

TESE DE DOUTORADO

**PROJETO DE UM DESCRITOR PARA O  
ALINHAMENTO DE IMAGENS DE  
PROFUNDIDADE DE SUPERFÍCIES COM  
APLICAÇÃO EM VISÃO ROBÓTICA**

**GERARDO ANTONIO IDROBO PIZO**

**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA**



**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**TESE DE DOUTORADO EM SISTEMAS  
MECATRÔNICOS**

**PROJETO DE UM DESCRITOR PARA O  
ALINHAMENTO DE IMAGENS DE  
PROFUNDIDADE DE SUPERFÍCIES COM  
APLICAÇÃO EM VISÃO ROBÓTICA**

**GERARDO ANTONIO IDROBO PIZO**

**ORIENTADOR  
JOSÉ MAURÍCIO SANTOS TORRES DA MOTTA  
(ENM- UnB)**

**PUBLICAÇÃO: ENM.TD – 07A/14  
BRASÍLIA-DF  
07 DE AGOSTO 2014**

**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**PROJETO DE UM DESCRITOR PARA O ALINHAMENTO DE  
IMAGENS DE PROFUNDIDADE DE SUPERFÍCIES COM  
APLICAÇÃO EM VISÃO ROBÓTICA**

**TESE SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA  
MECÂNICA DA FACULDADE DE TECNOLOGIA DA  
UNIVERSIDADE DE BRASÍLIA COMO PARTE DOS REQUISITOS  
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM  
SISTEMAS MECATRÔNICOS**

APROVADA POR:

---

PROF. DR. JOSÉ MAURÍCIO S. T. DA MOTTA (ENM-UnB)

(Orientador)

---

PROF. DR. DÍBIO LEANDRO BORGES (CIC-UnB)

(Examinador Interno)

---

PROF. DR<sup>a</sup>. MYLÈNE CHRISTINE QUEIROZ DE FARIAS (ENE-UnB)

(Examinador Externo)

---

PROF. DR. ADSON FERREIRA DA ROCHA (FGA-UnB)

(Examinador Externo)

---

PROF. DR. HUGO VIEIRA NETO (DAELN-UTFPR)

(Examinador Externo)

## FICHA CATALOGRÁFICA

PIZO, GERARDO ANTONIO

Projeto de um descritor para o alinhamento de imagens de profundidade de superfícies com aplicação em visão robótica: [Distrito Federal] 2014.

xxv, 125p. 210 x 297 mm (ENM/FT/UnB, Doutor, Sistemas Mecatrônicos, 2014).

Tese de Doutorado – Universidade de Brasília. Faculdade de Tecnologia.

Departamento de Engenharia Mecânica.

1. Imagem de profundidade

2. Registro

3. Descritor

4. Robótica

I. ENM/FT/UnB

II. Título (série)

## REFERÊNCIA BIBLIOGRÁFICA

PIZO, G. A. (2014). Projeto de um descritor para o alinhamento de imagens de profundidade de superfícies com aplicação em visão robótica. Tese de Doutorado em Sistemas Mecatrônicos, Publicação EMN.TD – 07A/14, Departamento de Engenharia Mecânica e Mecatrônica, Universidade de Brasília, Brasília, DF, 125 p.

## CESSÃO DE DIREITOS

AUTOR: Gerardo Antonio Idrobo Pizo

TÍTULO: Projeto de um descritor para o alinhamento de imagens de profundidade de superfícies com aplicação em visão robótica.

GRAU: Doutor

ANO: 2014

É concedida à Universidade de Brasília permissão para reproduzir cópias desta tese de doutorado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa tese de doutorado pode ser reproduzida sem autorização por escrito do autor.

---

Gerardo Antonio Idrobo Pizo

Departamento de Engenharia Mecânica,  
Campus Universitário Darcy Ribeiro  
70.910-900 - Brasília - DF – BRASIL

# DEDICATÓRIA

**A DEUS.**

*À minha mãe, Cristobalina Pizo, e às minhas irmãs e sobrinhos.*

*À minha linda namorada Tatiana Athayde Cavalcante.*

# AGRADECIMENTOS

Agradeço em primeiro lugar a Deus, pela saúde, força e luz que sempre ilumina meu caminho e por todas as bênçãos e milagres que sempre recebo!

Ao meu orientador Professor José Maurício Santos Torres da Motta, pelo compartilhamento de sua sabedoria, paciência na orientação, incentivo e apoio que tornaram possível a conclusão do Mestrado e agora o Doutorado, que nunca mediu esforços para que eu chegasse até esta etapa da minha vida. Quero agradecer pela amizade oferecida e por me ajudar sempre nos diferentes momentos, desde que cheguei ao Brasil.

Agradeço também a todos os professores que me acompanharam durante minha pós-graduação, em especial ao Professor Carlos Humberto Llanos Quintero, pelo apoio, ensinamentos, confiança, amizade e pelas nossas conversas que foram muito enriquecedoras. E ao Professor Guilherme Caribé de Carvalho, por seus ensinamentos e confiança ao longo das supervisões das minhas atividades curriculares.

À minha família, por sua capacidade de acreditar e por sempre torcer e rezar por mim. Minha mãe Cristobalina Pizo sempre será minha musa de inspiração!

Quero agradecer a todos aqueles que de alguma forma estiveram e estão próximos de mim durante estes últimos quatro anos, sempre apoiando-me, especialmente a minha linda namorada Tatiana Athayde Cavalcante e amigos Frederico Furlan, Jorge Maia, Magno Correa, Jones Yudi, Evandro Teixeira e Thiago Siqueira.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e à Fundação de Empreendimentos Científicos e Tecnológicos (FINATEC) pelo apoio financeiro concedido.

