

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

REIGA RAMALHO RIBEIRO

**RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR
IMPEDÂNCIA ELÉTRICA USANDO EVOLUÇÃO
DIFERENCIAL**

Recife - PE

2016

REIGA RAMALHO RIBEIRO

**RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR
IMPEDÂNCIA ELÉTRICA USANDO EVOLUÇÃO
DIFERENCIAL**

Dissertação de mestrado 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: Prof. Ricardo Emmanuel de Souza, DSc.

COORIENTADOR: Prof. Wellington Pinheiro dos Santos, DSc.

Recife

2016

Catálogo na fonte
Bibliotecária Maria Luiza de Moura Ferreira, CRB-4 / 1469

- R484r Ribeiro, Reiga Ramalho.
Reconstrução de imagens de tomografia por impedância elétrica usando evolução diferencial / Reiga Ramalho Ribeiro. - Recife: O Autor, 2016.
99 folhas, il.
- Orientador: Prof. Ricardo Emmanuel de Souza, DSc.
Coorientador: Prof. Wellington Pinheiro dos Santos, DSc.
Dissertação (Mestrado) – Universidade Federal de Pernambuco.
CTG. Programa de Pós-graduação em Engenharia Biomédica, 2016.
Inclui Referências.
1. Engenharia Biomédica. 2. Tomografia por impedância elétrica. 3. Evolução diferencial. 4. Algoritmos genéticos. 5. Otimização por enxame de partículas. 6. Recozimento simulado. 7. Hibridização. I. Souza, Ricardo Emmanuel de (Orientador). II. Santos, Wellington Pinheiro dos (Coorientador). III. Título.


610.28 CDD (22. ed.)

UFPE/BCTG/2016-170

ATA DA VIGÉSIMA DEFESA DE DISSERTAÇÃO DE MESTRADO, DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA DO CENTRO DE TECNOLOGIA E GEOCIÊNCIAS DA UNIVERSIDADE FEDERAL DE PERNAMBUCO, NO DIA 23 DE FEVEREIRO DE 2016.

Aos 23 (vinte e três) dias do mês de fevereiro de dois mil e dezesseis (2016), às 14 horas e 30 minutos, na sala 2, do Programa de Engenharia Biomédica, área 2, da Universidade Federal de Pernambuco, em sessão pública, teve início a defesa da Dissertação de Mestrado intitulada "RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA USANDO EVOLUÇÃO DIFERENCIAL", do(a) aluno(A) **REIGA RAMALHO RIBEIRO**, na área de concentração de Computação Biomédica, sob a orientação do Prof. Dr. Ricardo Emmanuel de Souza e coorientação do prof. Dr. Wellington Pinheiro dos Santos. O(A) mestrando(a) Reiga Ramalho Ribeiro cumpriu todos os demais requisitos regimentais para a obtenção do grau de Mestre em Engenharia Biomédica. A Banca Examinadora foi aprovada pelo colegiado do programa de pós-graduação Em Engenharia Biomédica, na sua 01ª Reunião ordinária, ocorrida em 19 de janeiro de 2016 e homologada pela Diretoria de Pós-Graduação, através do Processo Nº. 23076.003342/2016-79 em 25/01/2016, composta pelos Professores: Prof. Dr. Ricardo Emmanuel de Souza, do Departamento de Engenharia Biomédica da Universidade Federal de Pernambuco – UFPE, na qualidade de presidente, Prof. Dr. Wellington Pinheiro dos Santos, do Departamento de Engenharia Biomédica da Universidade Federal de Pernambuco – UFPE, o Prof. Dr. Ricardo Yara, do Departamento de Engenharia Biomédica da Universidade Federal de Pernambuco – UFPE, a Profª. Drª. Rita de Cássia Fernandes de Lima, do do Departamento de Engenharia Mecânica da Universidade Federal de Pernambuco – UFPE. Após cumpridas as formalidades, o (a) candidato (a) foi convidado (a) a discorrer sobre o conteúdo da Dissertação. Concluída a explanação, o/a candidato/a foi arguido pela Banca Examinadora que, em seguida, reuniu-se para deliberar e conceder ao mesmo a menção (Aprovado/Reprovado/em exigência) Aprovado da referida Dissertação. E, para constar, lavrei a presente Ata que vai por mim assinada, Secretário (a) de Pós-Graduação, e pelos membros da Banca Examinadora.

Recife, 23 de fevereiro de 2016.


Juliana Alves de Farias – Secretária PPGEB

BANCA EXAMINADORA

Prof. Ricardo Emmanuel de Souza
Prof. Wellington Pinheiro dos Santos
Prof. Ricardo Yara
Profª. Rita de Cássia Fernandes de Lima

AGRADECIMENTOS

A Deus, primeiramente, por ter colocado pessoas maravilhosas na minha vida, que me ajudaram durante todo o tempo deste curso possibilitando o término com êxito;

Ao meu coorientador Dr. Wellington Pinheiro dos Santos e meu orientador Dr. Ricardo Emmanuel de Souza, pela sua confiança, paciência e enorme assistência e disponibilidade em cada momento deste curso;

À minha família, em especial aos meus pais, pelo apoio e por sempre me incentivar na jornada pelo conhecimento;

Ao meu irmão e grande amigo Weiga Ivan Ribeiro o qual sem ele eu não estaria hoje onde me encontro, meu muito obrigado irmão;

À minha amiga e namorada Priscila Mendonça pelo seu carinho, paciência e consolações nos momentos difíceis;

Ao colega de pesquisa e amigo Allan Rivalles, pelos bons momentos de estudo e pesquisa;

Aos colegas e amigos Valter Augusto e Victor Luiz pelo apoio e cumplicidade;

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior 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 e não-destrutiva. Com base na aplicação de corrente elétrica e na medição dos potenciais de borda do corpo, feita através de eletrodos, um algoritmo de reconstrução de imagens de TIE gera o mapa de condutividade elétrica do interior deste corpo. Diversos métodos são aplicados para gerar imagens de TIE, porém ainda são geradas imagens de contorno suave. Isto acontece devido à 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 iterativa 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 o erro médio quadrático relativo (função objetivo) entre os potenciais de borda mensurados no corpo (imagem ouro) e os potenciais gerados pela resolução do problema direto de um candidato à solução. Assim, o objetivo deste trabalho foi construir uma ferramenta computacional baseada em algoritmos de busca e otimização híbridos, com destaque para a Evolução Diferencial, a fim de reconstruir imagens de TIE. Para efeitos de comparação também foram utilizados para gerar imagens de TIE: Algoritmos Genéticos, Otimização por Enxame de Partículas e Recozimento Simulado. As simulações foram feitas no EIDORS, uma ferramenta usada em MatLab/ GNU Octave com código aberto voltada para a comunidade de TIE. Os experimentos foram feitos utilizando três diferentes configurações de imagens ouro (fantomas). As análises foram feitas de duas formas, sendo elas, qualitativa: na forma de o quão as imagens geradas pela técnica de otimização são parecidas com seu respectivo fantoma; quantitativa: tempo computacional, através da evolução do erro relativo calculado pela função objetivo do melhor candidato à solução ao longo do tempo de reconstrução das imagens de TIE; e 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, cinco versões clássicas de Evolução Diferencial, versão modificada de Evolução Diferencial, Otimização por Enxame de Partículas, Recozimento Simulado e três novas técnicas híbridas baseadas em Evolução Diferencial propostas neste trabalho. De acordo com os resultados obtidos, vemos que todas as técnicas híbridas foram eficientes para resolução do problema da TIE, obtendo bons resultados qualitativos e quantitativos desde 50 iterações destes algoritmos. Porém, merece destacar o rendimento do algoritmo obtido pela hibridização da Evolução Diferencial e Recozimento Simulado por ser a técnica aqui proposta mais promissora na reconstrução de imagens de TIE, onde mostrou ser mais rápida e menos custosa computacionalmente do que as outras técnicas propostas. Os resultados desta pesquisa geraram diversas contribuições na forma de artigos publicados em eventos nacionais e internacionais.

Palavras-chaves: Tomografia por impedância elétrica. Evolução diferencial. Algoritmos genéticos. Otimização por enxame de partículas. Recozimento simulado. Hibridização.

ABSTRACT

Electrical Impedance Tomography (EIT) is a technique that aim to reconstruct images of the interior of a body in a non-invasive and non-destructive form. Based on the application of the electrical current and on the measurement of the body's edge electrical potential, made through of electrodes, an EIT image reconstruction algorithm generates the conductivity distribution map of this body's interior. Several methods are applied to generate EIT images; however, they are still generated smooth contour images. This is due of the mathematical nature of EIT reconstruction problem as an ill-posed and ill-conditioned problem. Thus, there is not an exact internal conductivity distribution for one determinate edge potential distribution. The EIT is ruled mathematically by Poisson's equations, and the image generation involves an iterative resolution of a direct problem, that treats the obtainment of the edge potentials through of an internal distribution of conductivity. The direct problem, in this dissertation, was applied through of Finite Elements Method. Thereby, is possible to apply search and optimization techniques that aim to minimize the mean square error relative (objective function) between the edge potentials measured in the body (gold image) and the potential generated by the resolution of the direct problem of a solution candidate. Thus, the goal of this work was to construct a computational tool based in hybrid search and optimization algorithms, highlighting the Differential Evolution, in order to reconstruct EIT images. For comparison, it was also used to generate EIT images: Genetic Algorithm, Particle Optimization Swarm and Simulated Annealing. The simulations were made in EIDORS, a tool used in MatLab/GNU Octave open source toward the TIE community. The experiments were performed using three different configurations of gold images (phantoms). The analyzes were done in two ways, as follows, qualitative: in the form of how the images generated by the optimization technique are similar to their respective phantom; quantitative: computational time, by the evolution of the relative error calculated for the objective function of the best candidate to the solution over time the EIT images reconstruction; and computational cost, by evaluating the evolution of the relative error over the amount of calculations of the objective functions by the algorithm. Results were generated for Genetic Algorithms, five classical versions of Differential Evolution, modified version of the Differential Evolution, Particle Optimization Swarm, Simulated Annealing and three new hybrid techniques based in Differential Evolution proposed in this work. According to the results obtained, we see that all hybrid techniques were efficient in solving the EIT problem, getting good qualitative and quantitative results from 50 iterations of these algorithms. Nevertheless, it deserves highlight the algorithm performance obtained by hybridization of Differential Evolution and Simulated Annealing to be the most promising technique here proposed to reconstruct EIT images, which proved to be faster and less expensive computationally than other proposed techniques. The results of this research generate several contributions in the form of published paper in national and international events.

Keywords: Electrical impedance tomography. Differential evolution. Genetic algorithms. Particle swarm optimization. Simulated annealing. Hybridization.

SUMÁRIO

1	INTRODUÇÃO	15
1.1	MOTIVAÇÃO	15
1.2	JUSTIFICATIVA	17
1.3	OBJETIVO GERAL	18
1.4	OBJETIVOS ESPECÍFICOS.....	18
1.5	ORGANIZAÇÃO DO TRABALHO	18
2	TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA (TIE)	19
2.1	PRINCÍPIOS FUNDAMENTAIS DA TIE.....	19
2.2	VANTAGENS E DESVANTAGENS DA TIE	20
2.3	RECONSTRUÇÃO DE IMAGENS EM TIE	21
2.4	O PROBLEMA DIRETO.....	22
2.5	O PROBLEMA INVERSO	23
2.6	FUNÇÃO OBJETIVO	24
2.7	APLICAÇÕES DA TIE	25
3	OTIMIZAÇÃO POR COMPUTAÇÃO EVOLUCIONÁRIA	26
3.1	TEORIA DE DARWIN E NEO-DARWINISMO	26
3.2	ALGORITMOS EVOLUTIVOS	27
3.3	ALGORITMOS GENÉTICOS	28
3.4	OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS	29
3.5	EVOLUÇÃO DIFERENCIAL	31
3.5.1	Conceitos Básicos da Evolução Diferencial.....	31
3.5.2	Etapas da Evolução Diferencial.....	32
3.5.3	Pseudocódigo da Evolução Diferencial.....	34
3.5.4	Estratégias da Evolução Diferencial.....	35
4	DEMAIS TÉCNICAS DE BUSCA E OTIMIZAÇÃO.....	37
4.1	BUSCA NÃO-CEGA	37
4.2	TOPOLOGIA EM ANEL	38
4.3	MUTAÇÃO CAÓTICA.....	39
4.4	RECOZIMENTO SIMULADO.....	40
5	RECONSTRUÇÃO DE IMAGENS DE TIE UTILIZANDO EVOLUÇÃO DIFERENCIAL	43
5.1	OTIMIZAÇÃO EM TIE	43
5.2	INFRAESTRUTURA.....	43
5.3	FUNÇÃO OBJETIVO	45
5.4	ALGORITMOS GENÉTICOS	47
5.5	OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS	47
5.6	RECOZIMENTO SIMULADO.....	48
5.7	EVOLUÇÃO DIFERENCIAL	49
5.8	EVOLUÇÃO DIFERENCIAL HÍBRIDA.....	50
5.8.1	Evolução Diferencial com Busca Não-Cega.....	50
5.8.2	Evolução Diferencial com Topologia em Anel e Mutação Caótica.....	51
5.8.3	Evolução Diferencial com Recozimento Simulado.....	53
6	EXPERIMENTOS, RESULTADOS E DISCUSSÃO	56
6.1	CARACTERÍSTICAS GERAIS DOS EXPERIMENTOS.....	56
6.2	RESULTADOS DA APLICAÇÃO DOS AG'S.....	57
6.2.1	Discussão dos Resultados para AG's.....	59
6.3	RESULTADOS DA APLICAÇÃO DE OEP.....	60
6.3.1	Discussão dos Resultados para OEP.....	63

6.4 RESULTADOS DA APLICAÇÃO DE SA	64
6.4.1 Discussão dos Resultados para o SA.....	67
6.5 RESULTADOS DA APLICAÇÃO DE ED	68
6.5.1 Discussão dos Resultados para ED.....	75
6.6 RESULTADOS DA APLICAÇÃO DE ED-BNC	75
6.6.1 Discussão dos Resultados para a ED-BNC.....	78
6.7 RESULTADOS DA APLICAÇÃO DE ED-TAMC	79
6.7.1 Discussão dos Resultados para a ED-TAMC.....	82
6.8 RESULTADOS DA APLICAÇÃO DE ED-SA	83
6.8.1 Discussão dos Resultados para a ED-SA.....	86
6.9 DISCUSSÃO GERAL	87
7 CONCLUSÃO E TRABALHOS FUTUROS.....	89
7.1 DIFICULDADES APRESENTADAS	89
7.2 CONCLUSÕES GERAIS	89
7.3 CONTRIBUIÇÕES	90
7.4 TRABALHOS FUTUROS	92
REFERÊNCIAS	94

LISTA DE ILUSTRAÇÕES

Figura 1.1 Esquematisação da TIE.....	15
Figura 2.1 Esquema de um exame de TIE.....	20
Figura 2.2 Representação do problema direto.....	22
Figura 2.3 Representação do problema inverso.....	23
Figura 2.4 Domínio com objeto conhecido (A) e domínio com objeto desconhecido (B)	24
Figura 5.1 Malha de elementos finitos triangulares gerada pelo EIDORS.....	44
Figura 5.2 Distribuição de condutividade elétrica representada graficamente.....	45
Figura 5.3 Esquema da resolução da função objetivo.....	46
Figura 6.1 Imagens ouro utilizadas como fantoma nos experimentos.....	56
Figura 6.2 Imagens reconstruídas com objeto no centro, entre o centro e a borda, e perto da borda, respectivamente, para AG.....	58
Figura 6.3 Erro relativo ao longo das iterações para AG.....	59
Figura 6.4 Erro relativo ao longo do tempo para AG.....	59
Figura 6.5 Imagens reconstruídas com objeto no centro, entre o centro e a borda, e perto da borda, respectivamente; para Otimização por Enxame de Partículas canônico.....	60
Figura 6.6 Erro relativo ao longo das iterações para objeto localizado no centro para OEP e AG.....	61
Figura 6.7 Erro relativo ao longo das iterações para objeto localizado entre o centro e a borda para OEP e AG.....	61
Figura 6.8 Erro relativo ao longo das iterações para objeto localizado perto da borda para OEP e AG.....	62
Figura 6.9 Erro relativo ao longo do tempo para objeto localizado no centro para OEP e AG.....	62
Figura 6.10 Erro relativo ao longo do tempo para objeto localizado entre o centro e a borda para OEP e AG.....	62
Figura 6.11 Erro relativo ao longo do tempo para objeto localizado perto da borda para OEP e AG.....	63
Figura 6.12 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Recozimento Simulado canônico.....	64
Figura 6.13 Erro relativo ao longo das iterações para objeto localizado no centro para OEP, AG e SA.....	65
Figura 6.14 Erro relativo ao longo das iterações para objeto localizado entre o centro e a borda para OEP, AG e SA.....	65
Figura 6.15 Erro relativo ao longo das iterações para objeto localizado perto da borda para OEP, AG e SA.....	66
Figura 6.16 Erro relativo ao longo do tempo para objeto localizado no centro para OEP, AG e SA.....	66
Figura 6.17 Erro relativo ao longo do tempo para objeto localizado entre o centro e a borda para OEP, AG e SA.....	66
Figura 6.18 Erro relativo ao longo do tempo para objeto localizado perto da borda para OEP, AG e SA.....	67
Figura 6.19 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Evolução Diferencial clássica (ED-1) (ED/rand/1/bin).....	68
Figura 6.20 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Evolução Diferencial (ED-2) (ED/rand/2/bin).....	69
Figura 6.21 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Evolução Diferencial (ED-3) (ED/best/1/bin).....	69

