PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO E SISTEMAS

THIAGO GREBOGE

PROPOSTA DE UM MÉTODO BASEADO EM METAHEURÍSTICAS PARA MODELAGEM GEOMÉTRICA DE PRÓTESES EM SISTEMAS CAD

CURITIBA
2013

THIAGO GREBOGE

PROPOSTA DE UM MÉTODO BASEADO EM METAHEURÍSTICAS PARA MODELAGEM GEOMÉTRICA DE PRÓTESES EM SISTEMAS CAD

Projeto de dissertação apresentado ao Programa de Pós-Graduação em Engenharia de Produção e Sistemas, da Pontifícia Universidade Católica do Paraná, como requisito para a obtenção do título de Mestre em Engenharia de Produção e Sistemas.

Orientador: Marcelo Rudek, Dr.
Coorientador: Osiris Canciglieri Junior, Ph. D.
Coorientador: Leandro Coelho, Dr.

CURITIBA
2013

Pontifícia Universidade Católica do Paraná

Programa de Pós-graduação em Engenharia de Produção e Sistemas

TERMO DE APROVAÇÃO

THIAGO GREBOGE

PROPOSTA DE UM MÉTODO BASEADO EM METAHEURÍSTICAS PARA MODELAGEM GEOMÉTRICA DE PRÓTESES EM SISTEMAS CAD

Dissertação aprovada como requisito para a obtenção de grau de Mestre no Curso de Mestrado em Engenharia de Produção e Sistemas, Programa de Pós-graduação em Engenharia de produção e Sistemas, do Centro de Ciências Exatas e de Tecnologia da Pontifícia Universidade Católica do Paraná, pela seguinte banca examinadora.

_____

Prof. Marcelo Rudek, Dr. (PPGEPS – PUCPR)
Orientador

_____

Prof. Osiris Canciglieri Junior, Ph. D. (PPGEPS – PUCPR)
Co-Orientador

_____

Prof. Leando dos Santos Coelho, Dr. (PPGEPS - PUCPR)
Co-Orientador

_____

Prof. Gerson Linck Bichinho Dr. (PPGTS - PUCPR)
Membro Interno

_____

Prof. Alessandro Zimmer, Dr. (UFPR)
Membro Externo

Curitiba, junho de 2013.

RESUMO

O desenvolvimento tecnológico sempre esteve atrelado às necessidades do ser humano. Muitos dos progressos alcançados buscam em sua essência prolongar a longevidade das pessoas. A medicina com a necessidade do desenvolvimento de próteses anatômicas vem recebendo suporte de diversas áreas da engenharia. Esse auxílio está permitindo a criação e o aprimoramento de técnicas corretivas relacionadas à má formação ou acidentes. A modelagem de próteses é uma das vertentes de grande demanda por tecnologia, porém a sua construção é, em muitos casos complexa por ser realizada de forma artesanal. Através da tomografia computadorizada (TC) é possível extrair os parâmetros necessários para automatizar o processo de modelagem de próteses anatômicas. Esta automação torna o processo de modelagem simplificado, permitindo ao médico avaliar seu resultado final com a redução de intervenções durante o desenvolvimento. Partindo de modelos conceituais já validados na literatura, é possível desenvolver um novo conceito por meio de processamento de imagens e uso de elipses, utilizando algoritmos evolutivos, de forma a modelar a curvatura do crânio em um software CAD. Através de ensaios e da aplicação de um estudo de caso, o modelo conceitual proposto foi analisado e apontou as limitações e comportamentos de alguns métodos e funções utilizadas, bem como o passo à passo e a integração do algoritmo desenvolvido.

Palavras Chave: Modelagem, prótese anatômica, tomografia computadorizada, algoritmos evolutivos, processamento de imagens, CAD.

ABSTRACT

The technological development has always been tied to human needs. Many of the achieved technological progress seek to prolong people's longevity. With the need to develop anatomical prostheses, the medicine has received support from various fields of engineering. The involvement of this two areas, medicine and engineering, has enabling the creation and enhancement of corrective techniques related to malformation or accidents. The prostheses' modeling is one of the aspects of great demand for technology, but its construction is, in many cases, made by hand which makes it complex. Through computed tomography (CT) it is possible to extract the necessary parameters to automate the process of creation of anatomical prostheses. This automation becomes necessary in the production process due to the complexity found in modeling because to the unique characteristics of each person. Using CAD software to assist in the development process, along with CT and image processing, it is possible to propose a new concept to obtain approximations of the contour of the skull from the elliptic approximations. Through testing and application of a case study, a new conceptual model was proposed. This research proposed and evaluated a new technique addressing results and pointing out their limitations

Keywords: Anatomical prosthesis, Computed Tomography (CT), evolutionary algorithms, image processing, CAD.

LISTA DE FIGURAS

Figura 1 – Representação geral do tema 4
Figura 2 – Procedimento técnico 8
Figura 3 - Princípio de um tomógrafo 12
Figura 4 - Relação *pixel* - *voxel* 12
Figura 5 - Passos fundamentais para processamento de imagens 16
Figura 6 - Princípio do AG com representação binária 17
Figura 7 - Operação de crossover 18
Figura 8 - Mutação 19
Figura 9 - Triangulação de Delaunay (malha topográfica) 25
Figura 10 - Interpolação proposta por Kels e Dyn 26
Figura 11 - Passos de interpolação 27
Figura 12 – Nuvem de pontos original (a) e interpolada (b), e respectivas superfícies (c e d). 27
Figura 13 - Modelo conceitual 29
Figura 14 - Detalhamento do método proposto 30
Figura 15 - Exemplo de conversão de escalas de cinza 31
Figura 16 – Método para a separação de áreas 32
Figura 17 - Exemplo de separação de áreas em uma fatia de TC. 33
Figura 18 - Planos de referência 34
Figura 19 - Distância entre pontos 35
Figura 20 - Mapeamento polar 36
Figura 21 - Histograma polar 37
Figura 22 - Parâmetros da elipse 38
Figura 23 – Limites do espaço de busca 38
Figura 24 – Representação polar da elipse 39
Figura 25 – Aproximações interna e externa 41
Figura 26 - Delimitação da deformação 42
Figura 27 - Vetor de histograma 42
Figura 28 – Posição dos arcos H’1 e H’2 43
Figura 29 - Histograma balanceado 44
Figura 30 – Regiões do contorno no histograma de posição 45
Figura 31 – Aproximação elíptica 45

Figura 32 - Histograma da elipse E (H_E) 46
Figura 33 – Sobreposição do histograma H_e com o histograma H_c 47
Figura 34 - Elipse externa e interna aplicadas na ROI 49
Figura 35 – Arco-solução resultante 49
Figura 36 - Conversão *pixel* x *mm* 50
Figura 37 - Nuvem e superfície do crânio 52
Figura 38 - Nuvem e superfície da solução 52
Figura 39 - Estrutura de funções 53
Figura 40 – Fatia de TC original 54
Figura 41 - Área óssea segmentada 55
Figura 42 - ROI da descontinuidade 55
Figura 43 - Perímetros separados 56
Figura 44 - Comparativo após interpolação 58
Figura 45 - Fatias analisadas 60
Figura 46 - Aproximações para fatia 1 (AG) 61
Figura 47 - Aproximações para fatia 2 (AG) 62
Figura 48 - Aproximações para fatia 3 (AG) 62
Figura 49 - Aproximações para fatia 1 (PSO) 63
Figura 50 - Aproximações para fatia 2 (PSO) 63
Figura 51 - Aproximações para fatia 3 (PSO) 64
Figura 52 - Aproximações para fatia 1 (HS) 65
Figura 53 - Aproximações para fatia 2 (HS) 65
Figura 54 - Aproximações para fatia 3 (HS) 65
Figura 55 – Relação entre erro médio por pontos representativos 67
Figura 56 – Segmento de crânio sem e com deformação. 70
Figura 57 - Desvio 3D da nuvem de pontos 70
Figura 58 - Solução obtida através do método proposto 71
Figura 59 - Solução aplicada 72
Figura 60 – Diferenças de medição entre a solução e a superfície original. 72
Figura 61 – Visualização 3D do crânio estudado 74
Figura 62 - Desvio 3D da nuvem de pontos exportada 75
Figura 63 – Alguns arcos-solução obtidos 76
Figura 64 – Arcos-solução com excesso de informações 77
Figura 65 - Remoção de ruídos 78
Figura 66 - Solução 3D obtida 79

Figura 67 – Avaliação do desvio 3D da fatia 79
Figura 68 – Fatias fora do padrão 80
Figura 69 - Regiões e limites 80
Figura 70 - Solução aplicada no estudo 81
Figura 71 - Vista interna e superior 83
Figura 72 - Vista posterior direita 83
Figura 73 - Distribuição exponencial 101

LISTA DE TABELAS

Tabela 1 - Disposição da nuvem de pontos 51
Tabela 2 - Análise de pontos representativos 66
Tabela 3 - Compilação dos resultados de eficiência 67
Tabela 4 - Resultados dos algoritmos 68
Tabela 5 - Relações de erros 68
Tabela 6 – Tabela de números de Hounsfield 98
Tabela 7 – Comparativo quanto à Detecção de Bordas 99
Tabela 8 - Experimentos com IA 102
Tabela 9 – Tomografias do Estudo de Caso 103

LISTA DE ABREVIATURAS E SIGLAS

SIGLAS	INGLÊS	PORTUGUÊS
ACR	*American College of Radiology*	Colégio Americano de Radiologia
BMP	*BITMAP IMAGE FILE*	Imagem por mapa de bits
CAD	*Computer-aided Design*	Projeto Auxiliado por Computador
CAE	*Computer-aided Engineering*	Engenharia Auxiliada por Computador
CAM	*Computer-aided Manufacturing*	Manufatura Auxiliada por Computador
CNC	*Computed Numeric Command*	Comando Numérico Computadorizado
CT	*Computer Tomography*	Tomografia Computadorizada (TC)
DICOM	*Digital Imaging Communication in Medicine*	Comunicação digital de imagem na medicina
NEMA	*National Electric Manufacturers Association*	Associação nacional de manufatura elétrica
JPEG	*Joint Photographic Experts Group*	-
Pixel	*Picture Element*	Elemento de imagem

SUMÁRIO

1 INTRODUÇÃO 1
1.1 CONTEXTO 1
1.2 JUSTIFICATIVA 3
1.3 MOTIVAÇÃO 5
1.4 OBJETIVOS 6
1.4.1 Objetivo Geral 6
1.4.2 Objetivos específicos 7
1.5 METODOLOGIA DA PESQUISA 7
1.6 ESTRUTURA DO DOCUMENTO 9
2 FUNDAMENTAÇÃO TEÓRICA 10
2.1 TOMOGRAFIA COMPUTADORIZADA (TC) 10
2.1.1 Evolução Histórica 10
2.1.2 Princípio de Funcionamento 11
2.2 DICOM (*DIGITAL IMAGING AND COMUNICATIONS IN MEDICINE*) 13
2.3 PROCESSAMENTO DE IMAGENS MÉDICAS 15
2.4 TÉCNICAS DE COMPUTAÇÃO EVOLUTIVA 16
2.4.1 Algoritmos Genéticos (AG) 17
2.4.2 Otimização por Enxame de Partículas (PSO) 19
2.4.3 Busca Harmônica (HS) 22
2.5 RECONSTRUÇÃO TRIDIMENSIONAL 24
2.5.1 Diagrama de Voronoi e Triangulação de Delaunay 25
3 PROPOSTA DO MODELO CONCEITUAL 29
3.1 EXTRAÇÃO DA IMAGEM (ETAPA A) 30
3.2 SEGMENTAÇÃO (ETAPA B) 31
3.3 IDENTIFICAÇÃO E CORREÇÃO (ETAPA C) 34
3.3.1 Definições de eixos de simetria 34
3.3.2 Varredura por Coordenadas Polares a Partir do Centro da Imagem 35
3.3.3 Método para Geração das Elipses 37
3.3.4 Utilização de Elipses para Aproximação 40
3.3.5 Função de Aptidão (*Fitness*) 41
3.3.6 Aplicação de Metaheurísticas 47

3.4 EXPORTAÇÃO DAS INFORMAÇÕES (ETAPA D) 48
3.5 CRIA MODELO 3D NO CAD (ETAPA E) 51
4 Implementação do método proposto 53
5 Avaliação do Método Proposto 59
5.1 ANÁLISE COMPARATIVA DE TÉCNICAS PARA DETECÃO DE BORDAS 59
5.2 AVALIAÇÃO COMPARATIVA DOS ALGORITMOS EVOLUTIVOS 59
5.2.1 Eficiência dos algoritmos 60
5.2.2 Análise comparativa 66
5.3 RECONSTRUÇÃO TRIDIMENSIONAL 69
5.3.1 Reconstrução do Crânio 69
5.3.2 Reconstrução da Prótese 71
6 Estudo de Caso 74
7 CONCLUSÃO E RECOMENDAÇÕES 84
7.1 RECOMENDAÇÕES 86
8 REFERÊNCIAS 88
9 APÊNDICES 98
9.1 ANEXO 1 98
9.2 ANEXO 2 99
9.3 ANEXO 3 100
9.4 ANEXO 4 101
9.5 ANEXO 5 102
9.6 ANEXO 6 103

1 INTRODUÇÃO

1.1 CONTEXTO

O desenvolvimento tecnológico sempre esteve atrelado às necessidades do ser humano. Muitos desses progressos buscam prolongar a longevidade e a qualidade de vida das pessoas. Esta é a essência da Medicina. Uma especialidade médica importante é a que trata do desenvolvimento de próteses anatômicas e que atualmente vem recebendo suporte de diversas áreas da engenharia, permitindo gerar produtos capazes de trazer maior conforto, melhor estética e segurança para pacientes que sofreram algum trauma ou possuem alguma má formação física.

A reconstrução craniana é uma das vertentes de grande demanda por tecnologia. O processo de desenvolvimento de próteses de crânio é, em muitos casos, realizado de forma artesanal (FRANCESCONI, 2008), o que o torna complexo devido às características únicas de cada pessoa, como tamanho do crânio, posição e formato da fratura/deformação, entre outras (CLIJMANS, *et. al.*, 2008).

Ter acesso a essas características do crânio é algo de grande importância para realizar um plano minucioso de como desenvolver a prótese, como implantá-la e também como realizar o procedimento cirúrgico. A aplicação de próteses personalizadas visa reduzir o tempo do procedimento cirúrgico e também na quantidade necessária de anestesia para o paciente (BERTOL, 2008). Esta redução pode ser obtida através da otimização do processo cirúrgico em horas (redução de cerca de 85% em alguns casos como apresentado por Saldarriaga et al., (2011) bem como a redução de procedimentos para ajustes ou troca de próteses. A tomografia computadorizada (TC) é uma das técnicas desenvolvidas para se ter acesso a essas informações com acurácia (CONNOR, *et. al.*, 2005). Através da TC é possível extrair os parâmetros geométricos necessários para a representação tridimensional do crânio (PEREIRA, *et. al.*, 2005).

As tomografias são imagens digitais compostas de informações que representam ossos, tecidos, músculos, etc (HAAGA, *et. al.*, 1996). Assim é possível utilizá-las como dados para entrada em algoritmos que utilizem técnicas de

processamento de imagens para reconhecer padrões e extrair informações como, por exemplo, identificar a área óssea contida na TC e segmentar essa informação das demais. O conjunto dessas informações forma uma faixa de valores normalizada para uma escala de níveis de cinza (ALEXANDRE, *et. al*., 2005). Identificar e segmentar a área óssea contida nessa faixa de valor é uma das possíveis aplicações das técnicas de processamento de imagem.

A literatura atual demonstra a gradual evolução nos métodos de modelagem de ossos e confecção de próteses anatômicas. Diversas técnicas estão sendo experimentadas (CENTENERO & HERNÁNDEZ, 2011; LEE, 2009; CHEN, 2010; GREBOGE *et. al., 2010;* AQUINO *et. al.*, 2011; HUANG, 2011; SALDARRIAGA, 2011; JIN, 2013) onde o objetivo geral delas é criar uma ferramenta que substitua o trabalho manual de confecção destas prósteses devido ao grau de dificuldade e limitações impostas na produção artesanal como exposto por Francesconi (2008) e Greboge (2009).

Dentre as técnicas existentes, a utilização de métodos baseados em algoritmos evolucionários, são promissores na geração de descritores das seções transversais de crânios, como em Greboge *et. al.* (2010, 2011b) e Rudek *et. al.* (2012, 2013). Utilizando técnicas de inteligência artificial (IA) também é possível realizar aproximações geométricas de superfícies (LAMPINEN, 2003) e obter o resultado ótimo utilizando parâmetros pré-definidos (RENNER & EKÁRT, 2003). Essas técnicas são importantes na busca de soluções pela forma relativamente simples que operam em sistemas onde equações que regem seu comportamento são muito complexas e, na maioria dos casos, desconhecidas. Como a anatomia do crânio possui formas complexas, o grau de dificuldade para obter informações matemáticas que o representam é elevado. Neste caso, é viável o uso de metaheuristicas para uma aproximação mais simplificada e compatível, dentro dos limites estipulados para uma solução esperada, como em Lodygowski *et al.* (2009) que apresenta a aplicação de inteligência artificial para a busca ótima em implantes dentários. Essas técnicas de IA possuem características únicas, geralmente inspiradas em comportamentos encontrados na natureza, como a seleção natural do mais forte por algoritmos genéticos, comportamento de cardumes de peixes, enxame de abelhas, ou o padrão de voo de um bando de pássaros, entre outros. O estudo preliminar de Greboge *et. al.* (2011b) comprovou que o uso de técnicas de IA, como as anteriormente citadas, juntamente com as informações obtidas pela segmentação

de imagens de TC, permite definir os parâmetros necessários para a modelagem de uma prótese anatômica.

Neste processo, um software CAD (*Computer-Aided Design*), é necessário para fornecer a representação virtual do modelo bem como permitir a sua visualização em 3D. Uma das técnicas utilizadas para o envio das informações ao sistema CAD é através de nuvem de pontos (BERTOL, 2008). Essa técnica mostra-se eficiente em procedimentos de engenharia reversa para a reconstrução de sólidos (ZAHNG, *et. al.*, 2010). O modelo gerado pode ser avaliado por um médico especializado e, após aprovado, ser traduzido para um sistema CAM (*Computer-Aided Manufacturing*) e fabricado para uso em implante.

O escopo desta pesquisa trata da integração entre as áreas do conhecimento como o processamento de imagens médicas, a otimização por metaheuristicas, a reconstrução 3D e a integração com CAD, como meio para desenvolver de forma automática um modelo geométrico de uma prótese anatômica.

1.2 JUSTIFICATIVA

O desenvolvimento de próteses personalizadas, modeladas através de sistemas computacionais, tem se tornado usual na medicina (COSTA, *et. al.*, 2005), e empresas já atuam no segmento (*Miami Prosthodontics, 2013*), (*Custom IMD, 2013*) explorando comercialmente os implantes, fabricados com diferentes abordagens tecnológicas.

Do ponto de vista médico, a dificuldade encontrada para planejar o procedimento cirúrgico é a de modelar uma prótese que atenda os requisitos físicos específicos de cada paciente. Isso implica no menor tempo do procedimento de correção, pois o cirurgião tendo em mãos a prótese, devidamente projetada para o paciente, consegue evitar procedimentos paralelos, como ajustes e retirada de tecido ósseo (BERTOL, 2008). Eufinger, *et. al.* (1995) sugere a correção de deformações cranianas com uso de próteses pré-fabricadas. Neste caso o processo de concepção da prótese se torna mais barato porque segue um padrão comum, mas em contrapartida diversos ajustes cirúrgicos podem ser requeridos tendo em vista que os defeitos nos ossos não seguem um padrão.

Do ponto de vista da engenharia, automatizar o processo de fabricação de próteses anatômicas implica diretamente na redução de tempo e custo dos procedimentos, e no aumento da qualidade dos implantes. Propostas emergentes como a aproximação através de cubos apresentada por You *et al*. (2009) se demonstram promissoras. Também, de forma semelhante Aquino *et. al.*, (2011) apresenta o uso de *marching cubes* como método de busca da posição de deformação, mas define um modelo chamado *balloon model* para obter o fechamento da curvatura através da tangência da deformação. Pesquisas similares também são apresentadas para estudar aplicações de materiais em próteses proposta por Lee *et al*. (2009), com o objetivo voltado para sistemas CAE.

Portanto, a modelagem geométrica está sendo considerada como uma etapa essencial do processo de fabricação. Trata-se de uma tarefa delicada que envolve riscos e que requer determinada precisão, mas pode ser automatizada em algumas etapas. A Figura 1 ilustra o conceito geral desta pesquisa.

Figura 1 – Representação geral do tema

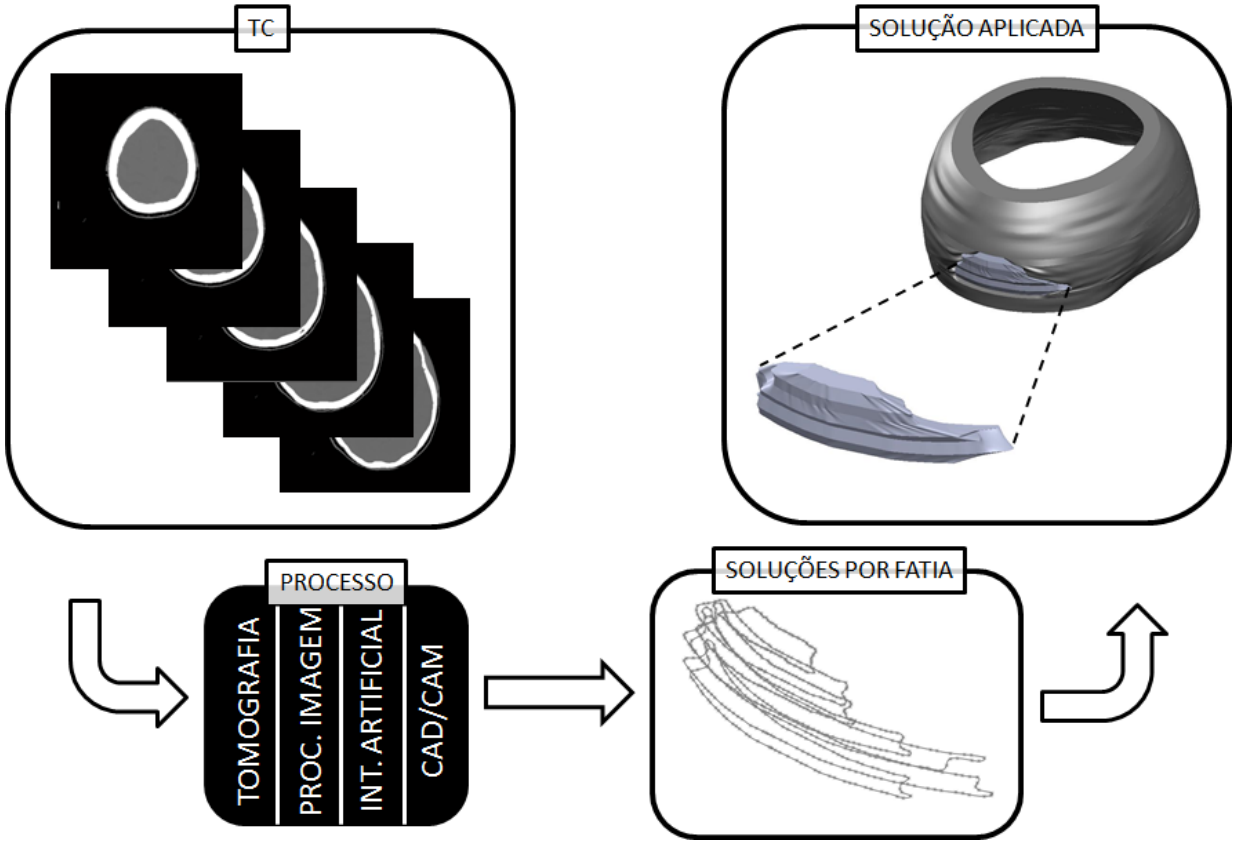

FONTE: O Autor

De acordo com a Figura 1, busca-se um processo para interpretar as imagens a partir das tomografias e gerar a área ausente do crânio. A partir das tomografias, através de um nível de automação adequado, o sistema deve ser capaz de realizar a extração das características do crânio, e desenvolver uma solução aproximada para suprir a área ausente do crânio.

Esta pesquisa busca interpretar imagens tomográficas para gerar a área ausente do crânio deformado. Com a solução desenvolvida, através de uma nuvem de pontos, pode-se gerar uma representação tridimensional da superfície ausente do crânio em um sistema CAD. Essa superfície pode ser mapeada para ser reproduzida em um ambiente CAM usando uma plataforma CNC.

De forma diferente a Liang *et. al.* (2009), You (2009) e Wuyang *et. al.* (2010), esta pesquisa se baseia na segmentação dos contornos da área óssea como apresentado por Francesconi (2008) e propõe um novo modelo aplicado ao problema de modelagem de próteses. Este modelo busca analisar os contornos internos e externos do crânio, fatia por fatia da TC, e criar a aproximação geométrica por elipses para corrigir a deformação. O ajuste de arcos e elipses que representam padrões curvos ou circulares é uma abordagem típica em processamento de imagens (HOUGH, 1962). Portanto a ideia de se usar elipses ajustadas às regiões curvas não é nova, e é amplamente usada para as mais diversas aplicações, como exemplificam Reed (1994), Rosin (1996), Gielis (2003) e Ouellet (2007).

Outras áreas de pesquisas voltadas para a biomedicina envolvendo técnicas com algoritmos evolutivos também são amplamente utilizadas como apresentado por Jennane, *et. al.* (2010). Nesta pesquisa, a abordagem utilizada é uma inovação, pois envolve aplicação de meta-heurísticas de otimização para obtenção de parâmetros geométricos que descrevem a curvatura do crânio a partir das imagens de seções tomográficas.

1.3 MOTIVAÇÃO

Partindo do modelo conceitual validado por Francesconi (2008), onde o mesmo comprova a representação óssea em um sistema CAD de forma satisfatória e dando continuidade a trabalhos anteriores (GREBOGE, 2009), têm-se a motivação

dessa pesquisa. Como citado anteriormente, reduzir o tempo cirúrgico é algo de grande importância, porém outros parâmetros envolvidos na concepção de uma prótese anatômica também são cruciais. As aproximações computacionais contam com o desempenho de técnicas de algoritmos evolucionários e de técnicas de processamento de imagem com menores custos computacionais.

As aplicações de algoritmos evolucionários, processamento de imagem e imagens médicas, permitem expandir ainda mais os ramos onde a automação se torna presente. A motivação desta pesquisa é a possibilidade de criar um processo em sua maioria autônomo, para obtenção de uma geometria que represente uma prótese anatômica. Esse método vem a aperfeiçoar o processo de produção na fase de concepção do produto, e assim reduzir custos computacionais, de tempo e de mão de obra nas etapas seguintes de fabricação.

1.4 OBJETIVOS

A direção dada ao trabalho é a de gerar um modelo tridimensional de prótese anatômica de crânio que possa ser integrado num sistema CAD. A principal pergunta a ser respondida é:

“As falhas cranianas podem ser corrigidas eficientemente a partir de aproximações elípticas tomando como referência imagens tomográficas?”

A partir deste questionamento, definem-se o objetivo geral e os específicos como:

1.4.1 Objetivo Geral

O objetivo geral da pesquisa é propor um método para modelar geometricamente próteses anatômicas de crânio de forma autônoma, sem interação humana e, cuja estrutura de dados se integre aos requisitos de manufatura.

1.4.2 Objetivos específicos

Para que a meta principal possa ser alcançada, os objetivos específicos necessários são os seguintes:

- Criar um método para diferenciar TCs com contornos abertos ou fechados e que permita localizar a região de interesse (posição da falha / buraco no crânio).
- Avaliar o uso de elipses como um descritor que represente geometricamente os parâmetros de curvatura de uma borda de crânio em uma imagem de tomografia.
- Criar um algoritmo que use uma imagem de TC como parâmetro de entrada e que permita ajustar as elipses sobre a curvatura desta imagem.
- Definir uma função de aptidão, implementar e testar algoritmos baseados em metaheuristicas para se obter uma busca otimizada dos parâmetros que melhor representam a curvatura da região a ser reconstruída. Testar um método tradicional, um método largamente difundido e um método recente.
- Definir comparativamente o melhor método para geração de elipses.
- Definir um método para exportar os parâmetros geométricos e reconstruir as elipses no CAD.
- Criar o modelo virtual da prótese no CAD e verificar seu ajuste na respectiva falha de crânio criada sinteticamente.
- Propor um estudo de caso que permita avaliar o método para um problema real.

1.5 METODOLOGIA DA PESQUISA

Esta pesquisa é de natureza aplicada visando à geração de conhecimentos para uma aplicação prática por meio de um problema específico. Sua abordagem é qualitativa por interpretar um fenômeno específico através da observação, descrição e compreensão, sendo assim de caráter exploratório. Por se tratar de uma proposta

de modelo conceitual, será utilizado um procedimento técnico através de estudo de caso para a aplicação do mesmo e demonstração dos resultados obtidos.

Esta pesquisa é de caráter multidisciplinar e busca integrar diversas áreas do conhecimento. É necessário entender os temas a um nível em que as variáveis de cada processo se tornem claras para poder integrá-las. A Figura 2 apresenta o embasamento teórico para que possa ocorrer o desenvolvimento da pesquisa.

Figura 2 – Procedimento técnico

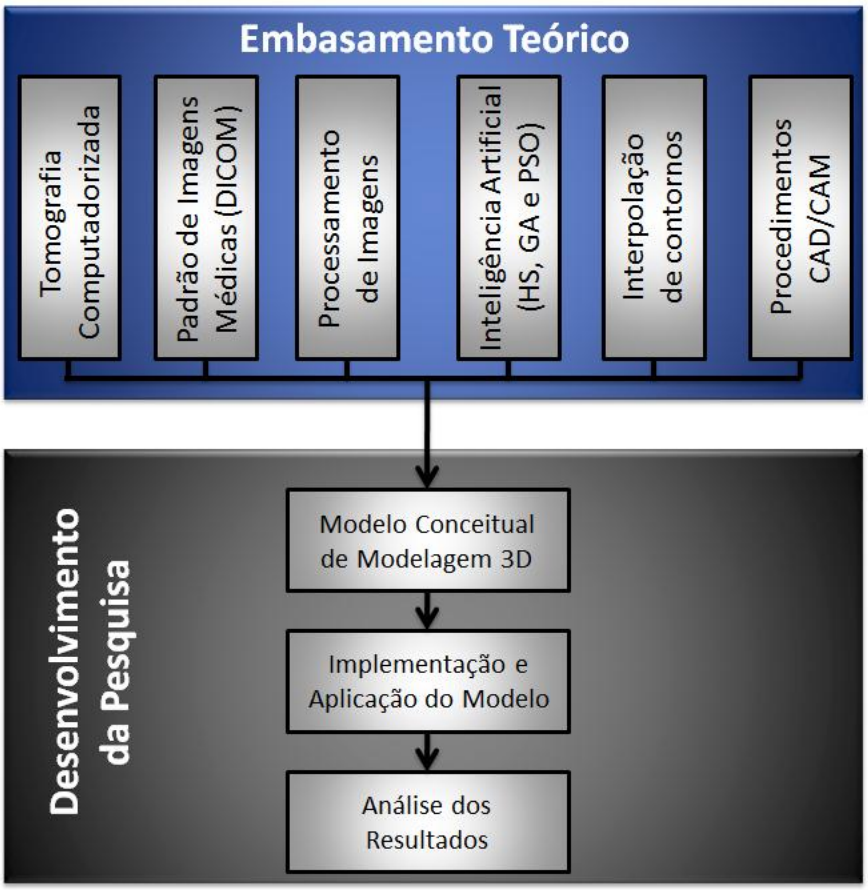

FONTE: O Autor

Através do embasamento teórico é possível definir o modelo conceitual para a modelagem tridimensional e a aplicação do modelo no nível de manufatura. A metodologia de pesquisa permite realizar a pesquisa de forma sistemática e coerente tanto para a estruturação quanto para a validação dos resultados obtidos. O tópico de tomografia computadorizada é necessário para identificar de qual forma é feita a aquisição das informações do crânio e de que forma são disponibilizadas (DICOM). O processamento de imagem é necessário para se ter conhecimento de

técnicas já apresentadas na literatura e também a utilização de conceitos para a criação de novas técnicas e ferramentas. A inteligência artificial, mais precisamente algoritmos evolutivos, é necessária para entender como o modelo pode aplicar suas variáveis na busca de resultados ótimos. A interpolação de contorno é estudada a fim de melhorar a resolução das imagens entre fatias adquiridas pelas tomografias. Essa resolução pode ser necessária dependendo da forma de reconstrução tridimensional utilizados nos sistemas CAD/CAM.

Fazendo uso de todas as informações adquiridas no embasamento teórico, é proposto o modelo conceitual seguido de sua aplicação, bem como a discussão e analise dos resultados obtidos.

1.6 ESTRUTURA DO DOCUMENTO

Esta dissertação está disposta no seguinte formato: o capítulo 1 fez uma introdução referente à visão global da problemática apresentada nesta pesquisa. O mesmo ilustra as áreas do conhecimento envolvidas e também como cada uma está disposta neste contexto. Também descreve a metodologia de pesquisa para a busca dos resultados observados. O capítulo 2 apresenta toda a fundamentação teórica utilizada para a busca do cumprimento dos objetivos desta pesquisa. O capítulo 3 faz uma apresentação da proposta do modelo conceitual para a correção de falhas cranianas. No capítulo 4 é descrito como o modelo sugerido no capitulo anterior irá buscar a melhor solução. O capítulo 5 faz uma avaliação do modelo proposto a partir de um crânio com falha sintética, onde é demonstrada a eficiência dos algoritmos. O capitulo 6 demonstra a aplicação do método em um estudo de caso real. O capitulo 7 conclui a pesquisa e apresenta algumas recomendações para pesquisas futuras na área.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo tem como objetivo expor os conhecimentos existentes na literatura para fundamentar a metodologia de pesquisa empregada.

Será feita uma breve introdução sobre os seguintes temas: a TC e seus padrões para utilização de suas informações (DICOM, 2013); as técnicas de processamento de imagem utilizadas; os algoritmos de otimização; os conceitos dos sistemas CAD/CAM para a tradução dos resultados e exportação para processos de usinagem.