Quero agradecer à Universidade de Brasília, bem como ao programa de Pós-Graduação em Sistemas Mecatrônicos, por me oferecerem as condições necessárias para realização deste trabalho.

Ficaria um texto longo para escrever meus sinceros votos de amor e agradecimento que tenho pelo BRASIL. “Desejo sempre prosperidade, poder e glória para o BRASIL”. Muito obrigado, BRASIL!

**Muito obrigado, DEUS!**

# EPÍGRAFE

*“A tarefa não é tanto ver aquilo que ninguém viu, mas pensar o que  
ninguém ainda pensou sobre aquilo que todo mundo vê.”*  
(Arthur Schopenhauer)

# RESUMO

O processo de Reconstrução 3D de objetos a partir de imagens de profundidade compreende três fases: a) aquisição, na qual a superfície do objeto é digitalizada a partir de vários pontos de vista, gerando um conjunto de  $n$  imagens de profundidade; b) registro, no qual uma transformação rígida  $\mathbf{M}$  deve ser estimada para posicionar as imagens, par a par, em um único referencial; e c) combinação ou “matching”, na qual redundâncias entre vistas registradas são tratadas para construir um modelo 3D completo único.

Na etapa de registro distinguem-se ainda duas etapas: pré-alinhamento e alinhamento fino. Na primeira, uma aproximação inicial de registro é estimada através da extração de pontos característicos correspondentes de duas imagens que ocupem a mesma posição no espaço do objeto e do cálculo de uma transformação rígida de forma que a distância quadrática entre os pares de pontos característicos correspondentes seja minimizada. Na segunda etapa, iterações são aplicadas sobre a transformação obtida para que os erros de alinhamento sejam minimizados.

A fase de alinhamento fino é um problema resolvido, muito diferente da etapa de pré-alinhamento, cujo problema é o desconhecimento da correspondência entre as regiões de sobreposição; por tal motivo, a solução mais usual é escolher pontos que tenham alguma característica que os distingam do resto.

Nesta tese propôs-se uma metodologia que está baseada na segmentação/reconstrução de imagens de profundidade fazendo uso da técnica de detecção de bordas aliada à técnica de agrupamento usando dizimação de malhas. A partir das bordas propõe-se um descritor de propriedades invariantes sob transformações de similaridade que incluem transformações de rotação, translação e escala uniforme como também robusto a ruído.

Através do descritor proposto, são extraídos  $n$  pontos correspondentes de ambas as imagens, e gera-se como valor de saída uma assinatura que se relaciona diretamente ao ponto considerando a disposição geométrica de sua vizinhança. A assinatura resultante atribui um rótulo ao ponto na imagem de profundidade, o que permite que, no processo de busca, seja aumentada a eficiência de correspondências, facilitando a identificação de possíveis zonas de sobreposição e reduzindo a ambiguidade no processo de busca. O

descritor foi avaliado com diferentes imagens e seus resultados foram comparados com os de outros autores com as mesmas imagens.

Para verificar a validade das transformações candidatas, cada uma delas passa por um alinhamento fino, em que se avalia os erros de ajuste entre as duas imagens de profundidade através do algoritmo ICP (*iterative closest point*). A transformação que alinha o maior número de pontos é considerada a solução.

Destaca-se que a principal contribuição deste trabalho é o desenvolvimento de uma técnica de pré-alinhamento e de sua integração com uma técnica de alinhamento fino, definindo de forma geral uma metodologia completa para registro e reconstrução de modelos tridimensionais de superfícies que tenham variação de curvatura suave em uma vizinhança, a partir de curvas de contorno 3D de variações geométricas nesta superfície.

# RESUMEN

El proceso de Reconstrucción 3D de objetos a partir de imágenes de profundidad comprende tres fases: a) adquisición, en la cual la superficie del objeto es digitalizada a partir de varios puntos de vista, generando un conjunto de imágenes de profundidad. b) registro, en la cual una transformación rígida  $\mathbf{M}$  debe ser estimada para posicionar las imágenes, par a par, en un único marco referencial. c) combinación o “matching”, en la cual redundancias entre vistas registradas son tratadas para construir un modelo 3D completo único.

En la etapa de registro se distinguen dos etapas: pre-alineamiento y alineamiento fino. En la primera, una aproximación inicial de registro es estimada a través de extracción de puntos característicos correspondientes en las dos imágenes, que ocupen la misma posición en el espacio del objeto y el cálculo de una transformación rígida  $\mathbf{M}$  de forma que la distancia cuadrada entre los pares de puntos característicos correspondientes sea minimizada. En la segunda etapa, iteraciones son aplicadas sobre la transformación obtenida para que los errores de alineamiento sean minimizados.

La fase de alineamiento fino es un problema resuelto, muy diferente a la etapa de pre-alineamiento, cuyo problema es el desconocimiento de la correspondencia entre las regiones de sobre posición; por tal motivo, la solución más usual es escoger puntos que tengan alguna característica que los distingan del resto.

La fase de alineamiento fino es un problema resuelto, muy diferente a la etapa de pre-alineamiento, cuyo problema es el desconocimiento de la correspondencia entre las regiones de sobre posición; por tal motivo, la solución más usual es escoger puntos que tengan alguna característica que los distingan del resto. La propuesta deste trabajo es contribuir en la búsqueda de una solución más eficaz, tratando de superar inconvenientes que hacen que otros métodos fallen.

En esta tesis se plantea una metodología que está basada en la segmentación/reconstrucción de imágenes de profundidad, utilizando la técnica de detección de bordas aliada a la técnica de agrupamiento de mallas. A partir de las bordas se propuso un descriptor de propiedades invariantes sobre transformaciones de semejanza que incluye transformaciones de rotación, translación y escala uniforme como también robusto al ruido.