Figura 6.22 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Evolução Diferencial (ED-4) (ED/best/2/bin).....	70
Figura 6.23 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Evolução Diferencial (ED-5) (ED/rand-to-best/2/bin).....	70
Figura 6.24 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Evolução Diferencial modificada (ED-M).....	71
Figura 6.25 Erro relativo ao longo das iterações para objeto isolado localizado no centro para as versões de ED.....	72
Figura 6.26 Erro relativo ao longo das iterações para objeto isolado localizado entre o centro e a borda para as versões de ED.....	72
Figura 6.27 Erro relativo ao longo das iterações para objeto isolado localizado perto da borda para as versões de ED.....	73
Figura 6.28 Erro relativo ao longo do tempo para objeto isolado localizado no centro para as versões de ED.....	73
Figura 6.29 Erro relativo ao longo do tempo para objeto isolado localizado entre o centro e a borda para as versões de ED.....	74
Figura 6.30 Erro relativo ao longo do tempo para objeto isolado localizado perto da borda para as versões de ED.....	74
Figura 6.31 Imagens reconstruídas com objeto no centro, entre o centro e a borda, e perto da borda, respectivamente, para ED-BNC.....	75
Figura 6.32 Erro relativo ao longo das iterações para objeto localizado no centro para OEP, AG, SA, ED-3 e ED-BNC.....	76
Figura 6.33 Erro relativo ao longo das iterações para objeto localizado entre o centro e a borda para OEP, AG, SA, ED-3 e ED-BNC.....	77
Figura 6.34 Erro relativo ao longo das iterações para objeto localizado perto da borda para OEP, AG, SA, ED-3 e ED-BNC.....	77
Figura 6.35 Erro relativo ao longo do tempo para objeto localizado no centro para OEP, AG, SA, ED-3 e ED-BNC.....	77
Figura 6.36 Erro relativo ao longo do tempo para objeto localizado entre o centro e a borda para OEP, AG, SA, ED-3 e ED-BNC.....	78
Figura 6.37 Erro relativo ao longo do tempo para objeto localizado perto da borda para OEP, AG, SA, ED-3 e ED-BNC.....	78
Figura 6.38 Imagens reconstruídas com objeto no centro, entre o centro e a borda, e perto da borda, respectivamente, para ED-TAMC.....	79
Figura 6.39 Erro relativo ao longo das iterações para objeto localizado no centro para OEP, AG, SA, ED-3, ED-BNC e ED-TAMC.....	80
Figura 6.40 Erro relativo ao longo das iterações para objeto localizado entre o centro e a borda OEP, AG, SA, ED-3, ED-BNC e ED-TAMC.....	80
Figura 6.41 Erro relativo ao longo das iterações para objeto localizado perto da borda para OEP, AG, SA, ED-3, ED-BNC e ED-TAMC.....	81
Figura 6.42 Erro relativo ao longo do tempo para objeto localizado no centro para OEP, AG, SA, ED-3, ED-BNC e ED-TAMC.....	81
Figura 6.43 Erro relativo ao longo do tempo para objeto localizado entre o centro e a borda para OEP, AG, SA, ED-3, ED-BNC e ED-TAMC.....	81
Figura 6.44 Erro relativo ao longo do tempo para objeto localizado perto da borda para OEP, AG, SA, ED-3, ED-BNC e ED-TAMC.....	82
Figura 6.45 Imagens reconstruídas com objeto no centro, entre o centro e a borda, e perto da borda, respectivamente, para ED-SA.....	83
Figura 6.46 Erro relativo ao longo das iterações para objeto localizado no centro para OEP, AG, SA, ED-3, ED-BNC, ED-TAMC e ED-SA.....	84

Figura 6.47 Erro relativo ao longo das iterações para objeto localizado entre o centro e a borda OEP, AG, SA, ED-3, ED-BNC, ED-TAMC e ED-SA.....	84
Figura 6.48 Erro relativo ao longo das iterações para objeto localizado perto da borda para OEP, AG, SA, ED-3, ED-BNC, ED-TAMC e ED-SA.....	84
Figura 6.49 Erro relativo ao longo do tempo para objeto localizado no centro para OEP, AG, SA, ED-3, ED-BNC, ED-TAMC e ED-SA.....	85
Figura 6.50 Erro relativo ao longo do tempo para objeto localizado entre o centro e a borda para OEP, AG, SA, ED-3, ED-BNC, ED-TAMC e ED-SA.....	85
Figura 6.51 Erro relativo ao longo do tempo para objeto localizado perto da borda para OEP, AG, SA, ED-3, ED-BNC, ED-TAMC e ED-SA.	85

LISTA DE TABELAS

Tabela 1.1 Limiar de sensação de acordo com a frequência da corrente.....	16
Tabela 2.1 Valores típicos de condutividade elétrica dos tecidos.....	19
Tabela 3.1 Principais estratégias da Evolução Diferencial	36
Tabela 5.1 Parâmetros utilizados para Algoritmos Genéticos.....	47
Tabela 5.2 Parâmetros utilizados para Otimização por Enxame de Partículas.....	48
Tabela 5.3 Parâmetros utilizados para Recozimento Simulado.....	49
Tabela 5.4 Parâmetros utilizados para todas as versões de ED.....	49
Tabela 5.5 Parâmetros utilizados para a técnica ED-BNC.....	51
Tabela 5.6 Parâmetros utilizados para a técnica ED-TAMC.....	52
Tabela 5.7 Parâmetros utilizados para a técnica ED-SA.....	55
Tabela 6.1 Parâmetros do EIDORS utilizados nos experimentos.....	57
Tabela 6.2 Resumo dos resultados obtidos neste trabalho.....	87
Tabela 7.1 Contribuições geradas pelos resultados parciais desta dissertação.....	90

LISTA DE ABREVIATURAS

AG: Algoritmos Genéticos

ED: Evolução Diferencial

ED-BNC: Evolução Diferencial com Busca Não-Cega

ED-C: Evolução Diferencial Clássica

ED-M: Evolução Diferencial Modificada

ED-SA: Evolução Diferencial com Recozimento Simulado

ED-TAMC: Evolução Diferencial com Topologia em Anel e Mutação Caótica

EIDORS: Electrical Impedance and Diffuse Optical Tomography Reconstruction *Software*

GREIT: Graz consensus Reconstruction algorithm for Electrical Impedance Tomograph

MEF: Método de Elementos Finitos

NOSER: Newton's One-Step Error Reconstructor

OEP: Otimização por Enxame de Partículas

SA: Simulated Annealing

TIE: Tomografia por Impedância Elétrica

UTI: Unidade de Terapia Intensiva

LISTA DE VARIÁVEIS

Z : Impedância elétrica

V_{ef} : Tensão efetiva

I_{ef} : Corrente elétrica efetiva

$\vec{u}$: Posição de um determinado objeto

$\phi(\vec{u})$: Distribuição de potenciais elétricos internos e nos eletrodos de superfície

$\phi_{ext}(\vec{u})$: Distribuição de potenciais elétricos nos eletrodos de superfície

$I(\vec{u})$: Corrente elétrica aplicada

$\sigma(\vec{u})$: Vetor de condutividade elétrica (imagem de interesse)

Ω : Volume ou domínio de interesse

$\partial\Omega$: Borda do domínio de interesse

$\hat{n}$: Vetor normal à superfície do domínio

J : Densidade de corrente elétrica

K : Matriz de coeficientes

C : vetor de constantes

ρ : Resistividade elétrica

X : Candidato à solução

$f_0(X)$: Função objetivo

n_p : Número de eletrodos

V : Potenciais de borda da imagem ouro

$U(X)$: Potenciais de borda do candidato à solução

v : Peso de inércia ou velocidade da partícula no algoritmo de OEP

p_B : Melhor posição da partícula até o momento

g_B : Melhor posição de toda a população de partículas

ϕ_1 : Componente cognitivo do OEP

ϕ_2 : Componente social do OEP

X^* : Solução do problema de otimização


Γ : Espaço de busca de soluções
 NP : Número de candidatos à solução da população
 D : Dimensão do vetor candidato à solução
 G : Geração atual do algoritmo de otimização
 V : Vetor mutante de ED
 F : Vetor de amplificação
 W : Vetor de julgamento de ED
 P_{CR} : Constante ou probabilidade de cruzamento
 H : Espaço de Hibert real ou complexo
 Y : Espaço de Hibert real ou complexo
 h^o : Valor esperado de condutividade do elemento
 Σ_r : Matriz de covariância do ruído medido
 Σ_x : Covariância da imagem esperada
 h : Vetor de mudança de condutividade
 y : Vetor de mudança de potencial elétrico
 $\hat{h}$: Solução do problema inverso da TIE
 r : Ruído numérico
 σ_r : Medida da amplitude do ruído
 σ_h : Amplitude da condutividade
 l : Vetor local da técnica Topologia em Anel
 g : Vetor global da técnica Topologia em Anel
 β_i : Fator de peso entre exploração e exploração do Espaço de Busca
 X_{best} : Melhor agente na geração corrente
 β_{best} : fator de peso associado ao melhor agente na geração corrente
 m : Número total de agentes caóticos
 ΔE : Variação da função objetivo
 $P(\Delta E)$: Probabilidade do processo de otimização
 k : Parâmetro de processo
 T : Temperatura

1 INTRODUÇÃO

1.1 MOTIVAÇÃO

A Tomografia por Impedância Elétrica é uma técnica não-invasiva de imagem que pode ser utilizada para obter imagens do interior de uma seção de um corpo através de grandezas elétricas medidas em sua superfície. Tal técnica baseia-se na injeção de corrente elétrica alternada, de baixa amplitude e alta frequência, através de eletrodos dispostos e fixados na superfície da seção do corpo, onde desejasse obter a imagem, e na medição dos potenciais elétricos resultantes nestes eletrodos de superfície (GARCIA et al., 2013) (TEHRANI et al., 2010) como está esquematizado a Figura 1.1.

Figura 1.1 Esquematização da TIE. (Wang et. al. 2012)



As imagens de TIE são mapas de condutividade ou resistividade elétrica estimada para o interior da seção do corpo, a partir de cálculos baseados nos dados de excitação e de resposta. É importante mencionar que, estas imagens ainda apresentam baixa resolução espacial e baixa velocidade de reconstrução se comparadas a outras técnicas de imageamento utilizadas na literatura, no entanto possui diversas vantagens que possibilitam sua aplicação clínica e pesquisas na área médica (RIERA et al., 2011) (KUMAR et al., 2010).

Atualmente a TIE possui aplicações em diversas áreas. Podem ser destacadas as aplicações médicas, foco principal desse estudo, as aplicações em geofísica e na área industrial. Dentre as aplicações médicas, a TIE é aplicada principalmente na detecção de câncer de mama, acidente vascular cerebral e para monitorar a ventilação pulmonar imposta por ventilação mecânica (MENIN & ARTIOLI, 2010) (CHENEY et al., 1999). Isto se deve a diferença relativamente grande entre as resistividades dos diferentes tipos de tecidos que

compõem o corpo humano, permitindo assim, uma melhor diferenciação entre eles (MENIN et al. 2010). Com relação à detecção de tecidos tumorais, estudos mostram que este tipo de tecido possui maior conteúdo de sódio e água que os tecidos normais, consequentemente tende a possuir maior condutividade e permissividade elétrica que os tecidos normais circunvizinhos (WAN et al., 2013) (PAK et al., 2012) (MENIN et al. 2010) .

Apesar das áreas de aplicação de TIE e dos resultados promissores, a técnica de TIE ainda é recente e não está fortemente estabelecida. Outras técnicas para imagens médicas tais como ressonância magnética, ultrassonografia e tomografia computadorizada, possuem maior velocidade de reconstrução e resolução espacial das imagens geradas muito melhores que as da TIE. No entanto, a TIE não utiliza radiações ionizantes, sendo inofensiva ao paciente humano quando aplicada de acordo com o limiar de sensação elétrica, como mostra a Tabela 1.1.

Tabela 1.1 Limiar de sensação de acordo com a frequência da corrente. (PEREIRA, 2011)

Limiar de Sensação Elétrica (mA)	Frequência (Hz)
1	50-60
1,5	500
2	1.000
7	5.000
14	10.000
150	100.000

Além disso, outras vantagens da TIE em relação à tecnologia de Tomografia Computadorizada são o baixo custo associado e as pequenas dimensões do equipamento, podendo assim ser utilizada à beira do leito de UTI para monitoramento 24 horas da ventilação pulmonar imposta por ventilação mecânica (MENIN & ARTIOLI, 2010) (CHENEY et al., 1999).

A reconstrução de imagens de TIE consiste na solução dos problemas direto e inverso (TEHRANI et al., 2010). O problema direto busca determinar os potenciais elétricos no interior da seção do corpo e dos potenciais medidos em seu contorno a partir de um padrão de excitação de corrente elétrica. Essa relação é dada pela Equação de Poisson (FEITOSA et al., 2014b). Quanto ao problema inverso, este busca estimar a distribuição de condutividade ou resistividade elétrica do interior da seção do corpo a partir das medições dos potenciais

elétricos resultantes da excitação por corrente elétrica. Matematicamente, este problema é não linear e mal posto (KUMAR et al., 2010). Não-linear visto que o potencial obtido no contorno do corpo depende de forma não-linear da corrente elétrica aplicada. Mal posto porque a solução para a distribuição de condutividades ou resistividades pode não ser única e ser instável além de apresentar grande sensibilidade a erros numéricos e ruídos experimentais. Essas características fazem com que sua solução seja bastante dependente do algoritmo de reconstrução e da regularização (TEHRANI et al., 2010) e pode ser obtida através de métodos não-iterativos (lineares) e iterativos (não-lineares) (TEHRANI et al., 2010) (KUMAR et al., 2010). Em casos onde a solução do problema inverso é obtida através de um método iterativo, o problema direto é chamado frequentemente. Nesse caso é necessário que a solução do problema direto seja obtida de uma forma mais rápida e eficiente.

A baixa velocidade de reconstrução e a resolução das imagens estão diretamente relacionadas à solução do problema inverso da TIE. Sendo assim, vários grupos de pesquisa buscam desenvolver algoritmos que sejam ao mesmo tempo rápidos e em condições de gerar imagens com resolução espacial tão boa quanto às tecnologias de reconstrução de imagem existentes.

1.2 JUSTIFICATIVA

Como a TIE é uma técnica recente com grande potencial na obtenção de imagens para monitoração biológica, principalmente por ser não invasiva e não utilizar de radiação ionizante, há necessidade de maior investigação sobre este assunto, principalmente voltados para o desenvolvimento e melhoria de algoritmos que sejam capazes de reconstruir imagens de TIE com melhor qualidade e alta velocidade de obtenção. Atualmente são observados métodos de reconstrução de TIE híbridos, ou seja, utilizando a combinação de diferentes técnicas para resolução do problema inverso. O estado da arte dessa resolução caminha em direção ao uso de técnicas de Inteligência Computacional onde podem ser citados os métodos da Computação Evolucionária, tais como a Evolução Diferencial (LIU & SUN, 2011) (ADLER & LIONHEART, 2006) (PRICE et al., 2005). Por este motivo, o presente trabalho vem contribuir como mais um estudo dos métodos híbridos baseados em Computação Evolucionária para reconstrução de imagens de TIE.

1.3 OBJETIVO GERAL

O objetivo do presente trabalho é a elaboração de uma ferramenta computacional para reconstrução de imagens de TIE baseada em hibridização de algoritmos de busca e otimização, desde os bioinspirados até os evolucionários, com destaque para a técnica de Evolução Diferencial (LIU & SUN, 2011) (PRICE et al., 2005). A dissertação visa principalmente o aumento da velocidade de reconstrução e a redução do custo computacional.

1.4 OBJETIVOS ESPECÍFICOS

- Revisão dos métodos numéricos de resolução do problema direto da TIE, dos métodos iterativos de resolução do problema inverso da TIE e da Evolução Diferencial;
- Estudo do simulador EIDORS (*Electrical Impedance and Diffuse Optical Tomography Reconstruction Software*) e elaboração de uma ferramenta computacional de reconstrução de imagens de TIE;
- Obtenção dos resultados da técnica proposta e comparação com os resultados de técnicas do estado da arte implementadas também neste trabalho.

1.5 ORGANIZAÇÃO DO TRABALHO

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

No Capítulo 2, 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 a técnica de Evolução Diferencial.

No Capítulo 4, são apresentadas os métodos que foram hibridizados com a Evolução Diferencial a fim de melhorar o rendimento computacional desta técnica.

No Capítulo 5, é mostrado como foi implementada a proposta deste trabalho.

No Capítulo 6, são descritos os experimentos, são mostrados todos os resultados e é feita a discussão com base nestes resultados.

No último capítulo (Capítulo 7), são apresentadas as conclusões, com as dificuldades encontradas e as perspectivas de trabalhos futuros.

2 TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA

Desde a década de 1980, a Tomografia por Impedância Elétrica (TIE) vem sendo explorada com a finalidade de monitoração de tecidos biológicos através da reconstrução de imagens médicas, sendo motivada pelo fato de que diferentes tecidos biológicos possuem diferentes condutividades elétricas (ver Tabela 2.1). Sendo assim, caso haja uma forma de determinar as resistividades elétricas dentro do corpo é possível reconstruir uma imagem dos órgãos a serem monitorados (LI, 2006) (BAKER, 1989).

Tabela 2.1 Valores típicos de condutividade elétrica dos tecidos. (BAKER, 1989)

Tecido	Condutividade (mS/cm)
Sangue	6,79
Fígado	2,80
Músculo – longitudinal	8,00
Músculo – transversal	0,60
Músculo cardíaco – longitudinal	6,30
Músculo cardíaco – transversal	2,30
Tecido neural	1,70
Pulmão – expiração	1,00
Pulmão – inspiração	0,40
Gordura	0,36
Osso	0,06


Tal técnica consegue reconstruir imagens de uma seção do corpo através das medidas de potenciais elétricos, resultantes de excitação por corrente elétrica, através de eletrodos distribuídos ao redor do corpo. Isso contribui para tornar a TIE uma alternativa às técnicas clássicas de imageamento médico (MENIN, 2009) (VALLEJO, 2007).

2.1 PRINCÍPIOS FUNDAMENTAIS DA TIE

A TIE trata-se de uma técnica não-invasiva capaz de obter imagens de uma seção transversal de qualquer corpo/objeto, por meio da estimativa dos valores de condutividade ou resistividade elétrica dos seus componentes internos. Como é mostrado pela Figura 2.1, é

necessário que os eletrodos de superfície sejam distribuídos ao redor da seção do corpo a ser observada. Através destes eletrodos são injetadas correntes elétricas (trata-se do estímulo) e medidos os potenciais elétricos de contorno (trata-se da resposta ao estímulo) que são enviados para um sistema de aquisição de dados e reconstrução de imagem (neste exemplo, trata-se do computador) (VALLEJO, 2007).

Figura 2.1 Esquema de um exame de TIE. (MENIN, 2009)



As formas possíveis de excitação do corpo por injeção de corrente elétrica, podem ser classificadas em dois tipos: adjacente e diametral. No padrão de excitação adjacente, é aplicada num eletrodo a corrente elétrica e tomado o eletrodo mais próximo (vizinho) como ponto de referência (MENIN, 2009) (BORCEA, 2002). Quanto ao padrão diametral, a corrente elétrica é aplicada a corrente elétrica por um eletrodo e tomado o eletrodo diametralmente oposto como ponto referência (MENIN, 2009) (BORCEA, 2002). Desta forma, para ambos os padrões de excitação o par de eletrodos (eletrodo de injeção e eletrodo de referência) é sucessivamente alternado ao redor da seção do corpo até que se obtenha um conjunto de dados linearmente independentes, sendo determinado pela quantidade de eletrodos distribuídos em torno do corpo (MENIN, 2009) (BORCEA, 2002).

A imagem de TIE é gerada por meio de *hardware* e *software*, tendo em vista que o *hardware* é utilizado para aplicação de excitação e medição das respostas à excitação, e o *software* é utilizado para reconstruir a imagem através da obtenção de uma solução aproximada para o problema inverso da TIE (VALLEJO, 2007).

2.2 VANTAGENS E DESVANTAGENS DA TIE

Com relação à aplicação clínica da TIE, foco principal deste trabalho, é possível serem citadas as seguintes vantagens que a tornam viável: o tomógrafo de impedância elétrica possui

pequenas dimensões que o possibilita ser portátil e ser utilizado junto ao leito do paciente, além disso, possui baixo custo quando comparada às demais técnicas de tomografia. Trata-se de uma técnica de imageamento que não expõe a região do corpo a radiação ionizante (AGUILAR, 2009).

No entanto, são evidentes as desvantagens da TIE se comparada as técnicas tradicionais de imageamento, podem ser citadas: a baixa resolução espacial (YOJO, 2008) e a baixa velocidade de reconstrução (MENIN, 2009). Estas desvantagens são resultantes dos modos de solução do problema inverso. O fato é a fonte de estímulo a inúmeros grupos de pesquisa que buscam desenvolver e melhorar vários algoritmos de reconstrução, com a finalidade de obter imagens de TIE com boa resolução espacial e ao mesmo tempo rápida reconstrução.