2.1 TOMOGRAFIA COMPUTADORIZADA (TC)

A TC tem sido utilizada em diversas áreas do conhecimento como arqueologia, indústria madeireira, inspeção industrial, biologia e diversas outras (VAN KAICK & DELORME, 2005). Também tem um papel fundamental nas aplicações relacionadas aos diagnósticos médicos por imagem. Nesta pesquisa será usada para obter os dados para os estudos e validação do método proposto.

Será feita uma breve introdução de sua história e também uma apresentação de suas principais características.

2.1.1 Evolução Histórica

A tomografia computadorizada foi desenvolvida em torno de 1970, pelo engenheiro inglês Godfrey Newbold Hounsfield (1919 – 2004) (BAUTZ & KALENDER, 2005). A TC em suas primeiras aplicações foi utilizada em objetos, diferentemente da forma que é mais popular como é utilizada na medicina. Em seus primeiros experimentos, Hounsfield tomografou diversos objetos e pôde observar as características internas sem a necessidade de abri-los, num processo onde precisavam ficar expostos às fontes de radiação por 9 dias. Posteriormente novos estudos foram realizados, aplicados em componentes biológicos e o tempo de

exposição se tornou bastante reduzido com o aperfeiçoamento da técnica do tomógrafo.

Nessa mesma época ocorreu um grande desenvolvimento literário voltado para a TC. Diversas publicações foram realizadas tanto para os métodos técnicos e de aplicação quanto os estudos dos dados coletados pelos aparelhos de TC. Clackdoyle e Defrise (2010) citam que durante esses estudos, pesquisadores notaram que o problema da reconstrução dos dados, que era o maior obstáculo da TC, pois existiam incertezas com relação aos dados coletados, já havia sido solucionado. Johann Radon, em 1917, havia desenvolvido um método matemático denominado de retroprojeção filtrada (DEANS, 1983) que solucionaria as incertezas dos dados fornecidos pela aquisição da TC.

No final dos anos 70, outro método foi desenvolvido para melhorar o problema das informações incompletas, denominado de transformada por *Fan beam* (KAK & SLANEY, 1988). Apenas nos anos 90 foi considerado que a técnica de reconstrução analítica de imagens bidimensionais estava devidamente validada na literatura (CLACKDOYLE & DEFRISE, 2010).

2.1.2 Princípio de Funcionamento

Segundo Haaga e Lanzieri (1995), o aparelho de aquisição da TC reconstrói virtualmente o corpo analisado através de diversas projeções utilizando conceitos básicos de radiologia. Com transformadas analíticas específicas (transformada de Radon ou retroprojeção filtrada), é possível mapear áreas com densidades diferentes e ilustrar essas informações através de imagens bidimensionais.

Conforme ilustrado na Figura 3, o aparelho rotaciona em torno do corpo do paciente emitindo raios-X, cujas intensidades são captadas através de um arranjo de detectores rotatórios.

Figura 3 - Princípio de um tomógrafo

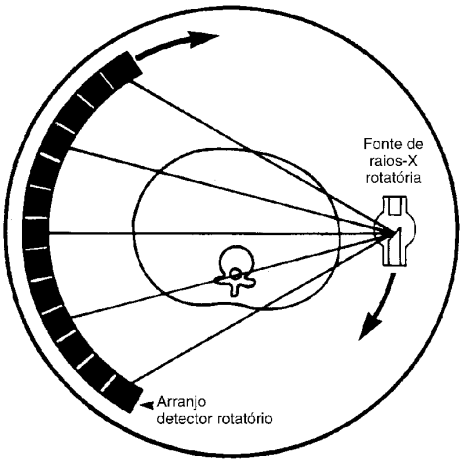

FONTE: Haaga e Lanzieri, 1995

As imagens de TC podem ser de alta resolução em três planos: axial, longitudinal ou sagital. Assim é possível obter uma representação precisa do corpo tomografado. Essa representação do corpo é dada através de *pixels* e denominada *voxel* (CONNOR, *et. al.*, 2005), o qual representa a entidade do pixel na imagem, porém contendo três dimensões. A Figura 4 apresenta a diferenciação entre pixel e *voxel*, em vermelho e azul, respectivamente.

Figura 4 - Relação *pixel* - *voxel*

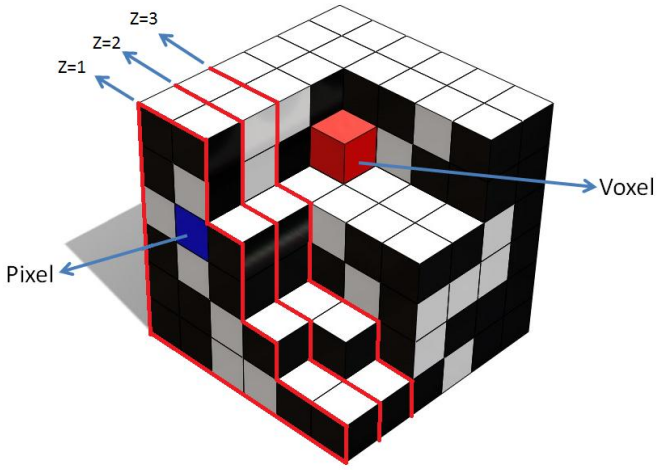

FONTE: O Autor

Em azul está a representação de um pixel que está contido na fatia referente ao plano z=1. Sucessivamente, estão representados os planos z=2 e z=3. O *voxel* (cubo ilustrado em vermelho) é uma representação tridimensional para área

referente a cada pixel com uma determinada profundidade. Assim é possível obter uma tradução de pixels para um contexto tridimensional.

Com uma melhor resolução dos *voxels*, tem-se uma medição mais precisa dos volumes parciais. Essa característica permite também um delineamento claro e preciso de fissuras, vasos e outras características na seção da TC (CONNOR, *et. al.,* 2005). As aplicações dessas informações podem ser traduzidas para sistemas tridimensionais em áreas como prototipagem rápida, CAD e CAM (GAUER, CEVIDANES & PROFFIT, 2009).

A informação representada por cada *voxel* traduz a taxa de absorção de cada tecido contido no corpo humano, consequentemente sua densidade. Essa absorção é convertida em valores numéricos pelos sensores e o conjunto de informação normalizada para uma escala de 8 ou 16 bits, constituindo uma imagem digital.

Segundo Haaga e Lanzieri (1996), essa imagem é apresentada em escala de cinza e seus valores representam as respectivas densidades de acordo com a tabela de Hounsfield (HU) apresentada no anexo 1. Esse número corresponde à atenuação linear média do tecido utilizando os coeficientes da água, do ar e dos ossos. Todas as densidades tem como valor de referência a densidade da água. As densidades são calculadas da seguinte forma, apresentados pela equação (2.1).

$$HU_x = \frac{1000 \cdot (\mu_x - \mu_{água})}{\mu_{água}}. \tag{2.1}$$

onde HU_x é a relação de quanto cada partícula absorve os raios-x com relação a absorção pela água.

Esses valores são armazenados em um padrão de imagens, definido como DICOM, que serão discutidos a seguir.

2.2 DICOM (*DIGITAL IMAGING AND COMUNICATIONS IN MEDICINE*)

Em torno de 1980 os órgãos NEMA (*National Electrical Manufacturers Association*) e ACR (*American College of Radiology*) desenvolveram o padrão não proprietário para o armazenamento de dados médicos que seria denominado

DICOM (*Digital Imaging and Communications in Medicine*). Este padrão tem como objetivo manter a intercomunicação entre os mecanismos de aquisição de imagens médicas e a flexibilidade de visualizações. Em 1985 foi lançado o padrão ACR-NEMA e foi oficialmente adotado em 1993 e renomeado para DICOM e atualmente se encontra na versão 3.0 (GRAHAM, PERRISS & SCARSBOOK, 2005).

Grauer *et al.* (2009) apresenta uma série de pesquisas que demonstram a confiabilidade das informações contidas nos arquivos DICOM, como as dimensões reais dos modelos mensurados. Graham *et al.* (2005) comenta de que forma essas informações são armazenadas e também descreve alguns *softwares* para a interpretação e visualização desses arquivos. Kahn *et al.*, (2007) define as principais funcionalidades onde o padrão DICOM é aplicado em: (1) informação cardíaca e vascular; (2) projeção de radiografia e angiografia; (3) medicina nuclear; (4) compreensão de informações; (5) intercâmbio de informações; (6) padrão de base; (7) radioterapia; (8) estruturação de relatórios; (9) consultor estratégico; (10) padronização para visualização de imagens; (11) ultrassom; (12) segurança de troca de informações; (13) imagem mamografia e CAD; (14) ressonância magnética; (15) ensaios clínicos e educação médica; (16) integração entre sistemas de imagem e informacional; (17) tomografia computadorizada e (18) cirurgias guiadas por imagens.

Segundo Bidgood *et al.* (1997), o padrão DICOM tem por objetivo atender cinco funcionalidades diferentes:

1. **Gerenciar as imagens via rede:** o DICOM trabalha com duas formas de imagens via rede, empurrada e puxada (*push* e *pull*). Na forma empurrada (mais comumente utilizada), o dispositivo de aquisição envia os dados para um dispositivo de armazenamento. Na forma puxada, é feita uma requisição para o dispositivo de aquisição que envia os dados coletados na sequência.

2. **Gerenciar a interpretação de imagens via rede:** vincula uma série de correlações entre os dados de entrada para a aquisição, dados de saída e informações adicionadas por observadores.

3. **Gerenciar a impressão via rede:** coordena a forma que o dispositivo de aquisição trabalha com relação à estação de trabalho. Essa funcionalidade se

assemelha a conectividade de um computador com uma impressora. Permite 4 formas de impressão: preto e branco, colorido, preto e branco com realce e colorido com realce.

4. **Gerenciar os procedimentos de imagem:** define um mecanismo de criação para catalogar os dados do paciente, os estudos, as séries e as imagens, agindo como uma base de dados dos procedimentos. Esta característica também informa relações entre *pixel* e mm, permitindo a medição de características do crânio diretamente nas imagens de TC

5. **Gerenciar o armazenamento de mídia *off-line*:** permite aos usuários trabalhar de maneira *off-line* ao sistema. É permitido transferir os dados coletados para sistemas de armazenamento de dados portáteis como *pen drives*.

2.3 PROCESSAMENTO DE IMAGENS MÉDICAS

O processamento de imagem surgiu de duas necessidades: melhorar a informação para interpretação humana e, para o processamento de dados para o controle de máquinas automáticas (RUSS, 2007). Segundo Gonzalez e Woods (2004), a imagem é uma matriz de ordem *N* x *M*, onde *N* é o comprimento e *M* é a largura, ambos dados em pixels. As imagens podem ser exibidas no formato: preto-e-branco (binária), em escala de cinza (256 níveis de intensidade por ponto em um único plano) ou colorida (por exemplo, a RGB que contém 3 planos de cores com variação de 256 valores cada, caso seja 8 *bits*: vermelho, verde e azul), variando sua extensão (formto que é compactado o arquivo que contém as informações da mesma, JPG, BITMAP, etc. Graham *et al.* (2005)).

A forma de aquisição das imagens também é um tópico que é interessante salientar em linhas gerais. Para todas as diferentes formas de aquisição de imagens, o processo é basicamente o mesmo.

Figura 5 - Passos fundamentais para processamento de imagens

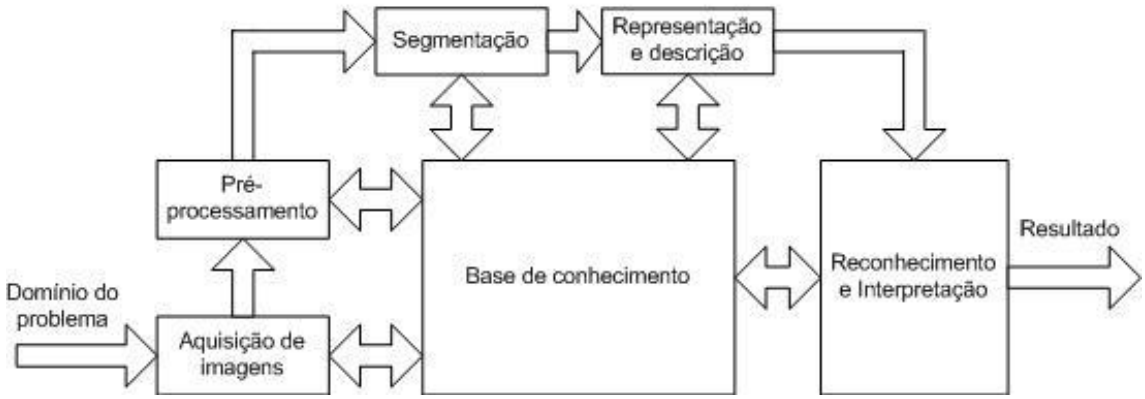

FONTE: Gonzalez e Woods, 2000

A partir da Figura 5, tomando como base a representação de Gonzalez e Woods (2000), é possível ilustrar como técnicas de processamento de imagens são aplicadas. Traçando um comparativo entre o problema abordado nesta pesquisa e a figura 5, pode-se considerar a aquisição como parte integrante do aparelho de TC. O pré-processamento entende-se como a extração das imagens do arquivo médico (DICOM). A segmentação é a parte em que o software deve identificar os tipos de tecido e extrair a parte óssea, pois é a informação necessária para a análise das superfícies representadas nas fatias de TC. A representação é a etapa em que se pode definir um descritor (por exemplo, matemático) para representar de forma mais simplificada o objeto segmentado. E o resultado final depende da interpretação dos dados gerados (imagem e descritores) sobre o quanto representam a informação da base de conhecimento.

2.4 TÉCNICAS DE COMPUTAÇÃO EVOLUTIVA

A computação evolucionária teve início por volta de 1950 e vem sendo usada de forma crescente em diversas áreas de pesquisas devido a grande flexibilidade, adaptabilidade, e desempenho robusto (BACK *et. al.*, 1997). Oduguwa, *et. al.* (2005) classifica os algoritmos evolucionários (ou computação natural) pela forma de busca utilizada por esses métodos, onde o conceito da realidade é caracterizada por distúrbios e sistemas caóticos não lineares. A utilização de técnicas de computação

evolutiva torna-se atrativa quando não é necessário o conhecimento aprofundado das variáveis envolvidas no sistema estudado, e também por gerar múltiplas soluções.

Para avaliar qual técnica melhor se adapta ao problema estudado, foram analisadas três hipóteses: (i) Algoritmos Genéticos (AG), por ser uma técnica tradicional. (ii) Otimização por Enxame de Partículas (PSO – Particle Swarm Optimization) por ser uma técnica amplamente usada atualmente e (iii) Busca Harmônica (HS- Harmony Search) por ser uma técnica recente e ainda não muito explorada. O princípio de funcionamento de cada um é apresentado a seguir.

2.4.1 Algoritmos Genéticos (AG)

O Algoritmo Genético é inspirado na teoria de Darwin, sobre a evolução e seleção natural das espécies. É usado amplamente nas áreas de pesquisa operacional, engenharias, desenho industrial, computação, bioquímica e diversos outros para a busca de soluções ótimas de problemas não lineares (LOPES, 2009). De acordo com Renner e Ekárt (2003), Kanungo *et al.* (2004), e Joshi (2007), o AG tem como função aplicar o modelo da sobrevivência do mais forte, como na natureza. Esse mecanismo de otimização busca beneficiar estatisticamente os indivíduos mais fortes (que possuem uma melhor aptidão) e garantir que suas características sejam passadas aos seus herdeiros (BACK, 1997; HASHEMI, 2009). A Figura 6 ilustra como o AG se comporta.

Figura 6 - Princípio do AG com representação binária

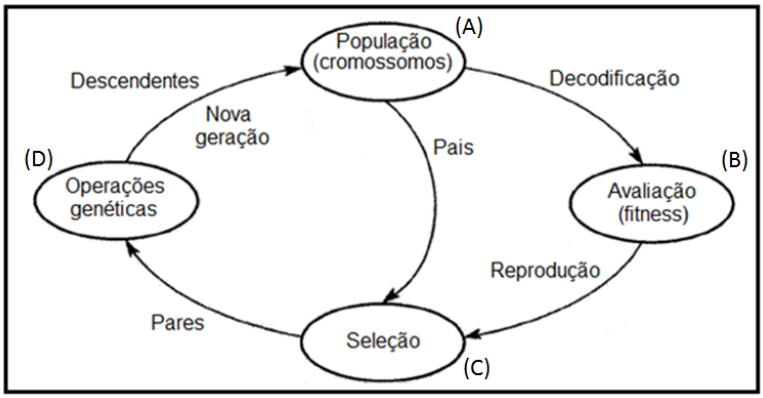

FONTE: Adaptado de RIBEIRO FILHO et al. (1994)

Conforme ilustrado na Figura 6, o processo comporta-se por meio dos seguintes passos:

Passo 1: Cria um conjunto de indivíduos (A), formando uma população. A cada indivíduo compete uma possível solução para o problema. A formação desta população é aleatória e/ou está contida dentro de um conjunto previamente definido.

Passo 2: Avalia a aptidão (*fitness*) de cada indivíduo (B), buscando pelo máximo valor. Este passo verifica a função *fitness* para todos os indivíduos. A verificação do *fitness* é dada através de uma equação matemática para expressar seu rendimento em números. Em outras palavras, é uma grandeza escalar que representa o quão adaptado determinado indivíduo está para aquela situação.

Passo 3: Cria uma nova população de *n* indivíduos selecionando pares da população, de acordo com a sua aptidão no meio, para gerar a nova população (C). Analogamente à seleção natural, os indivíduos são selecionados probabilisticamente para desenvolver novos indivíduos e garantir a sobrevivência dos mais aptos.

Passo 4: Aplica-se uma probabilidade de troca de informações por crossover (recombinação genética) dos cromossomos dos pais na nova geração (D). A Figura 7 ilustra a operação genética de crossover com os indivíduos P1 e P2:

Figura 7 - Operação de crossover

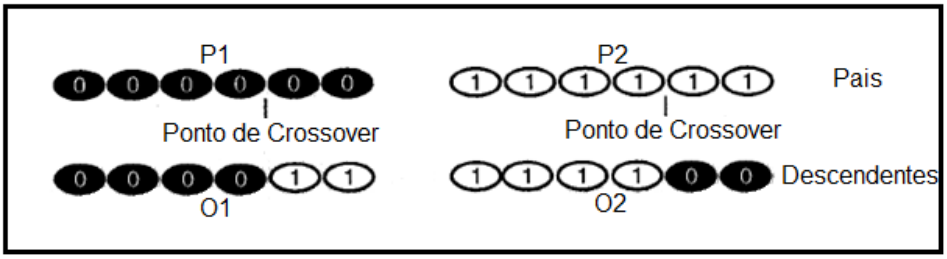

FONTE: Adaptado de RIBEIRO FILHO et al. (1994)

Também é aplicada uma probabilidade de mutação (apresentado na Figura 8) na nova geração para evitar que o sistema caia em um máximo local. Esta recombinação genética tem por objetivo obter informações hereditárias dos pais dos novos indivíduos. Os processos de recombinação e mutação têm por finalidade atuar na busca da solução ideal a níveis locais e globais, respectivamente.

Figura 8 - Mutação

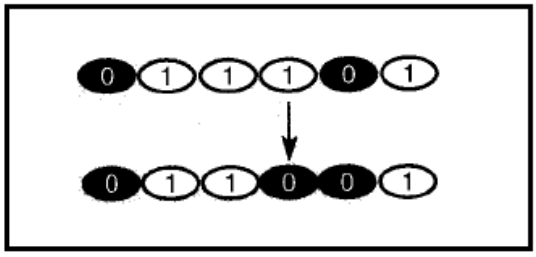

FONTE: RIBEIRO FILHO et al. (1994)

Passo 5: Uma nova população é formada para análise e usa a nova geração desenvolvida para verificar a aptidão dos novos indivíduos (A). Se o critério de parada for satisfeito, o processo termina, retorna a melhor solução na atual população e finaliza o programa. Caso contrário, retorna ao **passo 3**.

2.4.2 Otimização por Enxame de Partículas (PSO)

Segundo Jiang *et al* (2007) a técnica PSO (*Particle Swarm Optimization*) ou enxame de partículas é uma técnica de inteligência artificial voltada à busca de soluções ótimas. Essa técnica foi proposta inicialmente por Kennedy e Eberhart (JIANG, *et. al.*, 2007; MARIANI, *et. al.*, 2010). O algoritmo tem como fundamento simular o comportamento natural de movimentação de um cardume de peixes ou de um bando de pássaros (KENNEDY & EBERHART, 1995). A técnica PSO provou ser eficiente na otimização de diversos problemas, destacando-se em sistemas de não linearidade e não diferenciáveis, de múltiplas soluções ótimas e sistemas superdimensionados (SHI & EBERHART, 1998).

2.4.2.1 Método PSO Original

Cada partícula no algoritmo PSO é uma possível solução existente na população (enxame). No inicio do algoritmo, cada partícula recebe uma posição aleatória (solução) e se desloca no espaço multidimensional (possibilidades) buscando a melhor posição baseada em sua própria experiência e nas partículas ao seu redor. Essa experiência é determinada de acordo com a equação da velocidade.

Em cada iteração, durante a simulação, a função *fitness* é avaliada usando a posição da partícula e duas variáveis consideradas ótimas no processo. Essas variáveis são o melhor fitness da partícula e o melhor fitness da melhor partícula do grupo. Essas partículas são respectivamente *pbest* (*personal best*) e *gbest* (*global best*).

O conceito do algoritmo do PSO consiste em alterar a velocidade de cada partícula de acordo com o melhor da partícula e o melhor do bando. A mudança dessa velocidade das partículas é dada pela equação:

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot ud \cdot [pbest - x_i(t)] + c_2 \cdot Ud \cdot [gbest - x_i(t)], \quad (2.2)$$

onde $\mathrm{v_i} = [\mathrm{v_{i1}}, \mathrm{v_{i2}}, \dots, \mathrm{v_{in}}]^{\mathrm{T}}$ representa a velocidade da *i*-ésima partícula; $\mathrm{x_i} = [\mathrm{x_{i1}}, \mathrm{x_{i2}}, \dots, \mathrm{x_{in}}]^{\mathrm{T}}$ representa a posição da i-ésima partícula; w é o fator da inércia; $\mathrm{i} = 1,2,3, \dots, N$ indica o número de indivíduos (partículas) da população; $\mathrm{t} = 1,2, \dots, t_{max}$ indica as iterações; as constantes positivas $\mathrm{c_1}$ e $\mathrm{c_2}$ são variáveis cognitivas e sociais respectivamente, responsáveis pela variação de velocidade de acordo com *pbest* e *gbest*. As variáveis ud e Ud são aleatórias variando entre 0 e 1.

A equação abaixo representa a atualização da posição de acordo com os valores anteriores e as velocidades atuais:

$$x_i(t+1) = x_i(t) + \Delta t \cdot v_i(t+1), \quad (2.3)$$

onde $\Delta \mathrm{t} = 1$ e representa o tempo discreto para representar o deslocamento das partículas no espaço.

2.4.2.2 Variação do Método (*PSO with linear decaying inertia weigth)*

No PSO, o fator da inercia é uma regra especial, que influencia diretamente a busca global e a busca local. Este modelo foi proposto por Shi e Eberhart (1998). A alteração do peso da inercia causa um distúrbio na atual velocidade da partícula, a qual tenta manter sua velocidade no instante anterior. Shi e Eberhart (1998) também propuseram a variação dinâmica do peso da inércia. Essa variação pode ser linear positiva ou não linear em função do tempo, variando entre 0.9 e 1.2.

Engelbrecht (2005) propôs uma faixa de valores diferentes definida entre 0.4 e 0.9. Este modelo tem a desvantagem de uma maior possibilidade de cair em um mínimo local da função analisada. Caso isso ocorra, provavelmente ficará preso neste mínimo local. A função utilizada para estipular o peso da inércia é definido pela equação:

$$w(t) = \frac{iw_2 - iw_1}{iw_e - 1} \cdot (t - 1) + iw_1 \,, \tag{2.4}$$

onde iw_1é o valor inicial do peso da inércia; iw_2 é o valor final do peso da inércia; iw_e é o valor máximo para o número de iterações em relação ao tempo da função e t é a iteração atual do sistema. Para melhor exemplificar o processo realizado pelo PSO, este pode ser descrito através dos seguintes passos:

Passo 1: As variáveis otimizadas no PSO são como partículas dispostas em um espaço n-dimensional. Primeiramente é criado um conjunto de soluções, cada uma posicionada aleatoriamente no espaço.

Passo 2: Cada partícula é analisada pela aplicação da função *fitness* de acordo com sua posição espacial.

Passo 3: Após definido o *fitness* de cada partícula, é aplicada a equação para atualizar a sua velocidade individualmente, como apresentado pela equação *(2.2)*. Essa velocidade define a próxima posição da partícula de acordo com a equação (2.3) tomando como referência seu *fitness* (experiência) e das partículas vizinhas. Isso mudará sua posição e também sua experiência.

Passo 4: Neste passo é realizada uma nova verificação do *fitness* para cada partícula.

Passo 5: Caso o programa atinja o número máximo de iterações, finaliza. Caso contrário, volta ao **passo 3**.

2.4.3 Busca Harmônica (HS)

O algoritmo de busca harmônica (*Harmony Search*) é um modelo alternativo desenvolvido e apresentado por Geem *et al*. (2001) e ainda pouco explorado em problemas de otimização. Este algoritmo tem a mesma finalidade dos outros algoritmos de inteligência artificial que é a busca por soluções ótimas para sistemas multivariáveis. O método é inspirado na forma em que músicos realizam improvisações sobre o campo harmônico das melodias e buscam as melhores notas para obter a melhor harmonia.

A melodia pode ser entendida como o problema que se busca otimizar. A harmonia representa o vetor solução que se busca aperfeiçoar. Segundo Pan *et al*. (2010), este modelo possui menos requerimentos matemáticos quando comparados com outros algoritmos meta heurísticos, e tem demonstrado grande eficiência para a solução de diversos problemas matemáticos.

Este algoritmo foi selecionado devido a trabalhos anteriores que demonstram eficiência significativa posto paralelamente ao algoritmo genético como demonstrado por Mahdavi *et al*. (2007), Lee *et al.* (2005a) e Lee *et. al.* (2005b). Para este modelo, utilizou-se a variação do algoritmo de busca harmônica intitulado de *Improved Harmony Search Algorithm.* De acordo com Mahdavi *et al*. (2007) e Geem *et al*. (2001) O método adota os 5 passos descritos a seguir:

Passo 1: Neste passo são declaradas as variáveis de controle e também criadas as soluções iniciais. A partir do parâmetro HMS (parâmetro inicial do algoritmo) são definidos *N* vetores soluções em HM. Esses valores são gerados randomicamente, porém devem ser coerentes com o problema apresentado. Para garantir essa coerência e uma melhor convergência

para a solução ótima, é necessário delinear limites para esses valores gerados randomicamente. Durante a inicialização da memória harmônica (HM), cada posição do vetor solução busca seu intervalo de limites para cada variável correspondente como mostra a equação(2.5):

$$HM(x,y) = ran * (lim_{+} - lim_{-}) + lim_{-} \tag{2.5}$$

onde *ran* possuí distribuição uniforme no intervalo [0,1].

As variáveis lim_{+} e lim_{-} representam os limites superiores e inferiores para cada variável e *ran* é gerada randomicamente entre 0 e 1. Dessa forma garante-se que todos os valores criados no início serão pertencentes aos limites impostos no começo da simulação.

Passo 2: Após definido o HM, é realizada a verificação linha por linha (harmonias) do desempenho de cada solução contida na memória. Essa verificação é definida como aptidão. Quanto mais harmônica cada solução, mais próximo do ideal aquela memória harmônica está.

Passo 3: Depois de realizado o segundo passo e onde foram calculados todos os *fitness* das soluções, o programa busca analisar os melhores e os piores *fitness* e substituir as piores harmonias. Essa substituição é realizada com o auxílio de duas variáveis: $PAR(t)$ e $BW(t)$. Essas variáveis são calculadas por (2.6) e (2.7) respectivamente:

$$PAR(t) = PAR_{min} \frac{PAR_{max} - PAR_{min}}{NI} \times t, \tag{2.6}$$

e

$$BW(t) = BW_{max} e^{\left(\frac{ln\left(\frac{BW_{min}}{BW_{max}}\right)}{NI} \times t\right)} \tag{2.7}$$

onde *t* é definido como a iteração atual no instante de tempo do cálculo. Esses valores são utilizados para criar novas soluções que substituirão as que possuírem as piores harmonias. Após calcular esses valores, o

sistema utiliza uma probabilidade por meio da geração de um valor aleatório. Se esse valor for superior à taxa harmônica (*HMCR*), o sistema irá gerar uma nova solução dentro dos limites para substituir a solução com pior harmonia. Caso essa nova harmonia supere a anterior, será substituída e a antiga será excluída. Caso contrário, se o *HMCR* for superior, será realizado um ajuste mais adequado para aprimorar a solução. De acordo com Wang *et al*. (2010) o ajuste de tom determina quanto mais é necessário de ajuste na variável de acordo com o *BW* (largura de banda). O *BW* é similar a um mecanismo de busca local. Com os novos valores já calculados ou ajustados é necessário atualizar as novas soluções e comparar com as anteriores. PAR representa o intervalo da taxa para o ajuste do tom, também auxiliando como mecanismo de busca local.

Passo 4: Depois de calculados os novos valores, é realizada uma nova verificação das soluções encontradas para identificar seus valores de *fitness*. O comparativo é realizado em relação ao pior fitness encontrado. Caso a solução nova tenha uma harmonia melhor, substituirá a anterior.

Passo 5: Ao iniciar o programa é pré-estabelecido que exista um número limitado de iterações. A cada nova iteração o sistema realiza essa checagem. Caso a iteração não atenda ao critério de parada, continua para a próxima iteração (retornando ao **passo 3**), caso contrário encerra o procedimento.

2.5 RECONSTRUÇÃO TRIDIMENSIONAL

A reconstrução tridimensional é baseada no empilhamento (*stacks*) das fatias de imagens de TC, e é um fator muito relevante nesta pesquisa, pois permite a visualização espacial da superfície da prótese depois de modelada. Uma das técnicas amplamente usadas é a Triangulação de Delaunay baseada no diagrama de Voronoi (DE BERG, *et. al.*, 2008).

2.5.1 Diagrama de Voronoi e Triangulação de Delaunay

O diagrama de Voronoi é a ligação dos pontos que representam os centros das circunferências da triangulação de Delaunay (CATANI, 2009). Seria como uma interpretação geométrica do modelo que lhe é aplicado. O modelo de atribuição de Voronoi consiste em definir pontos que satisfaçam a menor proximidade entre a nuvem de pontos aplicada.

Essa subdivisão de pontos é definida como diagrama de Voronoi. Considerando que uma nuvem de pontos P está contida no espaço $\mathbb{R}^3$, então o diagrama de voronoi buscará o ponto de menor distância entre os elementos de P. Essa distância não pode ser maior que a distância entre os pontos P, a fim de sitiar as regiões que correspondam a um determinado número de pontos.

Esse diagrama possui diversas aplicações como na robótica, física e astronomia, mas está mais diretamente ligada à triangulação de Delaunay. Em 1934 a triangulação foi proposta por Boris Delaunay. O modelo consiste em verificar a existência de três pontos únicos, dentre uma nuvem de pontos, que constituam um triângulo.

Utilizando o diagrama de Voronoi é possível identificar esses triângulos a fim de constituir uma malha fechada formados pelo conjunto dos mesmos.

Figura 9 - Triangulação de Delaunay (malha topográfica)

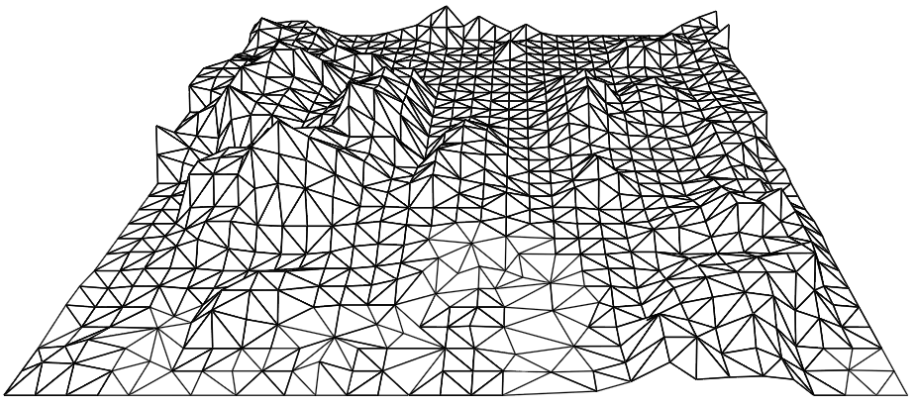

FONTE: DE BERG *et al.*, 2008

Como demonstrado na Figura 9, a triangulação de Delaunay cria triângulos para representar através dos mesmos as posições e ligações em uma malha

fechada (CATANI, 2009). O método de Delaunay utiliza esferas baseados nos pontos fornecidos pelo diagrama de Voronoi. Com a existência de apenas três pontos coincidentes à esta esfera, o modelo busca formar triângulos onde os ângulos de suas arestas não sejam muito pequenos. Essa restrição garante a identificação de triângulos mais uniformes.

2.5.2. Nuvem de Pontos e Interpolação.

Segundo Kels e Dyn (2011), a interpolação aplicada a uma nuvem de pontos 3D tem sido muito utilizada na área de imagem médica com modelos conhecidos como paramétricos por correspondência ou seções cruzadas (fatias). A proposta de Kels e Dyn, apresenta uma combinação de dois modelos: (i) adaptação para conjuntos reais usando métodos de subdivisões, e (ii) utilização de média ponderada. A Figura 10 demonstra como o modelo é aplicado e ilustra um conjunto de *sketches*, como conceitualmente é o conjunto de imagens da TC. Utilizando o modelo proposto de interpolação é possível aumentar a quantidade de informações geradas entre as fatias.

Figura 10 - Interpolação proposta por Kels e Dyn

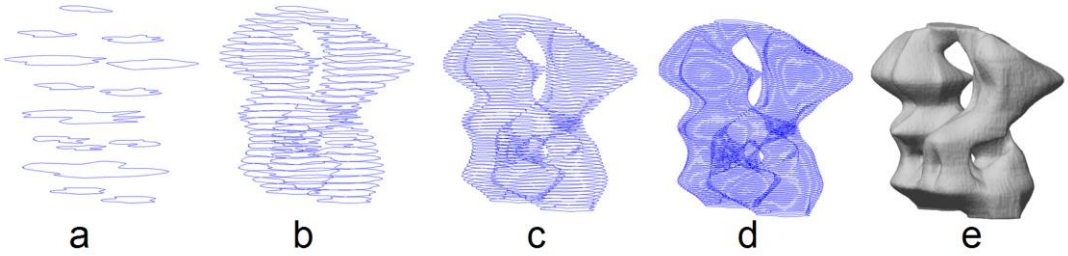

FONTE: Adaptado de Kels e Dyn (2011)

O algoritmo toma como referência duas fatias por vez. Essas fatias são aproximadas através do modelo de subdivisão (DYN, *et. al.*, 1987) e é realizada uma interpolação entre as mesmas. A Figura 11 apresenta o funcionamento da interpolação utilizando pesos na interpolação.