A través del descriptor propuesto, son extraídos  $n$  puntos correspondientes de las dos imágenes, generando como valor de salida un código que lo relaciona directamente al punto considerando la disposición geométrica de su vecindad. El código resultante atribuye una etiqueta al punto de la imagen de profundidad, lo que permite que en el proceso de búsqueda, sea aumentada la eficiencia de correspondencias, facilitando la identificación de posibles zonas de superposición y reduciendo la ambigüedad en el proceso de búsqueda. El descriptor fue evaluado con diferentes imágenes y sus resultados fueron comparados con los resultados de otros autores usando las mismas imágenes.

Para verificar la validez de las transformaciones candidatas, cada una de ellas pasó por un alineamiento fino, en que se evalúa los errores de ajuste entre las dos imágenes de profundidad a través del algoritmo ICP (*iterative closest point*). La transformación que alinee el mayor número de puntos es considerada la solución.

Se destaca que la principal contribución deste trabajo es el desenvolvimiento de una técnica de pre-alineamiento y su integración con una técnica de alineamiento fino, definiendo de forma general una metodología completa para el registro y reconstrucción de modelos tridimensionales de superficies, con variación de curvatura suave en una vecindad, a partir de curvas de contornos 3D de variaciones geométricas en esta superficie.

# ABSTRACT

The process of reconstruction of 3D objects from range images consists of three steps: a) acquisition, in which the surface of the object is scanned from various points of view, generating  $n$  depth images; b) registration, in which a rigid transformation  $\mathbf{M}$  must be estimated to locate images, pair by pair, in a single framework; c) matching, in which redundancies between registered views are processed to construct a single complete 3D model.

Registration is further distinguished in two stages: pre-alignment and fine alignment. First, an initial approximation of the register is estimated by extracting the corresponding feature points from the two images that occupy the same position in the object space and the computation of a rigid transformation  $\mathbf{M}$  so that the squared distance between pairs of corresponding feature points is minimized. In the second step, iterations are applied to the transformation obtained for alignment errors to be minimized.

The fine alignment stage is a solved problem, very differently from the pre-alignment step, whose problem is the lack of correspondence between the overlap regions; therefore, the most common solution is to choose points that have some characteristics that distinguish them from the rest.

This thesis proposes a methodology that is based on segmentation / reconstruction of depth images making use of an edge detection technique combined with a clustering technique using mesh decimation edges. From the edges it is proposed a descriptor which is invariant to similarity transformations including rotation, translation and uniform scale as also robust to noise.

Through the proposed descriptor,  $n$  corresponding points from the two images are extracted, and a signature value is generated as output that is related directly to the point considering the geometrical distribution of its neighborhood. The resulting signature assigns a label to the point in the depth image, which allows that in the search process the efficiency of the correspondences is increased, facilitating the identification of possible areas of overlapping and reducing the ambiguity in the search process. The descriptor was evaluated with different images and their results were compared with those of other authors that used the same images.

To verify the validity of the candidate transformations, each of which passes through a fine alignment, in which the fitting errors are evaluated between the two depth images by the ICP (iterative closest point) algorithm. The transformation that aligns the largest number of points is considered the solution.

It is noteworthy that the main contribution of this work is the development of a technique for pre-alignment and its integration with a fine alignment technique, defining a complete methodology for registration and reconstruction of three-dimensional surface models, with smooth curvature variation in a neighborhood, from the curves of 3D contours.

<b>SUMÁRIO</b>		<b>Pág.</b>
<b>1.</b>	<b>INTRODUÇÃO .....</b>	24
<b>2.</b>	<b>CONCEITOS INTRODUTÓRIOS .....</b>	28
2.1.	SENSOR ÓPTICO LASER .....	28
2.2.	FILTRAGEM DA NUVEM DE PONTOS .....	31
2.3.	FORMATO DE NUVEM DE PONTOS.....	33
2.4.	REGISTRO .....	38
2.4.1.	Definição do problema .....	40
2.4.2.	Imagens de profundidade usadas no processo de registo...	44
2.4.3.	Hipótese para solucionar o problema de pré-alinhamento de imagens de profundidade .....	45
<b>3.</b>	<b>OBJETIVOS .....</b>	47
<b>4.</b>	<b>PROPOSTA DE SOLUÇÃO – ALGORITMO DE PRÉ-ALINHAMENTO .....</b>	48
4.1.	METODOLOGIA PARA CONSTRUÇÃO DO DESCRITOR.....	48
4.1.1.	Etapa 1: Fundamentos para construir o descritor .....	48
4.1.2.	Etapa 2: redução de dados .....	50
4.1.2.1.	Resultado experimental Etapa 2 – redução de dados .....	51
4.1.3.	Etapa 3: rotulagem de regiões .....	51
4.1.3.1.	Resultado experimental Etapa 3 - rotulagem de regiões .....	53
4.1.4.	Etapa 4: detecção de curvas de contorno .....	54
4.1.4.1.	Resultado experimental Etapa 4 - detecção de curvas de contorno .....	55
4.1.5.	Etapa 5: detecção de pontos característicos de um mapa de curvas de contorno .....	58
4.1.5. 1.	Algoritmo de código de cadeia .....	59
4.2.5. 2.	Otimização do algoritmo de código de cadeia para determinar pontos característicos .....	60

