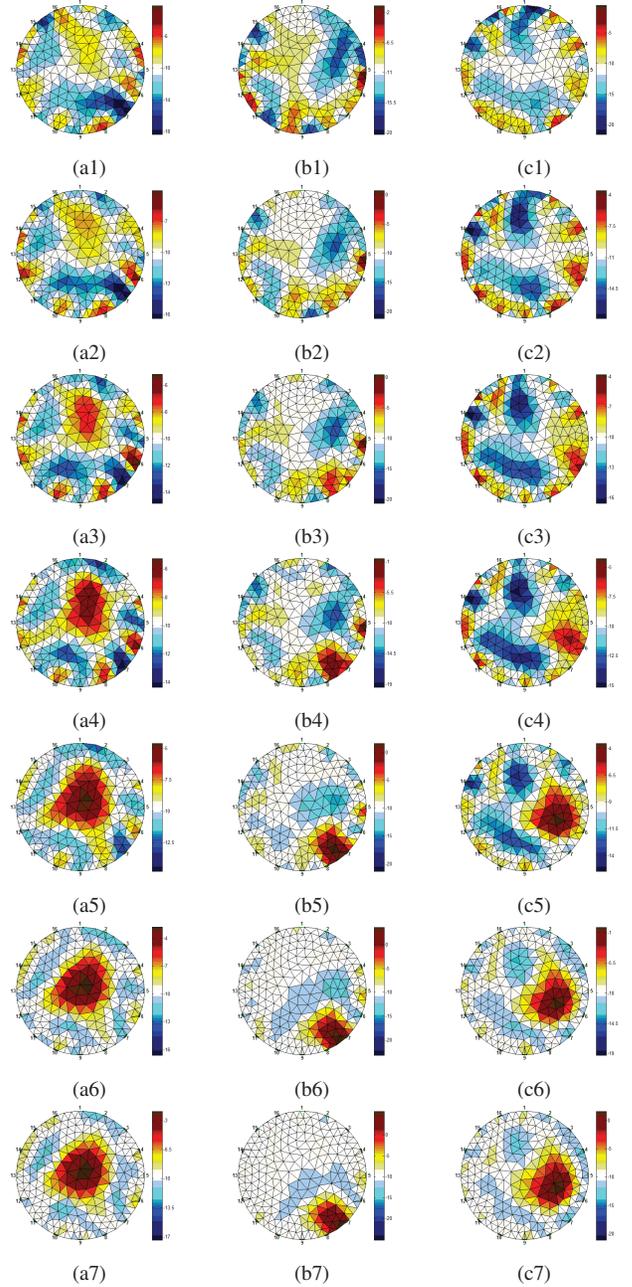


Figure 2. Reconstruction results for objects placed in the center (a), near the border (b), and between the center and the border (c) of the circular domain, for 50 (1), 100 (2), 150 (3), 200 (4), 300 (5), 400 (6), and 500 (7) iterations, using method GA

consistent, results for 300 iterations are already anatomically correct, considering the low resolution of EIT images (see Figure 2). PSO with totally random initialization returned morphologically consistent results from the very beginning, as can be seen on Figure 3, but was not able to converge to lower errors, as can be demonstrated by graphs of Figures 5, 6 and 7. However, PSO-NSB got reasonable results from 200 iterations, both quantitative and qualitatively, as demonstrated by Figures 5, 6 and 7, and 4. It is evident that the introduction of an