Figura 11 - Passos de interpolação

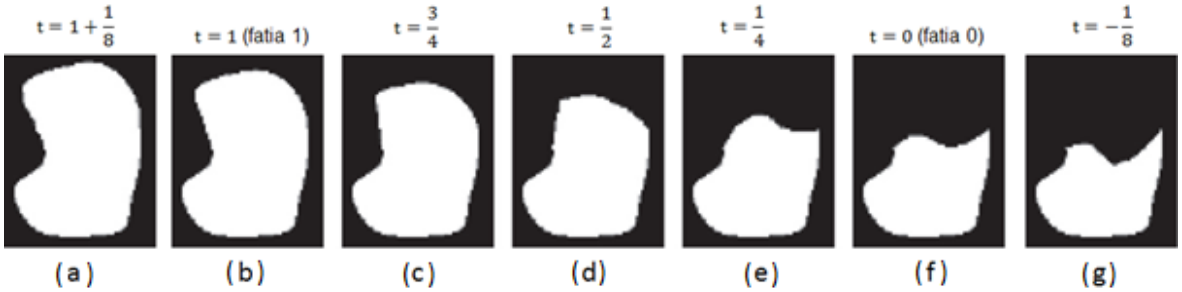

FONTE: Modificado de Kels e Dyn (2011)

A Figura 11 apresenta duas formas distintas de aproximação: interpolação nos casos (c), (d) e (f) e extrapolação nos casos (a) e (g). Exemplificando, o procedimento usa duas fatias, neste caso a imagem (f) representa uma fatia no plano z=0 (“t=0”) e a imagem (b) representa a fatia no plano z=4 (“t=1”). Para melhorar a resolução da TC, deseja-se obter as informações para z={1,2,3}. Kels e Dyn por intermédio da técnica de subdivisão (DYN, LEVIN & GREGORY, 1987) utilizam a média ponderada com peso t, como demonstrado em (2.8).

$$I = tA \oplus (1 - t)B, \tag{2.8}$$

onde *A* representa a fatia 1; *B* representa a fatia 0; *I* é a fatia resultante e; *t* é o peso da média para cada nível de interpolação dentro do intervalo [0,1]. Este processo de interpolação tem implicação direta no resultado da reconstrução tridimensional. A Figura 12 mostra o resultado final.

Figura 12 – Nuvem de pontos original (a) e interpolada (b), e respectivas superfícies (c e d).

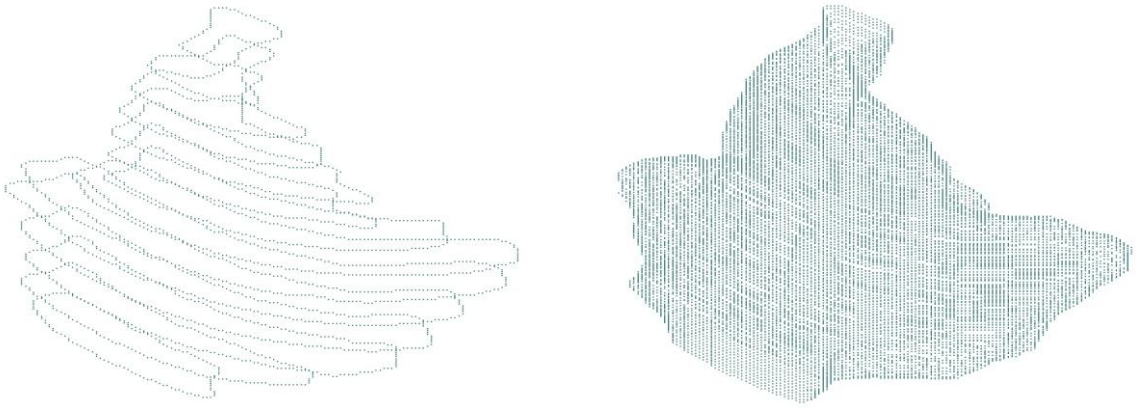

(a) (b)

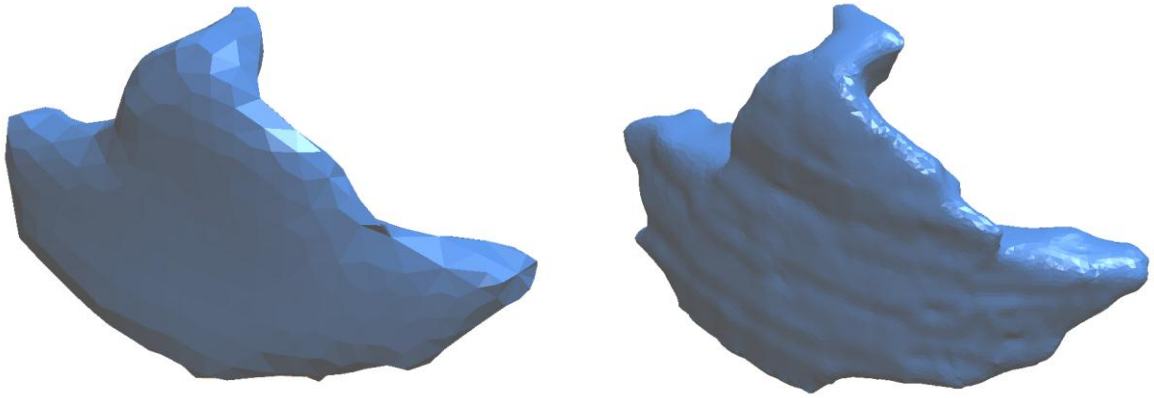

(c) (d)

FONTE: O Autor

De acordo com a Figura 12.c, a reconstrução tridimensional a partir das fatias na Figura 12.a se torna menos precisa devido a pouca quantidade de informações entre as fatias adjacentes (resolução de 3 mm). Pelo processo de interpolação Figura 12.b observa-se a diminuição do espaçamento (0,4mm) implicando no melhor detalhamento da representação 3D da superfície como Figura 12.c e Figura 12.d.

3 PROPOSTA DO MODELO CONCEITUAL

A proposta da pesquisa é definir um modelo conceitual para criar geometricamente próteses anatômicas de crânio de forma autônoma sem interação humana, desde a fase de extração de imagens tomográficas até a definição dos requisitos de manufatura, aplicada à casos assimétricos. A partir do referencial teórico do capítulo 2 é possível definir os elementos fundamentais que constituem este modelo cuja estrutura é apresentada na Figura 13.

Figura 13 - Modelo conceitual

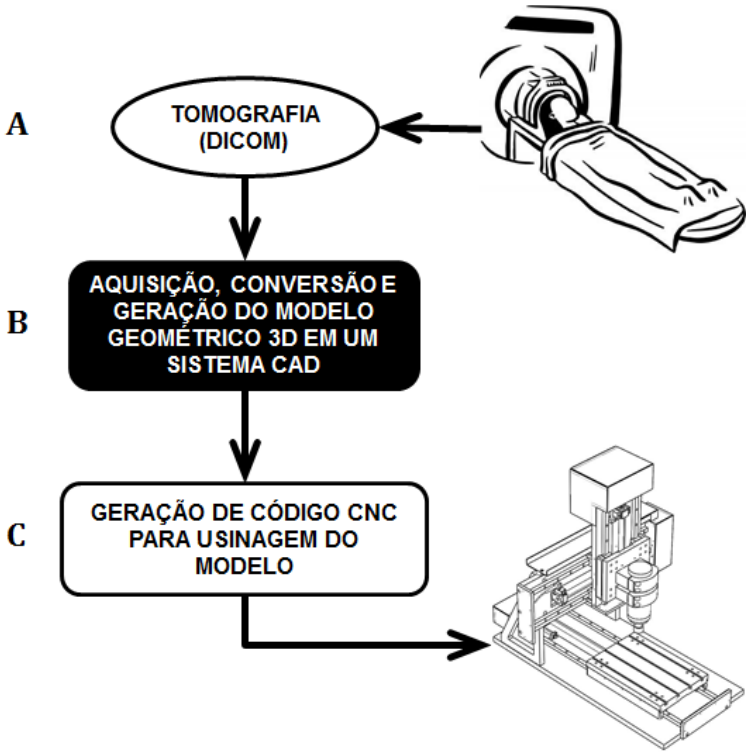

FONTE: O Autor

A Figura 13 apresenta o fluxograma da proposta subdividido em três níveis principais. O item ‘A’ representa todo o conjunto de ações necessárias para extração e processamento das imagens. O nível ‘B’ representa todo o desenvolvimento da metodologia para a criação do modelo conceitual, e que abrange todas as tarefas específicas para a geração do modelo geométrico da prótese, e o terceiro nível ‘C’ que é a execução final da tarefa pela produção do protótipo. O presente diagrama apresenta o encadeamento do processo que é complexo e amplo, mas que não é totalmente abordado nesta pesquisa. O principal conjunto de temas tratado neste

trabalho é o item ‘B’ destacado na Figura 13. Este nível é mais bem detalhado no diagrama da Figura 14.

Figura 14 - Detalhamento do método proposto

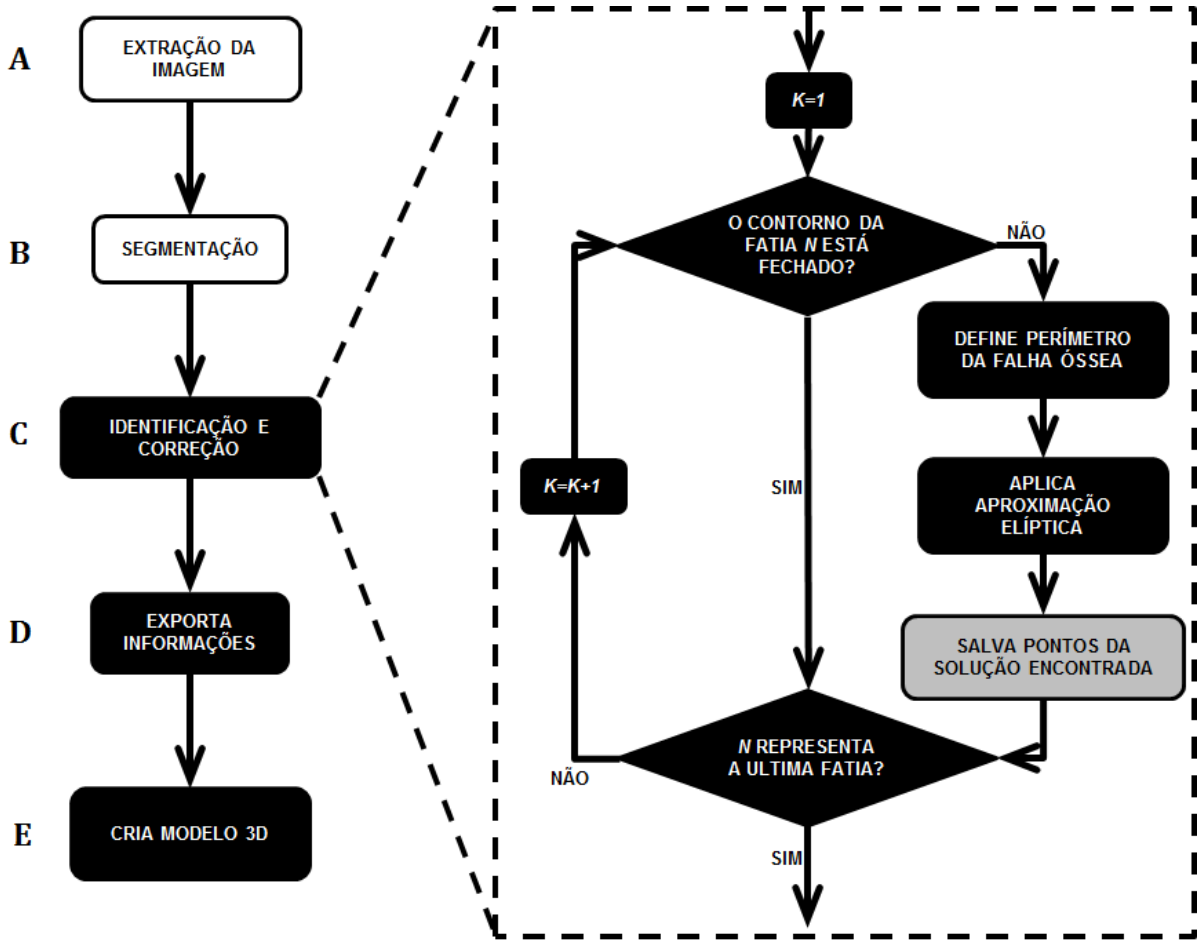

FONTE: O Autor

O modelo proposto é composto de cinco etapas principais (representadas na Figura 14 de A à E), dispostas a seguir.

3.1 EXTRAÇÃO DA IMAGEM (ETAPA A)

Nesta primeira etapa, o algoritmo deve realizar a aquisição dos arquivos no padrão DICOM para extrair as informações do crânio para o estudo. Características como largura e comprimento dos *pixels* (em mm) e distância em mm entre as fatias

do crânio são obtidas nesta etapa através das informações contidas no DICOM. Os valores de intensidade dos pixels são então traduzidos originalmente de 16 bits para 8 bits, em tons de cinza. Esta redução é realizada para um menor consumo de memória, e consequentemente, menor custo computacional.

Figura 15 - Exemplo de conversão de escalas de cinza

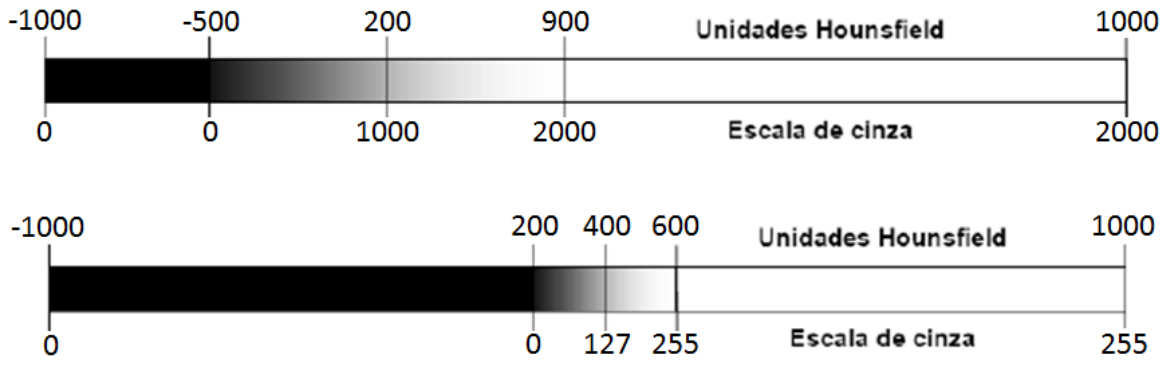

FONTE: modificado de GREBOGE, 2009

A Figura 15 ilustra uma LUT (*Look Up Table*) dos valores em escala de cinza para valores de 16 *bits* (valores acima de cada escala) e 8 *bits* (valores abaixo de cada escala). Com os valores adequados para o intervalo de 0 a 255, o algoritmo armazena o conjunto de *K* imagens, onde *K* depende de quantas imagens o usuário deseja incluir no início do algoritmo procedendo ao próximo passo.

3.2 SEGMENTAÇÃO (ETAPA B)

Todas as informações apresentadas nas fatias da TC que não correspondem à área óssea são desconsideradas. Informações como tecidos cartilaginosos, órgãos, derme e fluidos corpóreos. Também é nessa etapa que o modelo segmenta a área óssea mais significativa, descartando possíveis ruídos nas informações. Todo o perímetro da TC que não corresponder ao intervalo definido na tabela de Hounsfield como sendo ósseo assumirá o valor zero. Se estiver dentro da faixa de valores para tecido ósseo, assumirá valor um.

O método de detecção de áreas na imagem tem por finalidade dividir áreas que constituem a imagem separando-as e catalogando-as. Este método é uma adaptação da técnica de segmentação por crescimento de regiões (POLAK, *et. al.*, 2009) e identifica regiões e pode calcular suas áreas através do número de pixels. Assim é possível desconsiderar áreas de baixa relevância. Após transformar todos os pixels para um vetor com suas coordenadas, é selecionado um ponto aleatório neste vetor para dar inicio ao procedimento. A Figura 16 auxilia na demonstração do procedimento:

Figura 16 – Método para a separação de áreas

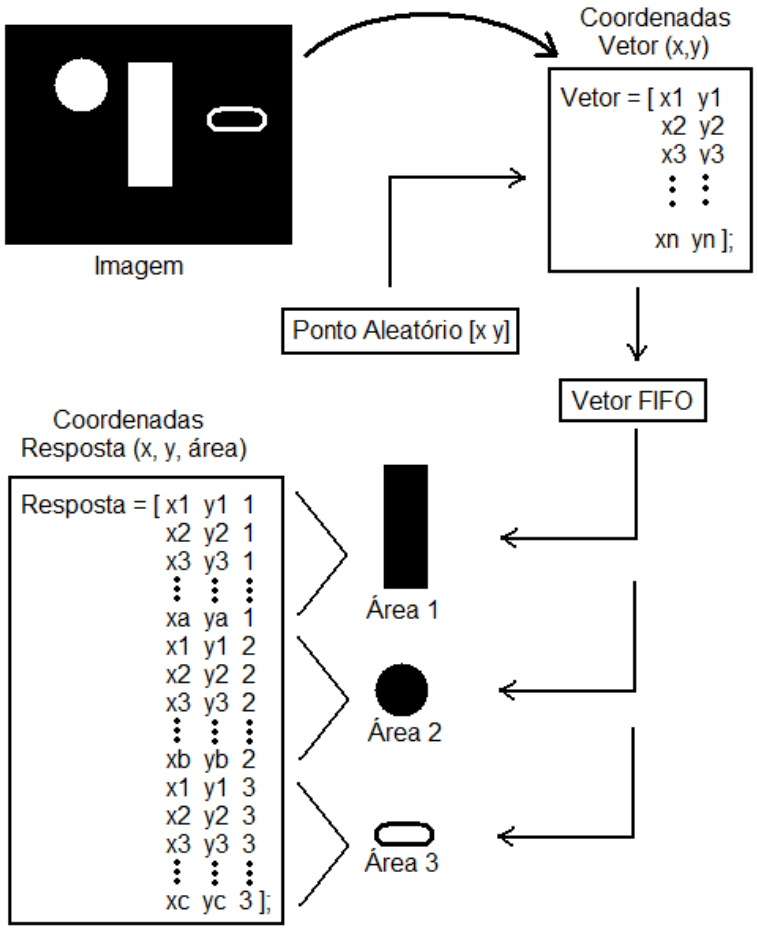

FONTE: O Autor

O processo consiste em utilizar um ponto inicial para fazer a aquisição dos pixels ao seu redor e copiá-los para um vetor FIFO (*first in, first out*). Para identificar quando uma área chega ao final da aquisição, o sistema utiliza este vetor, onde o novo *pixel* analisado é apagado do vetor original de pontos para garantir que não

será considerado novamente. Após analisar o ponto, é realizada uma nova aquisição dos pixels próximos que também serão inseridos no FIFO.

Quando o processo identifica que todos os elementos do vetor FIFO foram utilizados, é feita uma comparação dos números já analisados com o número total de pontos. Se estes números não forem o mesmo, o sistema interpreta que existem mais áreas para realizar a aquisição, dando inicio ao processo novamente com um novo ponto randômico entre os pontos que não foram verificados.

Figura 17 - Exemplo de separação de áreas em uma fatia de TC.

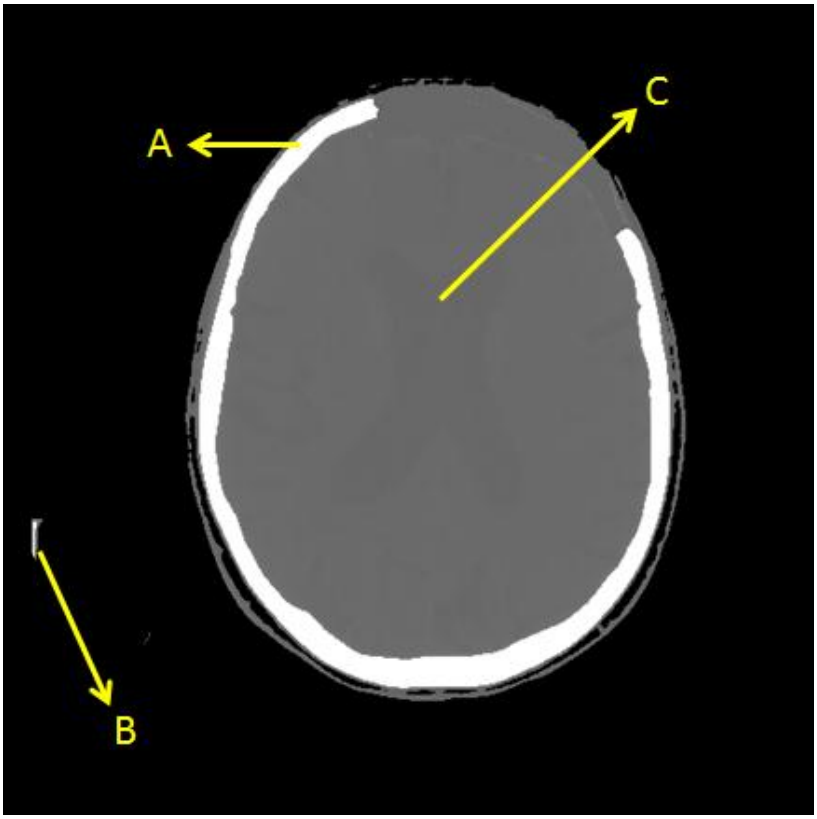

FONTE: O Autor

No caso apresentado pela Figura 17, existem três áreas distintas. A região ilustrada em ‘C’ é removida através da limiarização dos níveis de cinza. Porém, outras informações presentes na imagem (como indicado por ‘B’) que possuem valores iguais aos que representam a área óssea (‘A’) se mantem aparentes na imagem. Aplicando a técnica de separação de áreas removem-se regiões pequenas como ilustrada em ‘B’, mantendo apenas a região ‘A’.

3.3 IDENTIFICAÇÃO E CORREÇÃO (ETAPA C)

Esta etapa tem como entrada todas as fatias do conjunto previamente extraídas e segmentadas. O quadro expandido na Figura 14 mostra em detalhes o fluxograma do processo. É definida uma variável *K* incremental para identificar as fatias consecutivamente. Cada fatia é analisada individualmente e, caso seja detectada a falha, é mapeada uma área onde necessita criar a correção.

Identificar a região faltante do crânio é realizado através de uma varredura por coordenadas polares a partir do centro da imagem.

3.3.1 Definições de eixos de simetria

Para uma melhor compreensão e identificação dos planos utilizados no modelo conceitual, a Figura 18 ilustra os mesmos.

Figura 18 - Planos de referência

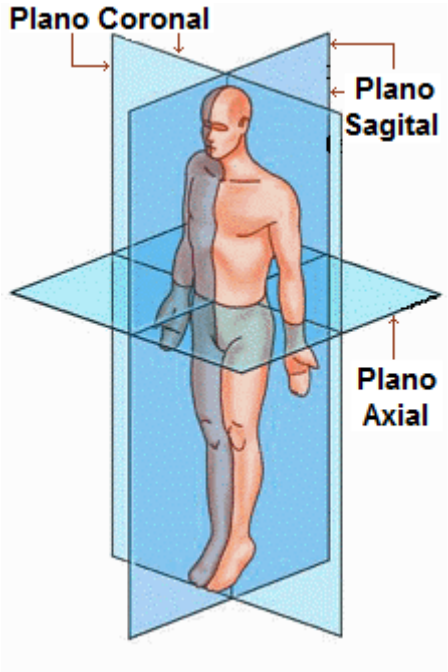

FONTE: Modificado de Spine Universe (2013)

As imagens extraídas dos arquivos de TC utilizam cortes paralelos ao plano ilustrado como plano axial. Desta forma quando houver referências destes planos (axial, sagital e coronal), estes terão como referência os planos ilustrados na Figura 18.

A partir do plano sagital é considerado o eixo de simetria natural do corpo humano. Dessa forma o eixo contido no plano sagital centrado nas tomografias será a referência para os procedimentos demonstrados nos passos seguintes do método.

3.3.2 Varredura por Coordenadas Polares a Partir do Centro da Imagem

Esta técnica de varredura parte do centro da imagem e realiza uma varredura circular a partir da sua origem. A resolução utilizada para o incremento de radianos é de 0.001*rad*. Este valor foi definido para garantir que a distância D1 entre P1 e P2 seja pequena o bastante para realizar a aquisição da maioria dos pontos do contorno, como apresentado na Figura 19.

Figura 19 - Distância entre pontos

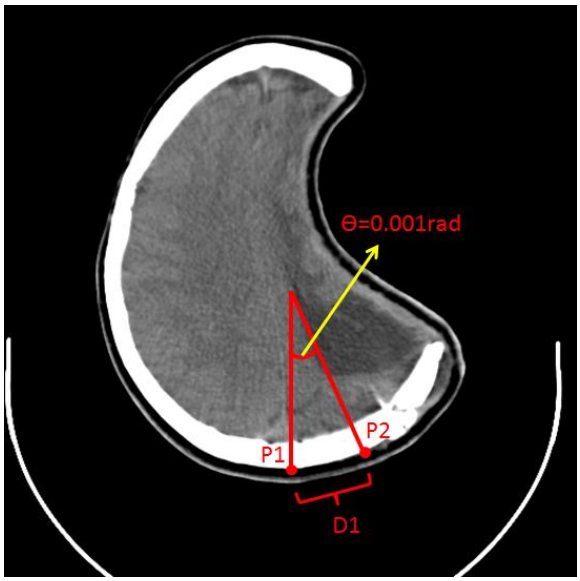

FONTE: O Autor

As imagens utilizadas possuem resolução de 53 DPI (equivalente à 512x512 *pixels*, com 0,475mm de dimensão real para cada *pixel* referente à altura e largura). Quando o *pixel* for encontrado em determinado ângulo, sua posição será definida

pelo raio (*r*). O valor de *r* é um contador incrementado até encontrar um pixel de valor 1, caso contrário o contador assumirá o valor 0. Assim sua coordenada pode ser descrita e traduzida para coordenadas polares a partir da equação (3.1).

$$P(x,y) = (r * cos\theta + x_0, r * sen\theta + y_0) \quad (3.1)$$

Na equação (3.1), x_0 e y_0 representam o centro da imagem de onde partem os vetores de varredura. A Figura 20 ilustra como a técnica se comporta a partir do ângulo 0 até 2*π rad*.

Figura 20 - Mapeamento polar

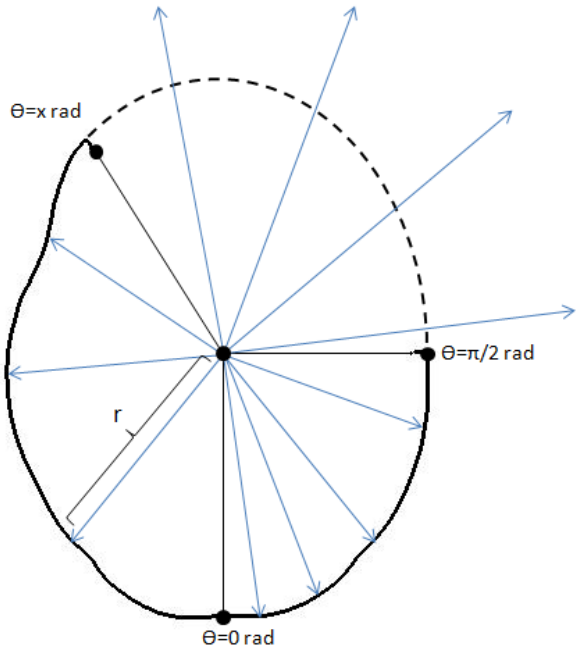

FONTE: O Autor

Na Figura 20, a técnica não utiliza a forma convencional para posição dos ângulos porque a referência usada é o eixo de simetria do crânio (plano sagital) (0 rad e *π rad* estão sobre o eixo de simetria). A partir do resultado desta varredura tem-se o histograma do contorno, conforme apresentado na Figura 21:

Figura 21 - Histograma polar

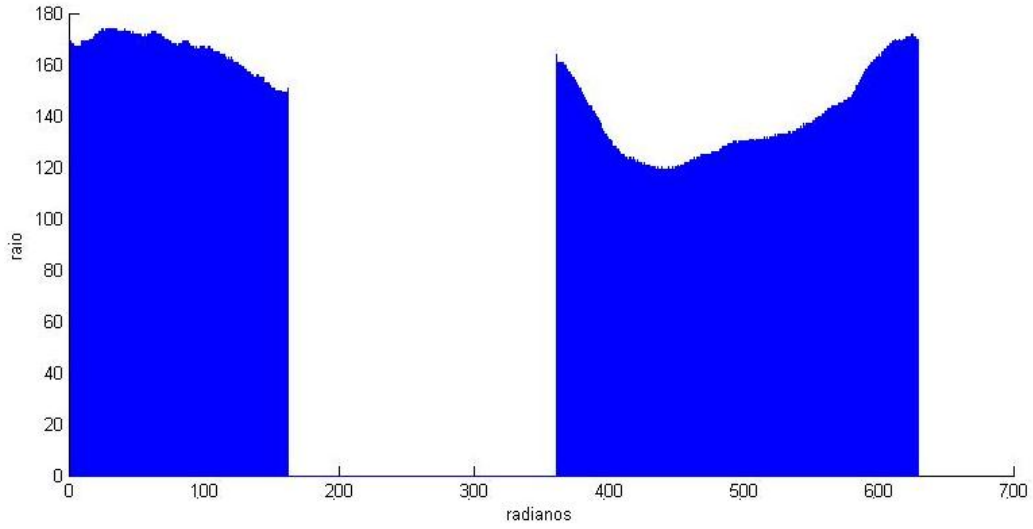

Com este histograma é possível identificar os pontos onde estão as descontinuidades a partir de sua derivada. Diferentemente da varredura anterior, agora não se necessita da análise de uma segunda varredura para identificar a deformação. Assim onde houver os picos de derivada, utilizando a abscissa (radianos) e ordenada (raio), em conjunto com a equação (3.1), é possível identificar os dois pontos onde se define a região da deformação.

3.3.3 Método para Geração das Elipses

Como o sistema busca uma aproximação elíptica para a fatia do crânio, é necessário gerar um vetor com as variáveis pertinentes à criação das elipses. Esse vetor é definido como “vetor solução”, chamado de “população” no (AG), ou “posição do enxame” no (PSO), ou “memória harmônica (HM)” no algoritmo de busca harmônica (HS). Nele serão contidas as informações do comprimento dos eixos ‘*a’*, e ‘*b’*, e da posição do centro da elipse ‘*O’* de coordenadas ‘x_0’ e ‘y_0’, como mostra a Figura 22.

Figura 22 - Parâmetros da elipse

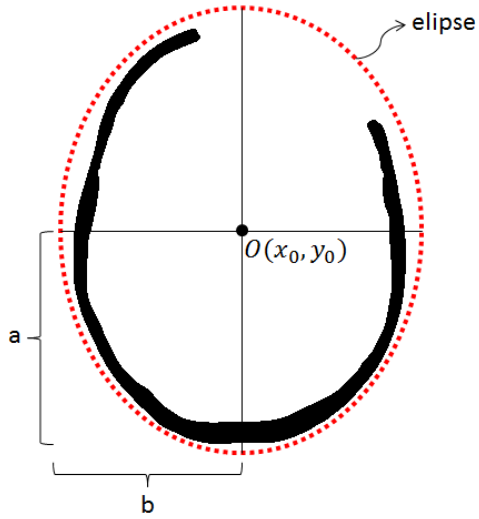

FONTE: O Autor

Dadas às características anatômicas do crânio, é possível definir os limites do espaço de busca usado nas simulações, como apresenta a figura 28.

Figura 23 – Limites do espaço de busca

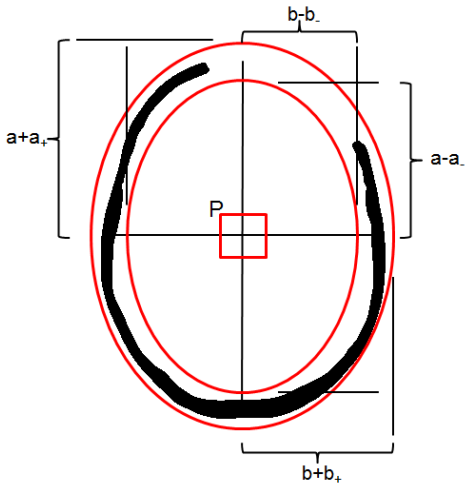

FONTE: O Autor

A Figura 23 apresenta como são definidos os limites para a aproximação elíptica utilizados anteriormente por Rudek, *et. al*. (2011b). Os limites do eixo *a* são definidos por a_- e a_+. Isso também ocorre para o eixo *b*. O centro aproximado da elipse pode variar, portanto é delineado um perímetro *P* onde este pode estar contido. Os limites ficam da seguinte forma:

$$
\begin{aligned}
a_- - 10 \leq a \leq a_+ + 10 \\
b_- - 10 \leq b \leq b_+ + 10 \\
x_0 - 15 \leq x_0 \leq x_0 + 15 \\
y_0 - 15 \leq y_0 \leq y_0 + 15
\end{aligned}
\tag{3.2}
$$

Foi observado em simulações que os valores otimizados para *a* e *b* pertenciam, em sua maioria, em uma faixa de 10 *pixels* (aproximadamente 4 mm, utilizando as características do *voxel* contido nas características da TC) para mais ou para menos da largura e comprimento originais do crânio. O mesmo ocorreu para as origens x_0 e y_0 com uma variação de 15 *pixels* (em torno de 7 mm) para mais ou para menos. Estes valores obtidos empiricamente fornecem ao sistema de busca um conjunto de soluções mais próximo ao resultado desejado.