2.3 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 (Z), esta grandeza é a razão entre a tensão efetiva (V_{ef}) aplicada no circuito e a corrente elétrica efetiva (I_{ef}) que o atravessa. Esta razão é dada pela Equação 2.1.

$$Z = \frac{V_{ef}}{I_{ef}} \quad (2.1)$$

A impedância, dada no Sistema Internacional em Ω (Ohm) conceitualmente, corresponde à oposição que um dado circuito apresenta à passagem de uma 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 mostrada nas expressões vetoriais a seguir.

$$\nabla \bullet [\sigma(\vec{u}) \nabla \phi(\vec{u})] = 0, \quad \forall \vec{u} \in \Omega, \quad (2.2)$$

e nas condições de contorno (RIBEIRO et al., 2014a):

$$\phi_{ext}(\vec{u}) = \phi(\vec{u}), \quad \forall \vec{u} \in \partial\Omega, \quad (2.3)$$

$$I(\vec{u}) = -\sigma(\vec{u}) \nabla \phi(\vec{u}) \bullet \hat{n}(\vec{u}), \quad \forall \vec{u} \in \partial\Omega, \quad (2.4)$$


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), Ω 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 $\vec{u} \in \partial\Omega$. De acordo com Cheney et al. (1999), a Equação (2.2) pode ser obtida pelas Equações de Maxwell.

Os algoritmos de reconstrução na TIE buscam resolver a Equação de Poisson, a partir da solução de duas classes de problemas: o problema direto e o problema inverso (AGUILAR, 2009) (VALLEJO, 2007). Estas classes serão explicadas a seguir.

2.4 O PROBLEMA DIRETO

O problema direto trata-se em, dada uma distribuição interna de condutividade ou resistividade elétrica em um meio condutivo não-homogêneo (como exemplo, o corpo humano), estimar qual será o potencial elétrico mensurado nos eletrodos de superfície, a partir da injeção de corrente elétrica como é mostrado a seguir.

Figura 2.2 Representação do problema direto.



A estimativa dos potenciais de superfície, quando é conhecida a priori a distribuição interna de condutividade, é feita pela Equação de Poisson, mostrada pela Equação 2.2. Com as condições de contorno dadas pela seguinte expressão:

$$\sigma \frac{\partial \phi}{\partial \hat{n}} = J \quad (2.5)$$

onde $\hat{n}$ é o vetor normal a superfície e J corresponde a densidade de corrente elétrica (MARTINS et al., 2012). É importante enfatizar que, não existem soluções analíticas para

(2.2) e (2.5) em um domínio Ω arbitrário. Contudo, uma solução aproximada para os potenciais de borda pode ser obtida através do Método dos Elementos Finitos (MEF) que converte o sistema não linear (2.2) e (2.5) no seguinte sistema de equações lineares:

$$\mathbf{K}(\sigma) \bullet \Phi - \mathbf{C} = 0 \quad (2.6)$$

onde $\mathbf{K}(\sigma)$ é uma matriz de coeficientes dependente da distribuição de condutividade σ e $\mathbf{C}$ é um vetor de constantes. Desta forma, é possível se obter uma aproximação para os potenciais de borda Φ , conhecida uma distribuição de condutividade σ .

Vale ressaltar que, caso seja conhecida a condutividade elétrica σ , é possível obter a resistividade elétrica ρ através da seguinte expressão:


$$\rho = 1/\sigma \quad (2.7)$$

onde as unidades de resistividade ρ e condutividade σ no S.I. (Sistema Internacional de unidades) são, respectivamente, o ohm-metro ($\Omega.m$) e siemens por metro (S/m).

2.5 O PROBLEMA INVERSO

O problema inverso busca encontrar a distribuição de condutividade elétrica no interior de um corpo (Ω), dada a corrente elétrica de excitação e os potenciais elétricos (Φ) medidos na superfície do corpo (AGUILAR, 2009) (VALLEJO, 2007).

Figura 2.3 Representação do problema inverso.




Nas técnicas propostas neste trabalho, busca-se resolver o problema inverso através da resolução iterativa do problema direto, de forma a tratar o problema inverso como um problema de otimização. Este processo será descrito de forma detalhada na próxima secção.

2.6 FUNÇÃO OBJETIVO

A obtenção iterativa dos potenciais elétricos de borda para uma distribuição de condutividade interna conhecida (problema direto), possibilita a reconstrução das imagens de TIE como um problema de busca e otimização. Este problema consiste em minimizar uma função objetivo, que foi considerada neste trabalho como o erro médio quadrático entre os potenciais de borda mensurados no corpo e os potenciais de borda gerados pela resolução do problema direto para distribuições aleatórias de resistividade interna candidatas à solução. De forma que, quanto mais parecidos foram os potenciais de borda do candidato à solução com os mensurados no corpo, menor será o valor da função objetivo e mais parecida a sua distribuição interna de resistividade será com a distribuição no corpo analisado.

A fim de realizar comparações qualitativas, entre a seção do corpo analisado e as soluções obtidas pelos algoritmos de reconstrução propostos neste trabalho, através de simulações computacionais, foi necessário o uso do *software* EIDORS para que fosse criado o corpo analisado (fantoma numérico) a partir de uma grade circular de elementos finitos triangulares, onde a cada elemento finito está associado a um valor de resistividade elétrica.

Figura 2.4 Domínio com objeto conhecido (A) e domínio com objeto desconhecido (B).



Considerando a Figura 2.4(A) como o corpo analisado, foi criado, a partir do EIDORS, um objeto interno ao corpo analisado com resistividade diferente do meio e seus potenciais de borda foram gerados através da resolução do problema direto. Quanto à Figura 2.4(B), foi gerada uma distribuição interna aleatória de resistividade de acordo com o método utilizado para otimização, sendo seus potenciais de borda gerados também através da resolução do problema direto. Assim, para cada candidato à solução obtido pelo algoritmo de reconstrução, são calculados seus potenciais de borda através da resolução do problema direto e estes potenciais são comparados com os do corpo analisado, que a partir de agora passa a ser conhecido como imagem ouro.

Neste trabalho, foi usado o erro relativo médio quadrático entre os potenciais de borda da imagem ouro e os do candidato à solução X , como função objetivo $f_0(X)$ a ser minimizada. Este erro é calculado pela seguinte expressão:

$$f_0(X) = \left[\frac{\sum_{i=1}^{n_p} (U_i(X) - V_i)^2}{\sum_{i=1}^{n_p} V_i^2} \right]^{1/2} \quad (2.8)$$

onde n_p é o número de eletrodos, V_i são os potenciais de borda da imagem ouro e $U_i(X)$ são os potenciais de borda do candidato à solução obtido pelo algoritmo de reconstrução.

2.7 APLICAÇÕES DA TIE

A TIE possui diversas áreas de aplicação. Segundo Vallejo (2007), na área médica apresentam-se várias aplicações, como por exemplo, a mamografia, a monitoração do fluxo sanguíneo e de órgãos como o coração, a detecção de derrames cerebrais, e a monitoração do pulmão. Já Menin (2009), mostra inúmeras aplicações da TIE em processos industriais, como por exemplo, o monitoramento de escoamentos multifásicos em tubulações, ensaios não-destrutivos de controle de qualidade na detecção de corrosão ou de defeitos, como fissuras ou vazios em peças metálicas, e monitoramento e detecção de vazamento em tanques subterrâneos.

Em trabalhos científicos mais recentes podem-se encontrar diversas outras aplicações médicas da TIE, podemos citar: avaliação da perfusão pulmonar (RIERA et. al., 2011), detecção de redistribuição de pressão pulmonar (RADKE et. al., 2012), visualização de inclusões pleurais (BHATIA et. al., 2012), detecção de hematomas subdurais (DAI et al., 2013), avaliação de alterações no volume sistólico (MAISCH et al., 2011), auxílio no diagnóstico de câncer de próstata (WAN. et. al., 2013) e detecção de câncer de mama (PAK et. al., 2012). De acordo com Marinho et al. (2013), o fato de a técnica de TIE ainda ser pouco explorada pelos pesquisadores brasileiros, não impediu sua utilização em pacientes com diferentes problemas de saúde no Brasil. Entre tais problemas é possível citar: diagnósticos de lesão pulmonar aguda, de carcinoma brônquico, de edema pulmonar, de pneumotórax, de enfisema pulmonar e de hiperinsuflação dinâmica, além de ser utilizado para observar o posicionamento do tubo traqueal.

3 OTIMIZAÇÃO POR COMPUTAÇÃO EVOLUCIONÁRIA

De acordo com Back et al. (1991), a Computação Evolucionária trata-se de uma linha de pesquisa da ciência da computação que utiliza os princípios das Teorias da Evolução de Darwin e da Genética de Mendel para inspirar o desenvolvimento de algoritmos capazes de resolver diversos problemas complexos da engenharia.

3.1 TEORIA DE DARWIN E NEO-DARWINISMO

O naturalista inglês Charles Robert Darwin (1809-1882) reuniu inúmeras evidências que favoreceram o evolucionismo e propôs um mecanismo consistente para explicar o processo evolutivo que denominou de Seleção Natural em sua obra *A origem das espécies* (1859).

Na expedição em volta da terra a bordo do navio *H.S.S. Beagle* (1822-1827), Darwin elaborou sua teoria a partir de estudos realizados em visitas à Austrália e à América do Sul, passando também pelo Brasil e arquipélagos tropicais. Desta forma, o autor conseguiu concluir que todas as espécies da natureza possuem uma grande capacidade de crescimento populacional, sendo tal característica responsável por levar o número de indivíduos produzidos a cada geração ser sempre maior do que a disponibilidade de recursos para sua sobrevivência. Sendo assim, Darwin observou que a sobrevivência dos indivíduos está fortemente relacionada com a adaptação destes às condições ambientais, tais como a falta de alimentos, que levam os indivíduos competirem entre si para sobreviverem. Assim, os indivíduos que sobrevivem e se reproduzem a cada geração são, preferencialmente, os que possuem características que favorecem melhor adaptação às condições ambientais. Essa ideia foi sintetizada com a expressão Seleção Natural (AMABIS & MARTHO, 2002).

Assim como o Darwinismo (ou Teoria de Darwin), a teoria moderna da evolução biológica tem a seleção natural como seu ponto central. No entanto, o evolucionismo moderno leva em conta os conhecimentos atuais no campo da Genética (Teorias de Mendel), que permitem explicar por que os indivíduos de uma população variam do ponto de vista gênico e como essas variações são transmitidas à descendência. Esta moderna teoria ficou conhecida como teoria sintética da evolução ou neo-Darwinismo, a qual admite três principais fatores evolutivos responsáveis pela adaptação dos indivíduos: mutação gênica, recombinação gênica e seleção natural (AMABIS & MARTHO, 2002). A mutação e a recombinação

gênicas são responsáveis por permitir a existência da diversidade populacional, ou seja, o aparecimento das variações gênicas nas populações sobre as quais atua a seleção natural.

3.2 ALGORITMOS EVOLUTIVOS

De acordo com Back et al. (1991), os algoritmos evolutivos são inspirados na teoria neo-Darwiniana, sendo geralmente utilizados como processos iterativos de Busca e Otimização para resolver problemas genéricos, se para estes problemas não são conhecidas muitas informações. Com relação aos algoritmos evolutivos podemos descrever as seguintes características (BACK et al., 1991):

- 1) *População de candidatos à solução*: os candidatos à solução do problema são conhecidos como indivíduos ou cromossomos. Cada candidato à solução é uma representação numérica de um ponto do espaço de busca do problema;
- 2) *Reprodução*: os candidatos à solução possuem a capacidade de se reproduzirem de forma sexuada ou assexuada, resultando na geração de filhos com algumas características herdadas de seu(s) pai(s). É importante mencionar que, somente na reprodução sexuada são gerados filhos a partir de troca de materiais genéticos entre dois ou mais indivíduos pais;
- 3) *Variação genética*: os indivíduos filhos podem sofrer, durante o processo reprodutivo do(s) pai(s), variações no nível de seu código genético causadas por mutação genética, que pode resultar numa maior diversidade da nova geração de candidatos à solução;
- 4) *Seleção natural*: os indivíduos são avaliados a partir de uma função objetivo ou de aptidão que mostra um valor associado à qualidade ou adaptabilidade deste indivíduo em seu ambiente. A partir da comparação entre estes valores individuais de aptidão é realizada a competição pela sobrevivência e reprodução no ambiente, sabendo que os indivíduos com maiores valores de aptidão possuem maior vantagem seletiva.

No caso em que todas as etapas acima (reprodução, variação genética, e seleção) tiverem sido executadas, diz-se que ocorreu uma geração. Sendo que, podemos considerar o critério de parada como um número fixo de gerações percorrido ou a determinação de uma solução satisfatória de acordo com o valor de aptidão. Os algoritmos evolutivos, implementados neste trabalho, serão descritos com maiores detalhes nas próximas secções.

3.3 ALGORITMOS GENÉTICOS

De acordo com Cintra (2007), os algoritmos genéticos (AG) foram criados por volta de 1960 e publicados por Holland (1975). Tais algoritmos são inspirados nos fenômenos naturais associados à adaptação das espécies e à seleção natural. Segundo Lopes (2006), estes algoritmos tratam-se de processos iterativos capazes de resolver um problema genérico em um tempo considerado aceitável, apesar de tal resposta não ser a solução ótima para o problema sob estudo.

Os algoritmos genéticos seguem fortemente aos princípios das teorias de Mendel, implementando as funções de recombinação e mutação gênica para gerar novos indivíduos com maior adaptação ao ambiente (LOPES, 2006). A seguir está esquematizado o que ocorre em cada geração do AG básico (ROLNIK & SELEGHIM, 2006) (CAROSIO et al., 2007):

Pseudocódigo do AG:

- 1) Gerar a *população inicial*;
- 2) Repetir até que o *critério de parada* seja alcançado:
 - a) Avaliar a função objetivo (também conhecida como *função de aptidão* – função de probabilidade do indivíduo sobreviver para a próxima geração) para cada indivíduo;
 - b) A *seleção natural*: indivíduos com melhor aptidão são selecionados para a etapa de cruzamento. A estratégia de seleção para uma determinada quantidade dos melhores ancestrais passar para a próxima geração é chamada *elitismo* (ROLNIK & SELEGHIM, 2006);
 - c) *Crossover*: Dada uma máscara definida (coordenadas de interesse em vetores), os indivíduos descendentes são gerados através da combinação de dois genes ancestrais;
 - d) *Mutação*: genes dos descendentes são selecionados aleatoriamente e modificados.

Os conceitos básicos dos algoritmos genéticos (AG) são:

- **Geração da população inicial:** a partir da literatura escolhe-se a forma mais simples de geração da população inicial de candidatos à solução, como sendo um modelo randômico baseado na aleatoriedade dos genes que compõe o indivíduo. Tal modelo é construído de forma a evitar a representação repetida de um mesmo valor a fim de combater a ambiguidade de soluções (MICHALEWICZ, 1996).

• **Seleção:** os processos de seleção dos indivíduos a compor uma população intermediária de candidatos à solução podem ser classificados nos seguintes métodos (MICHALEWICZ, 1996):

- i. **Roleta:** este método é caracterizado por escolher os indivíduos para fazer parte da próxima geração através de um sorteio, onde cada indivíduo da população é representado numa roleta como sendo uma fatia com tamanho proporcional ao seu índice de aptidão. Tal índice é obtido a partir da avaliação da função objetivo (ou função de aptidão) definida para o problema. Sendo assim, quanto maior a aptidão deste indivíduo ao ambiente, maior é a chance de ser escolhido para compor a população intermediária;
- ii. **Torneio:** este método é caracterizado por escolher aleatoriamente NP indivíduos de uma população (geralmente $NP = 3$), a seguir dentre estes NP indivíduos é selecionado para compor a população intermediária aquele indivíduo que possui o maior índice de aptidão. Tal índice corresponde ao valor obtido pela função objetivo (ou função de aptidão) definida para o problema. O processo é repetido até que seja obtida toda a população intermediária de candidatos à solução.

• **Crossover:** este processo realiza troca de informações genéticas entre dois indivíduos da população intermediária selecionados através de sua aptidão. Desta forma, tal processo pode resultar na geração de um ou dois indivíduos filhos, dependendo das informações genéticas dos indivíduos pais (MICHALEWICZ, 1996).

• **Mutação:** a operação de mutação busca alterar um ou mais genes de um indivíduo da população intermediária tomada como base, buscando assim obter um novo indivíduo com material genético diversificado (MICHALEWICZ, 1996).

• **Critério de Parada:** este operador é utilizado como condição de término da execução do algoritmo, podendo ser: tempo de execução, número de gerações ou valor de aptidão (MICHALEWICZ, 1996).

3.4 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS

De acordo com Kennedy & Eberhart (1995), o método de Otimização por Enxame de Partículas (OEP) é um algoritmo de busca e otimização inspirado no comportamento social entre partículas e de um enxame, baseado nos estudos do biólogo Frank Heppner, que observou a forma como um grupo de pássaros busca um lugar para construir seus ninhos e busca o alimento numa região.

Este algoritmo trabalha com o fato de que cada indivíduo (ou partícula) possui sua própria experiência (SANTOS & ASSIS, 2009) e considerando-o como ser social dentro do grupo (ou enxame), este indivíduo é capaz de conhecer o comportamento de seus vizinhos. Desta forma, todos os indivíduos do grupo possuem dois tipos de informação: a informação obtida pela aprendizagem individual (experiência) e a obtida pela transmissão cultural. Portanto, cada indivíduo busca realizar uma determinada função tendo como base sua experiência e a experiência de alguns de seus vizinhos (SERAPIÃO, 2009). A partir de Kennedy et al. (2001), podemos observar três princípios para resumir o processo de adaptação cultural:

- *Avaliar* – neste caso, os indivíduos podem estimar seu comportamento através da capacidade de analisar o ambiente;
- *Comparar* – neste caso, cada indivíduo toma uma nova decisão baseado na comparação entre seu comportamento e os comportamentos de seus vizinhos.
- *Imitar* – este processo é fundamental em organizações sociais humanas, sendo importante na aquisição e manutenção das habilidades mentais.

Portanto, a OEP é um algoritmo que utiliza as propriedades de autoavaliação, comparação e imitação dos indivíduos de um grupo para levá-los a interagir entre si e com o meio ambiente. Desta forma, estes indivíduos serão capazes de lidar com inúmeras situações apresentadas pelo ambiente.

O que ocorre em cada iteração do OEP baseado no comportamento dos passáros (partículas) está esquematizado a seguir (SERAPIÃO, 2009) (KENNEDY et al., 2001):

Pseudocódigo do OEP:

1. Determine o número de partículas da população P .
2. Inicialize aleatoriamente a posição inicial (X) de cada partícula p de P .
3. Atribua uma velocidade inicial (v) igual para todas as partículas.
4. Para cada partícula p em P faça:
 - (a) Calcule sua aptidão $f_p = f_0(p)$, f_p corresponde ao valor da função objetivo para p .
 - (b) Encontre a melhor posição da partícula p até o momento (p_B), a partir da comparação de sua aptidão ao longo das iterações.
5. Encontre a partícula com a melhor aptidão de toda a população (g_B).
6. Para cada partícula p em P faça:

(a) Atualize a velocidade da partícula pela fórmula:

$$v = v + \phi_1 \cdot (p_B - X) + \phi_2 \cdot (g_B - X).$$

(b) Atualize a posição da particular pela fórmula:

$$X = X + v$$

7. Se condição de término não for alcançada, retorne ao passo 4.

onde ϕ_1 e ϕ_2 são constantes limitadas a um intervalo finito, em que Kennedy et al. (2001) denomina-os como sendo respectivamente os componentes “cognitivo” e “social” do OEP, sendo definido na literatura $\phi_1 + \phi_2 = 4$.