4.1.5. 3.	Critério de Similaridade .....	66
4.2.	DISCUSSÃO .....	70
<b>5.</b>	<b>AVALIAÇÃO DO DESCRITOR .....</b>	<b>71</b>
5.1.	TRATAMENTO DE RUÍDO .....	71
5.1.1.	Resultados experimentais .....	81
5.2.	ALGORITMO DE BUSCA DE PONTOS CORRESPONDENTES .....	82
5.2.1.	Algoritmo K-NN para identificar pontos característicos correspondentes .....	83
5.2.2.	Resultado experimental do algoritmo de pré-alinhamento .....	84
5.3.	DISCUSSÃO .....	87
<b>6.</b>	<b>ALINHAMENTO FINO .....</b>	<b>88</b>
6.1	METODOLOGIA .....	88
6.1.1.	Modelo de matriz de transformação.....	88
6.2.	ADAPTAÇÃO DO ALGORITMO ICP .....	90
6.2.1.	Medida do erro cometido no alinhamento aproximado .....	91
6.3.	RESULTADOS OBTIDOS .....	91
6.4.	AVALIAÇÃO DO MÉTODO DE ALINHAMENTO DE IMAGENS PROPOSTO .....	93
6.5.	ALINHAMENTO DE NUVENS DE PONTOS DO DIGITALIZADOR TRI_IDENT .....	95
6.6.	ALINHAMENTO DE NUVENS DE PONTOS DE UMA PÁ DE TURBINA HIDRELÉTRICA DANIFICADA .....	99
6.7.	DISCUSSÃO .....	102
<b>7.</b>	<b>CONCLUSÃO .....</b>	<b>106</b>
<b>8.</b>	<b>TRABALHOS FUTUROS .....</b>	<b>109</b>
<b>9.</b>	<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>110</b>
<b>10.</b>	<b>APÊNDICES .....</b>	<b>116</b>

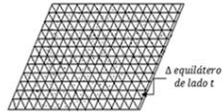
A.	DIZIMAÇÃO DE UMA MALHA .....	116
B.	DIGITALIZADOR TRI_IDENT .....	117
C.	DEFINIÇÕES .....	121

## LISTAS DE SÍMBOLOS, NOMENCLATURA E ABREVIACÕES.

$A_S$	Região de sobreposição;
$A_{I_1}$	Conjunto de pontos da imagem $I_1$ ;
$A_{I_2}$	Conjunto de pontos da imagem $I_2$ ;
$\alpha - shape$	Parâmetro que indica o nível de detalhes da representação volumétrica;
$C_{N_1}^N$	Explosão combinatorial, onde $N_1$ é o número de amostras de $I_1$ e $N$ é o número de pontos de correspondência;
$C(u)$	Função de uma curva paramétrica;
$H_u$	Vetor de dados (Sinal lido proveniente da nuvem de pontos);
$e_u$	Vetor de erro;
$V_u$	Vetor de dados (Sinal gerado pelo algoritmo adaptativo);
<i>GRACO</i>	Grupo de Automação e Controle;
$I$	Imagem de profundidade ;
$I_1$	Imagem de profundidade 1;
$I_2$	Imagem de profundidade 2;
$IT$	Malha Triangular;
<i>ICP</i>	<i>Iterative Closest Point</i> ;
$k$	Parâmetro de sensibilidade do ruído;
$k'$	Número total de pontos da curva $N$ ;
<i>LMS</i>	<i>Least Mean Square</i> ;
$n_{ref}$	Vetor Normal;
Nurbs	<i>Non Uniform Rational B-Spline</i> ;
<i>NLMS</i>	<i>Normal Least Mean Square</i> ;
<i>OpenGL</i>	Biblioteca Gráfica Aberta ( <i>Open Graphics Library</i> );
$p_i$	Ponto de uma amostra;

$(p_{i,j})$  Ponto nodal;  
 $q_i$  Ponto de uma amostra;  
 $R^2$  Espaço em duas dimensões;  
 $R^3$  Espaço em três dimensões;

$t$



Base de um triângulo equilátero utilizado na construção de uma malha estruturada.

TRI\_IDENT Digitalizador Laser 3D.

$u, v$  Pixels;

$M$  Matriz de transformação;

$\mu_{NLMS}$  Coeficiente NLMS do filtro adaptativo;

VISCAN 3D Digitalizador Laser 3D.

## LISTA DE TABELAS

	<b>Pág.</b>
Tabela 4.1. Volume de dados reduzidos.....	51
Tabela 4.2. Volume de dados reduzidos mapa de bordas.....	54
Tabela 4.3. Valores discretos através do código direcional de 4 estados.....	63
Tabela 4.4. Dados dos ângulos formados entre pontos característicos para formar uma assinatura.....	64
Tabela 4.5. Dados dos ângulos formados entre pontos característicos para formar uma assinatura - curva C(u).....	64
Tabela 4.6. Dados Organizados dos ângulos usados para formar uma assinatura - curva C(u).....	65
Tabela 4.7. Valores discretos através do código direcional de 4 estados.....	65
Tabela 4.8. Ângulos discretos fazendo uso do código direcional de 4 estados- assinatura completa.....	65
Tabela 4.9. Ângulos discretos fazendo uso do código direcional de 4 estados- assinatura reduzida.....	66
Tabela 4.10. Comparação técnica de descritores.....	66
Tabela 4.11. Informação da assinatura completa e reduzida do ponto característico da curva número 1.....	67
Tabela 4.12. Informação da assinatura completa e reduzida do ponto característico da curva número 2.....	67
Tabela 4.13. Valores discretos através do código direcional de 8 estados.....	69
Tabela 4.14. Informação da assinatura completa e reduzida fazendo uso do código direcional de 8 estados para curva número 1.....	69
Tabela 4.15. Informação da assinatura completa e reduzida fazendo uso do código direcional de 8 estados para curva número 2.....	69
Tabela 5.1. Tabela de comparação de resultados entre o algoritmo desenvolvido e demais técnicas.....	72
Tabela 5.2. Desempenho do descritor em diferentes escalas.....	76
Tabela 5.3. Desempenho do descritor em imagens com diferentes graus de perspectiva.....	79
Tabela 5.4. Obtenção de assinaturas completa e reduzida da imagem de profundidade – Cavalo.....	82
Tabela 5.5. Número de pontos correspondentes identificados - Imagem do cavalo.....	86
Tabela 6.1. Fontes de incerteza na medição – $I_{\text{registro}}$ .....	92