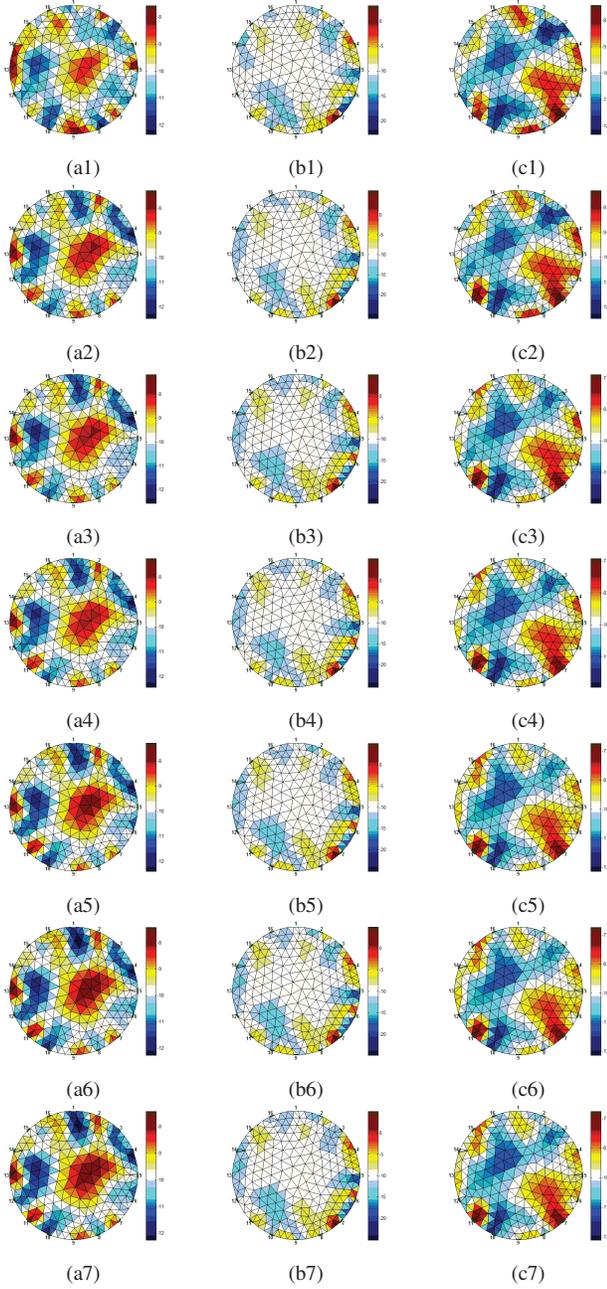


Figure 3. Reconstruction results for objects placed in the center (a), near the border (b), and between the center and the border (c) of the circular domain, for 50 (1), 100 (2), 150 (3), 200 (4), 300 (5), 400 (6), and 500 (7) iterations, using PSO with totally random initialization

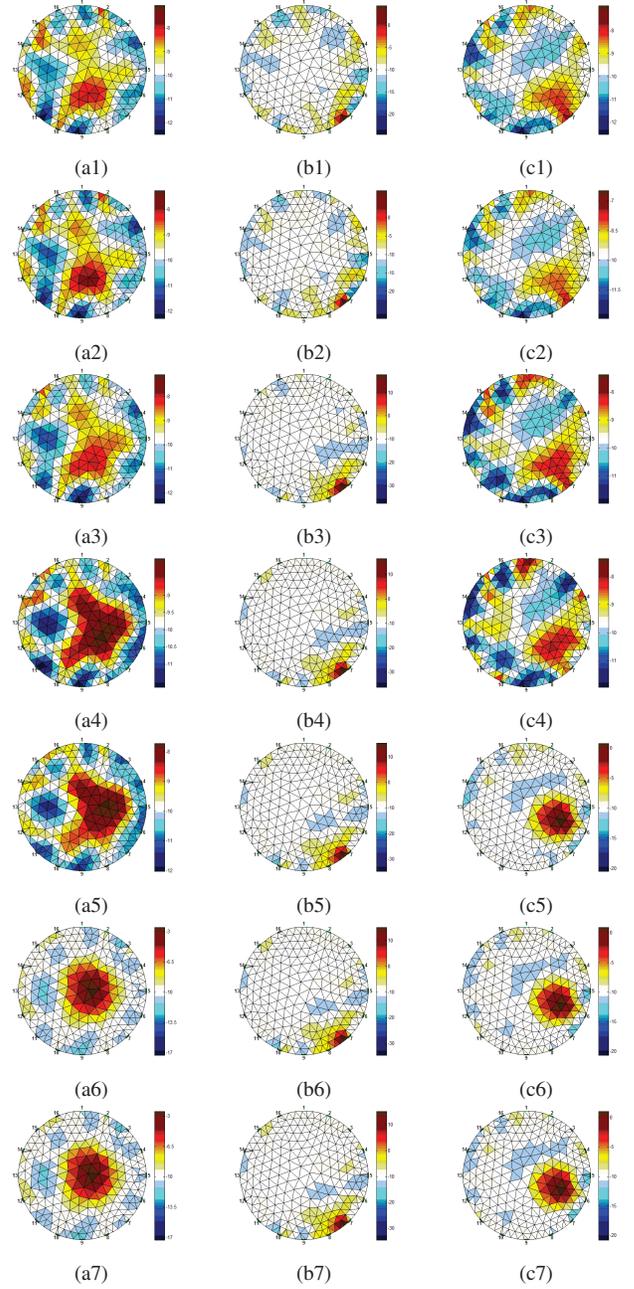


Figure 4. Reconstruction results for objects placed in the center (a), near the border (b), and between the center and the border (c) of the circular domain, for 50 (1), 100 (2), 150 (3), 200 (4), 300 (5), 400 (6), and 500 (7) iterations, using PSO with non-blind search (PSO-NBS)