3.5 EVOLUÇÃO DIFERENCIAL

A Evolução Diferencial (ED) foi criada por Kenneth Price (1995), quando tentava resolver o Problema do Polinômio de Chebychev utilizando a ideia de recriar um vetor população através de diferentes vetores. A partir deste momento, tal algoritmo passou por vários testes e aperfeiçoamentos essenciais para torná-lo um algoritmo da Computação Evolucionária versátil e robusto (SAUER, 2007).

3.5.1 Conceitos Básicos da Evolução Diferencial

O problema de busca e otimização trata-se de um problema clássico que inúmeras vezes os cientistas e engenheiros devem resolver. A otimização corresponde a um processo que busca obter, a partir das limitações e flexibilidades dadas por um problema genérico, uma solução mais próxima da solução ideal (DAS & SUGANTHAN, 2011). Desta forma, otimizar o desempenho de um sistema trata-se em encontrar um conjunto de valores dos parâmetros deste sistema que permita, a partir de certas condições, se atingir o melhor o desempenho global do sistema ser o melhor. Geralmente, os parâmetros que regulam o desempenho do sistema são representados num vetor como:

$$X = [x_1, x_2, x_3, \dots, x_D]^T \quad (3.1)$$

Para otimização de parâmetros reais, como próprio nome indica, cada parâmetro x_i é um número real. Para medir o desempenho alcançado por tais parâmetros, uma função objetivo f_0 é criada para o sistema. O processo de otimização trata-se em buscar por tais

vetores de parâmetros $\vec{X}^*$, que possa minimizar ou maximizar tal função objetivo dependendo do problema de estudo.

$$\begin{aligned} f_0(\vec{X})(f_0 : \Omega \subseteq \Re^D \rightarrow \Re), i.e., f_0(\vec{X}^*) < f_0(\vec{X}) \quad & \text{(problema de minimização)} \\ f_0(\vec{X})(f_0 : \Omega \subseteq \Re^D \rightarrow \Re), i.e., f_0(\vec{X}^*) > f_0(\vec{X}) \quad & \text{(problema de maximização)} \end{aligned} \quad (3.2)$$

para todo $\vec{X} \in \Gamma$, onde Γ é o espaço de busca. Normalmente, o processo de otimização é complicado pela existência de função objetivo não-linear com múltiplos mínimos ou máximos locais. Considerando $f_{0 \text{ minlocal}} = f_0(\vec{X}_{\text{minlocal}})$ como mínimo local e $f_{0 \text{ maxlocal}} = f_0(\vec{X}_{\text{maxlocal}})$ como máximo local, é possível defini-los como:

$$\begin{aligned} \exists \varepsilon > 0 \forall \vec{X} \in \Omega: \|\vec{X} - \vec{X}_{\text{minlocal}}\| < \varepsilon \Rightarrow f_{0 \text{ minlocal}} \leq f_0(\vec{X}) \\ \exists \varepsilon > 0 \forall \vec{X} \in \Omega: \|\vec{X} - \vec{X}_{\text{maxlocal}}\| < \varepsilon \Rightarrow f_{0 \text{ maxlocal}} \geq f_0(\vec{X}) \end{aligned} \quad (3.3)$$

onde $\|\cdot\|$ indica qualquer medida de distância p-norma.

3.5.2 Etapas da Evolução Diferencial

A ED é considerada simples e eficiente quando se trata de otimização global em espaço de busca contínuo (SAUER, 2007). A principal ideia da ED é gerar novos vetores de parametrização a partir de operadores de mutação e cruzamento (baseado nas teorias de Mendel), e utilizar a seleção (baseada no Darwinismo) como operador que determina qual desses vetores irá sobreviver para a próxima geração.

Em particular, ED mantém uma população de tamanho constante, que consiste de NP vetores de valor real D -dimensional, $X_{j,i,G}$, $i = 1, 2, \dots, NP$, $j = 1, 2, \dots, D$, onde j indica a dimensão do vetor, i indica o índice de população e G é a geração da população (OLIVEIRA, 2006).

O processo de otimização por ED é composto pelas seguintes etapas:

1) Inicialização: O algoritmo é iniciado criando uma população inicial de indivíduos (ou vetores de parâmetros) cujos componentes desses vetores são escolhidos aleatoriamente com distribuição uniforme, atendendo ao limite do espaço de busca (SAUER, 2007).

Normalmente, os parâmetros desconhecidos estão sujeitos a restrições de limite inferior e superior, $X_j^{(L)}$ e $X_j^{(U)}$, respectivamente, o que significa

$$X_j^{(L)} \leq X_j \leq X_j^{(U)}, j = 1, 2, \dots, D \quad (3.4)$$

Portanto, definir a população inicial com valores aleatórios que atendam as restrições de contorno dadas:

$$X_{j,i,0} = X_j^{(L)} + rand_j[0,1] \cdot (X_j^{(U)} - X_j^{(L)}) \quad (3.5)$$

onde, $i = 1, 2, \dots, NP$, $j = 1, 2, \dots, D$, $rand_j[0,1]$, denota um valor aleatório uniformemente distribuído no intervalo $[0,1]$, que é escolhido de novo para cada j .

2) Mutação: ED gera novos vetores de parâmetros, adicionando a diferença ponderada entre dois vetores de população para um terceiro. Para cada vetor alvo, $X_{i,G} = \{x_{1,i,G}, x_{2,i,G}, \dots, x_{D,i,G}\}$ ($i = 1, 2, \dots, NP$), um vetor mutante de ED (clássico) $V_{i,G} = \{v_{1,i,G}, v_{2,i,G}, \dots, v_{D,i,G}\}$ é gerado de acordo com:

$$V_{i,G+1} = X_{a,G} + F_i \cdot (X_{b,G} - X_{c,G}) \quad (3.6)$$

onde os índices aleatórios $a, b, c \in \{1, 2, \dots, NP\}$, são números inteiros, mutuamente diferentes, e são também escolhidos para serem diferentes do índice de execução i . Vetor de amplificação $F_i \in [0,1]$ é um vetor real, o qual controla a amplificação da variação diferencial $(X_{b,G} - X_{c,G})$. É importante mencionar que existem algumas outras operações variantes de mutação como mostra a Tabela 3.1.

Um fato considerado potencial para levar a ED trabalhar eficientemente é que a mutação é dirigida pela diferença entre os valores dos parâmetros dos membros correntes da população (SAUER, 2007). Portanto, a ED possibilita que cada parâmetro realize uma troca automática e de uma apropriada redução no processo de otimização, causando a convergência para a solução desejada.

3) Cruzamento: Os parâmetros do vetor mutado são então misturados com os parâmetros de um outro vetor predeterminado, o vetor alvo, para produzir o chamado vetor de julgamento. No cruzamento do tipo *Binomial*, utilizado neste trabalho, o vetor de julgamento é formado como $W_{i,G+1} = (w_{1,i,G+1}, w_{2,i,G+1}, \dots, w_{D,i,G+1})$, onde

$$W_{j,i,G+1} = \begin{cases} V_{j,i,G+1} & \text{if } (rand_{(z)} \leq P_{CR}) \text{ ou } z = rnbr(i) \\ X_{j,i,G} & \text{if } (rand_{(z)} > P_{CR}) \text{ ou } z \neq rnbr(i) \end{cases} \quad (3.7)$$

onde, $j = 1, 2, \dots, D$, $i = 1, 2, \dots, NP$, $rand(z)$ é a z -ésima avaliação de um gerador de número

aleatório uniforme com resultado $[0,1]$, $rnbr(i) \in 1, 2, \dots, D$ é um índice escolhido aleatoriamente, o que assegura que $W_{i,G+1}$ recebe pelo menos um parâmetro de $V_{i,G+1}$. O parâmetro $P_{CR} \in [0,1]$ é a constante ou probabilidade de cruzamento, o qual tem de ser determinado pelo utilizador (SAUER, 2007).

4) Seleção: No caso de processo de otimização por minização, se o vetor de julgamento $W_{i,G+1}$ produz um valor da função objetivo menor que a do vetor alvo $X_{i,G}$, o vetor de julgamento substitui o vetor alvo na geração; caso contrário, o vetor $X_{i,G}$ é mantido. Cada vetor população tem que servir como vetor alvo uma vez para que NP competições ocorram em uma geração (SAUER, 2007).

5) Critério de parada: A execução do algoritmo termina quando a função objetivo do melhor vetor atinge um valor predeterminado ou o número de gerações atinge o limite predefinido (SAUER, 2007).

6) Seleção dos parâmetros de controle: Normalmente, o tamanho da população NP é escolhida a partir de $5D$ a $10D$, e mantém-se constante durante o processo de otimização. Quanto aos parâmetros F_i e P_{CR} , são geralmente fixados durante o processo de pesquisa. Vale ressaltar que, tais parâmetros afetam a velocidade de convergência e robustez do processo de otimização. Os valores adequados para NP , F_i e P_{CR} podem ser encontrados por tentativa e erro (SAUER, 2007).

3.5.3 Pseudocódigo da Evolução Diferencial

O processo de otimização encontra-se detalhado a seguir no pseudocódigo do algoritmo da ED, concebido para a minimização de uma função objetivo $f_0 : \mathbb{R}^n \rightarrow \mathbb{R}$, onde P_{CR} é a probabilidade de cruzamento (DAS & KONAR, 2009) (BRAAK, 2006).

Pseudocódigo de ED:

- 1) Gerar a população inicial de NP agentes aleatórios, cada um representado por um vetor X_i , onde $i = 1, 2, \dots, NP$;
- 2) Repetir até que seja satisfeito o critério de parada:
 - a) Para $i = 1, 2, \dots, NP$ faça
 - i) Dado um número aleatório $r \sim U[0,1]$;
 - ii) Se $r \leq P_{CR}$ então

- A) gerar agente mutado através da Tabela (3.1);
- B) gerar agente cruzado W_i através da expressão (3.7);
- C) se $f_0(W_i) < f_0(X_i)$ então $X_i \leftarrow W_i$ (minimização);

3.5.4 Estratégias da Evolução Diferencial

As estratégias da Evolução Diferencial são classificadas de acordo com: o tipo de indivíduo (vetor alvo) a ser modificado, o número de indivíduos utilizados para gerar uma perturbação e o tipo de cruzamento a ser utilizado. Desta forma, tais estratégias podem ser escritas como: **ED/a/b/c** (OLIVEIRA, 2006), onde os índices **a**, **b** e **c** são definidos abaixo:

a. Este índice indica o tipo de indivíduo a ser perturbado, podendo ser:

- *rand* : corresponde ao indivíduo da população escolhido aleatoriamente;
- *best* : corresponde ao indivíduo da população com menor ou maior valor da função objetivo nos casos de problemas de minimização ou maximização de parâmetros, respectivamente;

b. Este índice corresponde a quantidade de diferenças ponderadas utilizadas para compor a perturbação do vetor **a**;

c. Este índice denota o tipo de cruzamento, podendo ser:

- *exp*: cruzamento exponencial;
- *bin*: cruzamento binomial.

Apesar de existirem inúmeras combinações possíveis de vetores lineares que podem ser utilizadas para realizar a mutação da ED, Storn & Price (1997) estudaram apenas dez diferentes estratégias para a ED. Tais estratégias são derivadas dos cinco diferentes regimes clássicos da mutação da ED mostrados na Tabela 3.1. É importante mencionar que cada regime de mutação da ED foi combinado com um tipo de cruzamento *Exponencial* ou *Binomial*. Desta forma, foram totalizadas 10 (dez) estratégias de ED.

A Tabela 3.1 mostra a formulação usada para cada uma das 10 estratégias da ED.

Tabela 3.1 Principais estratégias da Evolução Diferencial. (OLIVEIRA, 2006)

Expressão da Mutaç�o	Notaç�o
$V_{i,G+1} = X_{\alpha,G} + F_i \cdot (X_{\beta,G} - X_{\gamma,G})$	ED/rand/1/Bin
$V_{i,G+1} = X_{\alpha,G} + F_i \cdot (X_{\rho,G} - X_{\beta,G}) + F_i \cdot (X_{\gamma,G} - X_{\delta,G})$	ED/rand/2/Bin
$V_{i,G+1} = X_{best,G} + F_i \cdot (X_{\beta,G} - X_{\gamma,G})$	ED/best/1/Bin
$V_{i,G+1} = X_{best,G} + F_i \cdot (X_{\rho,G} - X_{\beta,G}) + F_i \cdot (X_{\gamma,G} - X_{\delta,G})$	ED/best/2/bin
$V_{i,G+1} = X_{i,G} + F_i \cdot (X_{best,G} - X_{i,G}) + F_i \cdot (X_{\gamma,G} - X_{\delta,G})$	ED/rand-to-best/2/bin
$V_{i,G+1} = X_{\alpha,G} + F_i \cdot (X_{\beta,G} - X_{\gamma,G})$	ED/rand/1/exp
$V_{i,G+1} = X_{\alpha,G} + F_i \cdot (X_{\rho,G} - X_{\beta,G}) + F_i \cdot (X_{\gamma,G} - X_{\delta,G})$	ED/best/1/exp
$V_{i,G+1} = X_{best,G} + F_i \cdot (X_{\beta,G} - X_{\gamma,G})$	ED/rand/2/exp
$V_{i,G+1} = X_{best,G} + F_i \cdot (X_{\rho,G} - X_{\beta,G}) + F_i \cdot (X_{\gamma,G} - X_{\delta,G})$	ED/best/2/exp
$V_{i,G+1} = X_{i,G} + F_i \cdot (X_{best,G} - X_{i,G}) + F_i \cdot (X_{\gamma,G} - X_{\delta,G})$	ED/rand-to-best/2/exp

Os  ndices α , β , γ , ρ e δ s o inteiros mutuamente exclusivos escolhidos aleatoriamente a partir do intervalo $[1, n]$, onde n   o n mero de indiv duos da popula  o inicial, e todos s o diferentes do  ndice corrente i . Estes  ndices s o aleatoriamente gerados uma vez, para cada vetor doador. O vetor de amplifica  o F_i   um vetor de par metros de controle positivos para a expans  o dos vetores de diferen a, que possibilita o aumento da diversidade de candidatos   solu  o. $X_{best,G}$   o vetor indiv duo com a melhor aptid o (isto  , menor valor da fun  o objetivo para um problema de minimiza  o), na popula  o de gera  o G .

Outra estrat gia de ED foi proposta por Ribeiro et. al. (2014a), baseada na estrat gia ED/rand-to-best/2/bin com perturba  o, composta por duas diferen as ponderadas, aplicada sobre o vetor alvo $X_{best,G}$, como segue:

$$V_{i,G+1} = X_{best,G} + F_i \cdot (X_{i,G} - X_{best,G}) + F_i \cdot (X_{\gamma,G} - X_{\delta,G}) \quad (3.8)$$

De acordo com (RIBEIRO et. al., 2014a), esta nova estrat gia de ED possibilitou r pida converg ncia do algoritmo para reconstru  o de imagens de TIE quando comparada   forma cl ssica da Evolu  o Diferencial (ED/rand-to-best/2/bin).

4 DEMAIS TÉCNICAS DE BUSCA E OTIMIZAÇÃO

Neste capítulo são descritas as principais técnicas a serem hibridizadas com o Método de Otimização por Evolução Diferencial (ED), a fim de desenvolver uma nova técnica de ED com melhor rendimento, em termos de custo e tempo computacional.

4.1 BUSCA NÃO-CEGA

Saha e Bandyopadhyay (2008) afirmam que, a fim de evitar busca totalmente aleatória e acelerar a convergência dos algoritmos de otimização, deve-se definir a população inicial de soluções candidatas, utilizando soluções obtidas de métodos imprecisos simples e diretos (SAHA & BANDYOPADHYAY, 2008). De acordo com Feitosa (2014a, 2014b, 2014c) e Ribeiro (2014b, 2014d), o uso de técnicas da Computação Evolucionária para resolver o problema inverso mal-posto da TIE pode obter soluções razoáveis, usando um pequeno número de iterações quando o primeiro conjunto da população envolve uma solução candidata construída a partir da modificação, por acréscimo de valores aleatórios, do vetor solução obtido pelo método de Gauss-Newton.

O método de Gauss-Newton é considerado o mais eficiente método conhecido para resolver problemas de mínimos quadrados não-lineares (GONÇALVES, 2011) (ADLER et al., 2007).

Sejam H e Y espaços de Hilbert reais ou complexos, $\Omega \subset H$ um conjunto aberto e seja $F: \Omega \rightarrow Y$ Fréchet diferenciável. Considere o problema de mínimos quadrados não-lineares

$$\min ||F(h)||^2 \quad (4.1)$$

Se $F'(h)$ é injetiva e tem imagem fechada para todo $h \in \Omega$, o método de Gauss-Newton encontra pontos estacionários para o problema (4.1), i.e., a solução para o sistema de equações lineares dada por

$$F'(h)^* F(h) = 0 \quad (4.2)$$

onde $F(h)^*$ corresponde a matriz adjunta do operador $F(h)$. Formalmente o método de Gauss-Newton é descrito como: Dado $h_0 \in \Omega$ então

$$h_{k+1} = h_k + S_k, \quad F'(h_k)^* F'(h_k) S_k = -F'(h_k)^* F(h_k), \quad k = 0, 1, \dots \quad (4.3)$$

É importante ressaltar que h^* é a solução de (4.1). Por outro lado, note que cada passo do método de Gauss-Newton consiste em resolver um sistema de equações lineares, o que pode ser computacionalmente muito “caro” se o número de incógnitas for muito grande. Uma alternativa é resolver diretamente uma matriz de reconstrução linear que descreve o problema (ADLER et al., 2007), o que dá origem a uma nova classe do processo iterativo Gauss-Newton, conhecido como Gauss-Newton One-Step. Este método busca resolver o problema dos mínimos quadrados em uma única etapa. No caso do problema inverso da TIE, defini-se como

$$\begin{aligned} & \left\| y - J\hat{h} \right\|_{\Sigma_r^{-1}}^2 + \left\| h - Jh^o \right\|_{\Sigma_h^{-1}}^2 \\ & y = Jh + r \end{aligned} \quad (4.4)$$

onde h^o é o valor esperado de condutividade do elemento; $\Sigma_n \in \mathbb{R}^{n_M \cdot n_M}$ é a matriz de covariância do ruído r medido; $\Sigma_x \in \mathbb{R}^{n_N \cdot n_N}$ é a covariância da imagem esperada; $J \in \mathbb{R}^{n_M \cdot n_N}$ é a matriz Jacobiano, h é o vetor de mudança de condutividade; y é o vetor de mudança de potencial elétrico, e $\hat{h}$ é a solução do problema inverso da TIE.