Para a criação da elipse é utilizada a forma polar da equação descrita em (3.3):

$$
r = \frac{ab}{\sqrt{a^2 sin^2\theta + b^2 cos^2\theta}} \tag{3.3}
$$

Tendo as variáveis desejadas e identificadas como *a*, *b*, x_0 e y_0, pode-se criar uma representação elíptica a partir de uma determinada origem com a variação de $0 < \theta \leq 2\pi$, como demonstrado na Figura 24:

Figura 24 – Representação polar da elipse

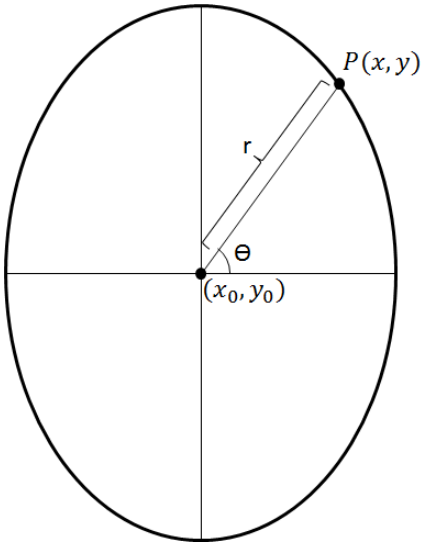

FONTE: O Autor

As variáveis $P(x,y)$, r, θ, x_0 e y_0 apresentadas na Figura 24, e definidas pela equação (3.1), estão correlacionadas com os parâmetros a, b e $O(x_0,y_0)$ da Figura 22 por meio da equação (3.3). Na inicialização do método, busca-se gerar N vetores que contenham as quatro variáveis (a, b, x_0 e y_0), e, portanto, o vetor solução será parte de uma matriz $Nx4$. Cada linha dessa matriz representa um vetor solução aplicável no modelo. Este valor N é um parâmetro definido inicialmente como sendo o tamanho da população, do enxame ou da memória harmônica (*HMS*). Esta limitação de variáveis permite definir o número de aproximações que o algoritmo vai realizar em cada iteração, podendo assim limitar o custo computacional do algoritmo.

Outro ponto definido na inicialização do sistema é a definição das variáveis para critério de parada. Para o AG define-se um número máximo de gerações; para o PSO limita-se a quantidade de iterações e para o HS delimita-se a taxa harmônica (*HMCR*). No caso do algoritmo de busca harmônica existe ainda o intervalo da taxa para o ajuste do tom (*PAR*) e largura de banda (*BW*). Essas variáveis definem uma margem de busca para os valores que estão sendo otimizados. Em outras palavras, A busca fica limitada para um perímetro próximo ao valor anterior.

3.3.4 Utilização de Elipses para Aproximação

Como o crânio humano segue padrões geométricos naturais, é possível à partir de formas circulares, esféricas, cilíndricas e também análises por transformadas de Fourier elípticas aplicar o conceito de aproximação para formas geométricas simplificadas (GIELIS, 2003). Dessa maneira é possível através de equações matemáticas, obter tais formas aproximadas e, assim, uma geometria que represente o contorno do crânio.

Através de equações genéricas que representam tais formas, é possível aplicar técnicas de metaheurísticas para a obtenção dos melhores parâmetros que representem a forma natural estudada (parâmetros apresentados na equação 3.1).

Figura 25 – Aproximações interna e externa

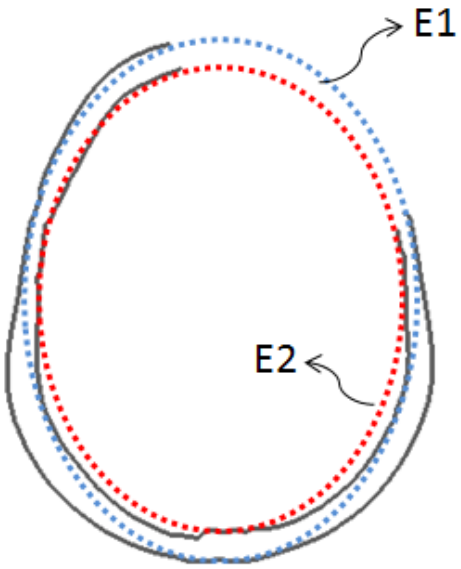

FONTE: O Autor

A Figura 25 demonstra as aproximações para o contorno externo e interno, em E1 e E2 respectivamente. Nota-se que existe uma correlação das elipses com os respectivos contornos do crânio (GREBOGE, 2009).

3.3.5 Função de Aptidão (*Fitness*)

Para este estudo, a determinação dos valores de *fitness* para cada parâmetro ocorre com o objetivo de aperfeiçoar as elipses de acordo o contorno do crânio. A Figura 25 ilustra o foco da otimização. Como o crânio possui um contorno interno e um externo, o algoritmo processa cada um separadamente. Para avaliar matematicamente cada aproximação, o sistema gera cada elipse e verifica seu desempenho individualmente. Essa elipse então é sobreposta na tomografia que se deseja fazer a aproximação. Para a definição da representatividade de cada elipse é necessário avaliar o quão sobreposta cada elipse está do contorno do crânio. A Figura 26 ilustra o resultado do método de mapeamento polar conforme descrito na Figura 20.

Figura 26 - Delimitação da deformação

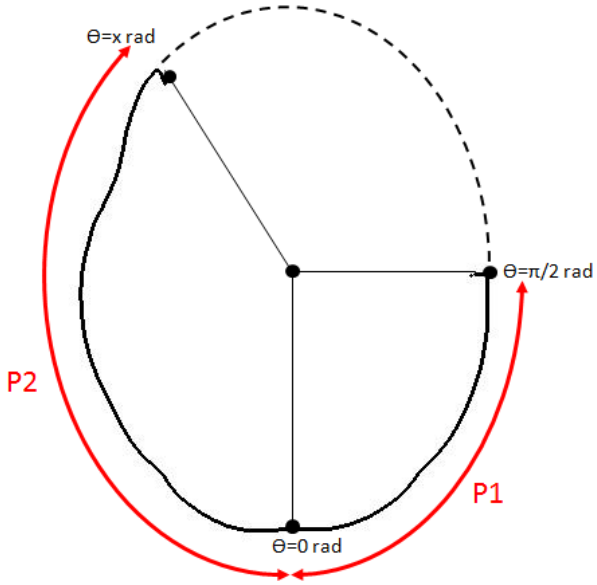

FONTE: O Autor

Conforme apresenta a Figura 26, com a detecção da deformação entre $\frac{\pi}{2}$ rad e *x* rad, as informações pertinentes ao histograma estão contidas no replemento da área de deformação (2*π* menos o ângulo que abrange a área da deformação). Este replemento é contido em um vetor que representa o histograma de posição com a deformação. A Figura 27 exemplifica o vetor do histograma.

Figura 27 - Vetor de histograma

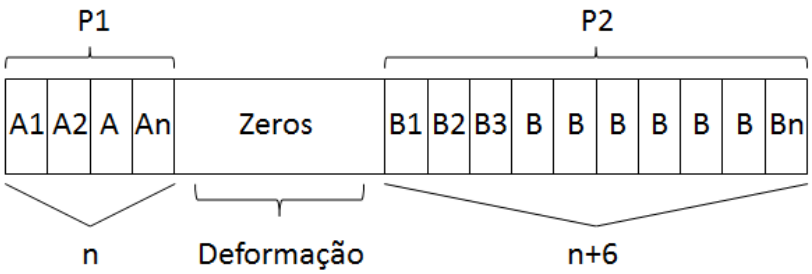

FONTE: O Autor

No vetor de histograma, P1 representa o conjunto de pontos que antecede à deformação (partindo de θ=0 no sentido anti-horário), identificado por ‘A’. P2 representa o conjunto de pontos que procede à deformação, identificado por ‘B’. Os valores inteiros que ‘A’ e ‘B’ representam as distâncias dos *pixels* do contorno com

relação ao centro da imagem. O tamanho deste vetor varia de acordo com a resolução utilizada para o ângulo de varredura, como mencionado no item 3.3.2. Como a resolução padrão é de 0.001 rad, e a varredura é realizada no intervalo [0,2π], então seu comprimento é de 6283. Como exemplificado no vetor (Figura 27), a região para a aproximação elíptica está desbalanceada, assim, quando aplicada à função de aptidão no algoritmo evolutivo, um lado será mais representativo na otimização que o outro.

Figura 28 – Posição dos arcos H'1 e H'2

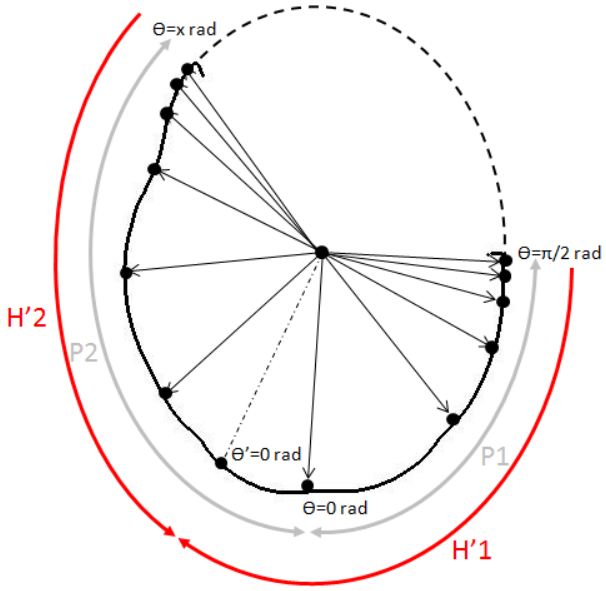

FONTE: O Autor

Para evitar essa tendência no processamento, o vetor é devidamente equilibrado simetricamente à deformação (tomando como eixo de simetria a semi-reta entre o centro e o ponto *θ'* na Figura 28). Dessa forma, com o balanceamento, os dois lados do contorno terão a mesma quantidade de informações. A Figura 28 ilustra o novo eixo *θ*' para equilibrar os histogramas e gerar os arcos H'1 e H'2.

Com as duas metades do histograma de posição balanceadas, é possível selecionar os "pontos representativos" do contorno craniano para realizar a aproximação elíptica. Esses pontos estão ilustrados na Figura 28 através dos vetores (com origem no centro da imagem até o contorno do crânio). Estes pontos seguem uma distribuição exponencial, visando manter os pontos representativos mais próximos à ROI, descrita pela equação (3.4),

$$v(i) = e^{i} \tag{3.4}$$

para i=1, 2, 3, ..., n

onde *n* representa a metade do número de pontos representativos que serão utilizados no histograma de posição (ilustrados como H'1 e H'2); *v* é o vetor que contém os valores exponenciais para cada *i*.

Os valores contidos no vetor *v* são então normalizados através da equação (3.5).

$$v_n(i) = \frac{v(i)}{\sum_{i=1}^{n} v(i)} \cdot k \tag{3.5}$$

para i=1, 2, 3, ..., n,

É apresentado no anexo 4 um arranjo técnico que demonstra a implementação. A Figura 29 apresenta o arranjo do vetor histograma e o grau de importância dos pontos após o balanceamento, fazendo uma analogia com o vetor apresentado na Figura 27 e o exemplo da Figura 73.

Figura 29 - Histograma balanceado

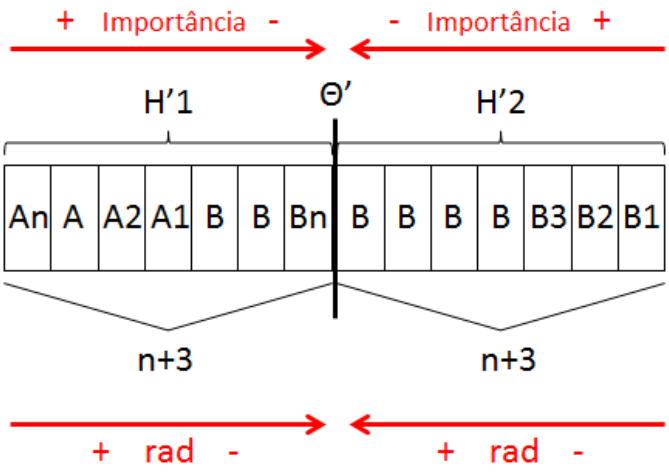

Fonte: O Autor

Desta forma, o algoritmo terá quantidades balanceadas para as duas extremidades onde foi detectada a deformação. Com o isto, o histograma do contorno tem o formato apresentado na Figura 30.

Figura 30 – Regiões do contorno no histograma de posição

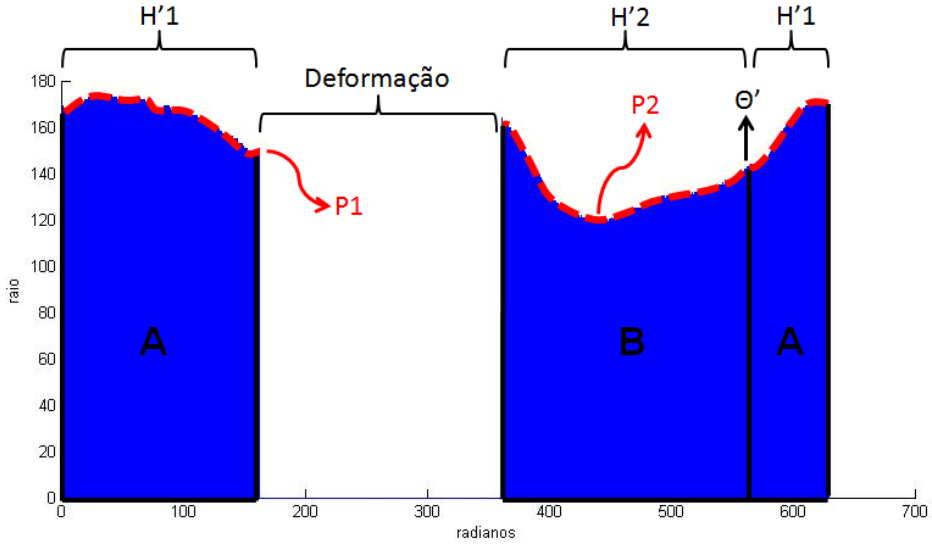

FONTE: O Autor

Para a aproximação da elipse no contorno craniano, o procedimento pode ser representado visualmente através da Figura 31.

Figura 31 – Aproximação elíptica

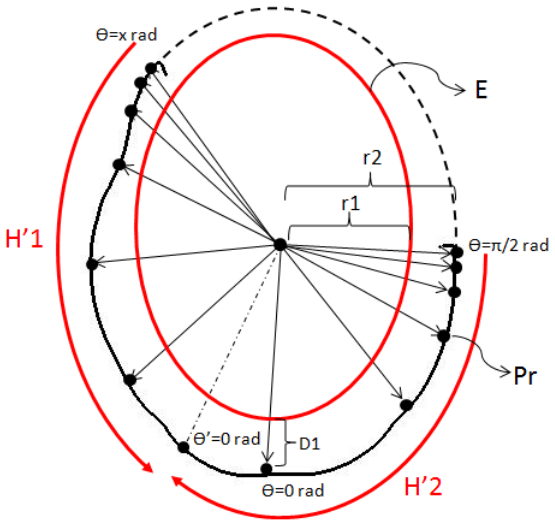

FONTE: O Autor

Para cada ponto representativo (Pr) existirão: um raio (r1), referente à distância do contorno da elipse ‘E’ ao centro da imagem; um raio (r2) referente à distância do contorno do crânio ao centro da imagem; uma distância (D1) referente à diferença entre os raios (r1) e (r2); sendo estes valores referentes ao ângulo que representa o ponto na imagem. É necessário medir esta distância D1 para se avaliar o ajuste.

Desta forma, a função fitness pode ser definida matematicamente pela equação 3.6.

$$F(z) = \sum_{i=1}^{n} R_2(z) - R_1(z) \tag{3.6}$$

onde:

z = elemento da otimização,
i = ponto do histograma para aproximação,
n = número de pontos representativos utilizados do histograma,
R_1 = raio representativo da elipse,
R_2 = raio representativo do contorno.

Figura 32 - Histograma da elipse E (H_E)

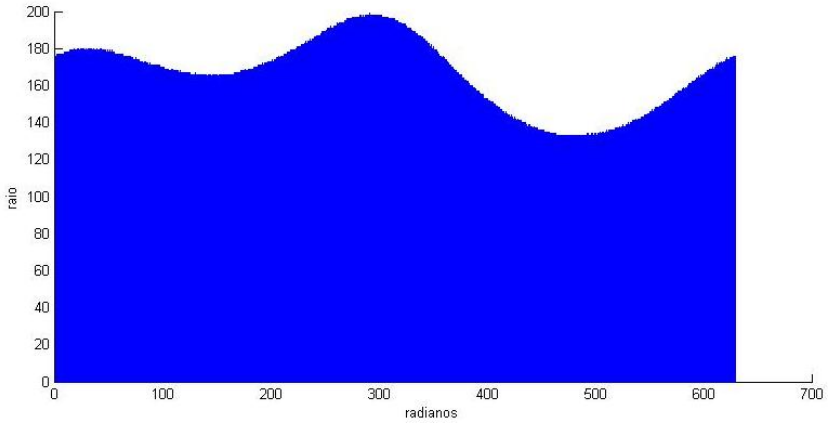

FONTE: O Autor

Para melhor ilustrar como ocorre a aproximação das elipses nos contornos do crânio, tem-se a Figura 32 que apresenta o histograma de uma elipse (onde os valores do raio na ordenada são definidos em *pixels*) semelhante à apresentada na Figura 31 (ilustrada como ‘E’).

Com a sobreposição do histograma de posição da elipse (Figura 32) no histograma de posição do contorno, tem-se a Figura 33.

Figura 33 – Sobreposição do histograma H_e com o histograma H_c

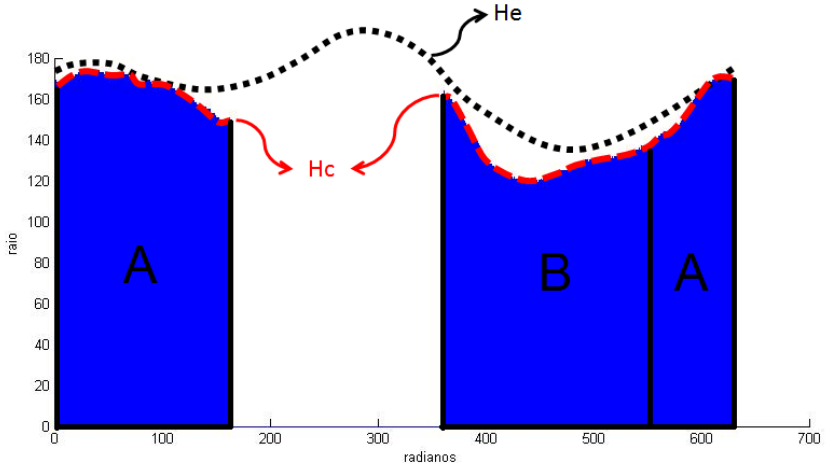

FONTE: O Autor

Na imagem, ‘He’ representa o histograma de posição da elipse que está sendo avaliada (histograma apresentado na Figura 32); ‘Hc’ representa o histograma do contorno com a deformação; as áreas delimitadas como ‘A’ representam os pontos do histograma ao lado direito da deformação e ‘B’ o lado esquerdo.

A função *fitness* busca minimizar a diferença entre as curvas ‘He’ e ’Hc’ (minimizar o somatório das distâncias). O valor do fitness vai indicar a elipse que melhor sobrepõe o contorno estudado.

3.3.6 Aplicação de Metaheurísticas

Apesar das limitações impostas aos valores do conjunto de parâmetros (a, b, x_0, y_0), essas variáveis ainda podem assumir inúmeras combinações de valores com pequenas variações, gerando elipses posicionadas com maiores ou menores

diferenças em relação ao contorno do crânio. Isto gera um número elevado de possíveis soluções. A função objetivo (*fitness*) deve ser avaliada para cada elipse ‘E’ gerada de modo que garanta como resultado o melhor conjunto de parâmetros (melhor elipse ajustada) para cada fatia de TC analisada. Para isto, os algoritmos sugeridos no capitulo 2 (IA, PSO e HS) são adequados para a avaliação do critério de *fitness*. Em linhas gerais, os passos realizados pelos algoritmos são:

1. Iniciar as variáveis que serão utilizadas durante a execução do algoritmo, incluindo o tamanho do vetor de solução. Para esta pesquisa o vetor é formado por (a, b, x_0, y_0).
2. Executar uma primeira análise do conjunto de possíveis soluções verificando a aptidão dos indivíduos.
3. Atualizar as possíveis soluções de acordo com as regras de cada método (criação de novos indivíduos, deslocamento das soluções no espaço, etc.).
4. Realizar nova verificação dos valores da aptidão para cada solução.
5. Se o critério de parada não for satisfeito, retornar para **passo 3**.

A escolha do melhor método é um dos objetivos específicos da pesquisa e foi definido de acordo com os resultados de simulação e da aplicação no estudo de caso. O algoritmo escolhido é apresentado no capítulo dos resultados.

3.4 EXPORTAÇÃO DAS INFORMAÇÕES (ETAPA D)

Com os vetores de parâmetros (a, b, x_0, y_0) obtidos para cada elipse ótima aproximada pelo algoritmo, é possível calcular as coordenadas de imagem e traduzi-las para coordenadas métricas contidas dentro da ROI, ou seja, apenas contida na área onde está a deformação. Com as coordenadas métricas para cada fatia K são então agrupadas e exportadas para um sistema CAD a fim de se representar o respectivo modelo geométrico tridimensional da prótese.

Para realizar a exportação, é necessário unir as informações das elipses aproximadas para o contorno externo e o contorno interno.

A Figura 34.a ilustra as duas elipses em uma mesma imagem. Na imagem o intervalo entre as elipses é preenchido para então obter um perfil representativo da área óssea ausente.

Figura 34 - Elipse externa e interna aplicadas na ROI

(a) (b)

FONTE: O Autor

Com o perfil representativo obtido através das elipses, é aplicada uma comparação deste com o contorno que possui a deformação dentro dos limites da ROI. Assim apenas a área da elipse onde sobrepõe a deformação é considerada, como apresentado na Figura 34.b.Foi considerado apresentar apenas o contorno das elipses na Figura 34.b para melhor visualizar a sobreposição da mesma na fatia do crânio. Descartando-se todas as informações não contidas na ROI obtém-se o arco-solução. A Figura 35 ilustra o arco-solução aplicado na fatia.

Figura 35 – Arco-solução resultante

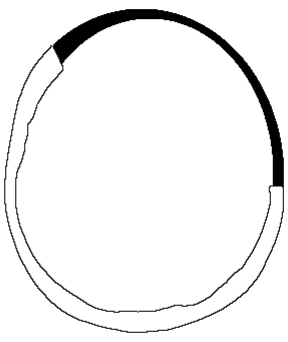

FONTE: O Autor

Com os contornos do crânio e do arco-solução definidos, o próximo passo é exportar as informações de ambos para que um software CAD faça a leitura e trate esses pontos para transformar o conjunto em uma representação geométrica. Cada ponto é representado no espaço tridimensional por três coordenadas (x, y, z), onde k representa a fatia analisada. A Figura 36 demonstra este conceito.

Figura 36 - Conversão *pixel* x *mm*

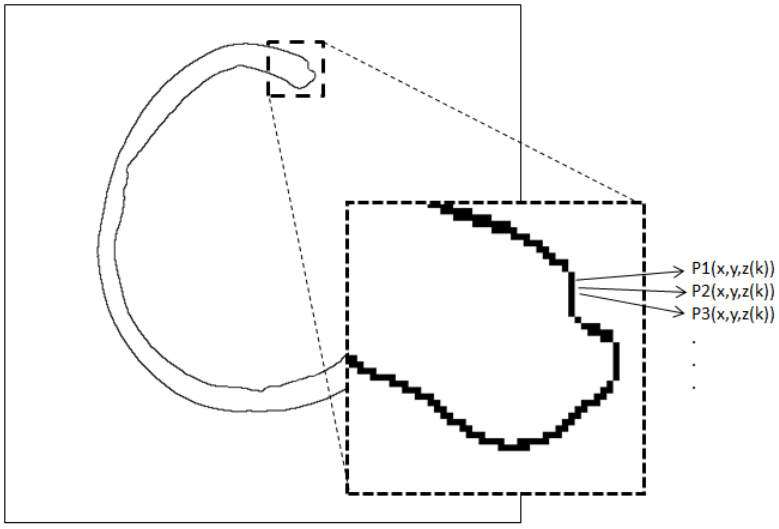

FONTE: O Autor

Através das coordenadas de imagem (contendo os pontos P1, P2, P3, ...) e as características métricas fornecidas pelo arquivo DICOM para os valores dos *pixels*, é possível traduzir as coordenadas de imagem para coordenadas métricas. Por exemplo: o arquivo DICOM informa que os valores para a resolução de *x* e *y* é de 0.4750mm e a fatia em questão é uma seção transversal em 10mm. Assim um pixel existente na posição P(100,200) será exportado como um ponto em x=47.5mm; y=90.0mm e z=10.0mm.

Assim, todos os pixels que estão contidos no contorno do crânio e do arco-solução (solução obtida) são traduzidos e exportados para duas nuvens de pontos, uma nuvem para as fatias do crânio e outra para as fatias dos arcos-solução. Assim que todas as fatias originais forem analisadas, são então interpoladas para aumentar a resolução dos pontos e, essas nuvens de pontos são então exportadas para dois arquivos de texto distintos (um para a nuvem do crânio e outro para a da solução) contendo as coordenadas em x, y e z. O formato de texto ASCII (“.txt”) para os

arquivos de pontos foi escolhido por ser um padrão aceito para a importação e exportação de dados entre diferentes aplicativos. Desta forma evita-se a incompatibilidade entre diferentes plataformas e versões dos sistemas CAD. A disposição para a exportação da nuvem de pontos no arquivo de texto é dada da seguinte forma:

Tabela 1 - Disposição da nuvem de pontos

x (mm)	y (mm)	z (mm)
…	…	…
2.6506000e+01	1.1973400e+02	2.2450567e+00
2.6506000e+01	1.2019100e+02	2.2450567e+00
2.6506000e+01	1.2064800e+02	2.2450567e+00
2.6506000e+01	1.2110500e+02	2.2450567e+00
...	...	...

As coordenadas dos pontos estão organizados em colunas separadas por caracteres de tabulação. Não há um formato de cabeçalho para o arquivo devido a forma de interpretação dos softwares CAD para nuvem de pontos em arquivos no formato *txt*. Este arquivo pode ser aberto manualmente no software CAD para a criação de malha (*rendering*) e representação geométrica.

3.5 CRIA MODELO 3D NO CAD (ETAPA E)

Utilizando os dois arquivos gerados na etapa anterior contendo as nuvens de pontos do crânio e da prótese (conjunto dos arcos-solução) respectivamente, o sistema CAD realiza a leitura desses arquivos, plotando-os em seu ambiente tridimensional permitindo assim criar uma malha para renderizá-los em uma superfície geométrica complexa. A Figura 37 ilustra a nuvem de pontos do crânio em (a) e a superfície em (b).

Figura 37 - Nuvem e superfície do crânio

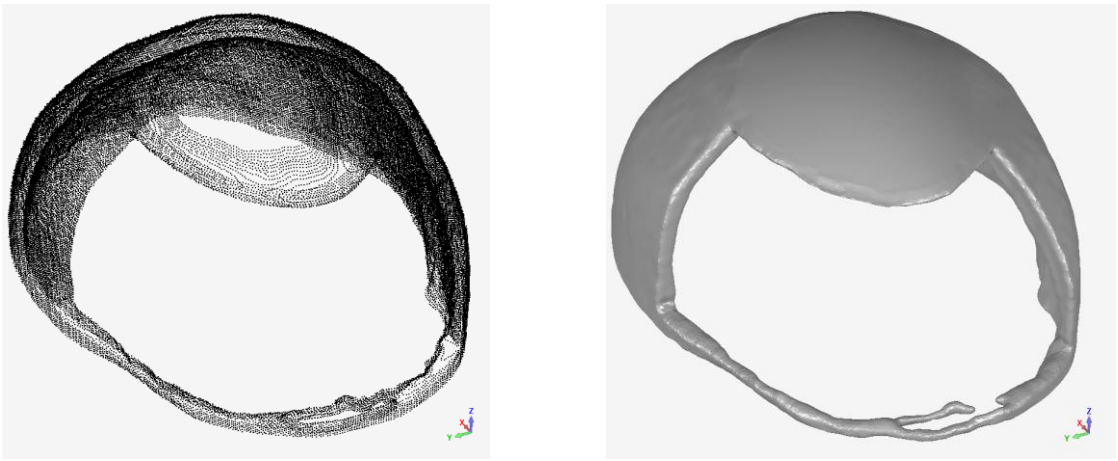

(a) (b)

FONTE: O Autor

A Figura 37.a ilustra os pontos referentes ao crânio, de acordo com a respectiva nuvem de pontos gerada na etapa D após a parametrização. Esses pontos estão em coordenas métricas tridimensionais. Após a leitura, o software mapeia esse conjunto de pontos e realiza a criação de uma malha para obter a representação geométrica da nuvem de pontos (Figura 37.b).

De forma similar, o processo é o mesmo para a leitura e geração da geometria para o conjunto de arcos-solução obtido (modelo geométrico da prótese). A Figura 38 apresenta a transição da nuvem de pontos da solução para a geometria que representa a solução.

Figura 38 - Nuvem e superfície da solução

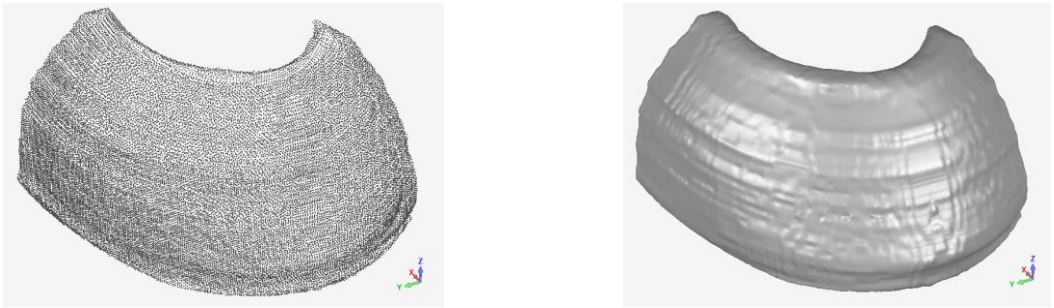

(a) (b)

FONTE: O Autor

A Figura 38.a ilustra os pontos dos segmentos das elipses obtidas pelo algoritmo de aproximação (conjunto de segmentos como exemplificado na Figura 35).

4 IMPLEMENTAÇÃO DO MÉTODO PROPOSTO

Baseando-se no método proposto (figura 16), foi implementado um programa protótipo utilizando o software MATLAB® e está estruturado em seções específicas para realizar um grupo de atividades pré-definidas de cada vez. A Figura 39 ilustra a estrutura do programa.

Figura 39 - Estrutura de funções

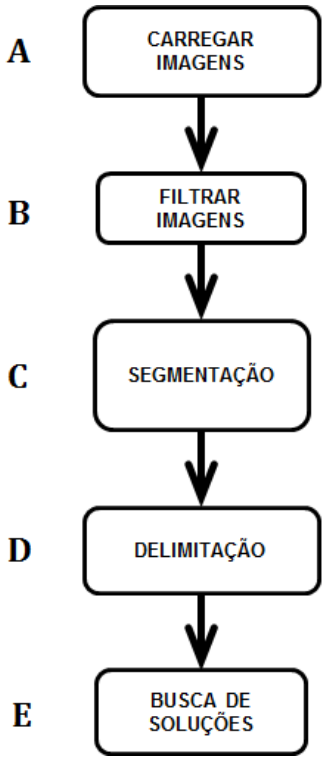

FONTE: O Autor

Como apresenta a figure 38, a etapa ‘A’ o sistema deverá carregar as imagens de interesse fornecidas (DICOM, JPEG ou BMP) e traduzi-las para escala de cinza em oito *bits*. Após isso, na etapa ‘B’ o programa deve reduzir essa informação para imagens binárias (1 *bit* de informação por pixel) retirando qualquer informação desnecessária para os procedimentos seguintes e na sequência identificar as bordas das informações contidas (etapa ‘C’).

Com todas as informações devidamente filtradas e segmentadas, o programa deve identificar as fatias que não possuem o perímetro craniano fechado (etapa ‘D’). Existem duas situações possíveis: (i) fatias com contorno do crânio fechado, que são

todas aquelas imagens de TC cuja borda da seção tomografada não corresponde a nenhuma parte da falha no crânio, e, portanto não precisa ser corrigida e (ii) fatias com contornos do crânio abertas, que correspondem à região de deformidade do crânio. No texto, as fatias fechadas serão chamadas de “fatias conformes” e as abertas de “fatias não conformes”.

Após identificar as fatias não conformes, é realizado um mapeamento para buscar o perímetro onde está localizada a região de interesse (ROI).

Com as informações referentes às fatias não conformes, e a região de interesse onde está o problema, o programa deverá realizar a otimização por aproximação das elipses para buscar a melhor solução que preencherá o espaço vazio, que é a última etapa (‘E’) do *software* protótipo. Para melhor ilustrar o procedimento descrito, a Figura 40 apresenta uma fatia de TC com uma imagem não conforme do crânio usada como dado entrada no algoritmo.

Figura 40 – Fatia de TC original

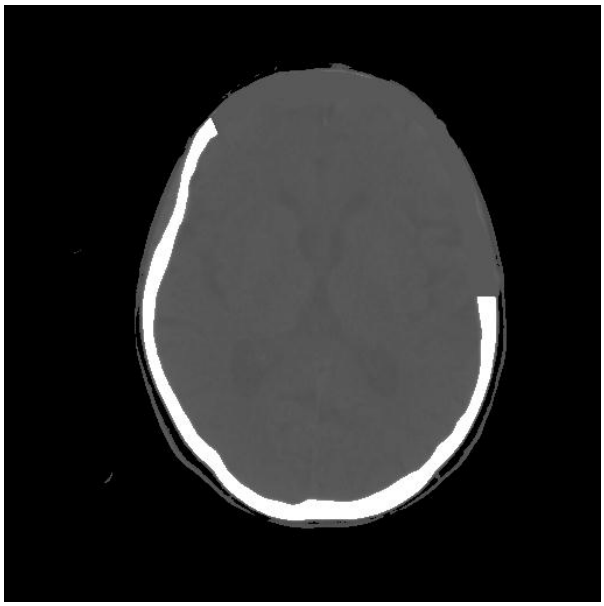

FONTE: O Autor

Após carregar o grupo de imagens (*stacks*) que será utilizado no algoritmo, a imagem é filtrada e informações desnecessárias são descartadas como apresentado na Figura 41.