imprecise but anatomically correct solution in the initialization set could aid PSO to scape from local minima, accelerating convergence even faster than genetic algorithms, but reaching an error limit near 350 iterations.

We can conclude that the use of PSO algorithms initialized with solution candidates obtained by using non-blind search based on Saha and Bandyopadhyay's criterion [8] can aid to get reasonable results at a non-prohibitive number of generations, avoiding an exaggerated number of objective function

evaluations, i.e. the amount of evaluations of the electric potentials on electrodes (EIT direct problem). This issue can be improved by the investigation of parallel architectures [5], parallelism strategies, and other evolutionary algorithms for numerical optimization to solve EIT inverse problem.

#### ACKNOWLEDGMENTS

The authors are grateful to the Brazilian scientific agencies CAPES and FACEPE, for the partial financial support of this work.

## REFERENCES

- [1] V. P. Rolnik and P. Selegim Jr, "A specialized genetic algorithm for the electrical impedance tomography of two-phase flows," *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, vol. 28, no. 4, pp. 378–389, 2006.
- [2] M. T. Groot, R. Baltussen, C. A. Uyl-de Groot, B. O. Anderson, and G. N. Hortobágyi, "Costs and health effects of breast cancer interventions in epidemiologically different regions of Africa, North America, and Asia," *The Breast Journal*, vol. 12, no. 1, pp. S81–S90, 2006.
- [3] S. Sharma, A. Oberoi, and Y. Chauhan, "A novel algorithm based on Adaptive Thresholding for Classification and Detection of Suspicious Lesions in Mammograms," in *IJCA Proceedings on National Workshop-Cum-Conference on Recent Trends in Mathematics and Computing 2011*, May 2012, vol. RTMC, pp. –, Published by Foundation of Computer Science, New York, USA.
- [4] M. G. Rasteiro, R. Silva, F. A. P. Garcia, and P. Faia, "Electrical Tomography: a review of Configurations and Applications to Particulate Processes," *KONA Powder and Particle Journal*, , no. 29, pp. 67–80, 2011.
- [5] G. L. C. Carosio, V. Rolnik, and P. Selegim Jr., "Improving efficiency in electrical impedance tomography problem by hybrid parallel genetic algorithm and a priori information," in *Proceedings of the XXX Congresso Nacional de Matemática Aplicada e Computacional*, Florianopolis (Brazil), 2007.
- [6] F. C. Peters, L. P. S. Barra, and A. C. C. Lemonge, "Application of a hybrid optimization method for identification of steel reinforcement in concrete by electrical impedance tomography," in *2nd International Conference on Engineering Optimization*, 2010.
- [7] "A Reconstruction Method for Electrical Impedance Tomography Using Particle Swarm Optimization," .
- [8] S. Saha and S. Bandyopadhyay, "Application of a New Symmetry-Based Cluster Validity Index for Satellite Image Segmentation," *IEEE Geoscience and Remote Sensing Letters*, vol. 5, no. 2, pp. 166–170, 2008.
- [9] A. Adler, A. Borsic, N. Polydorides, and W. R. B. Lionheart, "Simple FEMs aren't as good as we thought: experiences developing EIDORS v3.3," *Report of The University of Manchester*, 2008.
- [10] A. Adler and W. R. B. Lionheart, "Uses and abuses of EIDORS: An extensible software base for EIT," *Physiological measurement*, vol. 27, no. 5, pp. S25, 2006.
- [11] T. K. Bera, S. K. Biswas, K. Rajan, and 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*, vol. 2, no. 1, pp. 2–12, 2011.
- [12] C. R. Lima, L. A. M. Mello, R. G. Lima, and E. C. N. Silva, "Electrical impedance tomography through constrained sequential linear programming: a topology optimization approach," *Measurement Science and Technology*, vol. 18, no. 9, pp. 2847, 2007.
- [13] R. Eberhart and Y. Shi, *Computational Intelligence: concepts to implementations*, Morgan Kaufmann, 2007.
- [14] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *IEEE International Conference on Neural Networks*, Perth, Australia, 1995, CIS-IEEE, pp. 1942–1948.
- [15] R. Eberhart and J. Kennedy, "A new optimizer using particle swarm theory," in *IEEE Symposium on Micro Machine and Human Science*, Nagoya, Japan, 1995, CIS-IEEE, pp. 39–43.
- [16] J. Chuanwena and E. Bompardb, "A hybrid method of chaotic particle swarm optimization and linear interior for reactive power optimisation," *Mathematics and Computers in Simulation*, , no. 68, pp. 57–65, 2005.
- [17] D. W. van der Merwe and A. P. Engelbrecht, "Data clustering using particle swarm optimization," in *IEEE Congress on Evolutionary Computation*, Canberra, Australia, 2003, CIS-IEEE, pp. 185–191.
- [18] M. Vauhkonen, W. R. B. Lionheart, L. M. Heikkinen, P. J. Vauhkonen, and J. P. Kaipio, "A MATLAB package for the EIDORS project to reconstruct two-dimensional EIT images," *Physiological Measurement*, vol. 22, no. 1, pp. 107, 2001.