Resolvendo o problema (4.4), a solução inversa de Gauss-Newton One-Step é obtida como

$$\hat{h} = \left(J^T \frac{1}{\sigma_r^2} UJ + \frac{1}{\sigma_h^2} P \right)^{-1} J^T \frac{1}{\sigma_r^2} Uy \quad (4.5)$$

onde $U = \sigma_r^2 \Sigma_r^{-1}$, $P = \sigma_h^2 \Sigma_h^{-1}$, σ_r é a medida da amplitude do ruído e σ_h é a amplitude da condutividade.

4.2 TOPOLOGIA EM ANEL

Esta técnica consiste na organização do conjunto de candidatos a solução (ou agentes) $\{X_i\}_{i=1}^{NP}$ como um anel lógico, possibilitando um maior controle na exploração e exploração do espaço de busca, onde cada i -ésimo agente x_i é logicamente conectado com agentes x_{i-1} e x_{i+1} , $\forall i = 1, 2, \dots, NP$ (RIBEIRO et al., 2014c) (FEITOSA et al., 2014b).

De acordo com Ribeiro (2014c), a topologia em anel é usada na geração do i -ésimo agente, através do cálculo dos vetores local e global, l_i e g_i , respectivamente, adaptando-os segundo a Expressão (ED/best/1/bin) da Tabela 3.1 tem-se:

$$l_i = X_{best} + F_i(x_p - x_q), \quad (4.6)$$

$$g_i = X_{best} + F_i(x_{j1} - x_{j2}), \quad (4.7)$$

sendo

$$p = (i - 1) \bmod n,$$

$$q = (i + 1) \bmod n,$$

onde X_{best} é o melhor agente na geração corrente, $F_i \sim U(0,2]$, e $i \neq j_1 \neq j_2$.

O i -ésimo agente, $\check{x}_i$, é então calculado como segue (RIBEIRO et al., 2014c) (FEITOSA et al., 2014b):

$$\check{x}_i = \beta_i g_i + (1 - \beta_i) l_i \quad (4.8)$$

onde o fator de peso $0 \leq \beta_i \leq 1$ controla o balanço entre exploração e exploração. Se $\beta_i = 1$, o algoritmo trabalha em um esquema de exploração absoluta. Se $\beta_i = 0$, exploração é adotada. No caso auto-adaptativo, os fatores de peso β_i associados a cada agente X_i são ajustados iterativamente como segue (RIBEIRO et al., 2014c) (FEITOSA et al., 2014b):

$$\beta_i \leftarrow \beta_{best} + F_i(\beta_{j1} - \beta_{j2}), \quad (4.9)$$

onde $\beta_i(0) \sim U[0,1], \forall i$, $F_i \sim U(0,2]$, e $i \neq j_1 \neq j_2$. β_{best} é o fator de peso associado ao melhor agente na geração corrente, X_{best} .

4.3 MUTAÇÃO CAÓTICA

Esta técnica quando associada com um algoritmo de Otimização pode ajudá-lo escapar de mínimos ou máximos locais, para tanto é importante preservar um certo grau de diversidade em cada geração do algoritmo estudado. Isto pode ser realizada através da seleção dos piores agentes (v_w), de acordo com a função objetivo definida para o problema, e adição de suas versões caóticas, de acordo com a Eq. (4.10), na próxima geração (RIBEIRO et al., 2014c) (CASEIRO, 2009). Com esta abordagem trazemos a ideia central da teoria do Caos fundada por volta do início da década de 1960 por Edward Lorenz, no qual uma pequenina mudança no início de um evento qualquer, isto é, a adição dos piores agentes modificados pela Eq. (4.10) na próxima geração do algoritmo de Otimização, pode trazer consequências enormes e absolutamente desconhecidas no futuro, ou seja, pode causar o surgimento de inúmeros candidatos à solução distintos (aumentando a diversidade da população) fazendo com que o algoritmo escape de mínimos ou máximos locais (DIAMOND, 1993) (RICIERI, 1990).

Os fatores de mutação caótica são usados para calcular m agentes caóticos como segue (ZHENYU et al., 2006) (COELHO & MARIANI, 2006):

$$X_i \leftarrow 4D_w(1 - D_w), \quad (4.10)$$

onde $\{D_i\}_{i=1}^{NP}$ é o conjunto de agentes X_i ordenados com valores altos de $f_0(X_i)$ (ver Eq. 2.8) à esquerda, isto é, altos valores da função objetivo a ser minimizada (Problema de Minimização da função objetivo). Além disso, os índices w e i assumem os valores:

$$\begin{aligned} w &= i + m - NP, \\ i &= NP - m + 1, NP - m + 2, \dots, NP, \end{aligned}$$

onde NP é o número total de agentes da população e m é o número total de agentes caóticos.

4.4 RECOZIMENTO SIMULADO

Recozimento Simulado ou *Simulated Annealing* (SA) é uma meta-heurística de otimização por busca local de escalada do monte, ou seja, ele pode pular mínimos locais permitindo maior exploração do espaço de busca, sendo baseado na teoria da termodinâmica de resfriamento de corpos (KIRKPATRICK et al., 1983). Ele aplica sequencialmente modificações aleatórias no ponto de avaliação da função objetivo (ou função custo). Se uma modificação leva um ponto de custo menor, é automaticamente mantido. Caso contrário, a modificação que produz um ponto de menor custo também pode ser mantido, com uma probabilidade obtida a partir da distribuição de Boltzman

$$P(\Delta E) = e^{-\frac{\Delta E}{kT}} \quad (4.11)$$

onde $P(\Delta E)$ é a probabilidade do processo de otimização de manter uma modificação que produz um aumento de ΔE (análogo a um aumento de energia térmica) na função objetivo; k é um parâmetro de processo (análogo à Constante de Stefan-Boltzman) normalmente assume valor 1; e T é a temperatura do processo. Esta temperatura é definida por um esquema de resfriamento, sendo o principal parâmetro de controle do processo. A probabilidade de um determinado estado diminuir com a sua energia, mas à medida que a temperatura sobe, esta diminuição [a inclinação da curva $P(\Delta E)$] diminui (MARTINS & TSUZUKI, 2012). Além

disso, pode-se afirmar que o SA converge para o mínimo global, mas requer uma redução de temperatura muito lenta e um número de iterações muito grande (KIRKPATRICK et al., 1983).

O que ocorre em cada iteração do SA adaptado para reconstrução de TIE está esquematizado a seguir (MARTINS & TSUZUKI, 2012):

Pseudocódigo do SA:

- 1) $S^* \leftarrow S$; // Solução inicial;
- 2) $T \leftarrow T_0$; // Temperatura inicial;
- 3) k ; // parâmetro de processo;
- 4) γ ; // constante aleatória $\in [0,1]$;
- 5) $IterT_{max}$; // Iteração máxima para estabilidade da temperatura;
- 6) enquanto Critério de Parada não satisfeito faça
- 7) $IterT \leftarrow 0$; // Iterações para estabilidade da temperatura;
- 8) enquanto ($IterT < IterT_{max}$) faça
- 9) $IterT \leftarrow IterT + 1$;
- 10) $S' \leftarrow GerarVizinhoQualquer(S)$;
- 11) $\Delta E \leftarrow f(S') - f(S)$; // mudança da função objetivo f
- 12) se ($\Delta E < 0$) então $S \leftarrow S'$;
- 13) se ($f(S') < f(S^*)$) então $S^* \leftarrow S'$;
- 14) senão
- 15) tome aleatoriamente $P \in [0,1]$;
- 16) se ($P < e^{-\frac{\Delta E}{kT}}$) então $S \leftarrow S'$;
- 17) fim-enquanto;
- 18) $T \leftarrow \frac{T}{1+\gamma\sqrt{T}}$;
- 19) $IterT \leftarrow 0$;

```
20) fim-enquanto;  
21)  $S \leftarrow S^*$ ;  
22) Retorne  $S^*$ ;  
fim SimulatedAnnealing.
```

Com relação à função *GerarVizinhoQualquer*(S), esta é responsável por obter uma solução vizinha no espaço de busca da solução corrente (S) e depende do problema a ser resolvido.

5 RECONSTRUÇÃO DE IMAGENS DE TIE UTILIZANDO EVOLUÇÃO DIFERENCIAL

5.1 OTIMIZAÇÃO EM TIE


A proposta principal do presente trabalho foi resolver o problema inverso da TIE considerando-o como um problema de minimização da função objetivo (Eq. 2.8), que calcula o erro relativo entre a distribuição de potenciais de borda de uma imagem ouro, criada pelo autor (na plataforma EIDORS), e a distribuição de potenciais de borda dos candidatos à solução gerados pelos métodos de busca e otimização utilizados neste trabalho. Neste capítulo é descrita a implementação de cada um dos métodos de busca e otimização aplicados para resolver este problema.

5.2 INFRAESTRUTURA

Para se realizar os experimentos foi utilizado o *software* EIDORS - “*Electrical Impedance Tomography and Diffuse Optical Tomography Reconstruction Software*”, uma ferramenta computacional de código aberto, voltada para a TIE, desenvolvida desde 1999 para plataformas **MatLab** (versões $\geq 2008a$) e **Octave** (versões ≥ 3.6). A mesma é caracterizada por fornecer gratuitamente diversos algoritmos de resolução do problema inverso da TIE, tais como: Gauss-Newton (ADLER et al., 2007), GREIT (ADLER et al., 2009), NOSER (CHENEY et al., 1990) e Backprojection (SANTOSA & VOGELIUS, 1990). Esta ferramenta possibilita realizar algumas tarefas relativas à TIE que não são triviais, como a resolução dos problemas direto e inverso para um domínio qualquer, ou a representação gráfica de um vetor candidato à solução em uma malha de elementos finitos triangulares, a fim de se avaliar visualmente sua distribuição de condutividade elétrica.

O vetor candidato à solução contém os valores de condutividade elétrica de cada um dos elementos finitos triangulares do domínio em estudo. Abaixo segue uma malha gerada pelo EIDORS (ver Figura 5.1). Nesta malha, cada triângulo representa graficamente um elemento finito, e seu respectivo número corresponde ao índice do vetor candidato à solução que contém o valor de condutividade elétrica deste elemento.

Figura 5.1 Malha de elementos finitos triangulares gerada pelo EIDORS.




Portanto, 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 o valor de condutividade elétrica correspondente ao seu respectivo elemento triangular.

A configuração do EIDORS utilizada nesta pesquisa, obtida empiricamente para representar um fantoma numérico, gerou uma malha circular contendo 415 elementos finitos triangulares, ou seja, cada vetor candidato à solução tem 415 posições (dimensão do vetor), das quais cada uma contém a condutividade elétrica de seu respectivo elemento da malha.

A conversão de um vetor candidato à solução em uma imagem de distribuição de condutividade elétrica é feita pelo EIDORS e só é realizada quando necessária, no caso de 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 as condutividades elétricas do domínio sob estudo.

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

Figura 5.2 Distribuição de condutividade elétrica representada graficamente.




Na qual a cor vermelho escuro representa uma alta condutividade, e azul escuro uma baixa condutividade. As transições entre baixa e alta condutividade sob o ponto de vista numérico são representadas pelas cores intermediárias (amarelo, cinza, etc.) da barra de cores vertical presente à direita da Figura 5.2. Também podemos perceber a presença de artefatos de imagem (em cor azul), correspondentes a valores negativos de condutividade elétrica. Tais artefatos são resultados das aproximações numéricas durante a resolução do problema direto da TIE (ADLER et al., 2009).

5.3 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 (2.8). Nos experimentos realizados nesta pesquisa foram utilizados dados obtidos por simulação computacional. Um objeto (de alta condutividade), criado pelo autor, foi posicionado no centro, na borda ou entre o centro e a borda (intermediário) do domínio. A partir desta configuração do domínio foi resolvido o problema direto, a fim de gerar os potenciais elétricos de borda. Estes potenciais de borda simulam os potenciais medidos por eletrodos na superfície de um fantoma físico contendo em seu interior o objeto nas três posições citadas anteriormente. Estes objetos isolados são mostrados e detalhados, no próximo capítulo.

A seguir encontra-se um esquema de como foi feito o cálculo da função objetivo para um candidato à solução.

Figura 5.3 Esquema da resolução da função objetivo.



Através da resolução do problema direto, um vetor contendo a distribuição interna de condutividade foi transformado em um vetor de potenciais de borda. E por fim, utilizando a função objetivo, foi calculado o erro relativo entre os dois vetores de potenciais elétricos.

Na prática, a resolução do problema direto para a imagem ouro foi feita apenas uma vez por execução do algoritmo, devido ao fato de os potenciais de borda da imagem ouro serem independentes da técnica de otimização da função objetivo.

Desta forma, quanto mais próximos forem os valores dos potenciais de borda, calculados para o candidato à solução, daqueles valores dos potenciais de borda da imagem ouro, menor será o erro relativo (minimização da função objetivo). Esta característica configura o problema da TIE como um problema de minimização do erro relativo que pode ser resolvido utilizando as técnicas propostas neste trabalho e citadas nas próximas seções. É essencial mencionar que, para todas as técnicas propostas, os parâmetros foram obtidos de forma empírica com base nas simulações computacionais realizadas e os menores valores da função objetivo encontrados por elas. O critério de parada foi utilizado como o número máximo de gerações (ou iterações), sendo escolhido através de simulações que mostraram mudanças insignificantes da função objetivo, quando utilizado critério de parada acima de 500 gerações. Além disso, foi gerada a imagem de TIE e computado o erro relativo do

candidato mais apto à solução (isto é, com menor valor da função objetivo) presente na população a cada 50 gerações.

5.4 ALGORITMOS GENÉTICOS

Para implementar o método de busca e otimização por Algoritmos Genéticos (AG) na reconstrução de imagens em TIE, foram necessárias propor algumas analogias baseadas na teoria genética de Mendel como: os cromossomos da técnica AG foram representados em TIE pelos vetores de condutividade elétrica, isto é, as imagens de TIE candidatas à solução. Os genes foram representados pelas posições de tal vetor, isto é, os elementos finitos triangulares das imagens de TIE.

Na aplicação desta técnica foram utilizados os seguintes parâmetros obtidos empiricamente:

Tabela 5.1 Parâmetros utilizados para Algoritmos Genéticos.

Parâmetro	Valor
População Inicial	100 cromossomos
Seleção	10 cromossomos melhores avaliados
Probabilidade de Cruzamento	100%
Probabilidade de mutação	100% da prole
Critério de Parada	500 gerações

É importante enfatizar que, os cromossomos da população inicial foram definidos com uma distribuição de condutividade interna aleatória no intervalo $[0,1]$.

5.5 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS

Na implementação do método de busca OEP para resolver o problema de reconstrução em TIE, foi realizada a seguinte analogia: cada partícula do algoritmo foi representada por um vetor de condutividade elétrica, isto é, a imagem de TIE candidata à solução.

Na atualização das posições das partículas pela expressão já descrita (ver Seção 3.4), os vetores de condutividade têm seus conteúdos variados. Desta forma, acontece a exploração no espaço de busca por um candidato à solução que possua o menor valor da função objetivo.

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

Tabela 5.2 Parâmetros utilizados para Otimização por Enxame de Partículas.

Parâmetro	Valor
Partículas Iniciais	100
v (velocidade inicial)	8,5
ϕ_1	2,0992
ϕ_2	1,9008
Critério de Parada	500 iterações

É importante mencionar que, partículas iniciais foram definidas com uma distribuição de condutividade interna aleatória no intervalo $[0,1]$.

5.6 RECOZIMENTO SIMULADO

Como a técnica de busca e otimização por Recozimento Simulado (SA) é baseada na teoria da Termodinâmica de resfriamento de corpos, verificou-se a necessidade de fazer algumas analogias a fim de resolver o problema de reconstrução em TIE, sendo elas: a energia térmica foi representada pela função objetivo (Eq. 2.8), a Constante de Stefan-Boltzman foi representada pelo parâmetro de processo “ k ” e o corpo a ser resfriado foi representado por um vetor de condutividade elétrica, isto é, a imagem de TIE candidata à solução.

De acordo com o pseudocódigo do SA (ver Seção 4.4), para resolver o problema da TIE foi implementada a função *GerarVizinhoQualquer*(S) para obter um novo candidato à solução no espaço de busca da solução corrente (S). O novo candidato foi obtido através da adição de um ruído aleatório máximo de 5% sobre um elemento de condutividade da solução (S) escolhido aleatoriamente. É importante mencionar que, no momento em que a mudança do valor de um elemento de condutividade resultar na geração de um novo candidato à solução pior, i.e. resultar num aumento da função objetivo, o algoritmo evita a modificação deste elemento de condutividade durante todas as demais iterações até a convergência.

Como citado na Seção 4.4, o candidato à solução com alto valor da função objetivo associado também pode ser mantido com uma probabilidade obtida a partir da Equação (4.11). Tal fato possibilita o SA evitar mínimos locais. Daí observou-se que, quanto maior a

temperatura associada ao candidato à solução maior será a probabilidade para evitar mínimos locais, contribuindo para uma convergência mais rápida do algoritmo. Por isso, foi atribuído o valor de 200.000 como temperatura inicial.

Tabela 5.3 Parâmetros utilizados para Recozimento Simulado.

Parâmetro	Valor
Temperatura inicial	200.000
Parâmetro de processo	1
Iteração máxima para estabilidade da temperatura	100
Critério de parada	500 iterações

Para esta técnica, o candidato à solução inicial foi definido com uma distribuição de condutividade interna aleatória no intervalo $[0,1]$.

5.7 EVOLUÇÃO DIFERENCIAL

Para esta técnica foram realizados experimentos em cada uma das cinco versões encontradas na literatura bem como para uma versão modificada pelo autor deste trabalho (RIBEIRO et. al., 2014a). Para implementação, o agente referido pelo algoritmo de ED foi representado por um vetor numérico que contém os valores de condutividade interna de um candidato à solução, ou seja, o agente é um candidato à solução do problema de TIE. Para todas as versões de ED foram utilizados os seguintes parâmetros obtidos empiricamente:

Tabela 5.4 Parâmetros utilizados para todas as versões de ED.

Parâmetro	Valor
Número inicial de agentes	100
Probabilidade de cruzamento	90%
Critério de parada	500 iterações

Para todas as versões de ED, os agentes iniciais foram definidos com uma distribuição de condutividade interna aleatória no intervalo $[0,1]$.

5.8 EVOLUÇÃO DIFERENCIAL HÍBRIDA

5.8.1 Evolução Diferencial com Busca Não-Cega

De acordo com Saha e Bandyopadhyay (2008), pode-se evitar a busca totalmente aleatória e acelerar a convergência dos algoritmos de otimização através da definição de uma população inicial de soluções candidatas utilizando soluções obtidas de métodos imprecisos simples e diretos. Portanto, o uso da Evolução Diferencial para resolver o problema da TIE pode obter soluções razoáveis usando um pequeno número de iterações quando o primeiro conjunto da população envolve uma solução candidata, construída usando uma versão modificada da solução obtida pelo método de Gauss-Newton.

Consequentemente, propomos neste trabalho uma versão híbrida de ED baseada na teoria de Saha e Bandyopadhyay, passa-se a chamar de ED-BNC, cujo pseudocódigo é descrito a seguir.