Figura 41 - Área óssea segmentada

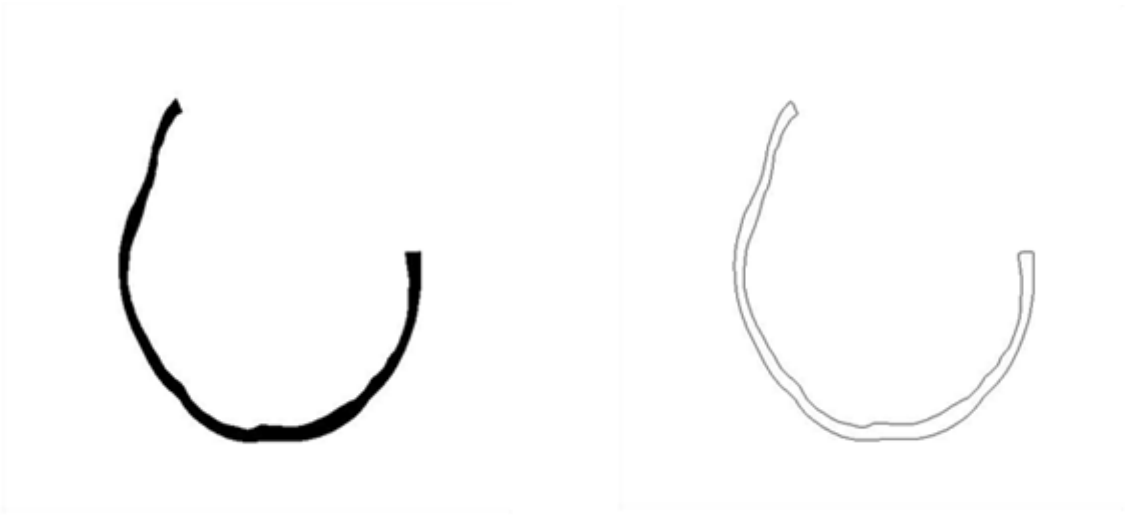

(a) (b)

FONTE: O Autor

Como mencionado no passo ‘C’ da Figura 39, o algoritmo segmenta o contorno do objeto, i.e. borda do crânio (Figura 41.a e Figura 41.b) que é a informação relevante na continuidade do processamento. Após realizar a identificação dos contornos em cada fatia não conforme, o algoritmo busca pela ROI no crânio. Neste exemplo, o perímetro identificado é apresentado na Figura 42.

Figura 42 - ROI da descontinuidade

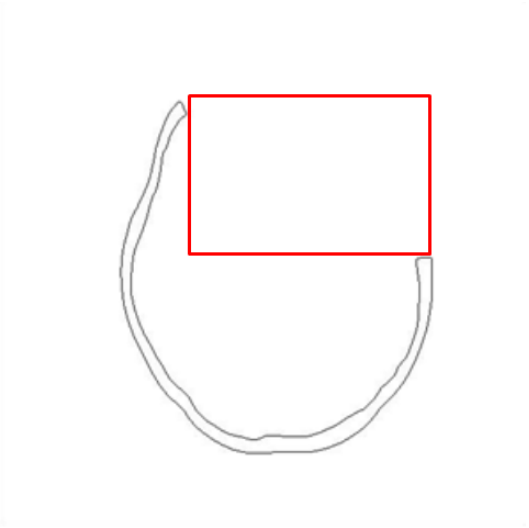

FONTE: O Autor

Como neste caso houve detecção de uma falha na fatia, o algoritmo realiza a busca de soluções (as elipses) para o contorno externo e interno separadamente.

Figura 43 - Perímetros separados

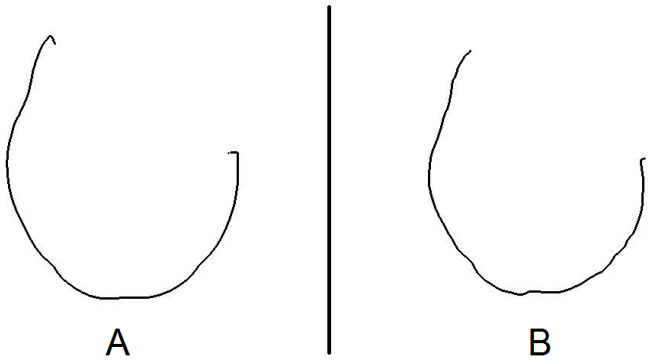

FONTE: O Autor

A Figura 43 ilustra a segmentação dos dois contornos (externo em ‘A’ e interno em ‘B’) para a utilização do algoritmo evolucionário. As imagens foram invertidas (bordas no valor branco=1 para preto=0) para uma melhor visualização do contorno.

Todo o procedimento do algoritmo (da etapa A até a etapa E) pode ser descrito a seguir:

1. Início do Algoritmo.
2. Requisita pacote de *n* imagens (Load).
3. Para imagem de 1 até *n* faça:
   Identifica características das imagens (DATA.CFG).
4. Carrega imagens para filtrar (Filter).
5. Para imagem de *1* até *n* faça:
   Transforma imagem *n* em binária (DATA.TC(n).BW).
   Identifica maior área de pixels.
   Salva maior área (DATA.TC(n).BW_SEG).
   Detecta borda da imagem e salva (DATA.TC(n).EDGE).
6. Carrega imagens para segmentar (Segmentation).
7. Para imagem de *1* até *n* faça:
   Busca deformação.
   Se deformação encontrada, faça:
   DATA.TC(n).DEFORM = 1.
   Aumenta perímetro em torno da deformação.
   Salva valores da deformação (DATA.TC(n).LIMS).
   Salva valores do perímetro ampliado (DATA.TC(n).PERIM.

Caso não haja deformação, faça:

DATA.TC(n).DEFORM = 0

Salva histograma polar da imagem *n* (DATA.TC(n).P.HIST).

Segmenta contorno interno (DATA.TC(n).EDGE_I).

Segmenta contorno externo (DATA.TC(N).EDGE_E).

8. Carrega imagens para delimitação (*Delimitation*).
9. Para imagem de 1 até *n*, faça:

   Identifica larguras e comprimentos da fatia.

   Salva valores aproximados de a e b para elipses (DATA.TC(n).BANDWIDTH).
10. Carrega imagens para aproximação (Find_Solution).
11. Para imagem de 1 até *n*, faça:

    Se DATA.TC(n).DEFORM = 1.

    Executa aproximação para contorno externo (DATA.TC(n).ELIP_E).

    Salva características da elipse externa (DATA.TC(n).PRM_E).

    Atualiza limites aproximação para elipse interna de acordo com anterior.

    Executa aproximação para contorno interno (DATA.TC(n).ELIP_I).

    Salva características da elipse interna (DATA.TC(n).PRM_I).
12. Carrega imagens para mapeamento de pontos (Mapping_Points).

    Subtrai DATA.TC(n).ELIP_E – DATA.TC(n).ELIP_I.

    Segmenta resultado da subtração para área da deformação.
13. Carrega grupo de imagens e parametriza para melhor resolução.
14. Traduz pixels para coordenadas para exportar para sistema CAD.

O anexo 3 contém o diagrama das funções utilizadas no algoritmo e as variáveis geradas em cada etapa do modelo. Com as imagens definidas para as elipses externas e internas, o algoritmo realiza a subtração das mesmas, respectivamente, para obter uma área mais espessa e não apenas os contornos das elipses, como demonstrado anteriormente na Figura 34.a. Após uma comparação e subtração da imagem resultante com a fatia do crânio, obtém-se o arco-solução para aquela seção do crânio. O procedimento de parametrização é então aplicado tanto no crânio, quanto na solução obtida, para todas as fatias do estudo. A Figura 44 ilustra as interpolações para crânio e prótese.

Figura 44 - Comparativo após interpolação

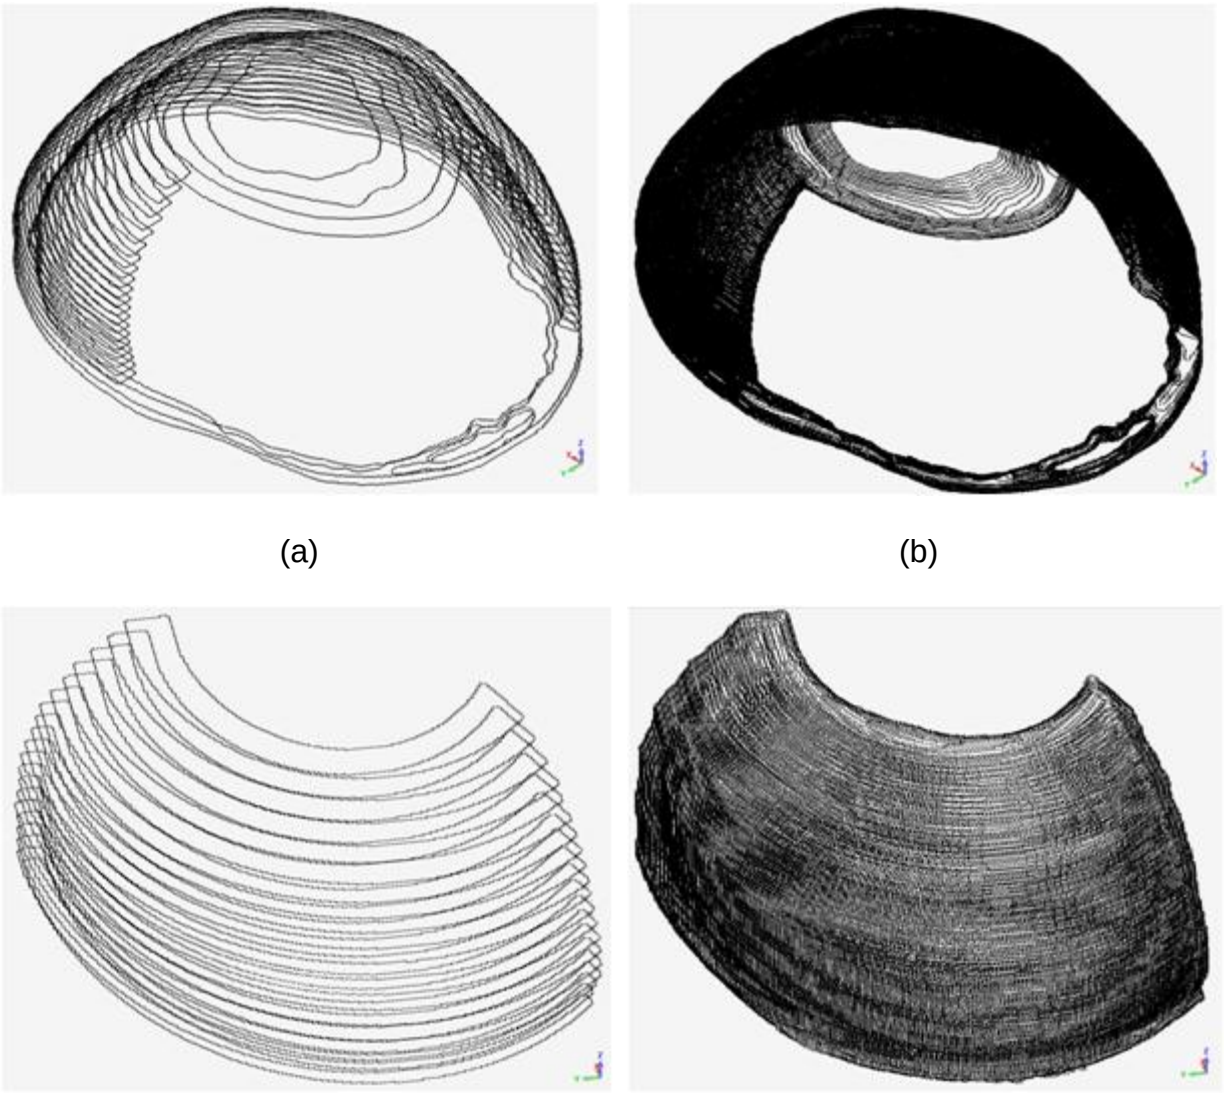

(a) (b)

(c) (d)

FONTE: O Autor

A Figura 44.b e a Figura 44.d apresentam a melhora de resolução se comparadas com a Figura 44.a e a Figura 44.c, respectivamente.

5 AVALIAÇÃO DO MÉTODO PROPOSTO

Neste capítulo serão apresentados os resultados obtidos através de testes aplicados no modelo proposto. Esses testes definirão características de como o modelo proposto realizará determinadas funções como: qual o melhor algoritmo de IA para a aplicação da aproximação de elipse, qual a melhor forma de reconstrução tridimensional e também resultados aplicados em casos distintos.

5.1 ANÁLISE COMPARATIVA DE TÉCNICAS PARA DETECÃO DE BORDAS

A detecção de borda é uma ferramenta de processamento de imagens utilizada para extrair a informação do contorno de um objeto. É uma aplicação necessária para identificar o contorno do osso de crânio para se realizar a aproximação elíptica. O *toolbox* de processamento de imagens do MatLab disponibiliza várias técnicas como Roberts, Canny, Sobel, Prewitt e ZeroCross (Matlab, 2013) É necessário definir qual técnica identifica melhor o contorno do crânio existente na fatia de TC. Desta forma, seis modelos são analisados para verificar sua confiabilidade, conforme a Tabela 7 do anexo 2

A Tabela 7 apresenta a imagem original utilizada nos testes, a imagem com a solução encontrada para cada técnica e também a relação entre imagem original menos o contorno encontrado. Essa subtração das imagens mostra onde ocorre o erro na borda encontrada.

Dessa forma observa-se que as técnicas de Canny, Log e Zerocross garantem uma melhor representação das informações utilizando bordas. Pela igualdade nos resultados, optou-se o uso da técnica de Canny.

5.2 AVALIAÇÃO COMPARATIVA DOS ALGORITMOS EVOLUTIVOS

Conforme enunciado no capítulo 2, os algoritmos evolutivos propostos para este estudo foram: Algoritmo Genético (AG), enxame de partículas clássico e com decaimento linear da inércia (PSO) e busca harmônica (HS). Estes algoritmos foram

escolhidos respectivamente por se tratarem de uma técnica tradicional (AG), uma técnica frequentemente utilizada em inúmeras aplicações comuns de otimização (PSO) e uma técnica mais recente pouco explorada (HS).

O critério de avaliação foi verificar qual técnica se adapta melhor a aproximação elíptica em relação ao custo computacional. Quanto menor o tempo para a busca da solução ótima, mais relevante é a técnica contanto que a aproximação obtida supra as características como a tangência da elipse na ROI e a sobreposição da elipse no contorno como um todo.

5.2.1 Eficiência dos algoritmos

A eficiência dos algoritmos foi testada analisando o tempo necessário para obter o melhor conjunto de parâmetros que representam o melhor ajuste da elipse numa fatia de TC, tanto para o contorno externo como para o contorno interno. Para demonstrar a eficiência foram utilizadas três fatias de TC de um caso real (detalhamento no capitulo 6). As três imagens estão apresentadas na Figura 45.

Figura 45 - Fatias analisadas

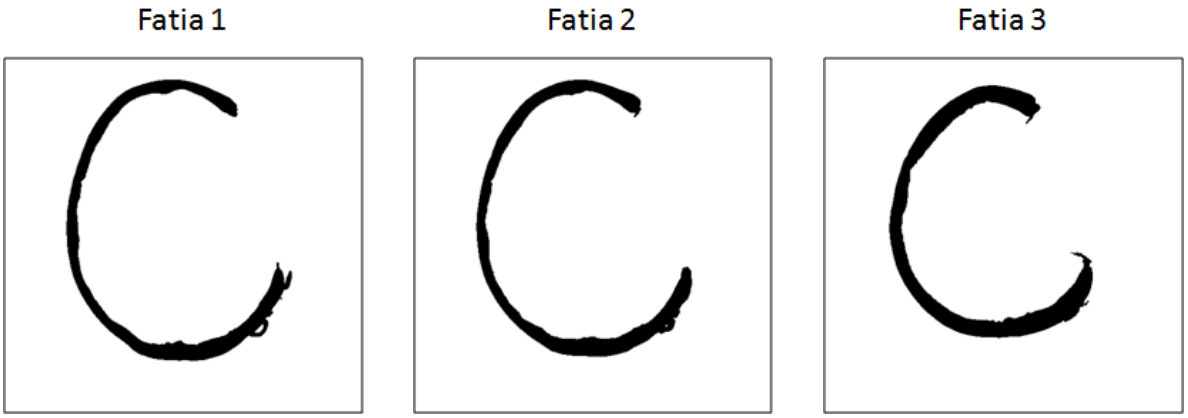

FONTE: O Autor

Em todas as aproximações, os limites populacionais, limites de busca para as elipses, número de iterações e função de aptidão se manteve os mesmos. Os limites para as elipses são definidos pela equação 5.1,

$$140 \leq a \leq 200$$
$$120 \leq b \leq 230$$
$$220 \leq x_0 \leq 280 \quad (5.1)$$
$$220 \leq y_0 \leq 280$$

Esses valores foram observados como limites para a faixa de valores que se observava nos contornos do crânio. Em conjunto com os limites apresentados na equação (3.2) esses valores em *pixels* foram definidos como limites de simulação. A quantidade de iterações foi limitada para 50 iterações por simulação e foram testados 100 indivíduos (memória harmônica, tamanho do enxame ou cromossomos) por iteração.

5.2.1.1. Resultado do AG

Para o algoritmo genético foram utilizados como parâmetros iniciais: probabilidade de cruzamento de 80%; probabilidade de mutação de 5% e; garantia de sobrevivência para indivíduo mais forte. Os resultados obtidos para o algoritmo genético estão dispostos nas figuras Figura 46, Figura 47 e Figura 48 respectivamente para cada uma das fatias de TC.

Figura 46 - Aproximações para fatia 1 (AG)

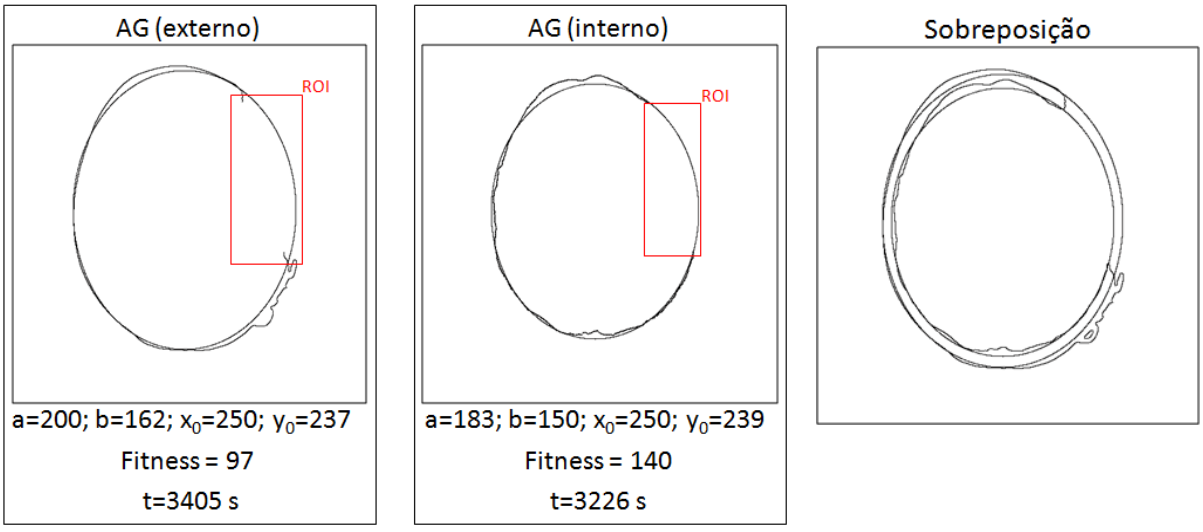

(a) (b) (c)

FONTE: O Autor

Figura 47 - Aproximações para fatia 2 (AG)

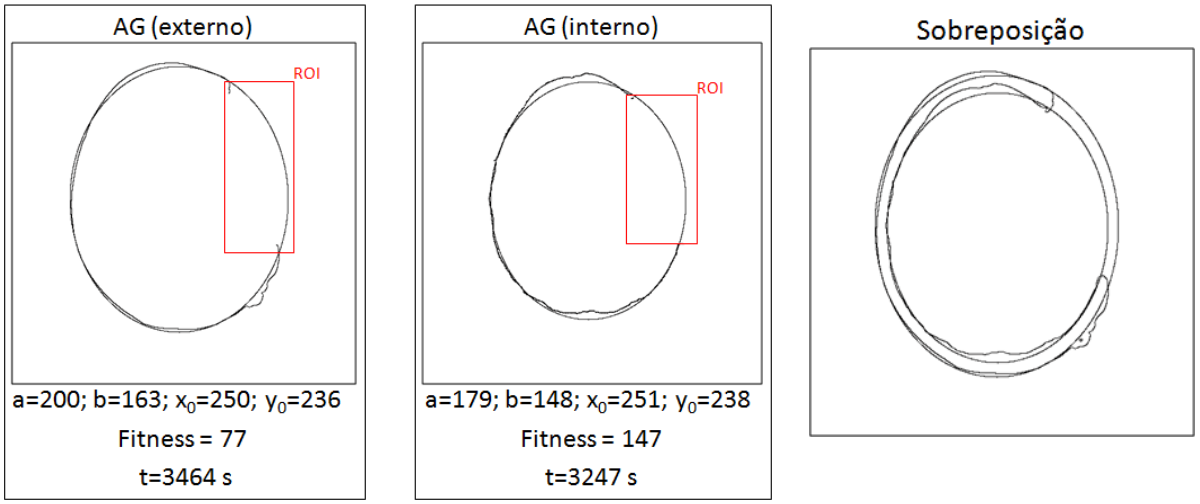

(a) (b) (c)

FONTE: O Autor

Figura 48 - Aproximações para fatia 3 (AG)

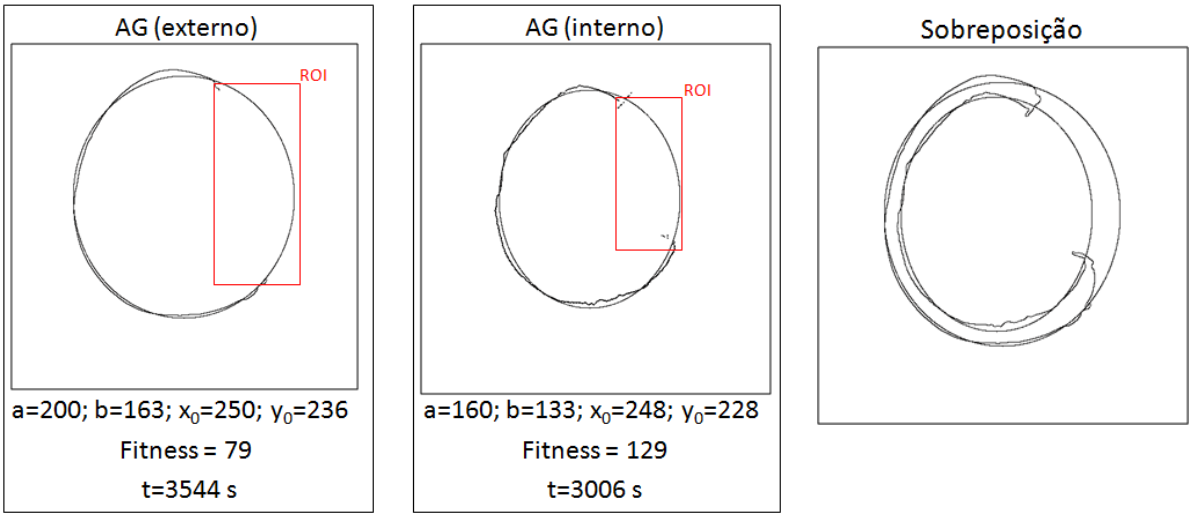

(a) (b) (c)

FONTE: O Autor

Nas seis aproximações verificou-se um custo computacional do algoritmo elevado, onde o tempo médio de execução foi de 3315 segundos. A plataforma utilizada para as simulações foi realizada no sistema operacional Windows 7® 64bits, com processador Xeon® E5-1660, 32Gb RAM.

5.2.1.2. Resultado do PSO e PSO com decaimento

Nas simulações para o algoritmo do PSO clássico e do PSO com decaimento linear da inércia, as características das elipses se mantiveram para as fatias correspondentes. Devido aos mesmos valores para *a*, *b*, x_0 e y_0 e também para o *fitness*, será apresentado apenas o resultado para o PSO clássico, mencionando apenas a diferença do tempo de execução dos algoritmos. Os resultados são apresentados nas figuras Figura 49, Figura 50 e Figura 51 a seguir.

Figura 49 - Aproximações para fatia 1 (PSO)

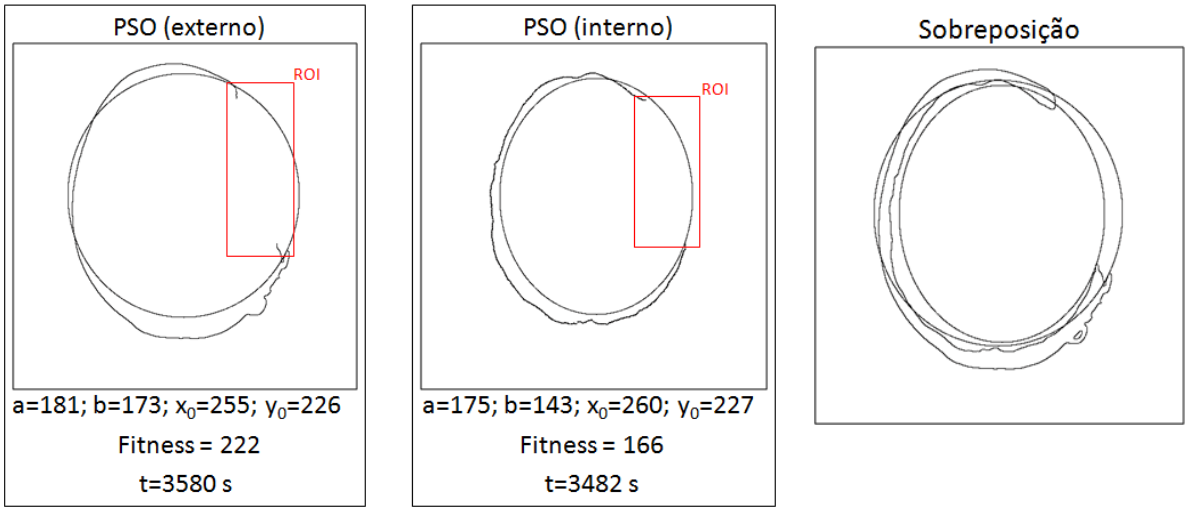

(a) (b) (c)

FONTE: O Autor

Figura 50 - Aproximações para fatia 2 (PSO)

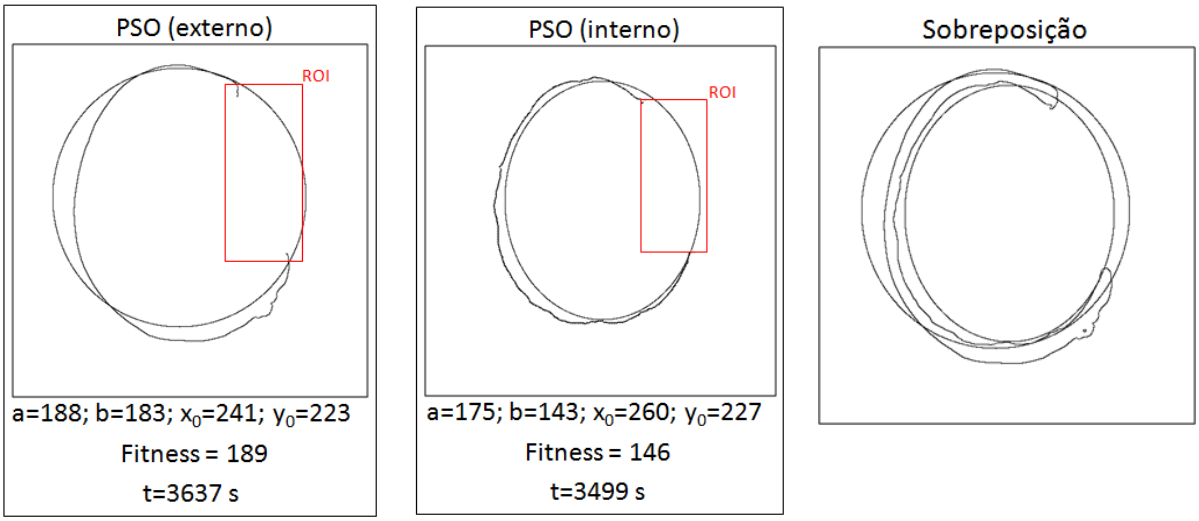

(a) (b) (c)

FONTE: O Autor

Para esta simulação (Fatia 1), o PSO com decaimento linear da inércia obteve um tempo computacional de 3578 segundos para o contorno externo, e de 3477 segundos para o contorno interno.

Para esta simulação (Fatia 2), o PSO com decaimento linear da inércia obteve um tempo computacional de 3648 segundos para o contorno externo e 3513 segundos para o contorno interno.

Figura 51 - Aproximações para fatia 3 (PSO)

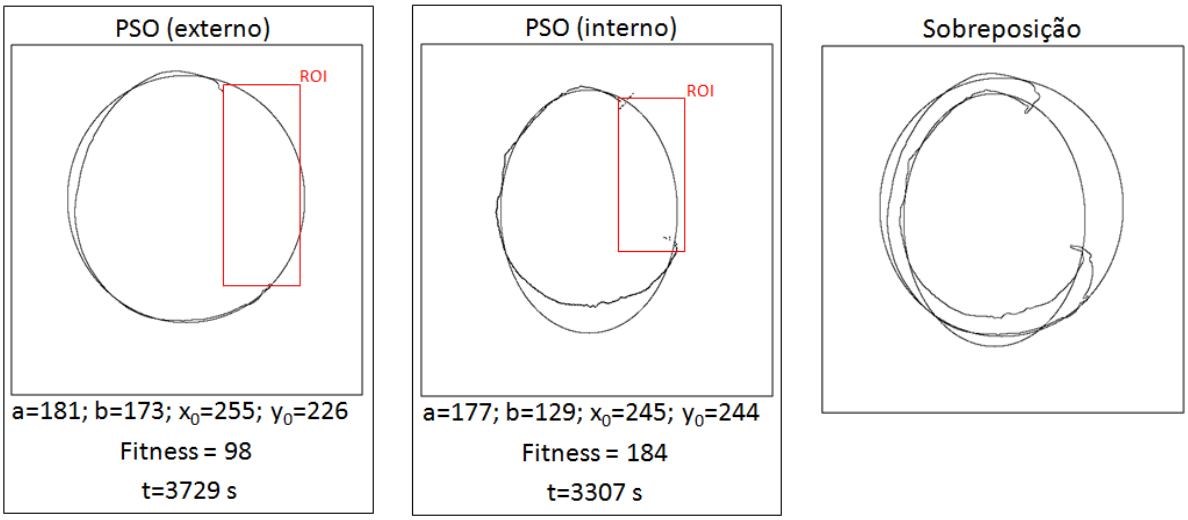

(a) (b) (c)

FONTE: O Autor

Para esta simulação (Fatia 3), o PSO com decaimento linear da inércia obteve um tempo de processamento de 3723 segundos para o contorno externo e 3307 segundos para o contorno interno. O tempo médio para a execução do PSO clássico para as seis fatias foi de 3539 segundos e para o PSO com decaimento linear da inércia foi de 3541 segundos.

5.2.1.3. Resultado do HS

Para as simulações utilizando a busca harmônica (HS), o algoritmo mostrou-se muito mais leve no custo de tempo computacional. As figuras 52, 53 e 54 a seguir apresentam os resultados obtidos.

Figura 52 - Aproximações para fatia 1 (HS)

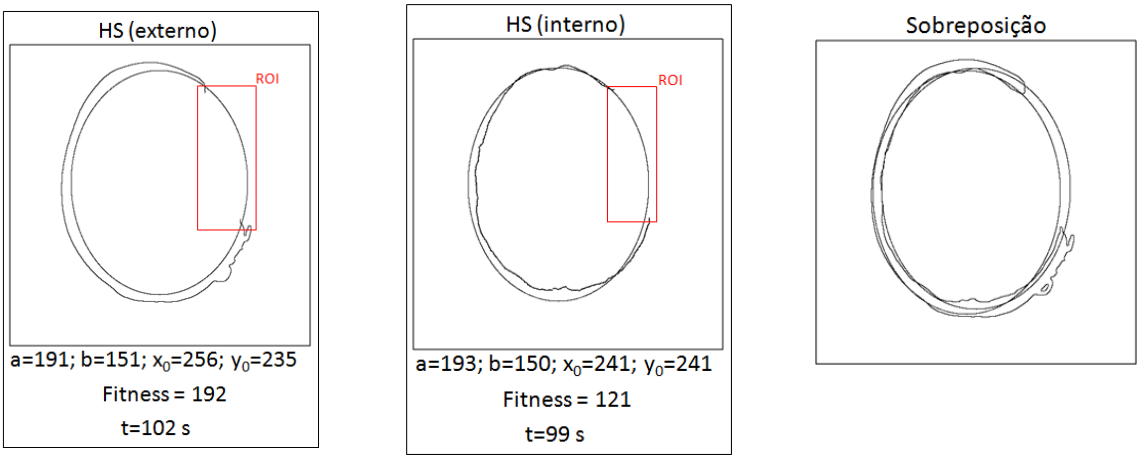

(a) (b) (c)

FONTE: O Autor

Figura 53 - Aproximações para fatia 2 (HS)

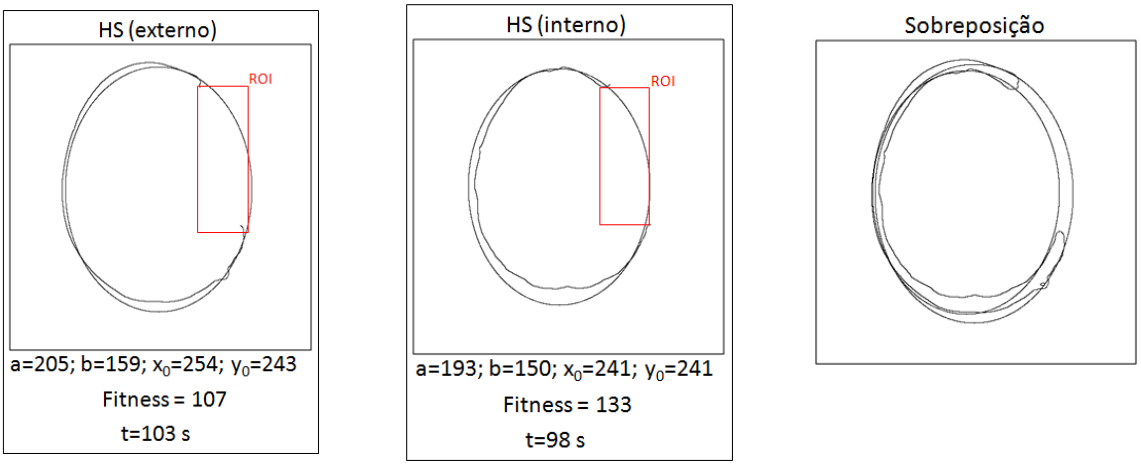

(a) (b) (c)

FONTE: O Autor

.