Tabela 6.2.	Fontes de incerteza na medição – objeto cavalo.....	93
Tabela 6.3.	Volume de dados reduzidos- crânio.....	97
Tabela 6.4.	Fontes de incerteza na medição – objeto crânio.....	99
Tabela 6.5.	Fontes de incerteza na medição – Pás de turbina hidrelétrica.....	102
Tabela 6.6.	Características principais do descritor proposto.....	103
Tabela 6.7.	Tabela comparativa dos principais trabalhos presentes na literatura com a nova proposta.....	104

## LISTA DE FIGURAS

	<b>Pág.</b>
Figura 2.1. Processo de aquisição de imagens de profundidade (Hardware).....	28
Figura 2.2. Versão de campo do <i>hardware</i> do sistema VISSCAN-3D.....	29
Figura 2.3. Desenho esquemático do Sistema VISSCAN-3D.....	29
Figura 2.4. Funcionamento do sensor de visão Fonte.....	29
Figura 2.5. Digitalizador laser VISSCAN-3D. ....	30
Figura 2.6. Diagrama do processo de atenuação do ruído para curvas.....	32
Figura 2.7. Atenuação de ruído usando diferentes critérios de desempenho.....	32
Figura 2.8. Organização da nuvem de pontos dentro de uma malha.....	34
Figura 2.9. Seleção de pontos nodais.....	35
Figura 2.10. Seleção de pontos utilizando o critério A.....	36
Figura 2.11. Seleção de ponto utilizando o critério C.....	36
Figura 2.12. Desenho de uma malha triangular 2D.....	37
Figura 2.13. Formação da malha triangular 3D construída em base de uma malha triangular 2D.....	37
Figura 2.14. Processo de reconstrução de superfícies através de modelos deformáveis.....	37
Figura 2.15. Apresenta um exemplo de diferentes configurações de orientação, posição e escala de duas imagens de profundidade.....	38
Figura 2.16. Determinação de zonas de correspondência através de descritores....	41
Figura 2.17. Etapa de busca de descritores.....	43
Figura 2.18. Configuração de imagens de profundidade encontradas em uma célula de trabalho.....	44
Figura 2.19. Reparação de turbinas hidrelétricas, realizada por uma equipe de soldadores.....	46
Figura 2.20. Identificação da zona danificada de uma pá de hidrelétrica.....	46
Figura 4.1. Etapas usadas no desenho do descritor proposto.....	49
Figura 4.2. Objeto cavalo de bronze.....	50
Figura 4.3. Imagens de profundidade do cavalo - Representação em malha.....	51
Figura 4.4. Borda de profundidade.....	53
Figura 4.5. Borda de orientação.....	53
Figura 4.6. Borda suave.....	53
Figura 4.7. Mapa de bordas.....	54
Figura 4.8. Histograma da imagem de profundidade <b>I1</b> - imagem.....	56
Figura 4.9. Histograma da imagem de profundidade <b>I2</b> - imagem.....	56
Figura 4.10. Refinamento da imagem segmentada- construção do mapa de contorno.....	57
Figura 4.11. Etapas usadas no desenho do descritor proposto- Etapa 5.....	58

Figura 4.12.	Código direcional de 8 estados.....	60
Figura 4.13.	Exemplo de código da cadeia (c.8) 7071075654.....	60
Figura 4.14.	Representação de dados <i>estado vs segmentos</i> .....	61
Figura 4.15.	Detecção de pontos característicos no gráfico <i>estado vs segmentos</i> ..	61
Figura 4.16.	Pontos característicos identificados sobre uma curva.....	62
Figura 4.17.	Ligação de pontos característicos entre segmentos.....	62
Figura 4.18.	Cálculo do ângulo de variação dos segmentos que conecta os pontos característicos.....	62
Figura 4.19.	Detecção de ponto característico semente.....	63
Figura 4.20.	Detecção de ponto característico semente no gráfico código de barras.....	63
Figura 4.21.	Processo de geração de assinatura de um ponto característico. Etapa: coleta de informação.....	64
Figura 4.22.	Gráfico da curva número 1.....	67
Figura 4.23.	Gráfico da curva número 2.....	67
Figura 4.24.	Comparação de assinaturas.....	68
Figura 5.1.	Oito exemplos de imagens usadas no teste.....	71
Figura 5.2.	Dados estatísticos da tabela 5.1.....	76
Figura 5.3.	Seleção do parâmetro de desempenho $\mu_{NLMS}$ .....	77
Figura 5.4.	Imagens de referência para avaliar o desempenho do descritor quando trabalha com imagens com diferentes graus de perspectiva ( $\mu_{NLMS} = 1.0$ ).....	78
Figura 5.5.	Gráfico ângulo de rotação vs número de pontos característicos correspondentes.....	80
Figura 5.6.	Etapas usadas no desenho do descritor proposto- Etapa 5.....	81
Figura 5.7.	Detecção de pontos do contorno da imagem de profundidade. Objeto cavalo.....	81
Figura 5.8.	Detecção de pontos do contorno da imagem de profundidade – Cavalo.....	82
Figura 5.9.	Exemplo de organização e quantificação de assinaturas.....	83
Figura 5.10.	Exemplo de dados reais onde se organizarão e quantificarão o número de assinaturas.....	84
Figura 5.11.	Ponto a classificar em uma imagem de profundidade.....	84
Figura 5.12.	Detecção do ponto cujo estado esteja representado em maior proporção que o ponto detectado da Fig.(6.10).....	85
Figura 5.13.	Identificação de pontos correspondentes usando algoritmo K-NN.....	86
Figura 5.14.	Eliminação de pontos correspondentes usando algoritmo K-NN.....	87
Figura 6.1.	Triângulos inscritos na imagem de profundidade para obter os coeficientes do vetor de transformação.....	90