Pseudocódigo de ED-BNC:

- 1) Gerar a população inicial de $NP-1$ agentes aleatórios, cada um representado por um vetor X_i , onde $i = 1, 2, \dots, NP-1$;
- 2) Definir o valor de P_{CR} ;
- 3) Incluir um agente na população inicial correspondente à solução ruidosa do método de Gauss-Newton;
- 4) Repetir até que seja satisfeito o critério de parada:
 - i) Para $i = 1, 2, \dots, NP$ faça
 - ii) Dado um número aleatório $r \sim U[0,1]$;
 - iii) Se $r \leq P_{CR}$ então
 - A) Gerar agente mutado V_i através do operador de mutação ED/best/1/bin (Tabela 3.1);
 - B) Gerar agente cruzado W_i através da Eq. (3.7);
 - C) Se $f_0(W_i) < f_0(X_i)$ então $X_i \leftarrow W_i$ (minimização);

Lembrando que, P_{CR} é a probabilidade de cruzamento e f_0 corresponde à função objetivo, dada pela Eq. (2.8), citada e detalhada na Seção 2.6.

Para implementação da técnica ED-BNC, foram utilizados os seguintes parâmetros obtidos empiricamente:

Tabela 5.5 Parâmetros utilizados para a técnica ED-BNC.

Parâmetro	Valor
Número de Agentes Aleatórios	99
Número de Agentes Gauss-Newton	1
Probabilidade de cruzamento	90%
Critério de Parada	500 gerações

Para a técnica ED-BNC, os agentes iniciais ($NP-1$) foram definidos com uma distribuição de condutividade interna aleatória no intervalo $[0,1]$.

5.8.2 Evolução Diferencial com Topologia em Anel e Mutação Caótica

De acordo com Ribeiro (2014c), a topologia em anel trata-se de uma técnica que consiste na organização do conjunto de candidatos à solução (ou agentes) como um anel lógico, possibilitando um maior controle na exploração e exploração do espaço de busca. Desta forma, a topologia em anel pode ser usada para aumentar a diversidade da população de agentes em cada geração do algoritmo de Evolução Diferencial. Também segundo Ribeiro (2014c), o algoritmo de ED pode evitar problemas de mínimo local através da seleção dos piores agentes (v_w) da geração corrente, adicionando-os como agentes caóticos na próxima geração, gerando uma perturbação no sistema. Tal estratégia é chamada de Mutação Caótica. Neste caso, propomos neste trabalho uma versão híbrida de ED baseada na Topologia em Anel e Mutação Caótica (ED-TAMC), possibilitando gerar uma maior diversidade da população de soluções candidatas e, ao mesmo tempo, evitando problemas de mínimo local resultando numa convergência mais rápida do algoritmo de ED.

Pseudocódigo de ED-TAMC:

- 1) Geração da população inicial de NP agentes, cada um representado por um vetor X_i , onde $i = 1, 2, \dots, NP$;
- 2) Definir o valor de P_{CR} ;
- 3) Organizar os agentes da população inicial na forma de anel lógico;
- 4) Repetir até o critério de parada ser alcançado:

- a) Ordenar agentes X_i com valores altos de $f_0(X_i)$ à esquerda, gerando o conjunto $\{D_i\}_{i=1}^n$;
- b) Para $j = 1, 2, \dots, NP$ faça
 - A) Gerar um número aleatório $r \sim U[0,1]$;
 - B) Se $r \leq P_{CR}$ então
 - a) Gerar agente local através da Eq. (4.6);
 - b) Gerar agente global através da Eq. (4.7);
 - c) Gerar agente mutado através da Eq. (4.8);
 - b) Gerar agente cruzado W_j através da Eq. (3.7);
 - c) Se $f_0(W_j) < f_0(X_j)$ então $X_j \leftarrow W_j$ (minimização);
 - d) Atualizar o fator de peso do anel através da Eq. (4.9);
- c) Para $i = NP - m + 1, \dots, NP$ faça:
 - i) $c = i + m - NP$;
 - ii) Se $X_i \neq X_{best}$ então $X_i \leftarrow 4D_c(1 - D_c)$.

Lembrando que, m é o número de agentes caóticos, x_{best} é o melhor agente da população corrente, P_{CR} é a probabilidade de cruzamento e f_0 corresponde à função objetivo, dada pela Eq. (2.8), citada e detalhada na Seção 2.6.

Para implementação da técnica ED-TAMC, foram utilizados os seguintes parâmetros obtidos empiricamente:

Tabela 5.6 Parâmetros utilizados para a técnica ED-TAMC.

Parâmetro	Valor
Número inicial de agentes	100
Número de agentes caóticos	30
Probabilidade de cruzamento	90%
Critério de parada	500 gerações

Para a técnica ED-TAMC, os agentes iniciais foram definidos com uma distribuição de condutividade interna aleatória no intervalo $[0,1]$.

5.8.3 Evolução Diferencial com Recozimento Simulado

De acordo com Liu (2011), por causa de a ED possuir um caráter de busca global mais forte, isto implica que poucas gerações são suficientes para encontrar uma solução próxima da ideal. No entanto, de acordo com seu algoritmo, cada geração requer a realização de seleção, cruzamento e mutação dos agentes da população corrente, desta forma exigindo alto custo computacional, ou seja, alto número de cálculos da função objetivo. Já a técnica SA, é caracterizada por ser um algoritmo de busca local com alta velocidade de convergência, devido ao fato de ser capaz de evitar mínimos locais (LIU et. al., 2007) (PEICHONG et. al., 2010). Desta forma, neste trabalho é proposta uma versão híbrida de ED baseada em Recozimento Simulado (ED-SA), que consiste na implementação da ED adicionando o Recozimento Simulado (SA) dentro do operador de seleção para melhorar a capacidade de busca global da ED.

Pseudocódigo de ED-SA:

1) Inicialização:

Gerar a população inicial de n agentes aleatórios D dimensional, cada um representado por um vetor $X_{j,i,G} = rand_{j,i} [0, 1]$, onde $j = 1, 2, 3, \dots, D$; $i = 1, 2, \dots, NP$; G é a geração corrente; $F_i = rand(0,2]$ é fator de escala de mutação para cada indivíduo.

2) Definir o valor de P_{CR} ;

3) Mutação da População:

A mutação da população é baseada na estratégia de ED/best/1/bin. Como mostrada pela Tabela (3.1)

$$V_{j,i,G} = X_{j,best,G} + F_i(X_{j,i_1,G} - X_{j,i_2,G})$$

onde $i_1 \neq i_2 \neq i$ e $X_{j,best,G}$ corresponde ao agente mais apto na geração corrente.

4) Cruzamento da População:

O cruzamento da população é baseado na operação Binomial de cruzamento da ED, como mostrada pela Eq. (3.7).

$$W_{j,i,G} = \begin{cases} V_{j,i,G} , & \text{se } (rand_{j,i}(0,1) \leq P_{CR} \text{ ou } j = j_{rand}) \\ X_{j,i,G} , & \text{caso contrário} \end{cases}$$

5) Seleção da população:

A seleção da população é processada comparando o vetor alvo $X_{j,i,G}$ com o vetor de julgamento $W_{j,i,G}$ da população. Além disso, Recozimento Simulado é adicionado dentro do operador de seleção, t_G representa a temperatura ambiente da geração corrente.

$$t_{G+1} = t_G / (1 + G * \sqrt[2]{t_G})$$

$$X_{j,i,G+1} = \begin{cases} W_{j,i,G}, & \text{se } f_0(W_{j,i,G}) \leq f_0(X_{j,i,G}) \\ W_{j,i,G}, & \text{se } f_0(W_{j,i,G}) > f_0(X_{j,i,G}) \text{ e } \text{resto}(G/4) = 0 \\ & \text{e } f_0(W_{j,best,G}) = f_0(X_{j,best,G-1}) \\ & \text{e } f_0(W_{j,best,G}) = f_0(X_{j,best,G-2}) \\ e \exp\left(-\left(f_0(W_{j,i,G}) - f_0(X_{j,i,G})\right)/t_G\right) > \text{rand}(0,1) \\ X_{j,i,G}, & \text{Caso contrário} \end{cases}$$

onde $W_{j,best,G}$ é o agente mais apto da geração corrente, $X_{j,best,G-1}$ é o agente mais apto da geração $(G - 1)$ e $X_{j,best,G-2}$ é o agente mais apto da geração $(G - 2)$. Estas condições são implementadas, para avaliar a cada quatro gerações do algoritmo, se o valor da função objetivo do melhor candidato à solução assumiu nas últimas três gerações um mínimo local. Caso isso ocorra, o vetor de julgamento $W_{j,i,G}$ pode ser mantido para a próxima geração, se satisfizer a condição imposta pela expressão exponencial baseada na probabilidade do processo de otimização do SA (Eq. 4.11 da Seção 4.4).

6) Parar se o critério de parada for satisfeito. Caso contrário, voltar a Etapa 3.

Lembrando que, P_{CR} é a probabilidade de cruzamento e f_0 corresponde à função objetivo, dada pela Eq. (2.8), citada e detalhada na Seção 2.6. Também para a técnica ED-SA, os agentes iniciais foram definidos com uma distribuição de condutividade interna aleatória no intervalo $[0,1]$.

Para implementação da técnica ED-SA, foram utilizados os seguintes parâmetros obtidos empiricamente:

Tabela 5.7 Parâmetros utilizados para a técnica ED-SA.

Parâmetro	Valor
Número inicial de agentes	100
Probabilidade de cruzamento	90%
Temperatura ambiente inicial	200.000
Critério de parada	500 gerações

6 EXPERIMENTOS, RESULTADOS E DISCUSSÃO

Os experimentos foram realizados a fim de se avaliar o desempenho das técnicas descritas nos Capítulos 3 a 5. Essas 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.

6.1 CARACTERÍSTICAS GERAIS DOS EXPERIMENTOS


Para todos os experimentos, foram utilizados como objetos de comparação (ou imagens ouro) três configurações de distribuição de condutividade elétrica no domínio circular, criadas pelo usuário, com objetos posicionados no centro, na borda e entre o centro e a borda (intermediário). A avaliação foi realizada de duas maneiras:

Quantitativa: cálculo do erro relativo feito pela função objetivo (Eq. 2.8) do melhor candidato à solução, encontrado pelo algoritmo ao final de cada geração, a fim de avaliar o custo e o tempo computacional para reconstrução de imagens de TIE. Assim como busca a técnica que encontra um menor valor de erro relativo em um menor número de avaliações da função objetivo e/ou em um menor tempo de reconstrução. A avaliação da função objetivo é a etapa mais custosa computacionalmente em todas as técnicas devido ao fato de resolver o problema direto da TIE para cada candidato à solução.

Qualitativa: esta avaliação foi realizada através da comparação visual das imagens reconstruídas com as imagens ouro, a fim de avaliar o quão parecido o melhor candidato à solução encontrado pelo algoritmo, ao final de cada geração, é com a imagem ouro.

A seguir são mostradas as imagens ouro, criadas pelo autor deste trabalho, a serem reconstruídas pelas técnicas propostas neste trabalho.

Figura 6.1 Imagens ouro utilizadas como fantoma nos experimentos.



Na Fig. 6.1, a área em marrom é uma área de maior condutividade, definida como 5 S/m, e a área branca, de menor condutividade, definida como 0 S/m. As figuras representam objetos de alta condutividade localizados no centro; entre o centro e a borda; e próximo a borda de um domínio circular, respectivamente. Tais configurações foram utilizadas a fim de simular computacionalmente a presença de um tumor, caracterizado pela alta condutividade elétrica, dentro de um corpo humano.

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

Tabela 6.1 Parâmetros do EIDORS utilizados nos experimentos.

Parâmetro	Valor
Número de eletrodos	16
Densidade da malha	“b”
Refinamento da malha	“2”
Dimensão dos candidatos à solução	415 elementos


A quantidade de candidatos à solução também foi um fator comum para todos os algoritmos implementados, exceto para o Recozimento Simulado, sendo 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 foram criados 99 candidatos à solução com distribuições aleatórias em adição com um candidato obtido pelo método de 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. Foram utilizados os *softwares* MatLab R2008a e EIDORS versão 3.7.1, para a implementação de todos os algoritmos propostos neste trabalho.

6.2 RESULTADOS DA APLICAÇÃO DOS AG's

A seguir são mostrados os resultados para AG canônico para objeto isolado localizado no centro, entre o centro e a borda, e perto da borda, respectivamente:

Figura 6.2 Imagens reconstruídas com objeto no centro, entre o centro e a borda, e perto da borda, respectivamente, para AG.



onde, (a), (b) e (c) representam os objetos isolados posicionados no centro, entre o centro e a borda, e perto da borda, respectivamente. As figuras (a1), (a2) e (a3) representam a imagem do melhor candidato à solução para o objeto no centro em 50, 300 e 500 iterações, respectivamente. As figuras (b1), (b2) e (b3) representam a imagem do melhor candidato à solução para o objeto entre o centro e a borda em 50, 300 e 500 iterações; respectivamente. E as figuras (c1), (c2) e (c3) representam a imagem do melhor candidato à solução para o objeto perto da borda em 50, 300 e 500 iterações, respectivamente.

A seguir são mostrados os resultados quantitativos, através do comportamento do erro relativo do melhor indivíduo presente na população com relação ao custo e ao tempo computacional.

Figura 6.3 Erro relativo ao longo das iterações para AG.





Figura 6.4 Erro relativo ao longo do tempo para AG.



onde a linha azul representa a evolução da função objetivo para o objeto localizado no centro; a linha vermelha para o objeto localizado entre o centro e a borda do domínio; e a verde para objeto localizado perto da borda.

6.2.1 Discussão dos resultados para AG's


Qualitativamente, a partir da Figura (6.2) é possível ver que o AG conseguiu gerar imagens anatomicamente consistentes, isto é, encontrou os objetos isolados mostrados na Figura (6.1), em apenas 300 iterações e também conclusivas, tendo em vista que conseguiu delimitar as bordas dos objetos isolados, a técnica mostrou-se capaz de reconstruir imagens com poucos artefatos, em um número razoável de iterações. Quantitativamente, a partir da Figura (6.3) é possível observar que o custo computacional para reconstrução de imagens de

TIE nas três configurações são iguais. A partir da Figura (6.4) é possível observar que o AG mostrou uma queda lenta do erro relativo para a reconstrução do objeto isolado posicionado na borda do domínio, logo para tal configuração o AG necessitou de maior tempo computacional para reconstrução de TIE. Enfim, o AG mostrou ser uma técnica capaz de fazer boas reconstruções de imagens de TIE.

6.3 RESULTADOS DA APLICAÇÃO DE OEP

A seguir são mostrados os resultados para OEP canônico para objeto isolado localizado no centro; entre o centro e a borda; e perto da borda, respectivamente:

Figura 6.5 Imagens reconstruídas com objeto no centro, entre o centro e a borda, e perto da borda, respectivamente; para Otimização por Enxame de Partículas canônico.



onde, (a), (b) e (c) representam os objetos isolados posicionados no centro; entre o centro e a borda; e perto da borda, respectivamente. As figuras (a1), (a2) e (a3) representam a imagem

do melhor candidato à solução para o objeto no centro em 50, 300 e 500 iterações, respectivamente. As figuras (b1), (b2) e (b3) representam a imagem do melhor candidato à solução para o objeto entre o centro e a borda em 50, 300 e 500 iterações, respectivamente. E figuras (c1), (c2) e (c3) representam a imagem do melhor candidato à solução para o objeto perto da borda em 50, 300 e 500 iterações, respectivamente.

A seguir estão representados os resultados quantitativos, através do comportamento do erro relativo da melhor partícula presente no enxame com relação ao custo e ao tempo computacional.

Figura 6.6 Erro relativo ao longo das iterações para objeto localizado no centro para OEP e AG.




Figura 6.7 Erro relativo ao longo das iterações para objeto localizado entre o centro e a borda para OEP e AG.




Figura 6.8 Erro relativo ao longo das iterações para objeto localizado perto da borda para OEP e AG.




Figura 6.9 Erro relativo ao longo do tempo para objeto localizado no centro para OEP e AG.




Figura 6.10 Erro relativo ao longo do tempo para objeto localizado entre o centro e a borda para OEP e AG.





Figura 6.11 Erro relativo ao longo do tempo para objeto localizado perto da borda para OEP e AG.



onde a linha azul representa a evolução da função objetivo para reconstrução usando AG e a linha vermelha a evolução da função objetivo para reconstrução usando OEP.

6.3.1 Discussão dos resultados para OEP

A OEP canônica não conseguiu gerar resultados anatomicamente consistentes para todas as configurações utilizadas. Estes resultados podem ser vistos na Figura (6.5), onde podemos perceber a presença constante de artefatos de imagem invertida.

Qualitativamente, quando comparada com a OEP canônica, o AG mostrou uma capacidade de gerar imagens com menos artefatos a partir de 300 iterações para todas as configurações, mostrando-se como uma potencial técnica contra artefatos de imagem invertida.

Através do comportamento do erro relativo ao longo das iterações mostrado nas Figuras (6.6), (6.7) e (6.8), apesar do AG e OEP terem mesmo custo computacional para reconstrução de TIE, o AG mostrou, quando comparada à OEP canônica, grande capacidade de escapar de mínimos locais, isto é, escapar da estagnação do erro relativo como aconteceu com a OEP canônica. Tal capacidade do AG está relacionada com a alta diversidade da população a cada geração do algoritmo, devido à alta probabilidade de mutação e cruzamento dos indivíduos da população.


Através do comportamento do erro relativo ao longo do tempo mostrado nas Figuras (6.9), (6.10) e (6.11), o AG geralmente possui maior tempo computacional para reconstrução de imagens de TIE, quando comparada à OEP, tendo em vista o AG possui geralmente

soluções iniciais com maior erro relativo associado. Desta forma, vemos que a OEP é uma boa técnica para gerar soluções nas primeiras iterações.

6.4 RESULTADOS DA APLICAÇÃO DE SA

Como nos resultados anteriores, a seguir são mostrados os resultados para SA canônico para objeto isolado localizado no centro; entre o centro e a borda; e perto da borda, respectivamente:

Figura 6.12 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Recozimento Simulado canônico.



onde, (a), (b) e (c) representam os objetos isolados posicionados no centro; entre o centro e a borda; e perto da borda, respectivamente. As figuras (a1), (a2) e (a3) representam a imagem do melhor candidato à solução para o objeto no centro em 50, 300 e 500 iterações, respectivamente. As figuras (b1), (b2) e (b3) representam a imagem do melhor candidato à

solução para o objeto entre o centro e a borda em 50, 300 e 500 iterações, respectivamente. E figuras (c1), (c2) e (c3) representam a imagem do melhor candidato à solução para o objeto perto da borda em 50, 300 e 500 iterações, respectivamente.

A seguir estão representados os resultados quantitativos, através do comportamento do erro relativo do candidato à solução com relação ao custo e ao tempo computacional.

Figura 6.13 Erro relativo ao longo das iterações para objeto localizado no centro para OEP, AG e SA.




Figura 6.14 Erro relativo ao longo das iterações para objeto localizado entre o centro e a borda para OEP, AG e SA.




Figura 6.15 Erro relativo ao longo das iterações para objeto localizado perto da borda para OEP, AG e SA.




Figura 6.16 Erro relativo ao longo do tempo para objeto localizado no centro para OEP, AG e SA.




Figura 6.17 Erro relativo ao longo do tempo para objeto localizado entre o centro e a borda para OEP, AG e SA.





Figura 6.18 Erro relativo ao longo do tempo para objeto localizado perto da borda para OEP, AG e SA.



onde a linha azul representa a evolução da função objetivo para reconstrução usando AG, a linha vermelha usando OEP e a linha verde usando SA.