Figura 54 - Aproximações para fatia 3 (HS)

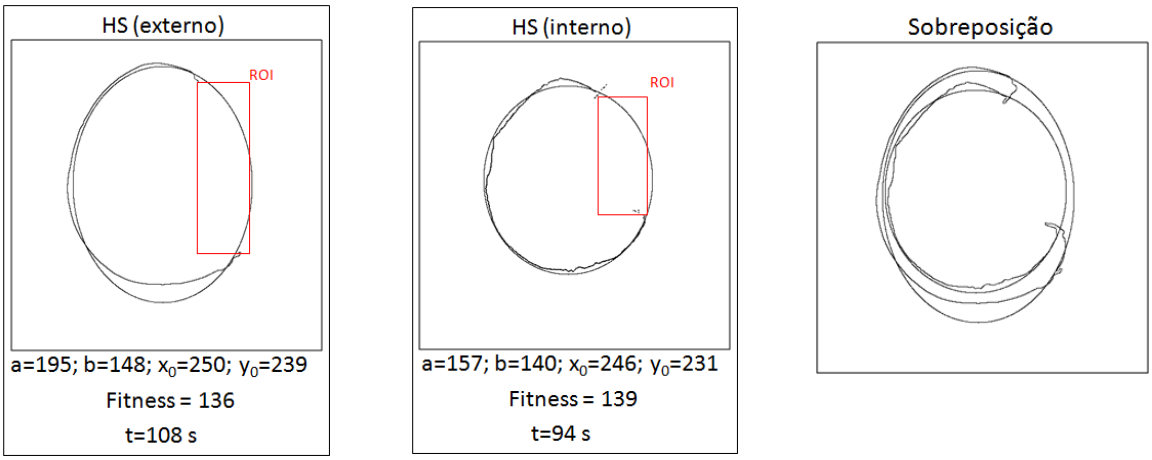

(a) (b) (c)

FONTE: O Autor

5.2.2 Análise comparativa

Para o processo de comparação dos métodos utilizados, referentes à computação evolutiva, foi utilizado como critério de análise: o tempo necessário para realizar a execução da otimização devido aos tempos totais necessários para os ensaios e; a melhor aptidão atingida para cada ensaio. Uma das variáveis utilizadas para a execução dos algoritmos é o número de pontos representativos para a aptidão da elipse em relação ao contorno craniano. Para a decisão da quantidade de pontos representativos utilizados foi realizado um estudo de desempenho utilizando uma fatia de TC. Esta fatia representa a seção média da deformação do crânio.

Os valores apresentados são válidos para qualquer método de IA desta pesquisa (GA, PSO e HS), pois a quantidade de pontos representativos está diretamente relacionada à função de aptidão. Apenas o número de pontos foi alterado para a execução deste teste, todos os outros parâmetros do algoritmo foram mantidos. A Tabela 2 apresenta os valores obtidos para ensaios com variação de 8 à 250 pontos representativos.

Tabela 2 - Análise de pontos representativos

Pontos	Aptidão	Média (Aptidão/Pontos)	Valores Obtidos (a, b, x_0, y_0)
8	40	5	175, 150, 248, 242
10	43	4,3	193, 145, 248, 242
12	54	4,5	191, 149, 248, 242
20	63	3,15	188, 148, 245, 243
40	2923	73,075	191, 112, 247, 243
80	7734	96,675	140, 104, 248, 243
120	12306	102,55	144, 103, 248, 245
250	27537	110,148	146, 103, 249, 245

FONTE: O Autor

É necessário obter um valor normalizado para as aproximações, desta forma foi calculada a média entre a aptidão obtida e a quantidade de pontos representativos utilizada. A Figura 55 ilustra o comportamento da quantidade de pontos aplicado nas otimizações, tendo como base a média obtida.

Figura 55 – Relação entre erro médio por pontos representativos

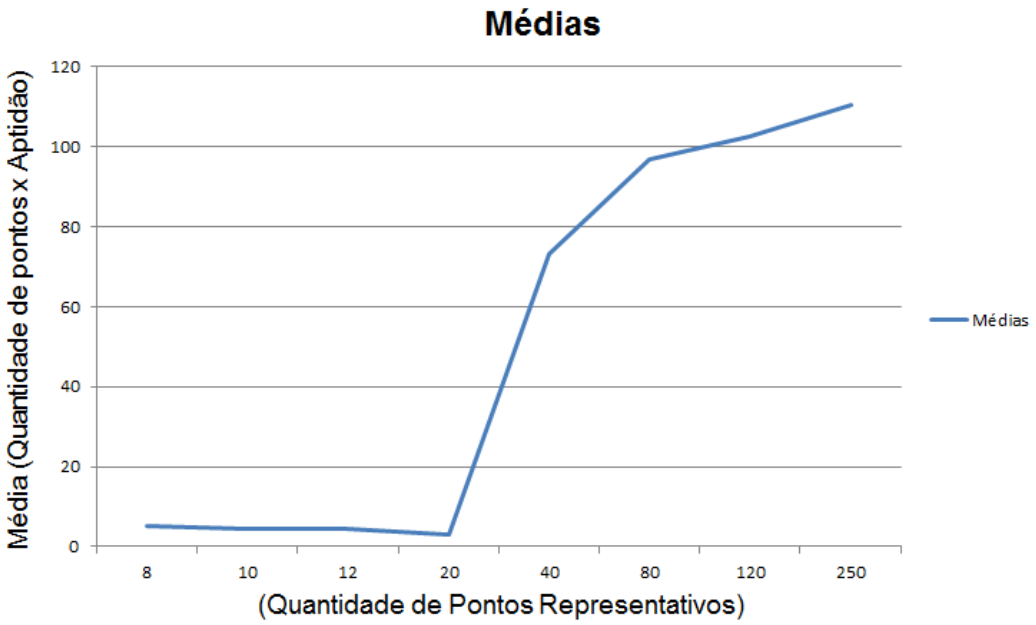

FONTE: O Autor

Tendo como base o gráfico apresentado na Figura 55, foram utilizados 20 pontos representativos para os testes comparativos entre os algoritmos evolutivos. Levando em consideração os valores obtidos no item anterior, a Tabela 3 apresenta uma compilação das eficiências dos algoritmos.

Tabela 3 - Compilação dos resultados de eficiência

Fatia #	Algoritmo Evolutivo							
	AG		PSO		PSO (dec. lin.)		HS	
	Aptidão	Tempo (s)	Aptidão	Tempo (s)	Aptidão	Tempo (s)	Aptidão	Tempo (s)
Fatia 1 (int)	97	3405	222	3580	222	3580	192	102
Fatia 1 (ext)	140	3226	166	3482	166	3482	121	99
Fatia 2 (int)	77	3464	189	3637	189	3637	107	103
Fatia 2 (ext)	147	3247	146	3499	146	3499	133	98
Fatia 3 (int)	79	3544	98	3729	98	3729	136	108
Fatia 3 (ext)	129	3006	184	3307	184	3307	139	94

Fonte: O Autor

Os valores da Tabela 3 foram compilados para verificar as médias de tempo e aptidões. A Tabela 4 apresenta os pontos mais relevantes para a escolha do algoritmo com o menor custo computacional para este processo.

Tabela 4 - Resultados dos algoritmos

Algoritmo	AG	PSO	PSO (dec. lin.)	HS
Melhor Aptidão	77	98	98	107
Aptidão Média	111.5	167.5	167.5	138
Melhor Tempo (s)	3006	3307	3307	94
Tempo Médio (s)	3315	3539	3541	101

FONTE: O Autor

Tendo em vista os resultados apresentados na Tabela 4, pode-se concluir que o melhor algoritmo para ser aplicado no método é o algoritmo genético. Porém o algoritmo utilizado para a aplicação do método é o de busca harmônica, pela grande diferenciação das demais devido ao custo computacional reduzido durante os ensaios. Seu tempo para a obtenção da melhor solução, considerando os mesmos fatores limitantes dos demais, é de mais de 30 vezes. Mesmo não obtendo o melhor resultado médio para a aptidão, foi optado por utilizar esta técnica por tornar menos dispendiosos os tempos de simulação do método.

Tabela 5 - Relações de erros

Algoritmo	Tempo Médio (s)	Fitness Médio (pixels)	Pixels/pto. rep.	erro pto. rep. (mm)	erro/erro(AG)	Erro acum. (mm)
AG	3315	115,5	5,8	2,7	0%	0,0
HS	101	138,0	6,9	3,3	19%	0,6
PSO	3539	167,5	8,4	4,0	45%	1,8
PSO (dec.)	3539	167,5	8,4	4,0	45%	1,8

FONTE: O Autor

A Tabela 5 apresenta uma correlação entre as técnicas utilizadas, seus respectivos tempos de execução, aptidões e comparativos com a técnica de melhor aptidão (AG). Para a análise da aptidão foram utilizados 20 pontos representativos. Tomando como base o resultado apresentado pelo algoritmo genético, cada um dos 20 pontos representativos apresentou em média uma aptidão de 5,8 *pixels*. Em outras palavras, esse valor demonstra que, em média, cada ponto representativo ficou a uma distância de 5,8 *pixels* do contorno do crânio. Como o valor para o *voxel* neste estudo é de 0,475mm (altura e largura), então o erro métrico médio para o algoritmo genético é de 2,7mm.

Fazendo um comparativo dos erros obtidos para cada técnica, é possível verificar o erro acumulado com relação ao AG. Os valores dos erros acumulados para o HS e para o PSO são respectivamente de 0,6mm e 1,8mm. Analisando os tempos de execução, o HS se destaca aos demais e, considerando o percentual de erro com relação ao AG, esta técnica foi adotada para a realização dos ensaios. Assim, considerando a pequena variação métrica entre os pontos e o custo de tempo para a obtenção da solução, a busca harmônica possui as melhores características para a realização dos ensaios nesta aplicação do método.

5.3 RECONSTRUÇÃO TRIDIMENSIONAL

A etapa final do método proposto trata da reconstrução 3D da prótese para visualização e avaliação das suas características geométricas. Como esta pesquisa não contempla a manufatura da prótese (CAM) foi utilizado uma ferramenta computacional para validar o modelo geométrico construído. Com o software GeoMagic Studio® é possível importar o modelo geométrico gerado, criar a superfície e comparar a geometria tomando como referencial a nuvem de pontos original, como apresentado por Chen, *et. al.* (2010) e Geomagic Studio (2013). O objetivo do teste é verificar como o modelo geométrico da prótese se adapta a respectiva falha crânio. Em função disto é abordada a representação 3D de ambos, crânio e respectiva prótese.

5.3.1 Reconstrução do Crânio

A Figura 56.a ilustra um segmento de crânio sem deformação em 3D, reconstruído através de nuvem de pontos. Para realizar o teste de validação, foi criada de maneira sintética uma falha nesta imagem com um formato aleatório. O objetivo é aplicar o método proposto, e recriar a área ausente pelo ajuste de elipses. Com um crânio sem deformação é possível tomar sua região como parâmetro de controle para comparar o erro entre a prótese modelada e a sua informação original.

Figura 56 – Segmento de crânio sem e com deformação.

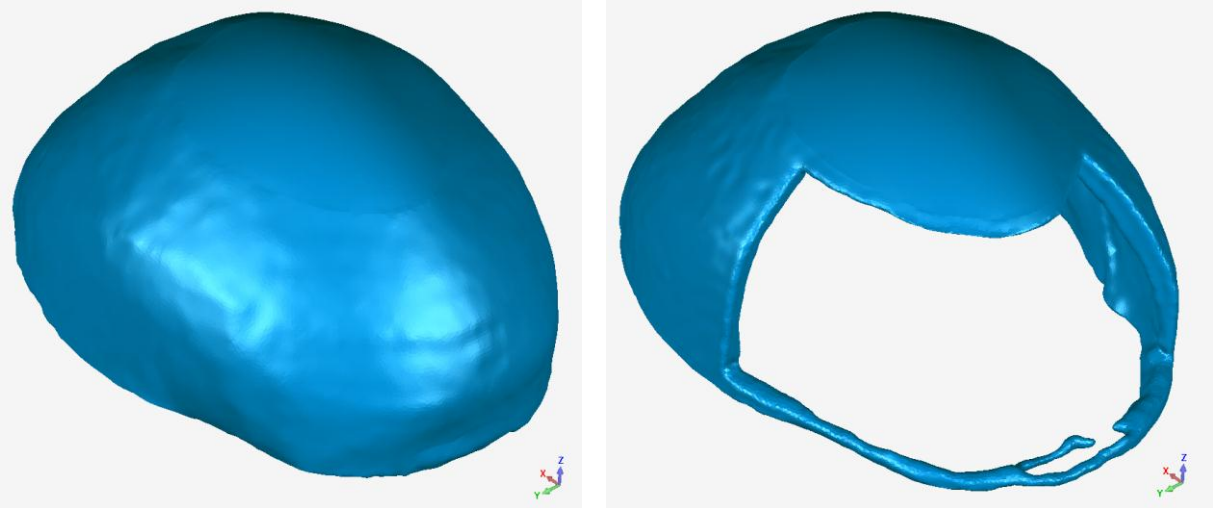

(a) (b)

FONTE: O Autor

O mesmo crânio pode ser visualizado na Figura 56.b com uma deformação criada de forma sintética efetuada diretamente sobre a superfície. A Figura 57 apresenta o nível de erro ocorrido durante o processo de conversão da nuvem de pontos para superfícies.

Figura 57 - Desvio 3D da nuvem de pontos

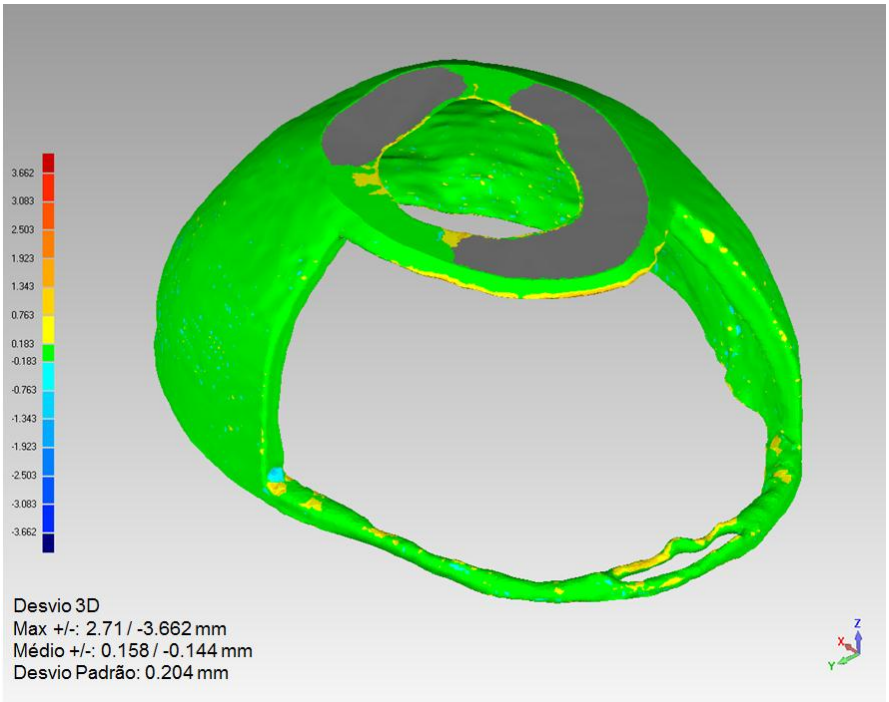

FONTE: O Autor

Com o software GeoMagic Studio® é calculado o desvio 3D na superfície gerada e verifica-se um erro mínimo, pois a conversão mantém as características originais da nuvem de pontos ao longo de toda a superfície. Conforme indicado pela escala de pseudo-cores na figura 57, alguns pontos possuem um desvio acima de 0.2 mm, mas podem ser desconsiderados na análise por representar áreas muito pequenas referentes a ruídos no processo de geração da superfície.

5.3.2 Reconstrução da Prótese

O método de ajuste por elipses foi aplicado ao crânio de teste e a respectiva prótese gerada, que representa a região da falha, é apresentada na figura 58.

Figura 58 - Solução obtida através do método proposto

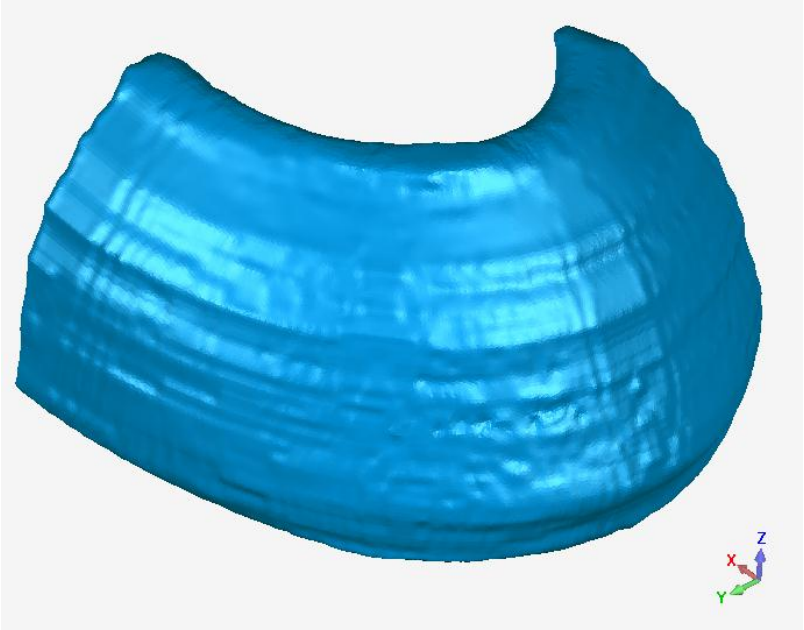

FONTE: O Autor

No ambiente 3D é possível compor as imagens do crânio (com a falha) com o seu respectivo modelo geométrico, obtendo-se o resultado apresentado na Figura 59.

Figura 59 - Solução aplicada

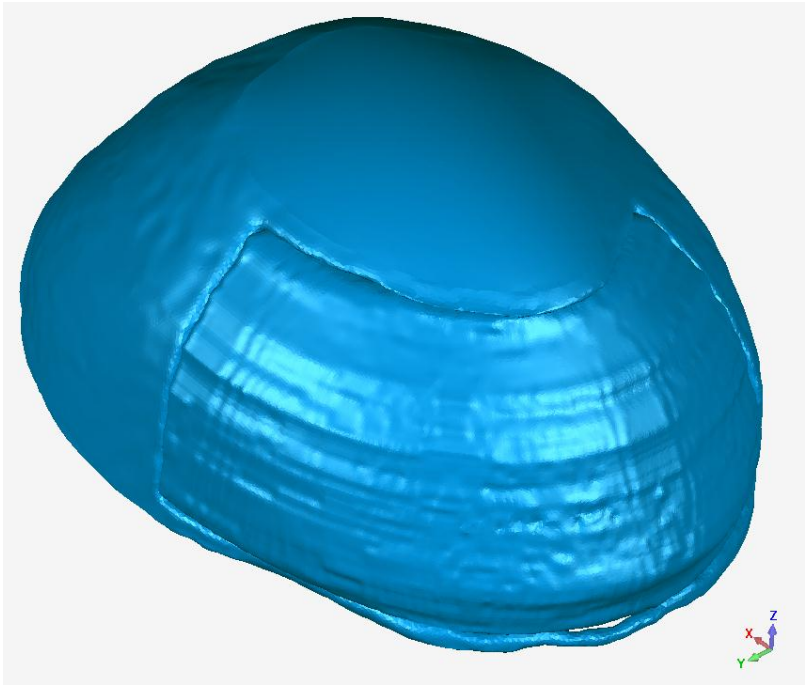

FONTE: O Autor

Utilizando a ferramenta de análise de desvio de superfície do software Geo Magic®, é possível verificar o erro entre a solução encontrada (modelo da prótese) e a superfície original do crânio que é conhecida.

Figura 60 – Diferenças de medição entre a solução e a superfície original.

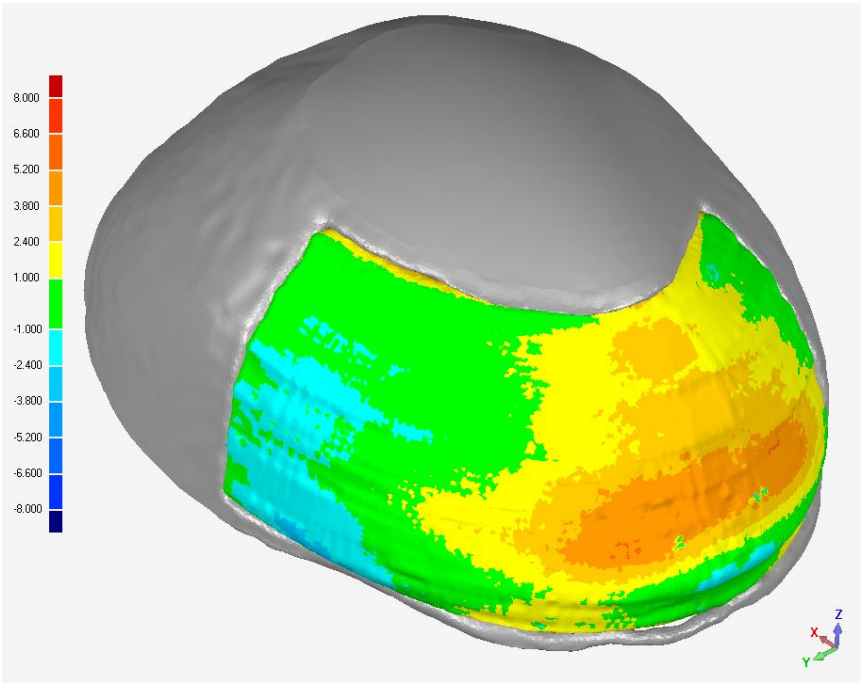

FONTE: O Autor

A Figura 60 apresenta através da escala de pseudo-cores as diferenças de medida entre a superfície desenvolvida e a superfície original do crânio. Verificando o resultado obtido pelo algoritmo de aproximação elíptica, observa-se um desvio máximo de 5 mm em algumas regiões. Esse desvio de 5 mm está situado mais na região posterior do crânio. Como o algoritmo não possui nenhuma informação referente de como seria a região óssea caso não houvesse deformação, o modelo se adequou satisfatoriamente.

As regiões próximas ao perímetro da deformação do crânio devem ter como característica principal uma boa tangência superficial na transição da superfície do crânio para a superfície da prótese. Todo o perímetro próximo à deformação do crânio está com uma variação máxima de ±2 mm. Essa variação pode influenciar em pontos específicos como a estética. Este desvio apresentado deve ser interpretado por um profissional da área médica para estudar se podem haver riscos ou não ao paciente.

6 ESTUDO DE CASO

6.1. Apresentação do Problema

Para o problema simulado no capitulo anterior, a medição do desvio em 3D entre o modelo gerado e uma superfície conhecida se demonstrou ser um bom meio para verificar as diferenças do conjunto crânio-prótese, como também a qualidade da geração da superfície. Num problema real a região ausente do crânio é completamente desconhecida, ou seja, não existe um volume 3D para comparação do conjunto crânio-prótese, entretanto pode-se usar a mesma ferramenta para avaliar a transformação entre a nuvem de pontos gerada e a superfície 3D. A Figura 61 apresenta a imagem reconstruída de um crânio com um problema real de um defeito congênito severo. As imagens tomográficas deste crânio foram usadas como o estudo de caso real para a aplicação do método proposto de correção através do algoritmo de aproximação por elipses[1]. As informações foram extraídas de um conjunto de 40 seções tomográficas, no padrão de 512x512 pixels, com espaçamento igual 3 mm entre as seções (informações obtidas do DICOM). As fatias de tomografia computadorizadas neste estudo de caso estão ilustradas no anexo 6, na Tabela 9.

Figura 61 – Visualização 3D do crânio estudado

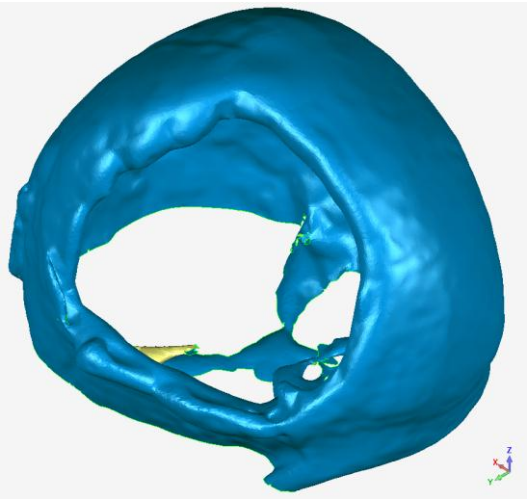

FONTE: O Autor

[1] A falha craniana neste caso é “lateral” e não “frontal” e poderia ser resolvida por simetria, através do espelhamento do lado direito sobre a parte ausente. Este estudo de caso foi selecionado devido à possibilidade de se verificar a eficiência do método, e identificar as possíveis restrições.

A reconstrução tridimensional do crânio foi realizada pelo processo de exportação de nuvem de pontos. A Figura 62 ilustra o desvio tridimensional da superfície em relação à nuvem de pontos original, exportada pelo algoritmo ao software CAD.

Figura 62 - Desvio 3D da nuvem de pontos exportada

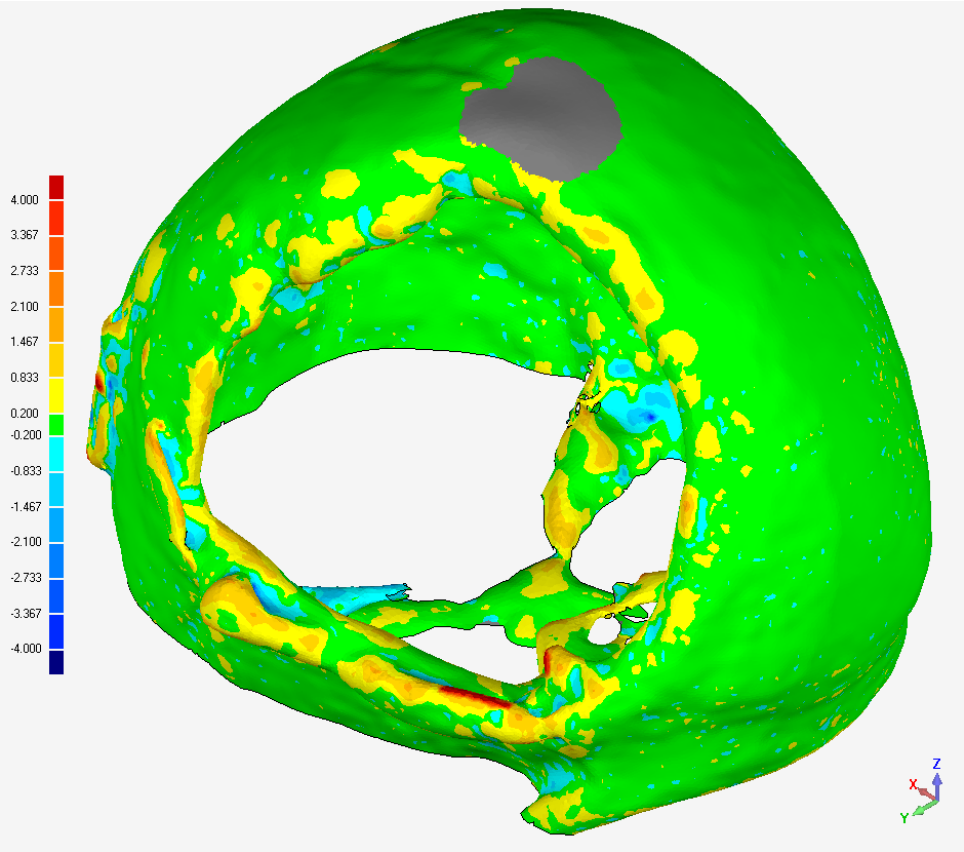

FONTE: O Autor

A tradução da nuvem de pontos em superfície possui um erro relativamente pequeno, variando em sua maioria entre -0,8 e +0,8mm. Demais regiões, em tons de vermelho ou tons de azul são relativamente pequenas e possui esse maior desvio pelo truncamento de alguns pontos na geração da malha e da superfície.

6.2. Aplicação do Método

A Figura 63 apresenta alguns exemplos de fatias utilizadas no processo para o estudo de caso

Figura 63 – Alguns arcos-solução obtidos

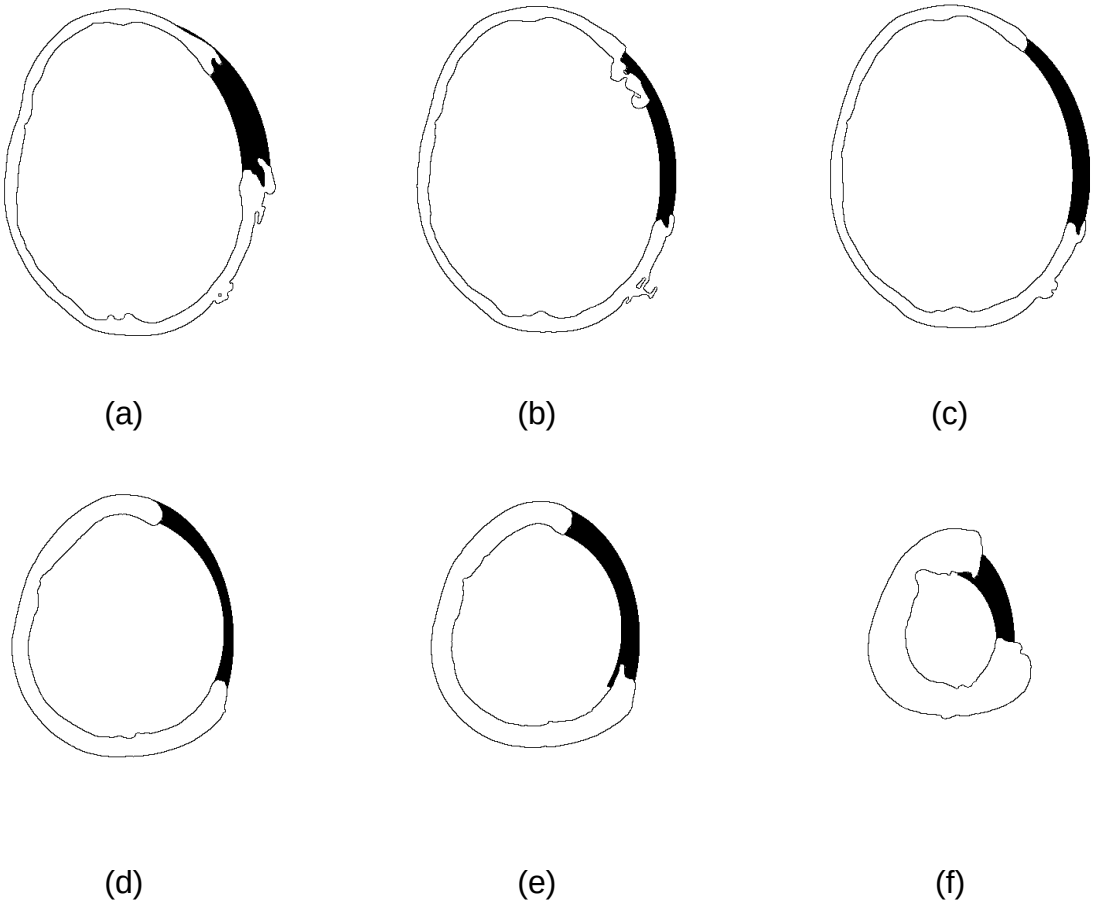

FONTE: O Autor

Na Figura 63.a até a Figura 63.f estão ilustradas as fatias 6238682, 6238718, 6238754, 6238952, 6239006 e 6239096, respectivamente (dispostas também no anexo 6). Nestas imagens estão apresentados os respectivos arcos-solução para cada caso. A Figura 63.a, a Figura 63.b e a Figura 63.c apresentaram um bom resultando. No primeiro caso, mesmo com a descontinuidade do contorno na parte inferior da deformação houve uma correspondência entre as tangências. Na Figura 63.b também há uma descontinuidade do contorno na parte superior, voltado para o contorno interno. Da mesma forma houve um resultado satisfatório.

Para o terceiro caso (Figura 63.c), não há grandes descontinuidades e deformações nos perímetros externo e interno. O resultado tangencia adequadamente as duas regiões. O arco solução está próximo do ideal devido ao baixo comprometimento da região da deformação.

No caso da Figura 63.d, a região inferior da deformação possui um pequeno ângulo, o que não possibilitou a tangência do arco-solução ao contorno do crânio. A

Figura 63.e e também para a Figura 63.f obtiveram resultados fora do desejado. Estas possuem descontinuidades que são indesejáveis, pois ultrapassam os limites das deformações, ocupando pequenas regiões na parte interna do crânio ou gerando saliências na superfície externa à caixa craniana, comprometendo assim a estética.

A Figura 64.a e a Figura 64.b destacam os segmentos dos arcos-solução que obtiveram excesso de informação no processo de criação do modelo geométrico da prótese.