Figura 6.2.	Imagem de profundidade $I_{\text{registro}}$ .....	92
Figura 6.3.	Imagens de profundidade dos repositórios.....	93
Figura 6.4.	Comportamento do algoritmo de alinhamento com duas imagens de profundidade.....	94
Figura 6.5.	Digitalizando um objeto (crânio) através do TRI_IDENT.....	95
Figura 6.6.	Metodologia usada no pré-alinhamento de imagens de profundidade.....	95
Figura 6.7.	Imagem de profundidade do crânio - Nuvem de pontos.....	96
Figura 6.8.	Imagens de profundidade do crânio - Representação em malha (Resolução da malha $t = 0.60 \text{ mm}$ ).....	96
Figura 6.9.	Mapa de bordas – crânio.....	97
Figura 6.10.	Refinamento da imagem segmentada- Construção do mapa de Contorno do objeto crânio.....	97
Figura 6.11.	Detecção das assinaturas dos pontos correspondentes - Imagem do crânio.....	98
Figura 6.12.	(a) apresenta o resultado de alinhamento fino utilizando ICP de par de imagens de profundidade $I_1$ e $I_2$ . $e_R = 0.35^0$ e $e_T=0.77$ .....	98
Figura 6.13.	Imagem de intensidade 2D – Pás de turbina.....	100
Figura 6.14.	Representação de imagens em pontos – Pás de turbina.....	100
Figura 6.15.	Imagem de profundidade representada através de entalhes paramétricos Nurbs. Pás de turbina. A Pá de turbina hidrelétrica está localizada numa célula de trabalho virtual (Perspectiva A).....	101
Figura 6.16.	Imagem de profundidade representada através de entalhes paramétricos Nurbs. Pás de turbina. A Pá de turbina hidrelétrica está Localizada numa célula de trabalho virtual(Perspectiva B).....	101

# 1. INTRODUÇÃO

Este trabalho está inserido em um projeto denominado “Desenvolvimento e Construção de Sistema Robotizado para Reparos de Falhas de Cavitação em Turbinas Hidráulicas” que tem como objetivo a construção de um robô capaz de detectar e reparar superfícies danificadas por efeitos de cavitação nas pás de turbinas hidráulicas. O desenvolvimento desse projeto possui três frentes de trabalho: uma na área de visão, uma na área de robótica e outra na área de soldagem. Áreas de pesquisa conduzidas de forma integrada por vários grupos pertencentes aos laboratórios do GRACO<sup>†</sup> da Universidade de Brasília.

As turbinas hidráulicas de grande porte das usinas de geração de energia elétrica apresentam erosão por cavitação e precisam ser restauradas pela deposição de material por soldagem. Os reparos são realizados no local e, na maioria das vezes, manualmente por uma equipe de soldadores. Esse tipo de operação apresenta uma série de problemas técnicos e econômicos, tais como: dificuldade de acesso aos locais, posições de soldagem desfavoráveis, trabalho intenso e demorado, trabalho de esmerilhamento, consumo excessivo de material de deposição e deterioração progressiva da forma geométrica das pás.

Os ganhos obtidos com uma operação robotizada por soldagem são muitos. No entanto, os robôs manipuladores convencionais não podem ser utilizados nesta tarefa em função do limitado espaço de trabalho existente no interior do rotor de uma turbina hidráulica.

O projeto que envolve esta tese de doutorado tem como objetivo ajudar a resolver o problema de reparação de turbinas hidroelétricas, que utilizam processos de soldagem robotizados e que são executados principalmente através de planejamentos de trajetória fornecida por um mapa de navegação capturado por um sistema de visão.

A proposta planejada da tese é de contribuir para o estado da arte na reconstrução de um espaço de trabalho definido por todos os pontos alcançáveis pela tocha de soldagem do manipulador robótico com pelo menos uma orientação. Isso será feito por meio do desenvolvimento de uma estratégia de exploração de ambientes desconhecidos que analisa, alinha e ajusta múltiplos mapas de profundidade, que por sua vez são capturados através de um sensor de visão montado num manipulador robótico. O

---

<sup>†</sup>GRACO Grupo de Automação e Controle em Processos de Fabricação

método proposto é baseado na decomposição do ambiente em células aproximadas para sua posterior unificação. De acordo com esse contexto, a construção de superfícies virtuais permitirá avaliar matematicamente a zona em estudo. Cada ponto descrito sobre o mapa servirá como parâmetro de entrada para encontrar a cinemática inversa do robô para o seu posterior movimento.

Como fonte primária de informação para o mapeamento 3D serão utilizados feixes de luz laser (Ginani, 2008) que proporcionarão informações mais detalhadas que as tecnologias em 2D. As desvantagens tecnológicas de sensoriamento 3D se caracterizam por serem lentas na aquisição e por terem um aumento significativo nos dados que precisam ser processados para eliminar os ruídos (IdroboPizo, 2009). Cada mapa deve estar relacionado com um sistema de referência único para seu posterior alinhamento com outros mapas, chamado de registro.