6.4.1 Discussão dos resultados para o SA

O SA canônico conseguiu gerar resultados anatomicamente consistentes e conclusivos a partir de 300 iterações para todas as configurações. Estes resultados podem ser vistos na Figura (6.12).

Qualitativamente, quando comparada com a OEP canônica e ao AG canônico, o SA mostrou uma capacidade de gerar imagens com menos artefatos a partir de 300 iterações para todas as configurações, mostrando-se como uma potencial técnica contra artefatos de imagem.

Através do comportamento do erro relativo ao longo das iterações mostrado nas Figuras (6.13), (6.14) e (6.15), apesar do SA, AG e OEP terem mesmo custo computacional para reconstrução de TIE, o SA mostrou, quando comparada à OEP e AG canônico, grande capacidade de escapar de mínimos locais, isto é, escapar da estagnação do erro relativo como aconteceu com a OEP canônica. Tal capacidade do SA está relacionada à probabilidade do processo de otimização (ver Seção 4.4) obtida a partir da distribuição de Boltzman.

Através do comportamento do erro relativo ao longo do tempo mostrado nas Figuras (6.16), (6.17) e (6.18), o SA geralmente possui maior tempo computacional para reconstrução de imagens de TIE, quando comparada à OEP e ao AG.

6.5 RESULTADOS DA APLICAÇÃO DE ED

Para 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 ED, já descritas neste trabalho, além de uma versão modificada (ED-M) proposta em (RIBEIRO et. al., 2014a).

Figura 6.19 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Evolução Diferencial clássica (ED-1) (ED/rand/1/bin).




Figura 6.20 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Evolução Diferencial (ED-2) (ED/rand/2/bin).





Figura 6.21 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Evolução Diferencial (ED-3) (ED/best/1/bin).






Figura 6.22 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Evolução Diferencial (ED-4) (ED/best/2/bin).





Figura 6.23 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Evolução Diferencial (ED-5) (ED/rand-to-best/2/bin).







Figura 6.24 Imagens reconstruídas com objeto no centro; entre o centro e a borda; e perto da borda, respectivamente; para Evolução Diferencial modificada (ED-M).



onde, (a), (b) e (c) representam os objetos isolados posicionados no centro, entre o centro e a borda, e perto da borda, respectivamente; (a1), (a2) e (a3) representam a imagem do melhor candidato à solução para o objeto no centro em 50, 300 e 500 iterações, respectivamente; (b1), (b2) e (b3) representam a imagem do melhor candidato à solução para o objeto entre o centro e a borda em 50, 300 e 500 iterações, respectivamente; e (c1), (c2) e (c3) representam a imagem do melhor candidato à solução para o objeto perto da borda em 50, 300 e 500 iterações, respectivamente.

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

Figura 6.25 Erro relativo ao longo das iterações para objeto isolado localizado no centro para as versões de ED.




Figura 6.26 Erro relativo ao longo das iterações para objeto isolado localizado entre o centro e a borda para as versões de ED.






Figura 6.27 Erro relativo ao longo das iterações para objeto isolado localizado perto da borda para as versões de ED.




onde, estão representados os resultados quantitativos para as cinco versões de ED e a versão modificada de ED proposta em (RIBEIRO et. al., 2014a).

Figura 6.28 Erro relativo ao longo do tempo para objeto isolado localizado no centro para as versões de ED.




na Fig. 6.28, estão representados os resultados quantitativos para as cinco versões de ED e a versão modificada de ED proposta em (RIBEIRO et. al., 2014a).

Figura 6.29 Erro relativo ao longo do tempo para objeto isolado localizado entre o centro e a borda para as versões de ED.



na Fig. 6.29, estão representados os resultados quantitativos para as cinco versões de ED e a versão modificada de ED proposta em (RIBEIRO et. al., 2014a).

Figura 6.30 Erro relativo ao longo do tempo para objeto isolado localizado perto da borda para as versões de ED.



na Fig. 6.30, estão representados os resultados quantitativos para as cinco versões de ED e a versão modificada de ED proposta em (RIBEIRO et. al., 2014a).

6.5.1 Discussão dos resultados para ED

Qualitativamente, podemos observar que a ED-3 mostrou ser a melhor abordagem dentre todas as versões de ED para a reconstrução de imagens TIE em todas as três configurações estudadas, de acordo com as Figuras (6.19) a (6.24). A partir da Figura 6.21 é possível ver que para apenas 50 iterações a ED-3 conseguiu encontrar resultados consistentes e conclusivos anatomicamente para todos os experimentos.


Quantitativamente, a partir das Figuras (6.25) a (6.27) vemos que apesar de todas as versões de ED possuir em o mesmo custo computacional, a ED-3 mostrou melhor eficiência computacional devido, em geral, possuir em os menores valores do erro relativo ao longo das iterações. Tal resultado é devido à alta diversidade da população de candidatos à solução gerada pelo operador de mutação do algoritmo de ED-3.


Quantitativamente, a partir das Figuras (6.28) a (6.30) vemos que a ED-3 mostrou melhor eficiência computacional devido, em geral, possuir os menores valores do erro relativo ao longo do tempo de reconstrução das imagens de TIE. Além disso, é possível observar que para a reconstrução de TIE com objeto isolado no centro e entre o centro e a borda mostrou baixo tempo de reconstrução quando comparada as demais versões da ED.

6.6 RESULTADOS DA APLICAÇÃO DE ED-BNC

Como nos resultados apresentados para outras técnicas, a seguir são mostrados os resultados obtidos a partir da técnica híbrida ED-BNC para objeto isolado localizado no centro; entre o centro e a borda; e perto da borda, respectivamente:

Figura 6.31 Imagens reconstruídas com objeto no centro, entre o centro e a borda, e perto da borda, respectivamente, para ED-BNC.





Nas figuras acima, (a), (b) e (c) representam os objetos isolados posicionados no centro, entre o centro e a borda, e perto da borda, respectivamente. (a1), (a2) e (a3) representam a imagem do melhor candidato à solução para o objeto no centro em 50, 300 e 500 iterações, respectivamente; (b1), (b2) e (b3) representam a imagem do melhor candidato à solução para o objeto entre o centro e a borda em 50, 300 e 500 iterações, respectivamente; e (c1), (c2) e (c3) representam a imagem do melhor candidato à solução para o objeto perto da borda em 50, 300 e 500 iterações, respectivamente.

A seguir estão representados os resultados quantitativos, através do comportamento do erro relativo do candidato à solução com relação ao custo e ao tempo computacional.

Figura 6.32 Erro relativo ao longo das iterações para objeto localizado no centro para OEP, AG, SA, ED-3 e ED-BNC.




Figura 6.33 Erro relativo ao longo das iterações para objeto localizado entre o centro e a borda para OEP, AG, SA, ED-3 e ED-BNC.




Figura 6.34 Erro relativo ao longo das iterações para objeto localizado perto da borda para OEP, AG, SA, ED-3 e ED-BNC.




Figura 6.35 Erro relativo ao longo do tempo para objeto localizado no centro para OEP, AG, SA, ED-3 e ED-BNC.




Figura 6.36 Erro relativo ao longo do tempo para objeto localizado entre o centro e a borda para OEP, AG, SA, ED-3 e ED-BNC.





Figura 6.37 Erro relativo ao longo do tempo para objeto localizado perto da borda para OEP, AG, SA, ED-3 e ED-BNC.



6.6.1 Discussão dos resultados para a ED-BNC

A ED-BNC conseguiu gerar resultados anatomicamente consistentes desde as 50 iterações, e conclusivos a partir de 300 iterações para todas as configurações. Estes resultados podem ser vistos na Figura (6.31).

Qualitativamente, quando comparada com a OEP canônica, o AG canônico, o SA e a ED-3, o ED-BNC mostrou uma alta capacidade de gerar imagens com menos artefatos desde 50 iterações para todas as configurações, mostrando-se, assim como ED-3, como uma potencial técnica para eliminação de artefatos de imagem.


Através do comportamento do erro relativo ao longo das iterações mostrado nas Figuras (6.32), (6.33) e (6.34), e do erro relativo ao longo do tempo mostrado nas Figuras

(6.35), (6.36) e (6.37), apesar do SA, AG, OEP, ED-3 e ED-BNC terem mesmo custo computacional para reconstrução de TIE, a ED-BNC conseguiu, quando comparada às demais técnicas para o objeto isolado no centro, grande capacidade de gerar candidatos à solução mais próximos à imagem ouro. No entanto, como se observa pelos resultados quantitativos, a ED-3 corresponde à técnica que obteve melhores resultados para geração de candidatos à solução para objeto isolado próximo à borda e o objeto entre o centro e a borda.

6.7 RESULTADOS DA APLICAÇÃO DE ED-TAMC

A seguir são mostrados os resultados obtidos a partir da técnica híbrida ED-TAMC para objeto isolado localizado no centro, objeto entre o centro e a borda, e objeto perto da borda, respectivamente:

Figura 6.38 Imagens reconstruídas com objeto no centro, entre o centro e a borda, e perto da borda, respectivamente, para ED-TAMC.



as figuras de índices (a), (b) e (c) representam os objetos isolados posicionados no centro, entre o centro e a borda, e perto da borda, respectivamente. As de índices (a1), (a2) e (a3) representam a imagem do melhor candidato à solução para o objeto no centro em 50, 300 e 500 iterações, respectivamente; (b1), (b2) e (b3) representam a imagem do melhor candidato à solução para o objeto entre o centro e a borda em 50, 300 e 500 iterações, respectivamente; e (c1), (c2) e (c3) representam a imagem do melhor candidato à solução para o objeto perto da borda em 50, 300 e 500 iterações, respectivamente.

A seguir estão representados os resultados quantitativos, através do comportamento do erro relativo do candidato à solução com relação ao custo e ao tempo computacional.

Figura 6.39 Erro relativo ao longo das iterações para objeto localizado no centro para OEP, AG, SA, ED-3, ED-BNC e ED-TAMC.




Figura 6.40 Erro relativo ao longo das iterações para objeto localizado entre o centro e a borda OEP, AG, SA, ED-3, ED-BNC e ED-TAMC.




Figura 6.41 Erro relativo ao longo das iterações para objeto localizado perto da borda para OEP, AG, SA, ED-3, ED-BNC e ED-TAMC.




Figura 6.42 Erro relativo ao longo do tempo para objeto localizado no centro para OEP, AG, SA, ED-3, ED-BNC e ED-TAMC.




Figura 6.43 Erro relativo ao longo do tempo para objeto localizado entre o centro e a borda para OEP, AG, SA, ED-3, ED-BNC e ED-TAMC.





Figura 6.44 Erro relativo ao longo do tempo para objeto localizado perto da borda para OEP, AG, SA, ED-3, ED-BNC e ED-TAMC.



6.7.1 Discussão dos resultados para a ED-TAMC

A ED-TAMC conseguiu gerar resultados anatomicamente consistentes a partir de 300 iterações para todas as configurações. Estes resultados podem ser vistos na Figura (6.38).


Qualitativamente, quando comparada com as demais técnicas não obteve resultados tão bons quanto se esperava, mas mostrou uma capacidade de gerar imagens com poucos artefatos de imagem desde 50 iterações para objeto isolado perto da borda, mostrando-se como uma potencial técnica para eliminação de artefatos de imagens para esta configuração.

Através do comportamento do erro relativo ao longo das iterações mostrado nas Figuras (6.39), (6.40) e (6.41), e do erro relativo ao longo do tempo mostrado nas Figuras (6.42), (6.43) e (6.44), observa-se que a ED-TAMC teve o maior custo computacional para reconstrução de TIE, quando comparada às demais técnicas para todas as configurações, e também mostrou lenta queda do erro relativo ao longo das iterações e do tempo de reconstrução. Como podemos ver pelos resultados quantitativos, a ED-3 corresponde à técnica que obteve melhores resultados para geração de candidatos à solução para objeto isolado próximo à borda e entre o centro e a borda, enquanto que a técnica ED-BNC mostrou ser a melhor técnica para reconstrução de imagens de TIE com objeto isolado no centro do domínio.

6.8 RESULTADOS DA APLICAÇÃO DE ED-SA

A seguir são mostrados os resultados obtidos a partir da técnica híbrida ED-SA para objeto isolado localizado no centro, entre o centro e a borda, e perto da borda, respectivamente:

Figura 6.45 Imagens reconstruídas com objeto no centro, entre o centro e a borda, e perto da borda, respectivamente, para ED-SA.



As figuras de índices (a), (b) e (c) representam os objetos isolados posicionados no centro, entre o centro e a borda, e perto da borda, respectivamente. As de índices (a1), (a2) e (a3) representam a imagem do melhor candidato à solução para o objeto no centro em 50, 300 e 500 iterações, respectivamente; (b1), (b2) e (b3) representam a imagem do melhor candidato à solução para o objeto entre o centro e a borda em 50, 300 e 500 iterações, respectivamente; e (c1), (c2) e (c3) representam a imagem do melhor candidato à solução para o objeto perto da borda em 50, 300 e 500 iterações, respectivamente.

A seguir estão representados os resultados quantitativos, através do comportamento do erro relativo do candidato à solução com relação ao custo e ao tempo computacional.

Figura 6.46 Erro relativo ao longo das iterações para objeto localizado no centro para OEP, AG, SA, ED-3, ED-BNC, ED-TAMC e ED-SA.




Figura 6.47 Erro relativo ao longo das iterações para objeto localizado entre o centro e a borda OEP, AG, SA, ED-3, ED-BNC, ED-TAMC e ED-SA.




Figura 6.48 Erro relativo ao longo das iterações para objeto localizado perto da borda OEP, AG, SA, ED-3, ED-BNC, ED-TAMC e ED-SA.




Figura 6.49 Erro relativo ao longo do tempo para objeto localizado no centro para OEP, AG, SA, ED-3, ED-BNC, ED-TAMC e ED-SA.




Figura 6.50 Erro relativo ao longo do tempo para objeto localizado entre o centro e a borda para OEP, AG, SA, ED-3, ED-BNC, ED-TAMC e ED-SA.





Figura 6.51 Erro relativo ao longo do tempo para objeto localizado perto da borda para OEP, AG, SA, ED-3, ED-BNC, ED-TAMC e ED-SA.



6.8.1 Discussão dos resultados para a ED-SA

A ED-SA conseguiu gerar resultados anatomicamente consistentes e conclusivos a partir de 300 iterações para todas as configurações. Estes resultados podem ser vistos na Figura (6.45).

Qualitativamente, quando comparada com as demais técnicas, a técnica ED-SA mostrou alta capacidade de gerar imagens com poucos artefatos de imagem desde 300 iterações para todas as configurações, mostrando-se como uma potencial técnica para eliminação de artefatos de imagem.

Através do comportamento do erro relativo ao longo das iterações mostrado nas Figuras (6.46), (6.47) e (6.48), é possível observar que o algoritmo ED-TAMC possui o maior custo computacional dentre todos os algoritmos implementados neste trabalho para reconstrução de imagens de TIE. Fato resultante da necessidade de mais cálculos da função objetivo, devido às alterações dos candidatos à solução através da Topologia em Anel e da Mutação Caótica.

Através do comportamento do erro relativo ao longo das iterações mostrado nas Figuras (6.49), (6.50) e (6.51), é possível observar que o algoritmo SA possui o maior tempo reconstrução computacional dentre todos os algoritmos implementados neste trabalho para reconstrução de imagens de TIE. Fato resultante do alto tempo para a execução de uma iteração do algoritmo SA, devido ao grande número de alterações do candidato à solução durante a execução deste algoritmo.

Através do comportamento do erro relativo ao longo das iterações mostrado nas Figuras (6.46), (6.47) e (6.48), e do erro relativo ao longo do tempo mostrado nas Figuras (6.49), (6.50) e (6.51), vemos que a ED-SA teve baixo custo computacional para reconstrução de TIE, quando comparada às demais técnicas para todas as configurações, e também mostrou boa queda do erro relativo ao longo das iterações e do tempo de reconstrução. Logo, é possível observar pelos resultados quantitativos, a ED-SA teve comportamento semelhante à ED-3 que corresponde à técnica que obteve melhores resultados para geração de candidatos à solução para objeto isolado próximo à borda e entre o centro e a borda, mas também a ED-SA teve comportamento semelhante à técnica ED-BNC que mostrou ser a melhor técnica para reconstrução de imagens de TIE com objeto isolado no centro do domínio.

A seguir, é apresentado um resumo dos resultados mencionados neste trabalho:

Tabela 6.2 Resumo dos resultados obtidos neste trabalho.

Trabalhos	Custo computacional	Tempo de execução	Qualidade da reconstrução	Ruído
Algoritmos genéticos (RIBEIRO et al., 2014d; FEITOSA et al., 2014c)	MÉDIO	BAIXO	MÉDIA	MODERADO
Evolução diferencial (RIBEIRO et al., 2014a; DAS & KONAR, 2009)	BAIXO	BAIXO	ALTA	LEVE
Otimização por enxame de partículas (FEITOSA et al., 2014c; KUMAR et al., 2010)	ALTO	MÉDIO	BAIXA	ELEVADO
Recozimento simulado (KIRKPATRICK et al., 1983)	MÉDIO	ALTO	MÉDIA	MODERADO
Evolução diferencial híbrida com busca não cega (Proposto)	BAIXO	BAIXO	ALTA	LEVE
Evolução diferencial híbrida com topologia em anel e mutação caótica (Proposto)	ALTO	MÉDIO	MÉDIA	MODERADO
Evolução diferencial híbrida com recozimento simulado (Proposto)	BAIXO	BAIXO	ALTA	LEVE

6.9 DISCUSSÃO GERAL

Na análise dos problemas propostos neste trabalho, 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 mostrar uma queda do erro relativo

que a longo prazo tende a estagnar, caracterizando que o algoritmo encontrou um mínimo local.

A Otimização por Enxame de Partículas na forma canônica se mostrou incapaz de resolver eficientemente o problema da TIE, tanto por análise dos resultados qualitativos quanto pelos quantitativos. Apesar disso, mostrou ser uma técnica eficiente para gerar candidatos à solução inicial.

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

Quanto às técnicas híbridas propostas neste trabalho, todas foram eficientes para resolução do problema da TIE, obtendo bons resultados qualitativos e quantitativos desde 50 iterações destes algoritmos. Porém, merece destacar o rendimento do algoritmo ED-SA por ser a técnica aqui proposta mais promissora na reconstrução de imagens de TIE, já que se mostrou ser mais rápido e apresentar menor custo computacional do que as outras técnicas analisadas. Este fator se deve à hibridização do SA com a ED, levando consequentemente o algoritmo de ED-SA escapar mais facilmente de mínimos locais, e desta forma, reduzir a quantidade necessária de cálculos da função objetivo para obtenção de soluções mais próximas da imagem ouro.

7 CONCLUSÃO E TRABALHOS FUTUROS

7.1 DIFICULDADES APRESENTADAS

As principais dificuldades encontradas na realização desta pesquisa estão relacionadas à seleção de parâmetros e ao tempo de processamento computacional.

A seleção dos parâmetros teve de ser feita de forma empírica devido ao fato de uma execução do algoritmo levar muito tempo, como apresentado nos resultados do Capítulo 6 deste trabalho. A grande maioria das técnicas propostas leva mais de 1 hora para se realizar apenas uma execução de 500 iterações do algoritmo. O tempo elevado inviabiliza 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 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.