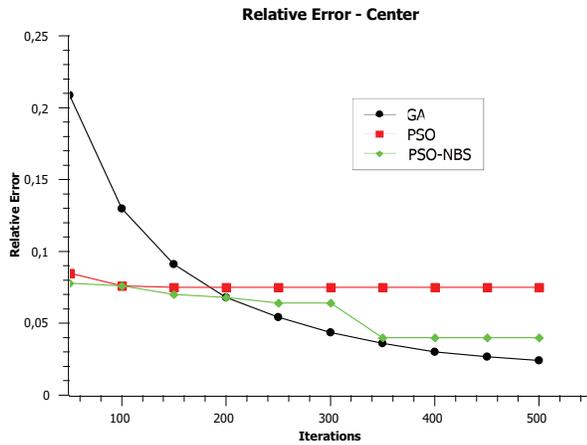


Figure 5. Error decreasing according to the number of iterations, considering 16 electrodes and an isolating object placed in the center of the domain

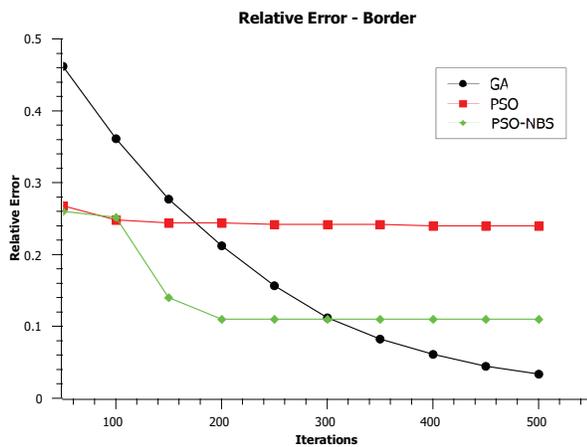


Figure 6. Error decreasing according to the number of iterations, considering 16 electrodes and an isolating object placed near the border of the domain

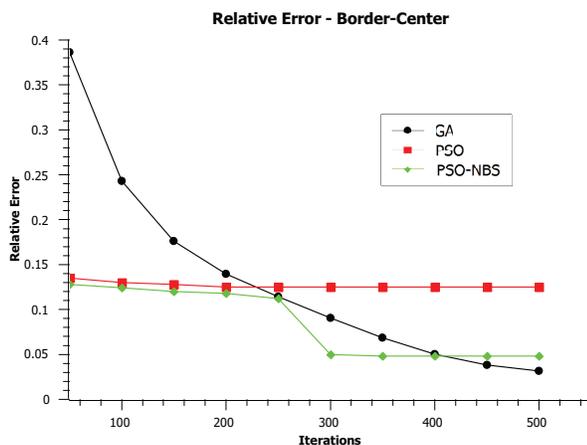


Figure 7. Error decreasing according to the number of iterations, considering 16 electrodes and an isolating object placed between the center and the border of the domain