O paradigma clássico para estimar a transformação geométrica de similaridade que registra duas imagens de profundidade é a minimização do erro da distância entre um conjunto de pares de pontos correspondentes extraídos de ambas as imagens. Portanto, a tarefa principal no ato de registro é a determinação de pares de correspondências entre vistas. Estas podem estar transladadas, rotacionadas e/ou escalonadas. A solução desse problema torna-se um desafio, pois a correspondência entre as regiões de sobreposição, das quais se precisam extrair os pares de pontos correspondentes, é desconhecida. Besl e McKay em 1992, apresentaram o algoritmo ICP (*iterative closest point algorithm*), propondo que os pontos mais próximos entre as duas imagens sejam os pontos correspondentes. Para encontrar tais correspondências, o algoritmo necessita de uma transformação inicial ( $M$ ) que aproxime suficientemente bem ambas as imagens.

Assim sendo, surge a necessidade de uma aproximação inicial do registro, o que é conhecido como pré-alinhamento de imagens de profundidade.

A literatura apresenta algumas técnicas para resolver essa questão, as quais se diferenciam basicamente pela procedência dos pares de correspondências. Há duas abordagens: na primeira, as correspondências são extraídas a partir do conjunto completo de amostras originais; na segunda, as correspondências são obtidas a partir de um subconjunto de dados originais composto por amostras que possuem características especiais. Essas técnicas, no entanto, ainda apresentam certas limitações. No caso da primeira, o espaço de busca gerado é muito grande, o que torna a técnica ineficiente. No caso da segunda, alguma informação importante para as correspondências pode vir a ser descartada por restringir-se somente a um conjunto específico de dados. Essa restrição

faz com que estas técnicas sejam dependentes da geometria e não asseguram a extração de pares de correspondências para qualquer forma da superfície.

Neste trabalho propõe-se um algoritmo de registro que procura contornar essas limitações com base em duas inovações. Propõe-se que em vez de usar o conjunto completo de amostras de uma imagem de profundidade, será utilizada uma malha triangular simplificada por meio da técnica de modelos deformáveis (Chui *et al.*, 2008). Isso permite preservar as características globais da forma original da imagem e que os pares de correspondências sejam extraídos a partir de espaços reduzidos, compostos pelos pontos de controle da malha (vértices). Além disso, propõe-se uma metodologia que combina vários descritores gerando um descritor geral, que permite buscar as correspondências entre os espaços reduzidos das amostras. Diferentemente das propostas existentes, esta atual integra informações geométricas locais e globais das amostras, o que o leva a ser mais discriminante na busca. Durante o desenvolvimento da proposta da tese foram analisados novos procedimentos de registro ainda não explorados anteriormente.

O objetivo principal e a contribuição deste trabalho é o desenvolvimento de uma técnica de pré-alinhamento que identifique características geométricas de similaridade entre duas imagens de profundidade que permite diminuir um número significativo de falsas correspondências entre pontos, com alta taxa de precisão. A técnica de pré-alinhamento foi integrada com uma técnica de alinhamento fino, definindo de forma geral uma metodologia completa para registro e reconstrução de modelos tridimensionais de superfícies.

Os capítulos do presente trabalho foram organizados de acordo com o objetivo acima citado

**O capítulo 2** apresenta conceitos introdutórios, descreve o processo de digitalização de objetos, faz uso dos conceitos e ferramentas matemáticas existentes na teoria de superfícies, como os conceitos clássicos de geometria diferencial e topologia. Como também é apresentado o problema de pré-alinhamento e ajuste automático de mapas de profundidade e os desafios que se têm. **O capítulo 3** descreve o objetivo geral e os objetivos específicos da tese. **O capítulo 4** contém a proposta de solução do algoritmo de pré-alinhamento de imagens de profundidade usando o descritor proposto. **O capítulo 5** apresenta avaliação do descritor proposto. **O capítulo 6** apresenta o algoritmo utilizado para realizar um alinhamento fino entre imagens de profundidade fazendo uso do algoritmo ICP. **O capítulo 7** resume as principais conclusões deste

trabalho, destacando as contribuições e limitações. Em seguida, no **capítulo 8** apresentam-se algumas melhorias que podem ser contempladas em trabalhos futuros e o **capítulo 9** apresenta a lista das referências bibliográficas utilizadas para o desenvolvimento do trabalho.

## 2. CONCEITOS INTRODUTÓRIOS

Este capítulo aborda o processo de reconstrução de superfícies baseado em nuvem de pontos obtida a partir de um digitalizador óptico que está montado em um sistema robotizado de cinco graus de liberdade. Posteriormente, são descritas diferentes configurações de orientação, posição e escala de duas imagens de profundidade que compartilham zonas de sobreposição e precisam ser registradas para eliminar zonas oclusas durante o processo de captura, como também são descritas as dificuldades, alternativas e limitações que dão solução ao problema de registro.

### 2.1. SENSOR ÓPTICO LASER

Há no mercado vários dispositivos de aquisição de imagens de profundidade. Para o trabalho foi utilizado um digitalizador laser que é posicionado sobre um braço robótico (Fig. 2.1) de cinco graus de liberdade.