7.2 CONCLUSÕES GERAIS

Os experimentos realizados neste trabalho mostraram que a técnica híbrida ED-SA tem a capacidade de convergir mais rapidamente do que as outras técnicas. Esta aceleração ocorre devido a fatores já citados. Ainda é possível, se ajustar os parâmetros desta técnica a fim de encontrar resultados quali e quantitativamente melhores do que os obtidos neste trabalho.

Acredita-se que a dificuldade de encontrar imagens bem definidas em apenas 50 iterações esteja relacionada ao ajuste de parâmetros desta técnica. Quando se trata da ED-SA, a complexidade da tarefa de ajustar os parâmetros aumenta devido ao 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.

Contudo, a combinação, entre o caráter exploratório da Evolução Diferencial com o caráter exploratório do Recozimento Simulado, resultou numa nova técnica híbrida (ED-SA) altamente eficiente com baixos custo e tempo computacional para reconstrução de imagens de TIE, quando comparada com as demais técnicas analisadas.

7.3 CONTRIBUIÇÕES

Através deste trabalho foi possível desenvolver novos algoritmos baseados na técnica de Evolução Diferencial, pode-se citar: a versão modificada da ED, o algoritmo ED-BNC, o algoritmo ED-TAMC e o algoritmo ED-SA. Este trabalho, além de contribuir para os estudos de aplicação dos algoritmos bioinspirados e evolucionários, também contribui como uma fonte de estudos de algoritmos híbridos para a reconstrução de imagens de TIE.

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

Tabela 7.1 Contribuições geradas pelos resultados parciais desta dissertação.

Nome do Artigo	Evento/ Cidade de publicação	Ano de publicação
RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA USANDO CARDUME DE PEIXES, BUSCA NÃO-CEGA E ALGORITMO GENÉTICO.	XII CONGRESSO BRASILEIRO DE INTELIGÊNCIA COMPUTACIONAL / CURITIBA - BRASIL	2015
RECONSTRUÇÃO DE IMAGENS DE TIE USANDO RECOZIMENTO SIMULADO, EVOLUÇÃO DIFERENCIAL E ALGORITMOS GENÉTICOS.	XII CONGRESSO BRASILEIRO DE INTELIGÊNCIA COMPUTACIONAL / CURITIBA - BRASIL	2015
RECONSTRUCTION OF ELECTRICAL IMPEDANCE TOMOGRAPHY IMAGES USING GENETIC ALGORITHMS AND NON-BLIND SEARCH.	INTERNATIONAL SYMPOSIUM ON BIOMEDICAL IMAGING/ BEJING - CHINA	2014
RECONSTRUCTION OF ELECTRICAL IMPEDANCE TOMOGRAPHY IMAGES USING PARTICLE SWARM OPTIMIZATION, GENETIC ALGORITHMS AND NON-BLIND SEARCH.	IEEE BIOSIGNALS AND BIOROBOTICS CONFERENCE / SALVADOR – BRASIL	2014

A MODIFIED DIFFERENTIAL EVOLUTION ALGORITHM FOR THE RECONSTRUCTION OF ELECTRICAL IMPEDANCE TOMOGRAPHY IMAGES.	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.	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.	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.	XXIV CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA / UBERLÂNDIA - BRASIL	2014
RECONSTRUÇÃO DE IMAGENS DE TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA USANDO EVOLUÇÃO DIFERENCIAL MODIFICADA.	XXIV CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA / UBERLÂNDIA - BRASIL	2014
UM ALGORITMO DE EVOLUÇÃO DIFERENCIAL MODIFICADO COM BUSCA NÃO-CEGA PARA TOMOGRAFIA POR IMPEDÂNCIA ELÉTRICA.	XXIV CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA /	2014

	UBERLÂNDIA - BRASIL	
APLICAÇÃO DE ALGORITMOS GENÉTICOS E EVOLUÇÃO DIFERENCIAL PARA RECONSTRUÇÃO DE IMAGENS DE TIE.	XXIV CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA / UBERLÂNDIA - BRASIL	2014

7.4 TRABALHOS FUTUROS

Como pesquisas futuras recomenda-se um estudo mais profundo da seleção de parâmetros para as técnicas propostas, na forma de execuções do algoritmo variando os parâmetros, a fim de encontrar o menor valor da função objetivo e permitindo manter a capacidade de diversidade dos candidatos à solução.

Também se coloca a necessidade de estudar a quantidade inicial de agentes (ou indivíduos) dos algoritmos e se ela interfere na velocidade de convergência da técnica.

Recomenda-se a aplicação da Busca Não-Cega, empregada em algumas técnicas deste trabalho, na ED-SA, para guiar o processo de convergência do algoritmo.

Do ponto de vista do *software*, recomenda-se investigar infraestruturas de *software* e linguagens de programação para migrar o código da linguagem interpretada MATLAB/Octave para um ambiente compilado ou pelo menos pré-compilado que suporte experimentação com técnicas de paralelismo e o uso de arquiteturas paralelas.

Do ponto de vista do *hardware*, recomenda-se realizar experimentos físicos em um protótipo de TIE composto por um aparelho de acrílico circular com 32 eletrodos de aço, usando objetos isolantes elétricos imersos em soluções salinas. Medidas deste aparelho não foram utilizadas neste trabalho porque seria necessário investigar em primeiro lugar o problema inverso da TIE, a partir do ponto de vista do problema numérico de engenharia. Além disso, recomenda-se, no nível de *hardware*, o uso de arquiteturas paralelas baseadas em GPUs (*Graphic Processing Units*) e *Cluster* para reduzir o custo computacional da tarefa de reconstrução de TIE usando abordagens evolutivas, uma vez que algoritmos evolutivos e bioinspirados em geral são fortes candidatos à paralelização, dado o fato de usarem como

base múltiplos estados simultâneos. A técnica possibilitaria, além do aumento de velocidade, fazer mais execuções do algoritmo e trabalhar algumas técnicas de análise estatística.

Recomenda-se também a construção de um método de reconstrução baseado em busca heurística que dependa pouco dos parâmetros iniciais.

Além disso, observou-se também a necessidade de se realizar um estudo para se desenvolver métricas de qualidade de imagem para experimentos envolvendo computação evolucionária e TIE.

REFERÊNCIAS

- ADLER, A.; DAI, T.; LIONHEART, W. R. B. **Temporal image reconstruction in electrical impedance tomography**. *Physiological Measurement*, v. 28, n. 2007, p. S1-S11, 2007.
- ADLER, A.; LIONHEART, W. R. B. **Uses and abuses of EIDORS: na extensive software base for EIT**. *Physiological Measurement*, v. 27, p. S25-S42, 2006.
- ADLER, A.; ARNOLD, J. H.; BAYFORD, R.; BORSIC, A.; BROWN, B.; DIXON, P.; FAES, T. J. C.; FRERICH, I.; GAGNON, H.; GÄRBER, Y.; GRYCHTOL, B.; HAHN, G.; LIONHEART, W. R. B.; MALIK, A.; PATTERSON, R. P.; STOCKS, J.; TIZZARD, A.; WEILER, N.; WOLF, G. K. **GREIT: a unified approach to 2D linear EIT reconstruction of lung images**. *Physiological Measurement*, v. 30, n. 6, p. S35, 2009.
- AGUILAR, J. C. Z. **Estudos Numéricos para o problema da tomografia por impedância elétrica**. Tese (Doutorado), Instituto de Matemática e Estatística da Universidade de São Paulo, 2009.
- AMABIS, J. M.; MARTHO, G. R. **Fundamentos da biologia moderna**. 3. ed. rev. e atual. – São Paulo: Moderna, 2002.
- BACK, T.; FOGEL, D. B.; MICHALEWICZ, Z. editors. **Handbook of Evolutionary Computation**. Chapter C2.3. Institute of Physics Publishing and Oxford University Press, 1991.
- BAKER, L. E. **Principles of the Impedance Technique**. *IEEE Engineering in Medicine and Biology Magazine*, p.11-15, 1989.
- 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*, v. 38, p. 308–315, 2012.
- BORCEA, L. **Electrical impedance tomography**. *Inverse Problems*, v. 18, p. R99-R136, 2002.
- 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*, v. 16, n. 3, p. 239–249, 2006.
- CAROSIO, G. L. C.; ROLNIK, V.; SELEGHIM, P. **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*, Brazil, 2007.

- CASEIRO, J. F. M. **Estratégias Evolucionárias de Optimização de Parâmetros Reais**. Tese (Mestrado), Universidade de Aveiro, 2009.
- CHENEY, M.; ISAACSON, D.; NEWELL, J. C. Sun. **Electrical Impedance Tomography**. *SIAM REVIEW*, v. 41, n. 1, p. 85-101, 1999.
- CHENEY, M.; ISAACSON, D.; NEWELL, J. C.; SIMSKE, S.; GOBLE, J. **NOSER: An algorithm for solving the inverse conductivity problem**. *Int. J. Imaging Systems and Technology*, v. 2, p. 66–75, 1990.
- CINTRA, M. E. **Geração genética de regras fuzzy com pré-seleção de regras candidatas**. Tese (Mestrado), Universidade Federal de São Carlos, 2007.
- COELHO, Ld. S.; MARIANI, V. C. **Combining of Chaotic Differential Evolution and Quadratic Programming for Economic Dispatch Optimization With Valve-Point Effect**. *IEEE Transactions on Power Systems*, no. 21, pp. 989–996, 2006.
- DAI, M.; LI, B.; HU, S.; XU, C.; YANG, B.; et al. **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).
- DAS, S.; KONAR, A. **Automatic image pixel clustering with an improved differential evolution**. *Applied Soft Computing*, v. 9, n. 1, p. 226–236, 2009.
- DAS, S.; SUGANTHAN, P. N. **Differential Evolution: A Survey of the State-of-the-Art**. *IEEE Transactions on Evolutionary Computation*, v. 15, n. 1, p. 4-31, 2011.
- DIAMOND, A. H. **Chaos Science**. New York: *Marketing Research*, v. 5, n. 4, p. 9-14, 1993.
- DOS SANTOS, W. P.; DE ASSIS, F. M. **Método Dialético de Optimização usando o Princípio da Máxima Entropia**. In *Learning and Nonlinear Models* – Revista da Sociedade Brasileira de Redes Neurais (SBRN), v. 7, n. 2, p. 54-64, 2009.
- FEITOSA, A. R. S.; RIBEIRO, R. R.; SOUZA, R. E.; SANTOS, W. P. **Reconstrução de imagens de tomografia por impedância elétrica utilizando optimização por enxame de partículas em anel, busca guiada e fator caótico**. In: *Proceedings of the XXIV Congresso Brasileiro de Engenharia Biomédica*; 2014a.
- FEITOSA, A. R. S.; RIBEIRO, R. R.; SOUZA, R. E.; SANTOS, W. P. **Reconstruction of electrical impedance tomography images using chaotic ring-topology particle swarm optimization and non-blind search**. In: *Proceedings of the IEEE International Conference on Systems, Man, and Cybernetics*; 2014b.
- FEITOSA, A. R. S.; RIBEIRO, R. R.; SOUZA, R. E.; SANTOS, W. P. **Reconstruction of electrical impedance tomography images using particle swarm optimization, genetic**

- algorithms and non-blind search.** In: *Proceedings of the 5th IEEE Biosignal and Robotics Conference*; 2014 May 26-28; Salvador, Brasil. 2014c.
- 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.** *Revista Brasileira de Engenharia Biomédica*, v. 29, n. 2, p. 133-143. 2013.
- GONÇALVES, M. L. N. **Análise de Convergência dos Métodos de Gauss-Newton do Ponto de Vista do Princípio Majorante.** Tese (Doutorado), COPPE da Universidade Federal do Rio de Janeiro, 2011.
- KENNEDY, J.; EBERHART, R.C.; SHI, Y. **Swarm Intelligence.** San Francisco: Morgan Kaufmann/ Academic Press, 2001.
- KENNEDY, J.; EBERHART, R. C. **Particle Swarm Optimization.** *Proceedings of the IEEE International Conference on Neural Networks*, Perth, Australia, pp.1942-1948, 1995.
- KIRKPATRICK, S.; GELLAT, D. C.; VECCHI, M. P. **Optimization by Simulated Annealing.** *Science*, v. 220, n. 4598, p. 671-680, 1983.
- KUMAR, S. P.; SRIRAM, N.; BENAKOP, P. G.; JINAGA, B. C. **Reconstruction of brain electrical impedance tomography images using Particle Swarm Optimization.** *5th International Conference of Industrial and Information Systems*, 2010.
- LI, Y.; XU, G.; GUO, L.; WANG, L.; YANG, S.; RAO, L.; HE, R.; YAN, W. **Resistivity Parameters Estimation Based on 2D Real Head Model Using Improved Differential Evolution Algorithm.** In: *Proceedings of the 28th IEEE Annual International Conference EBMS*; 2006.
- LIMA, C. R. **Estudos da Obtenção de Imagens de Tomografia por Impedância Elétrica do Pulmão pelo Método de Otimização Topológica.** Tese (Doutorado), Escola Politécnica da Universidade de São Paulo, 2006.
- LIU K.; DU X.; KANG L. **Differential Evolution Algorithm Based on Simulated Annealing.** In: Kang, L., Liu, Y., Zeng, S. (eds.) *ISICA 2007*. LNCS, vol. 4683, pp. 120–126. Springer, Heidelberg. 2007.
- LIU Y.; SUN F. **A fast differential evolution algorithm using k-Nearest Neighbour predictor.** *Expert Systems with Applications*, vol. 38, no. 4, pp. 4254-4258, 2011.
- LOPES, H. S. **Fundamentos de computação evolucionária e aplicações.** In: ESCOLA REGIONAL DE INFORMÁTICA DA SBC – PARANÁ. *Anais*, Bandeirantes. SBC, 2006.
- 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. *Critical Care Medicine*, v. 39, n. 9, 2011.

MARINHO, L. S.; MAGALHÃES, C. B. D. A.; VASCONCELOS, R. D. S.; NOGUEIRA, I. C.; NOGUEIRA, A. D. N. C.; HOLANDA, M. A. **Tomografia de Impedância Elétrica: Novo método de Avaliação Pulmonar.** 2013.

MARTINS, T. C.; TSUZUKI, M. S. G. **Electrical Impedance Tomography Reconstruction Through Simulated Annealing with Total Least Square Error as Objective Function.** In *Proceedings of the 34th Annual International Conference of the IEEE EMBS*, 2012.

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*, v. 59, n. 7, 2012.

MENIN, O. H. **Método dos Elementos de Contorno para Tomografia por Impedância Elétrica.** Tese (Mestrado), Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto da Universidade de São Paulo, 2009.

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

MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs.** 3rd edition, Springer, 1996.

OLIVEIRA, G. T. S. **Estudos e aplicações da evolução diferencial.** Tese (Mestrado), Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Uberlândia, 2006.

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*, v. 46, n. 4, p. 154-157, 2012.

PEICHONG W.; XU Q.; YU Z.; NING L. **A novel differential evolution algorithm based on Simulated Annealing.** In: *Control and Decision Conference (CCDC)*, p. 7–10, 2010.

PEREIRA, F. M. A. M. **Choque elétrico acidental em animais de vida livre: revisão de literatura.** Faculdade de Agronomia e Medicina Veterinária/ Universidade de Brasília, Brasília, 2011. Disponível em: <http://bdm.unb.br/bitstream/10483/3103/1/2011_FernandaMaraAragaoMacedoPereira.pdf>. Acesso em: 18 de março de 2015.

PRICE, K.; STORN, R. M.; LAMPINEM, J. A. **Differential Evolution: a practical approach to global optimization.** New York: Springer, 2005.

- 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, n. 6, 2012.
- 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**. In: Proceedings of the 5th *IEEE Biosignal and Robotics Conference*; 2014 May 26-28; Salvador, Brasil. 2014a.
- 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**. In: Proceedings of the *IEEE International Conference on Systems, Man, and Cybernetics*; 2014c.
- 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**. In: Proceedings of the *IEEE International Symposium on Biomedical Imaging*; 2014d.
- 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**. In: Proceedings of the *XXIV Congresso Brasileiro de Engenharia Biomédica*; 2014b.
- RICERI, A. P. **Fractais e Caos: A Matemática Hoje**. São Paulo: *Parma*. 1990.
- RIERA J.; RIU, P.J.; CASANC, P.; MASCLANSA, J.R. **Tomografía de impedancia eléctrica en la lesión pulmonar aguda**. *Medicina Intensiva*. v. 35, n. 8, p. 509-517, 2011.
- ROLNIK, V. P; SELEGHIM, P. **A specialized genetic algorithm for the electrical impedance tomography of two-phase flows**. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, v. 28, n. 4, p. 378–389, 2006.
- SAHA, S.; BANDYOPADHYAY, S. **Application of a New Symmetry-Based Cluster Validity Index for Satellite Image Segmentation**. *IEEE Geoscience and Remote Sensing Letters*, v. 5, n. 2, p.166-170, 2008.
- SANCHES, I. J.; FURLAN, D.C. **Métodos Numéricos**. Departamento de Informática/ Universidade Federal do Paraná, Paraná, 2007. Disponível em: <<http://www.ionildo.cjb.net/metodos/.htm>>. Acesso em: 18 mar. 2014.
- SANTOSA, F.; VOGELIUS, M. **A Backprojection Algorithm for Electrical Impedance Imaging**. *SIAM Journal on Applied Mathematics*, v. 50, n. 1, p. 216-243, 1990.

- SAUER, J. G. **Abordagem de evolução diferencial híbrida com busca local aplicada ao problema do caixeiro viajante**. Tese (Mestrado), Programa de Pós-Graduação em Engenharia de Produção e Sistemas da Pontifícia Universidade Católica do Paraná, 2007.
- SERAPIÃO, A. B. S. **Fundamentos de otimização por inteligência de enxames: uma visão geral**. *Revista Controle & Automação*, v. 20, n.3, p. 271–304, 2009.
- STORN, R.; PRICE, K. **Differential evolution: A simple and efficient heuristic for global optimization over continuous spaces**. *Journal on Global Optimization*, v. 11, n. 4, p. 341–359, 1997.
- TEHRANI, J. N.; JIN, C.; MCEWAN, A.; SCHAIK, A. **A comparison between compressed sensing algorithms in Electrical Impedance Tomography**. *32nd Annual Conference of IEEE EMBS*, 2010.
- VALLEJO, M. F. M. **Algoritmo de Tomografia por Impedância Elétrica utilizando Programação Linear como Método de Busca da Imagem**. Tese (Mestrado), Escola Politécnica da Universidade de São Paulo, 2007.
- WAN, Y.; BORSIC, A.; HEANEY, J.; SEIGNE, J.; SCHNED, A.; BAKER, M.; WASON S.; HARTOV, A.; HALTER, R. **Transrectal electrical impedance tomography of the prostate: Spatially coregistered pathological findings for prostate cancer detection**. *Medical Physics*, v. 40, n. 063102, 2013.
- 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*, v. 83, n. 104707, 2012.
- YOJO, A. Y. **Construção do Hardware de um Tomógrafo por Impedância Elétrica**. São Paulo, 2008.
- ZHENYU, G.; CHENG, B.; MIN, Y.; BINGGANG, C. **Self-Adaptive Chaos Differential Evolution**. In *Advances in Natural Computation*, p. 972–975, 2006.