Figura 64 – Arcos-solução com excesso de informações

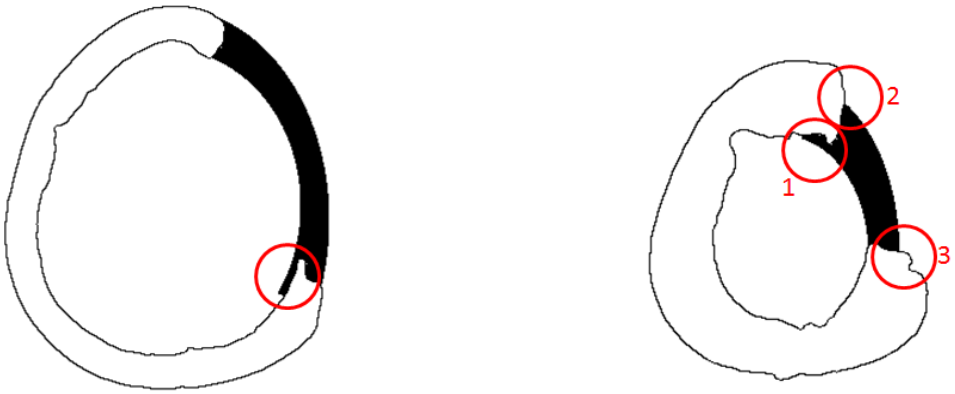

(a) (b)

FONTE: O Autor

Na Figura 64.a houve um excesso em um dos lados enquanto na Figura 64.b houve excesso demarcado em (1). As regiões (2) e (3) apresentaram uma aproximação insatisfatória com relação à tangência externa à deformação. Esta incoerência deve-se ao formato “triangular” do contorno externo e a redução do perímetro. Os excessos demonstrados na Figura 64.a na Figura 64.b no perímetro demarcado como (1) são então removidos manualmente, durante o processo da criação do modelo geométrico no software CAD. A Figura 65 ilustra em vermelho, os pontos removidos antes da criação da malha para geração da superfície da solução.

Figura 65 - Remoção de ruídos

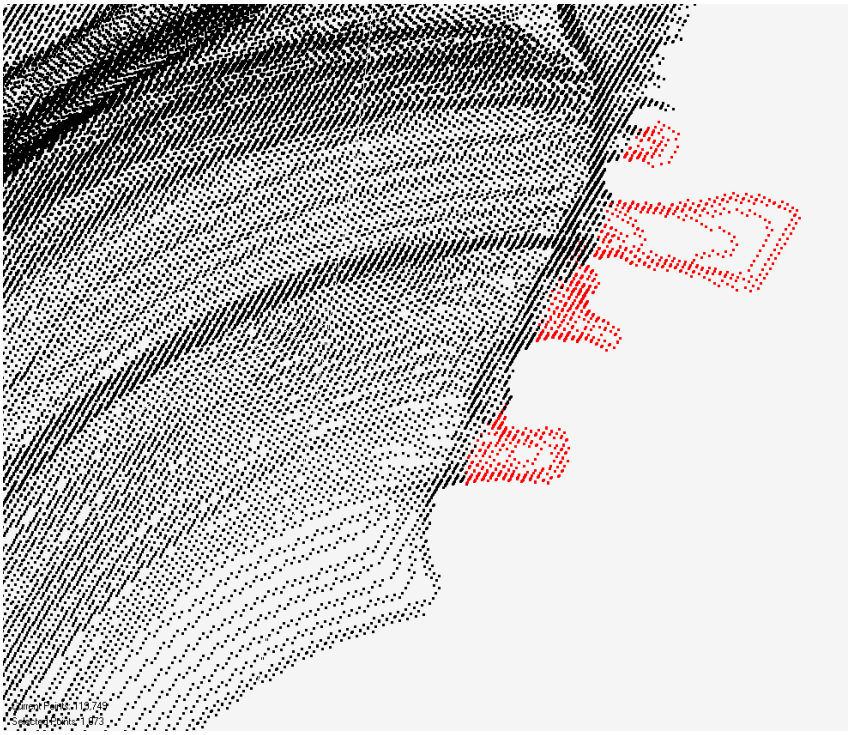

FONTE: O Autor

Nas demais fatias, como ilustra a Figura 63.a, Figura 63.b, Figura 63.c e Figura 63.d os resultados não geraram excesso de informações e o perímetro entre a região de contato do crânio com o arco-solução é uniforme e tangencia os contornos externo e interno adequadamente. Com o conjunto dos arcos-solução obtidos para cada fatia, é possível reconstruir tridimensionalmente o modelo geométrico da prótese.

6.3. Modelo geométrico gerado

O modelo geométrico obtido para solucionar a deformação estudada, utilizou aproximações de 24 fatias de TC. O conjunto dos arcos-solução foi interpolado para obter uma melhor resolução de pontos para a criação da malha da superfície. As fatias resultantes após a parametrização somaram 185 fatias, com 131,4 mm de largura, 80,45 mm de altura e 5 mm de espessura nas regiões com paredes mais finas para a geometria gerada, apresentada na Figura 66.

Figura 66 - Solução 3D obtida

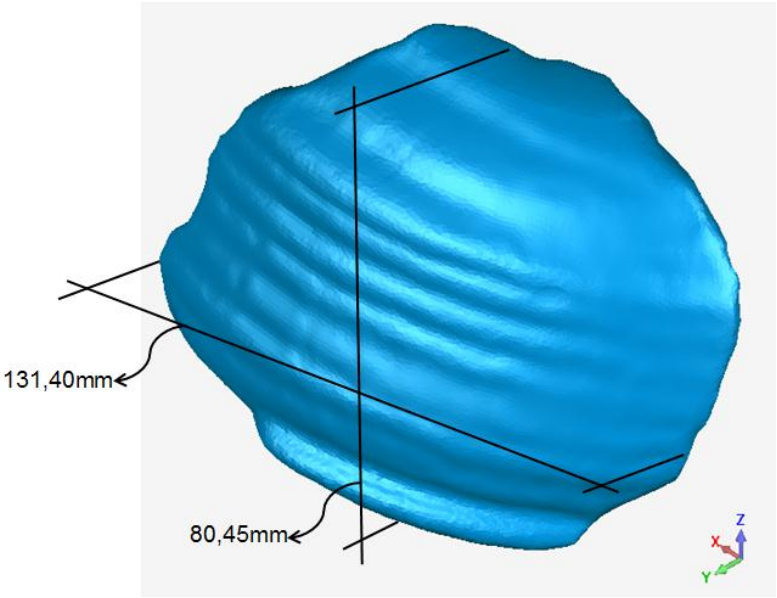

FONTE: O Autor

A Figura 67 apresenta a escala dos desvios da superfície.

Figura 67 – Avaliação do desvio 3D da fatia

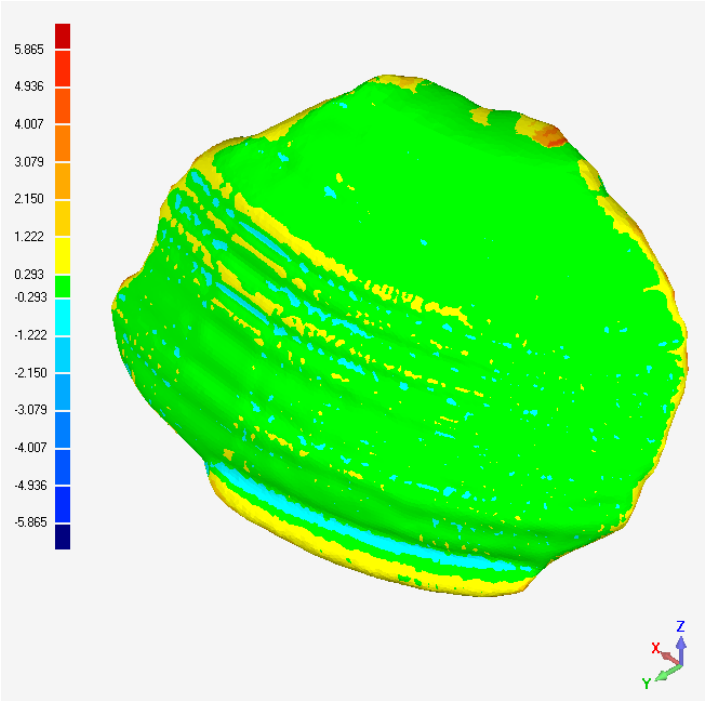

FONTE: O Autor

Analisando o desvio tridimensional da geometria da prótese, verifica-se que em algumas regiões a superfície possui um desvio de aproximadamente 5 mm em regiões pequenas e isoladas. Este desvio se dá devido ao truncamento da superfície

durante a geração da malha e principalmente devido à remoção dos excessos como demonstrado na Figura 64. Nota-se que os valores mais elevados para os desvios se encontram próximos às bordas do modelo. Estes são coincidentes ao perímetro da deformação óssea, onde estão contidos os excessos nos arcos-solução originais. Alguns pontos são ignorados para obter uma superfície mais homogênea.

A Figura 68.a apresenta a fatia onde o algoritmo não realizou a aproximação devido à diferença de formato em relação as demais fatias.

Figura 68 – Fatias fora do padrão

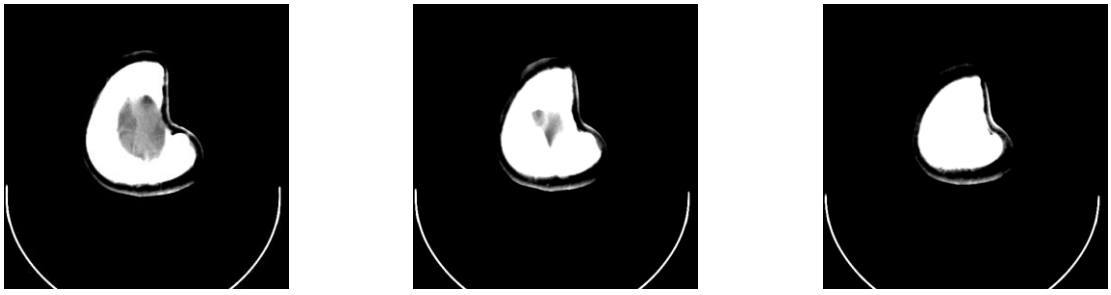

(a) (b) (c)

No caso da Figura 68.b e a Figura 68.c, o algoritmo considerou os contornos conformes por estarem fechados ou encontrar apenas um contorno. Devido a estas fatias estarem fora do padrão, houve uma descontinuidade na obtenção da geometria da prótese. A Figura 69 ilustra as regiões onde há limitações do algoritmo.

Figura 69 - Regiões e limites

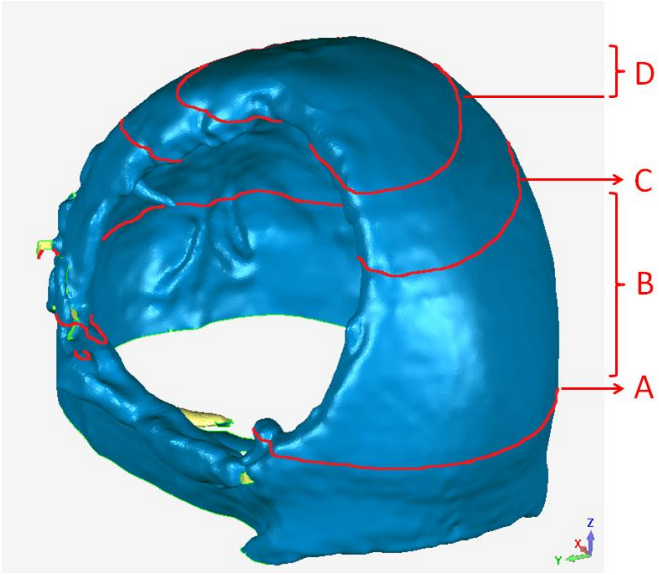

FONTE: O Autor

O contorno destacado como *A*, aponta onde aproximadamente o algoritmo teve inicio na otimização e busca dos arcos-solução. Em toda a faixa demarcada por *B,* houve aproximações satisfatórias como apresentadas anteriormente. A partir do contorno *C* até o topo do crânio houve divergências nas otimizações. Essa divergência ocorreu pelo formato do contorno do crânio se diferenciar dos padrões utilizados nos ensaios durante o desenvolvimento do algoritmo. A região *D* apresenta a fatia ilustrada na Figura 68.a até o topo do crânio, onde o algoritmo não buscou uma solução.

A Figura 70.a apresenta o conjunto dos arcos-solução aplicados, onde foi obtido um resultado satisfatório nas fatias que seguiram o padrão utilizado nos ensaios de desenvolvimento (região *B* da Figura 69). Na Figura 70.a e na Figura 70.b é possível verificar, na região circulada, a área que não foi obtida uma solução. Esta região que não foi solucionada devido ao diâmetro reduzido do corte transversal do crânio (região *D* da Figura 69) como demonstrado na Figura 68.

Figura 70 - Solução aplicada no estudo

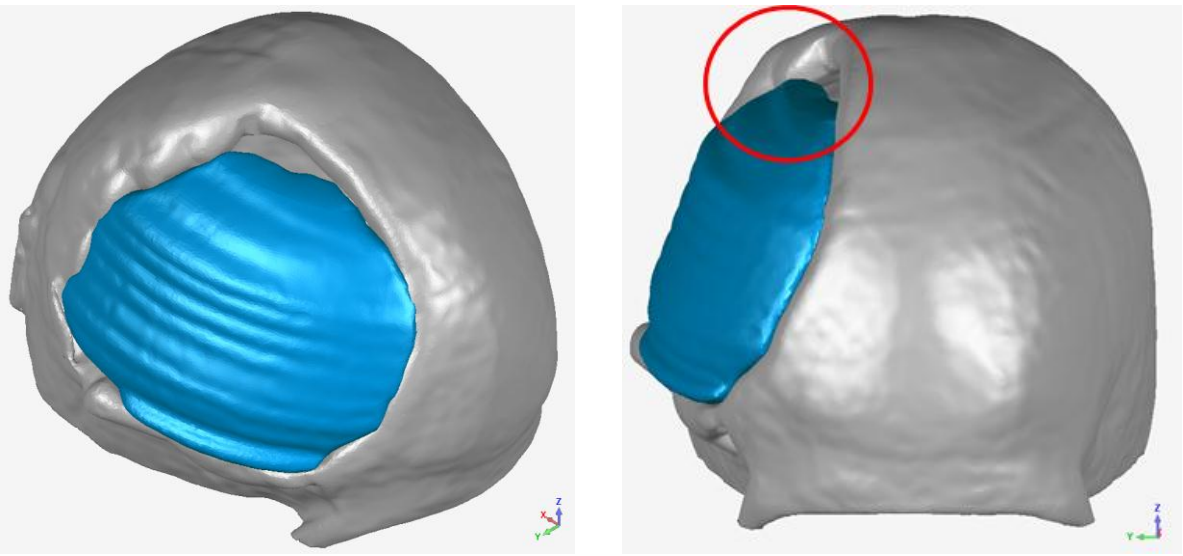

(a) (b)

FONTE: O Autor

O modelo de prótese na Figura 70 solucionou regiões da deformação onde existe uma baixa complexidade do crânio, o que não ocorreu na região superior devido às limitações como mencionadas anteriormente. A região destacada na Figura 70.b pode ser criada manualmente, mas como o escopo desta pesquisa é

busca automatizada dos arcos-solução, o processo manual para esta etapa foi desconsiderado.

A Figura 71.a ilustra uma seção axial do crânio, para a visualização da face da geometria voltada para o lado interno do crânio. A Figura 71.b ilustra a vista superior do crânio. É possível verificar que a solução segue uma tangência ao contorno do crânio, garantindo uma melhor estética à prótese implantada. Porém, a região de coincidência entre o crânio e a solução não se posiciona corretamente ao contorno da falha, devido à grande complexidade do perímetro da deformação Também é possível visualizar ondulações ao longo da geometria obtida. Essas ondulações são ocasionadas pelas aproximações elípticas não estarem correlacionadas com as aproximações anteriores e também devido à superfície com uma deformação complexa nas extremidades. Em outras palavras, o programa busca os arcos-solução da fatia mais inferior para a mais superior. Em alguns trechos do crânio, próximo à região temporal, existe uma variação baixa para as dimensões de largura e comprimento da caixa craniana. Acima dessa região, o crânio possui uma curvatura, vista no plano sagital e coronal e, conforme as seções transversais se aproximam do topo, as dimensões transversais diminuem.

A falta da correlação entre a aproximação e as características de sua anterior pode ocasionar essas ondulações por não seguir os padrões da curvatura sagital ou coronal do crânio. Assim, como os intervalos para as aproximações são definidos como na equação (5.1), pode-se obter arcos-solução com características próximas, porém diferentes para a, b, x_0 e y_0. Essa diferenciação e falta de correlação entre os arcos-solução é o motivo da existência de ondulações na superfície do modelo geométrico obtido e principalmente pelo nível de complexidade existente no perímetro da deformação real.

Neste caso não pode ser considerado a influência do método de interpolação das fatias, pois o mesmo foi utilizado no estudo do crânio com a deformação sintética. Neste caso, as ondulações presentes neste modelo geométrico, não foram replicadas. O mesmo ocorre para a parte interna do modelo geométrico, onde em uma das aproximações houve um recuo das elipses. Essas características se mantêm para as demais técnicas de IA por utilizarem a mesma função de aptidão e limites. A Figura 71.a apresenta a vista interna da solução e a descontinuidade na superfície interna na parte superior do modelo geométrico.

Figura 71 - Vista interna e superior

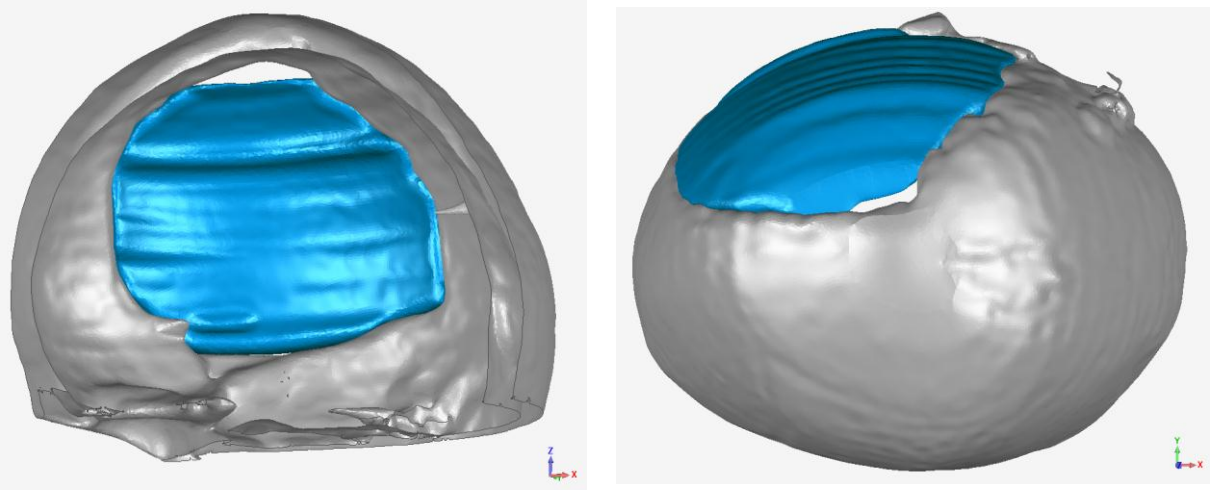

(a) (b)

FONTE: O Autor

A Figura 72 apresenta outra vista da aplicação da prótese posicionada externamente (região posterior-direita).

Figura 72 - Vista posterior direita

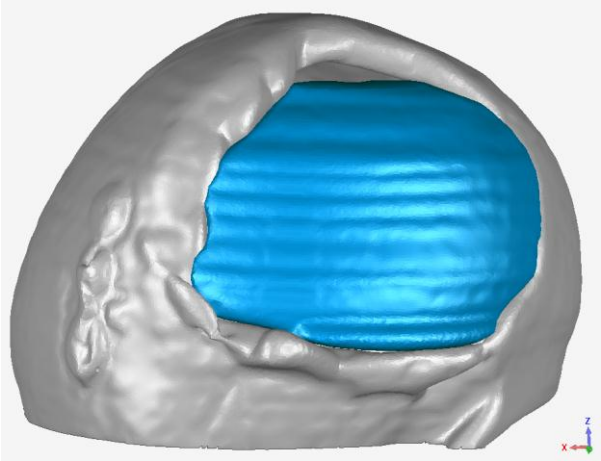

FONTE: O Autor

A solução encontrada supriu parcialmente da deformação do estudo de caso real. O estudo de caso utilizado para testar o algoritmo está muito comprometido esteticamente e sua análise apontou as limitações do algoritmo e pontos para melhorias posteriores.

7 CONCLUSÃO E RECOMENDAÇÕES

O objetivo desta pesquisa foi propor um método para modelar geometricamente próteses anatômicas de crânio de forma autônoma sem interação humana. Esse modelo geométrico pode se integrar aos requisitos de manufatura, fazendo uso de recursos de sistemas CAD como SolidWorks ®, Catia ® e Unigraphics ®. Essa integração da geometria em CAD para o CAM já é integrada à esses softwares e a execução da manufatura necessita apenas de estratégias para a usinagem, o que não é o escopo desta pesquisa. Observando e discutindo os resultados obtidos em testes e no estudo de caso real, os objetivos específicos propostos foram atingidos.

Foi desenvolvido um algoritmo que interpretou com sucesso imagens tomográficas que serviram como parâmetro de entrada para criar e ajustar as elipses em torno da curvatura do crânio. Foram desenvolvidos métodos que identificaram as regiões onde existiam aberturas no contorno com algumas limitações onde o diâmetro mínimo da fatia do crânio não permitia a identificação da deformação. A varredura de posição utilizando histogramas de posição obteve um resultado adequado, mas necessitava de um pós-processamento dos vetores da derivada do histograma. Outro método foi desenvolvido para mapear as deformações utilizando uma varredura polar a partir do centro da imagem. Este método não necessitou de uma segunda análise do vetor da derivada do histograma.

A avaliação do uso de elipses para representar geometricamente os contornos cranianos se mostraram válidos para uma sobreposição dos mesmos na região da deformação do crânio. Essa região parcial obteve bons resultados nas ROI que continham a deformação. As sobreposições das elipses resultantes ao contorno externo e interno do crânio obtiveram tangências adequadas em fatias onde o diâmetro do crânio não representava a parte superior do crânio (diâmetro menor).

Foram testadas algumas formas de avaliar o desempenho das elipses na sobreposição dos contornos do crânio. A melhor forma para averiguar esse desempenho foi através do mapeamento das distâncias dos pontos representantes do contorno da elipse analisada.

O melhor algoritmo evolutivo dos analisados nesta pesquisa no quesito de desempenho do sistema foi o *Harmony Search*. Este obteve um tempo de processamento muito reduzido. O algoritmo genético obteve o melhor resultado, mas considerando a grande diferença do custo computacional com relação ao HS, foi descartado para o processo de aproximação elíptica. O PSO e sua variação com decaimento linear da inércia obtiveram os piores valores de aptidão para os testes de aproximação. Considerando o custo computacional aproximado ao algoritmo genético, também foram descartados.

A exportação dos resultados obtidos foi analisada utilizando o software Geomagic Studio®. Com a ferramenta de desvio tridimensional, foi possível verificar que o desvio entre a nuvem de pontos e a superfície gerada é baixo. Desta forma houve pequenas áreas truncadas para se obter uma superfície mais uniforme e menos poligonal. Isto gerou pequenas alterações no processo de exportação das informações para o software CAD, necessitando da análise de um profissional da área médica para análise.

Analisando os resultados obtidos do modelo proposto para uma falha sintética, foi obtido um resultado adequado, utilizando aproximações elípticas. Como a falha foi gerada sinteticamente, foi possível analisar os resultados obtidos com o perímetro ósseo original. Desta forma, foi observado uma variação máxima de 5 mm na região posterior do crânio, como demonstrado anteriormente. Considerando a dimensão da falha artificial, a solução obteve um perímetro constante nas extremidades que tangenciam a deformação. O maior desvio na região posterior necessitaria da avaliação de um médico especializado tanto para a questão funcional quanto para a estética do modelo geométrico.

Aplicando o modelo em um estudo de caso real, foram verificadas algumas limitações do algoritmo. Como a grande maioria dos ensaios durante o desenvolvimento do software foram feitos com falhas sintéticas, foram desconsideradas imperfeições ou saliências ósseas no crânio. Informações como estas não são tratadas pelo algoritmo. Consequentemente a aplicação do modelo real no algoritmo não obteve um resultado totalmente satisfatório. Em fatias onde as deformações se adequavam aos padrões aplicados nos modelos sintéticos, foi observado um resultado satisfatório.

Embora haja restrições do método proposto para casos severos de deformação, foi verificado que é possível modelar geometricamente uma prótese a

partir das aproximações elípticas. O método ainda precisa ser melhorado em alguns aspectos, e o estudo ser aprofundado do ponto de vista médico. Por outro lado, do ponto de vista de engenharia, a pesquisa abordou os requisitos necessários que antecedem a manufatura, e demonstrou ser uma área de interesse atual, comprovado pelas publicações no XVII Simpósio de Engenharia de Produção (GREBOGE, *et. al.*, 2010), no *21st International Conference on Production Research* (RUDEK, *et. al.*, 2011c), no *13th Conference on Computer Graphics and Images* (RUDEK, *et. al.*, 2012), e no *18th ISPE International Conference on Concurrent Engineering* (RUDEK, *et. al.*, 2011a) (CANCIGLIERI JUNIOR, *et. al.*, 2011a) (RUDEK, *et. al.*, 2011b) (CANCIGLIERI JUNIOR, *et. al.*, 2011b).

Outros aspectos como os algoritmos evolutivos foram estudados e apresentados os diferentes desempenhos para as aproximações elípticas como apresentado no *21st Brazilian Congress of Mechanical Engineering (COBEM)*, (GREBOGE, *et. al.*, 2011a) e no *International Conference of Computers and Industrial Engineering (CIE41)* (GREBOGE, *et. al.*, 2011b)

7.1 RECOMENDAÇÕES

Partindo das limitações verificadas nos testes com falhas sintéticas e no estudo de caso real, é possível prever algumas recomendações para estudos futuros. Para as aproximações das elipses foram consideradas apenas informações transversais ao crânio. Desta forma foi possível verificar ondulações na superfície da solução obtida. Cruzar as informações das curvaturas transversais e sagitais podem melhorar o desempenho da aproximação e reduzir custos computacionais devido ao maior número de informações para limitar o espaço de busca para as elipses.

Para fatias com informações da região mais superior do crânio também podem ser feitas melhorias (onde o diâmetro do crânio é menor). Nesta pesquisa foram estudadas duas formas de detecção de deformação, porém estas não foram utilizadas em paralelo no algoritmo. Unir estas duas técnicas ou talvez desenvolver uma técnica que utilize os dois princípios pode aprimorar a detecção das deformações e ampliar as possibilidades para a obtenção de um resultado aprimorado.

Tornar o algoritmo mais genérico, permitindo a aplicação do modelo em situações onde existam informações ósseas excedentes à deformação (excesso de osso). Neste algoritmo, houve a limitação de realizar ensaios em casos onde existia apenas a ausência óssea em crânios saudáveis, por meio de deformações sintéticas. Realizar os ensaios considerando uma base de dados ampla, utilizando casos reais seria preferível.

Identificar o eixo de simetria do crânio e realizar um espelhamento da informação onde exista a simetria pode reduzir a região onde seja necessária a aproximação elíptica. Este formato pode reduzir características assimétricas provenientes da aproximação pelas elipses, como por exemplo, a perda das características das regiões das têmporas do crânio.

Realizar estudos referentes às estratégias de usinagem para o processo de manufatura da geometria obtida.

8 REFERÊNCIAS

AQUINO L.C.M; LEITE, D. A. T. Q.; GIRALDI, G. G.; CARDOSO, J. S.; RODRIGUES, P. S.; NEVES, L. A. P. Surface reconstruction for generating digital models of prosthesis. **Proceedings of the Sixth International Conference on Computer Vision Theory and Applications (VISAPP)**, Vilamoura, Algarve, Portugal, 5-7 March, 2011

ALEXANDRE, F.; JORGE, R. M. N.; EL SAYED, R.; MASCARENHAS, T.; FERNANDES, A. A. Obtenção de modelos sólidos de orgãos da cavidade pélvica da mulher. **Encontro Nacional de Visualização Científica**, Espinho, Portugal, p.1-5, set. 2005.

BACK, T.; HAMMEL, U.; SCHWEFEL, H. P. Evolutionary computation: comments on the history and current state. **IEEE Transactions on Evolutionary Computation**, v. 1, n. 1, p 3-17, 1997.

BAUTZ, W.; KALENDER, W. A. Was haben die Beatles mit der Computertomographie zu tun? **100 Jahre Deutsche Röntgengesellschaft**, p. 76-79, Stuttgart, Deutschland, 2005.

BERTO, R. V.; NAKANO, D. N. A produção científica nos anais do encontro nacional de engenharia de produção: um levantamento de métodos e tipos de pesquisa. **Produção***, v 9*, n. 2, p.65-76, 2000.

BERTOL, L. Contribuição ao estudo de prototipagem rápida, digitalização tridimensional e seleção de materiais no design de implantes personalizados. **Dissertação de Mestrado**, Programa de Pós-Graduação em Engenharia Minas, Metalúrgica e de Materiais. Porto Alegre, RS. Universidade Federal do Rio Grande do Sul, 2008.

BIDGOOD JR., D. W.; HORRI, S. C.; PRIOR, F. W.; VAN SYCKLE, D. E. Understanding and using DICOM, the data interchange standard for

biomedical imaging. **Journal of the American Medical Informatics Association***, v. 4, n.* 3, p. 199-212, 2008.

CANCIGLIERI JUNIOR, O.; RUDEK, M.; GREBOGE, T. A Prosthesis Design Based on Genetic Algorithms in the Concurrent Engineering Context. **Improving Complex Systems Today. 1ed.Massachusetts**: Springer, v. , p. 241-248, 2011a.

CANCIGLIERI JUNIOR, O.; RUDEK, M.; GREBOGE, T. A Prosthesis Design Based on Genetic Algorithms in the Concurrent Engineering Context. **ISPE Concurrent Engineering 2011 - CE2011**, Boston - USA. Springer, v. 1. p. 12-24, 2011b.

CATANI, F. Implementação de um software de auxílio de diagnóstico de subluxação do quadril baseado em imagens de tomografia computadorizada. **Trabalho de Conclusão de Curso**. Programa de Engenharia de Controle e Automação. Curitiba, PR, Pontifícia Universadade Católica do Paraná, 2009.

CENTENERO, S. A.; HERNÁNDEZ-ALFARO, F. 3D planing in orthognathic surgery: CAD/CAM surgical splints and prediction of the soft and hard tissues results - Our experience in 16 cases. **Journal of Cranio-Maxillo-Facial Surgery**, v. 40, n. 2, p. 162-8, 2011.

CHEN M. X.; GUAN T. M., SHAN L. J.; Digital Design of the Customized Cranial Prosthesis. **IEEE 2nd International Conference on Information and Computer Science**, Wuhan, China (ICIECS) p. 1-4, 2010.

CLACKDOYLE, R.; DEFRISE, M. Tomographic Reconstruction in the 21st Century. **IEEE Signal Processing Magazine**, v. 27, n. 4, p. 60-80, 2010.

CLIJMANS, T.; MOMMAETS, M.; GELAUDE, F.; SUETENS, P.; STOLEN, J. V. Skull reconstruction planning transfer to the operation room by thin metallic templates. **Journal of Cranio-Maxillofacial Surgery***,* v. 36, n. 2, p. 66-74, 2008.

CONNOR, S. J.; TAN, G.; FERNANDO, R.; CHAUDHURY, N. Computed tomography pseudofractures of the mid face and skull base. **Clinical Radiology**, v. 60 n. 12, p. 1268-1279, 2005.

COSTA, D. D.; PEDRINI, H.; BAZAN, O. Usinagem de próteses a partir de imagens tomográficas. **Congresso Brasileiro de Engenharia de Fabricação**, Joinville, SC, Anais do 3º COBEF, 2005.

CUSTOM IDM. Acesso em: < http://www.customimd.eu/ >. Acesso em: 5 fev. 2013.

DE BERG, M.; CHEONG, O.; VAN KREVELD, M.; OVERMARS, M. **Computation Geometry, Algorithms and Applications**, 3ª ed. Ed Springer, 2008.

DEANS, S. R. **The Radon Transform and Some of Its Applications,** 1ª ed. New York, USA,: Wiley, 1983.

DICOM. Disponível em: < http://medical.nema.org/ >. Acesso em: 20 fev. 2013

DYN, N.; LEVIN, D.; GREGORY, J. A 4-point interpolatory subdivision scheme for curve design. **Computer Aided Geometric Design**, v. 4, n. 4, p. 257-268, 1987.

ENGELBRECHT, A. P. **Fundamentals of computational swarm intelligence**. 1ª ed. England: Wiley, 2006.

EUFINGER, H.; WEHMÖLLER, M.; HARDERS, A.; HEUSER, L. Prefabricated prostheses for the reconstruction of skull defects. **International Journal of Maxillofacial Surgery**, v.24, n. 1, p. 104-110, 1995.

FRANCESCONI, T. Proposta metodológica para modelagem geométrica a partir de imagens médicas. **Dissertação de Mestrado**, Programa de Pós Graduação em Engenharia de Produção e Sistemas (PPGEPS), Curitiba, PR. Pontifícia Universidade Católica do Paraná, 2008.

GAUER, D.; CEVIDANES, L. S.; PROFFIT, W. R. Working with DICOM craniofacial images. **American Journal of Orthodontics and Dentofacial Orthopedics**, v. *136, n. 3,* 460-470, 2009.

GEEM, Z. W.; Kim, J. H.; Loganathan, G. V. A new heuristic optimization algorithm: harmony search. **Simulations**, v. 76, n. 2, p. 60-68, 2001.

GEOMAGIC STUDIO. Disponível em: <http://www.geomagic.com/en/ >. Acesso em 8 de mar. 2013.

GIELIS, J. A Generic Geometric Transformation That Unifies a Wide Range of Natural and Abstract Shapes, American Journal of Botany, v.90, n.3, p.333-338, 2003.

GOLDBERG, D. E. **Genetic algorithm in search, optimization and machine learning**. 1ª ed. Addison-Wesley Professional, 1989.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. 1ª ed. Ed. Blucher, 2000.

GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L. **Digital image processing using MATLAB**. 1ª ed. Ed. Pearson, 2004.

GRAHAM, R. J.; PERRISS, R. W.; SCARSBROOK, A. F. DICOM demystified: A review of digital file formats and their use in radiological practice. **Clinical Radiology**, v. 60, n. 11, p. 1133-1140, 2005.

GREBOGE, T. Modelagem 3D de próteses baseadas em imagens de tomografia computadorizada. **Trabalho de Conclusão de Curso**. Programa de Engenharia de Controle e Automação. Curitiba, PR, Pontifícia Universadade Católica do Paraná, 2009.

GREBOGE, T.; CANCIGLIERI JUNIOR, O.; RUDEK, M. Modelagem 3D de Próteses Baseada em Imagens de Tomografia Computadorizada. **XVII Simpósio de Engenharia de Produção (SIMPEP)**, Bauru, SP, Brasil, 2010.

GREBOGE, T.; RUDEK, M.; CANCIGLIERI JUNIOR, O.; COELHO, L. S. Using Genetic Algorithms to Support a Prosthesis Design in the CAD System. **21st Brazilian Congress of Mecanical Engineering (COBEM)**, Natal, 2011a.

GREBOGE, T.; GREBOGI, R. B.; RUDEK, M.; CANGLIERI JUNIOR, O. Geometric prostesis modeling to skull repairing using artificial intelligence methods. **International Conference of Computers & Industrial Engineering (CIE41)**, Los Angeles, USA, 2011b.

HAAGA, J. R.; FORSTING M.; GILKESON, R. C.; HA, H. K.; SUNDARAM, M. **Tomografia computadorizada e ressonância magnética do corpo humano**. 3ª ed. Ed. Guanabara Koogan S. A., v. 1, 1996

HASHEMI, S.; KIANI, S.; NOROOZI, N.; MOGHADDAM, M. E. An image-enhancement method based on genetic algorithm. **IEEE International Conference on Digital Image Processing**, New York, USA, p. 167-171, 2009.

HOUGH, P. V. C. "A method and means for recognising complex patterns," US Patent No. 3,069,654, 1962.

HUANG G. Y., SHAN L. J., Research on the Digital Design and Manufacture of Titanium Alloy Skull Repair Prosthesis. **IEEE 5th International Conference on Bioinformatics and Biomedical Engineering**, Wuhan, China (iCBBE), p. 1-4, 2011.

JENNANE, R.; ALMHDIE-IMJABBER, A.; HAMBLI, R.; UCAN, O. N.; BENHAMOU, C. L. Genetic algorithm and image processing for osteoporosis diagnosis. **IEEE Annual International Conference of Engineering in Medicine and Biology**, Buenos Aires, Argentina, p. 5597-5600, 2010.

JIANG, Y.; HU, T.; HUANG, CC.; WU, X. An improved particle swarm optimization algorithm. **Applied Mathematics and Computation**, v. 193, n. 1, p. 231-239, 2007.

JIN, G.Q.; LI, W.D.; GAO, L. An adaptive process planning approach of rapid prototyping and manufacturing. **Robotics and Computer-Integrated Manufacturing**, v. 29, n. 1, p. 23–38, 2013.

JOSHI, R. C.; TAPASWI, S. Image similarity: a geometric algorithm based approach. **Proceedings of World Academy of Science: Engineering and Technology**, v. 21, 327-331.

KAHN JR., C. E.; CARRINO, J. A.; FLYNN, M. J.; PECK, D. J.; HORII, S. C. DICOM and radiology: past, present and future. **American College of Radiology**, v. 4, n. 9, p. 652-657, 2007.

KAK, A. C.; SLANEY, M. **Principles of computerized tomographic imaging**. New York, USA: IEEE Press, 1988.

KANUNGO, P.; NANDA, P. K.; SAMAL, U. C. Image segmentation using thresholding and genetic algorithm. Acesso em 18 de Dezembro de 2010, disponível em http://dspace.nitrkl.ac

KELS, S.; DYN, N. Reconstruction of 3D objects from 2D cross-sections with the 4-point subdivision scheme adapted to sets. **Computers & Graphics**, v. 35, n. 3, p. 741-746, 2011.

KENNEDY, J.; EBERHART, R. C. Particle swarm optimization. **Proceedings of IEEE International Conference on Neural Networks**, Perth, Australia, v. 4, p. 1942-1948, 1995.

LAMPINEN, J. CAM shape optimization by genetic algorithm. **Computed-Aided Design**, v. 35, n. 8, p. 727-737, 2003.

LEE, K. S.; GEEM, Z. W. A new meta-heuristic algorithm for continuous engineering optimization, harmony search theory and practice. **Computer Methods in Applied Mechanics and Engineering**, v. 194, n. 36-38, p. 3902-3933, 2005a.

LEE, K. S.; GEEM, Z. W.; LEE, S-H.; BAE, K-W. The harmony search heuristic algorithm for discrete structural optimization. **Engineering Optimization**, v. 37, n. 7, p. 663-684, 2005b.

LEE, S. C.; WU, C. T.; LEE, S-T.; CHEN, P-J. Cranioplasty using polymethyl methacrylate prostheses. **Journal of Clinical Neuroscience**, v. 16, n. 1, p. 56-63, 2009.

LIANG, R., Craniofacial model reconstruction from skull data based on feature points. ***11th IEEE International Conference on Computer-Aided Design and Computer Grafics***, Huangshan, China, p. 602-605, 2009

LODYGOWSKI, T.; SZAJEK, K.; WIERSZYCKI, M. Optimization of dental implant using genetic algorithm. **Journal of Theoretical and Applied Mechanics**, v. 47, n. 3, p. 573-598, 2009.

LOPES, H. S. Algoritmos genéticos em projetos de engenharia: aplicações e perspectivas futuras. **Anais do IV Simpósio Brasileiro de Automação Inteligente**. Brasília, DF, Brasil, p. 1-11, 2009

MAHDAVI, M.; FESANGHARY, M.; DAMANGIR, E. An improved harmony search algorithm for solving optimization problems. **Applied Mathematics and Computation**, v. 188, n. 2, p. 1567-1579, 2007.

MARIANI, V. C.,NECKEL, V. J.; GREBOGI, R. B.; COELHO, L. S. Cauchy particle swarm optimization with dynamic adaptation applied to inverse heat transfer problem. **Proceedings of IEEE International Conference on Systems, Man and Cybernetics**, Istanbul, v. *1*, p. 1-6, 2010.

MATLAB. Disponível em: < http://www.mathworks.com/products/matlab/ >. Acesso em: 1 fev. 2013.

MIAMI PROSTHODONTICS. Disponível em: < http://www.miamiprosthodontics.com/ >. Acesso em: 5 fev. 2013.

ODUGUWA, V.; TIWARI, A.; ROY, R. Evolutionary computing in manufacturing industry: an overview of recent applications. **Applied Soft Computing**, v. 5, n. 3, p. 281-299, 2005.

OUELLET, J. N.; HÉBERT, P. Precise ellipse estimation without contour point extraction, **Proceedings of the Fourth Canadian Conference on Computer and Robot Vision, CRV '07**, pp. 21–28. IEEE Computer Society, Washington, DC, USA, 2007.

PAN, Q. K.; SUGANTHAN, P. N.; FATIH TASGETIREN, M.; LIANG, J. J. A self-adaptive global best harmony search algorithm for continuous optimization problems. **Applied Mathematics and Computation**, v. 216, n. 3, p. 830-848, 2010.

PEREIRA, E. L.; YAMAKI, J. T.; OLIVEIRA, M. B.; CARNEIRO NETO, W. S. Craniotomia dirigida por tomografia computadorizada com reconstrução tridimensional. **Arq Neuropsiquiatrica**, v. 35, n. 63, p. 1010-1015, 2005.

POLAK, M., ZHANG H., PI, M. An evaluation metric for image segmentation of multiple objects. **Image and Vision Computing**, v. 27, p. 1223-1227, 2009.

REED, J. M.; HUTCHINSON, S. A.; Subpixel Parameter Estimation for Elliptical Shapes Using Image Sequences; **Proceedings of 1994 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems, MFI'94**, Las Vegas, pp.567-574, 1994.

RENNER, G.; EKÁRT, A. Genetic algoritihm in computer-aided design. **Computer-Aided Design**, v. 35, n. 8, p. 709-726, 2003.

RIBEIRO FILHO, J.; TRELEAVEN, P. C.; ALIPPI, C. Genetic-algorithm Programming Environments. **IEEE Computers**, v. 26, n. 6, p. 28-43, 1994.

ROSIN, P.L. Assessing error of fit functions for ellipses. **Graphical Models and Image Processing**, v. 58, n. 5, p. 494-502,1996.

RUDEK, M.; CANCIGLIERI JUNIOR, O.; GREBOGE, T. A Prosthesis Design Based on Genetic Algorithms in the Concurrent Engineering Context. **Improving Complex Systems Today**, v. 1, p. 241-248, 2011a.

RUDEK, M. ; CANCIGLIERI JUNIOR, O.; GREBOGE, T. A Prosthesis Design Based on Genetic Algorithms in the Concurrent Engineering Context. **ISPE Concurrent Engineering 2011 - CE2011**, Boston, USA, v. 1, p. 12-24, 2011b.

RUDEK, M.;GREBOGE, T., CANCIGLIERI JUNIOR, O. Conceptual Geometric Model For Prothesis Modeling In CAD System: A Case Study To Skull Repairing With Asymmetric Defect. **21st International Conference on Production Research - ICPR 21**, Stuttgart, Germany, 2011c.

RUDEK, M. ; CANCIGLIERI JUNIOR, O.; GREBOGE, T. An Optimized Method for Anatomic Skull Prosthesis Modelling. **13th IASTED Conference on Computer Graphics and Image (CGIM 2012)**, Creta, 2012.

RUDEK, M. ; CANCIGLIERI JÚNIOR, O. ; GREBOGE, T. . A PSO Application in Skull Prosthesis Modelling by Superellipse. **ELCVIA. Electronic letters on computer vision and image analysis**, v. 12, p. 1-12, 2013.

RUSS, J. **The image processing handbook**. 6ª ed. CRC Press, 2007.

SALDARRIAGA J. F. I.; VÉLEZ, S. C.; POSADA, A. C.; HENAO, B. B.; VELANCIA, C. A. T. Design and Manufacturing of a Custom Skull Implant. **American J. of Engineering and Applied Sciences**, v. 4, n. 1, p. 169-174, 2011.

SHI, Y.; EBERHART, R. A. A modified particle swarm optimizer. **Proceedings IEEE Congress on Evolutionary Computation**, Anchorage, AK, USA, p. 69-73, 1998.

SPINE UNIVERSE. Disponível em: <http://www.spineuniverse.com/anatomy/anatomical-planes-body>. Acesso em: 15 jun. 2013.

VAN KAICK, G.; DELORME, S. Computed tomography in various fields outside medicine. **European Radiology Supplements**, v. 15, n.4, p. 74-81, 2005.

WANG, C.-M.; HUANG, Y.-F. Self-adaptive harmony search algorithm for optimization. **Expert Systems with Applications**, v. 37, n. 4, p. 2826-2837, 2010.

WUYANG, S., 3D craniofacial reconstruction using reference skull-face database. **25th International Conference of Image and Vision Computing**, Queenstown, New Zealand (IVCNZ), p. 1-7, 2010

YOU, F.; HU, Q.; YAO, Y.; LU, Q. A new modeling method on skull defect repair. **IEEE International Conference on Measuring Technology and Mechatronics Automation**, v. 1, p. 568-572.

ZAHNG, L.; LIU, L.; GOTSMAN, C.; HUANG, H. Mesh reconstruction by meshless denoising and parameterization. **Computer and Graphics**, v. 34, n. 3, p. 198-208, 2010.

9 APÊNDICES

9.1 ANEXO 1

Tabela 6 – Tabela de números de Hounsfield

Material	HU
Ar	-1000
Gordura	-120 a -80
Água	0
Transudato	<16
Exudato	>18
Plasma	25 a 29
Sangue	50 a 60
Coágulo	70 a 90
Rim	20 a 40
Pâncreas	25 a 55
Baço	35 a 55
Fígado	45 a 75
Músculo	35 a 50
Osso	150 a 1000
Pulmão	-300 a -900
Cérebro	20 a 35
Lcr	0 a 5

FONTE: Augusto (2002) *apud* Francesconi (2008)

9.2 ANEXO 2

Tabela 7 – Comparativo quanto à Detecção de Bordas

IMAGEM ORIGINAL			
Imagem Preto e Branco 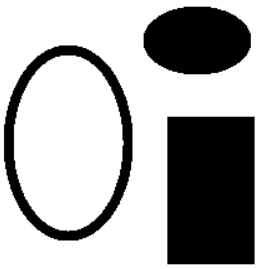			
CONTORNO	CONTORNO-IMAGEM ORIGINAL	CONTORNO	CONTORNO-IMAGEM ORIGINAL
Contorno usando modelo de Canny 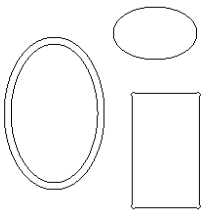	Área óssea - Contorno Canny 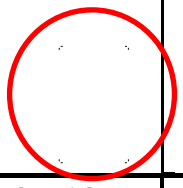	Contorno usando modelo de Roberts 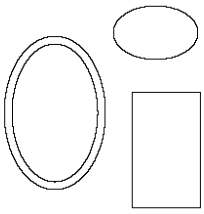	Área óssea - Contorno Roberts 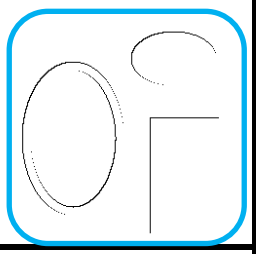
Contorno usando modelo de LoG 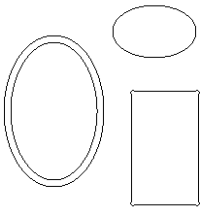	Área óssea - Contorno LoG 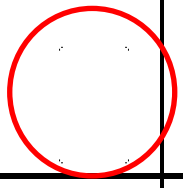	Contorno usando modelo de Prewitt 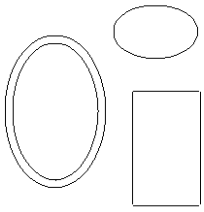	Área óssea - Contorno Prewitt 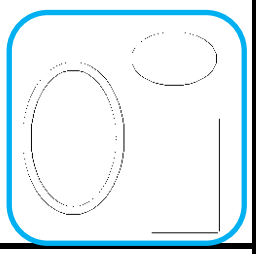
Contorno usando modelo de Zerocross 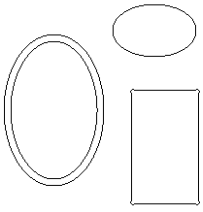	Área óssea - Contorno Zerocross 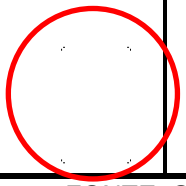	Contorno usando modelo de Sobel 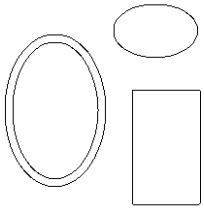	Área óssea - Contorno Sobel 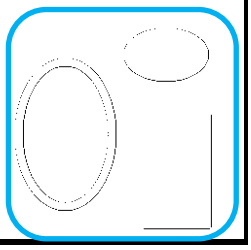

FONTE: O Autor

9.3 ANEXO 3

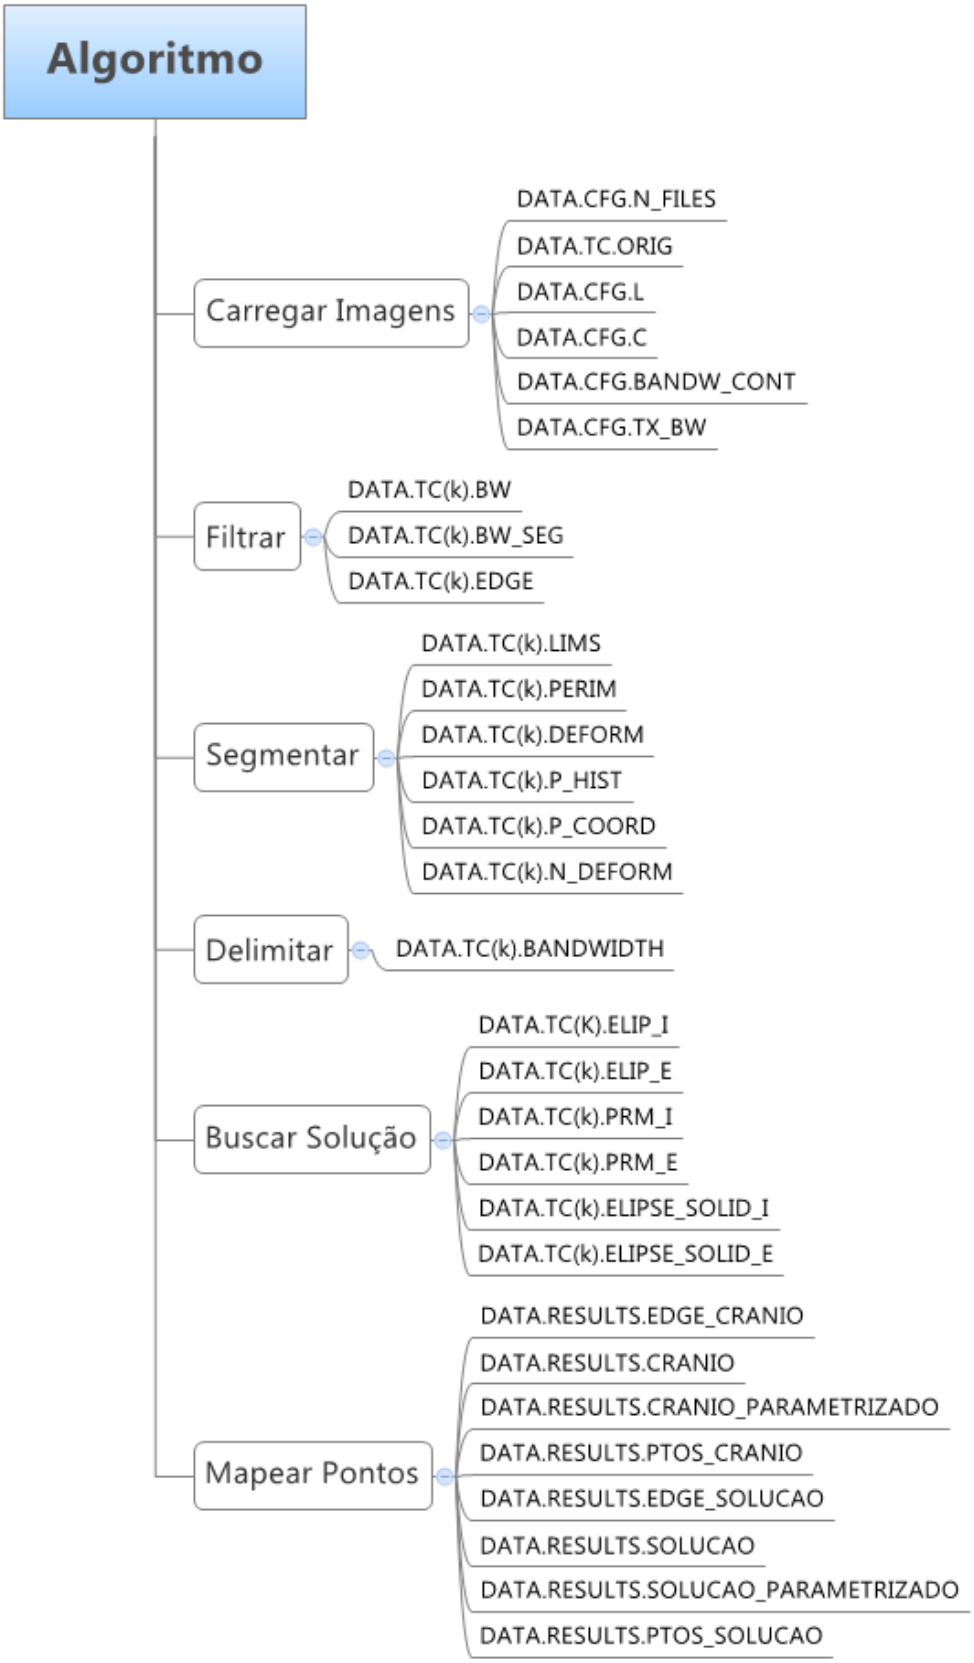
Algoritmo
Carregar Imagens
DATA.CFG.N_FILES
DATA.TC.ORIG
DATA.CFG.L
DATA.CFG.C
DATA.CFG.BANDW_CONT
DATA.CFG.TX_BW
Filtrar
DATA.TC(k).BW
DATA.TC(k).BW_SEG
DATA.TC(k).EDGE
Segmentar
DATA.TC(k).LIMS
DATA.TC(k).PERIM
DATA.TC(k).DEFORM
DATA.TC(k).P_HIST
DATA.TC(k).P_COORD
DATA.TC(k).N_DEFORM
Delimitar
DATA.TC(k).BANDWIDTH
Buscar Solução
DATA.TC(K).ELIP_I
DATA.TC(k).ELIP_E
DATA.TC(k).PRM_I
DATA.TC(k).PRM_E
DATA.TC(k).ELIPSE_SOLID_I
DATA.TC(k).ELIPSE_SOLID_E
Mapear Pontos
DATA.RESULTS.EDGE_CRANIO
DATA.RESULTS.CRANIO
DATA.RESULTS.CRANIO_PARAMETRIZADO
DATA.RESULTS.PTOS_CRANIO
DATA.RESULTS.EDGE_SOLUCAO
DATA.RESULTS.SOLUCAO
DATA.RESULTS.SOLUCAO_PARAMETRIZADO
DATA.RESULTS.PTOS_SOLUCAO

9.4 ANEXO 4

Com os valores normalizados para os pontos representativos, é realizada uma multiplicação elemento a elemento de v_n com o comprimento do vetor de histograma, definido como *k*. Este resultado fornece as posições dos pontos do histograma que serão utilizados como pontos representativos.

Figura 73 - Distribuição exponencial

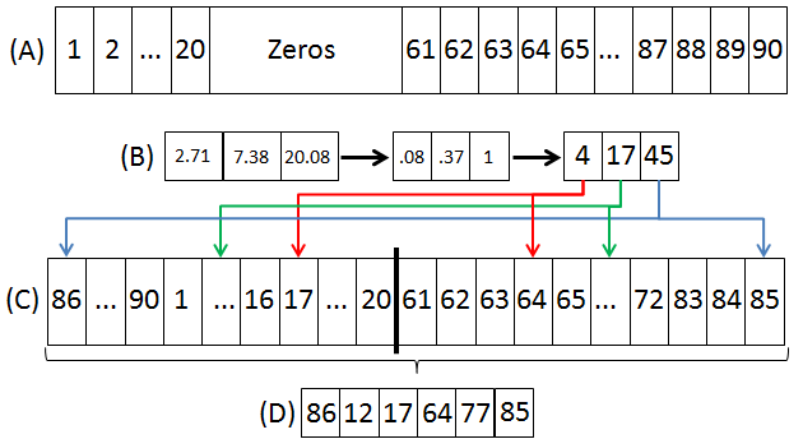

FONTE: O Autor

Seguindo a distribuição apresentada na Figura 73, foi exemplificado a extração de 6 pontos representativos de um histograma genérico com comprimento igual à 90. O vetor (A) representa o histograma original contendo a região da deformação (elementos iguais à zero). Em (B) é apresentado os valores distribuídos exponencialmente, em seguida normalizados e multiplicados pela metade do comprimento de (A) (igual à 45). Em seguida, (C) apresenta a distribuição dos pontos representativos para cada metade do histograma. A marca em negrito no centro de (C) ressalta a divisão onde está o inicio e o término da deformação. Em (D) está ilustrado as posições dos pontos do histograma que serão considerados para a aplicação da função de aptidão.

9.5 ANEXO 5

Tabela 8 - Experimentos com IA

	TC_8772	TC_8808	TC_8916
Tomografia Original		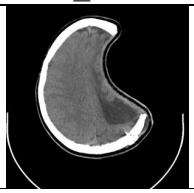	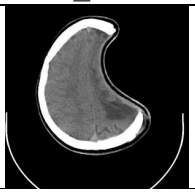
Tomografia Segmentada			
Soluções AG			
Soluções HS			
Soluções PSO Clássico			
Soluções PSO com decaimento linear			

FONTE: O Autor

9.6 ANEXO 6

Tabela 9 – Tomografias do Estudo de Caso

6238520	6238538	6238556	6238574
	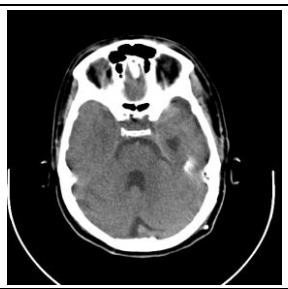		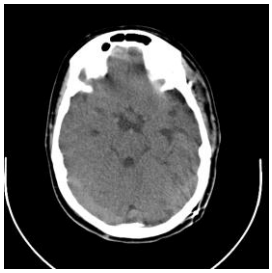
6238592	6238610	6238628	6238646
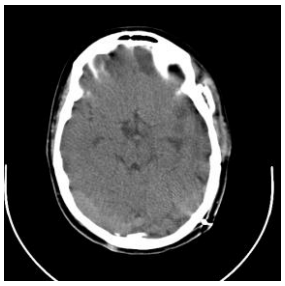	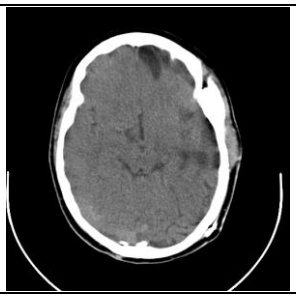	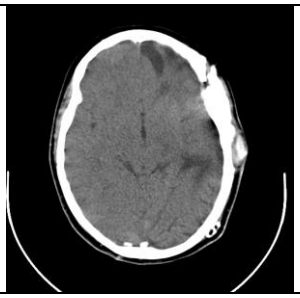	
6238664	6238682	6238700	6238718
	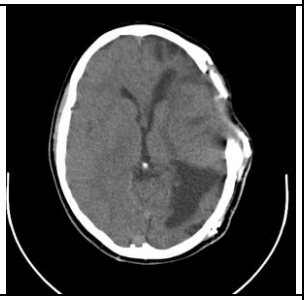	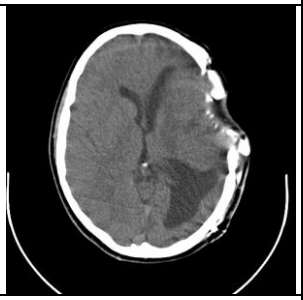	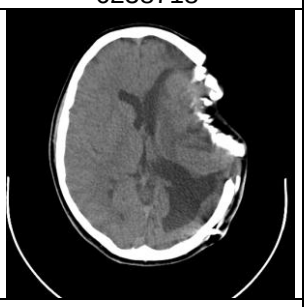
6238736	6238754	6238772	6238790
	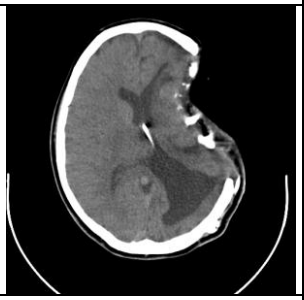	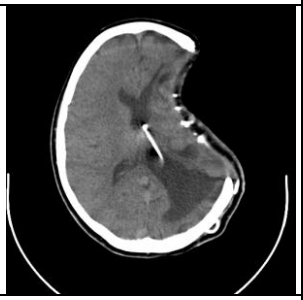	
6238808	6238826	6238844	6238862
	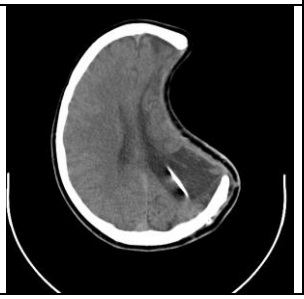	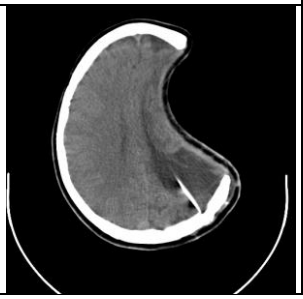	

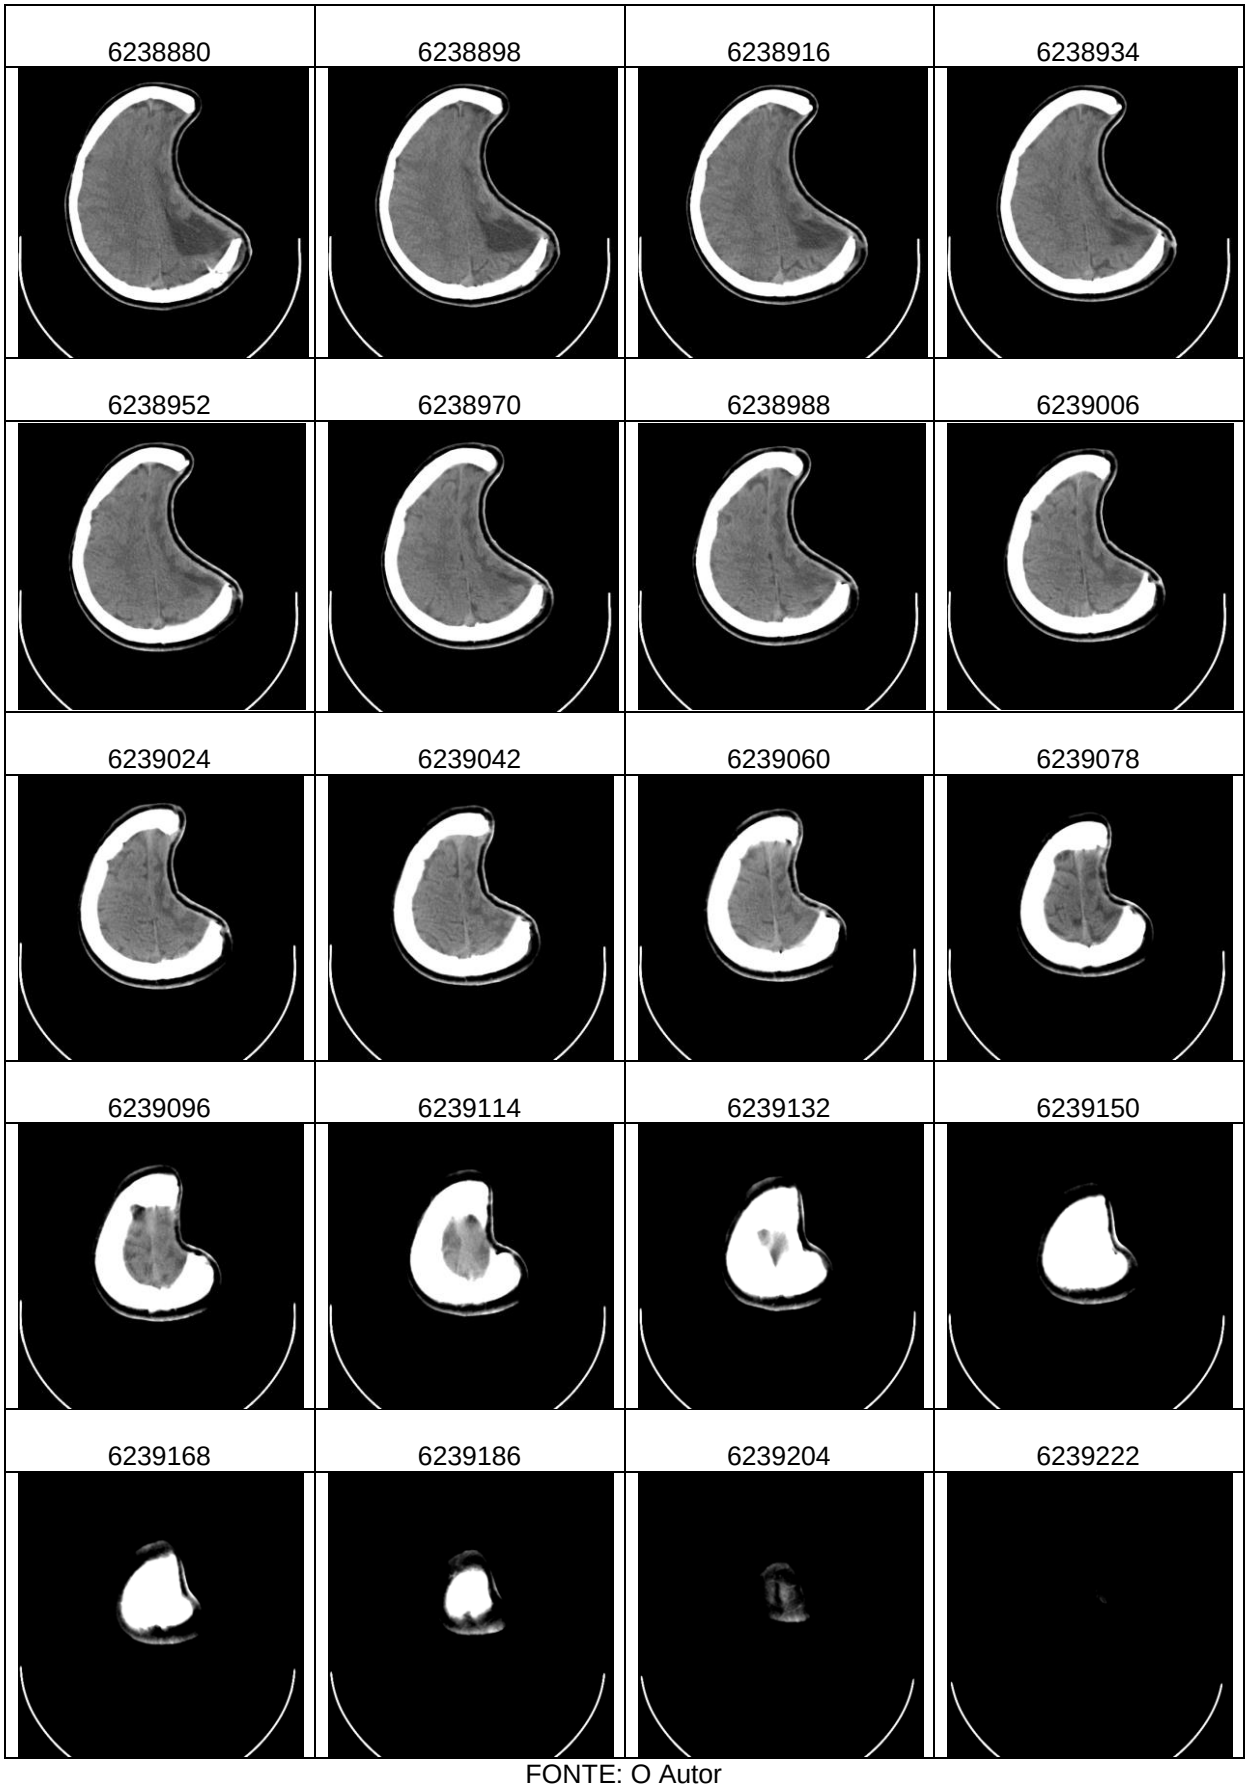

FONTE: O Autor