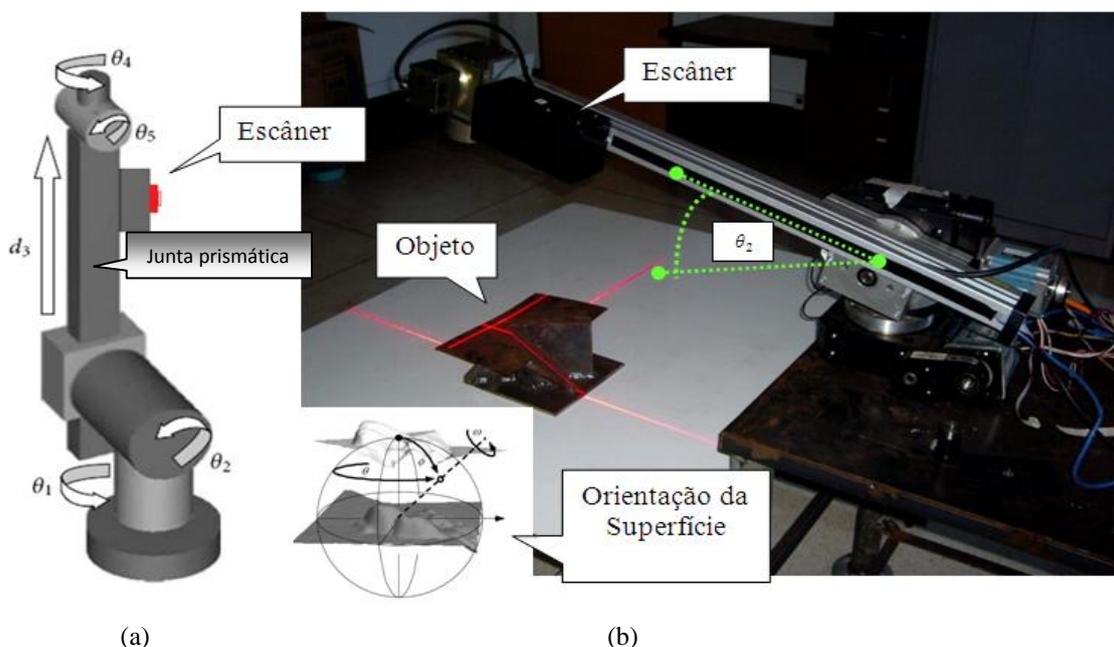


Fig. 2.1. Processo de aquisição de imagens de profundidade (Hardware).

O sistema digitalizador laser foi montado na junta prismática do robô (Fig. 2.1 (a)), e está formado por uma câmera de alta resolução e dois diodos laser (Fig.2.2), (Fig.2.3) e (Fig.2.4) (Idrobo-Pizo, 2009 e Ginani, 2008). Os diodos, em conjunto com um sistema eletromecânico, são responsáveis por projetar um plano de luz sobre o objeto. Através da câmera são capturadas as imagens e por meio de algoritmos de visão computacional são calculadas distorções geométricas da luz projetada na superfície. Conhecendo os

parâmetros intrínsecos da câmara é possível calcular as coordenadas 3D dos pontos da superfície, gerando como resultado uma imagem de profundidade.

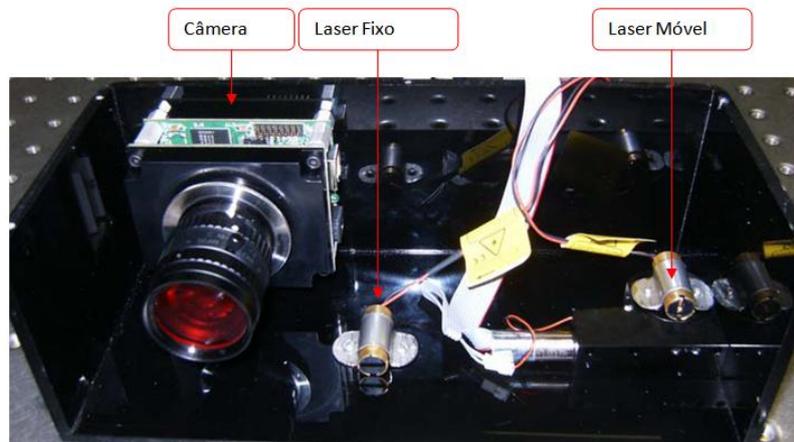


Fig. 2.2. Versão de campo do *hardware* do sistema VISSCAN-3D. Fonte: Ginani, 2008.

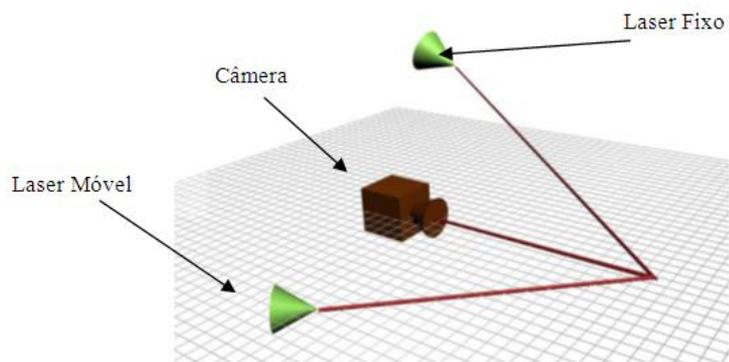


Fig. 2.3. Desenho esquemático do Sistema VISSCAN-3D. Fonte: Ginani, 2008.

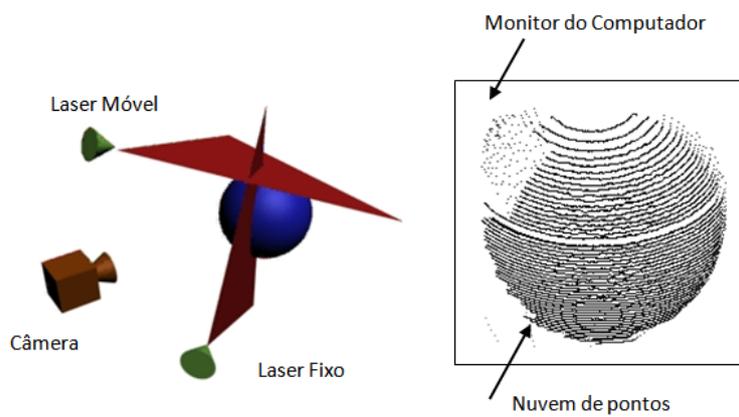
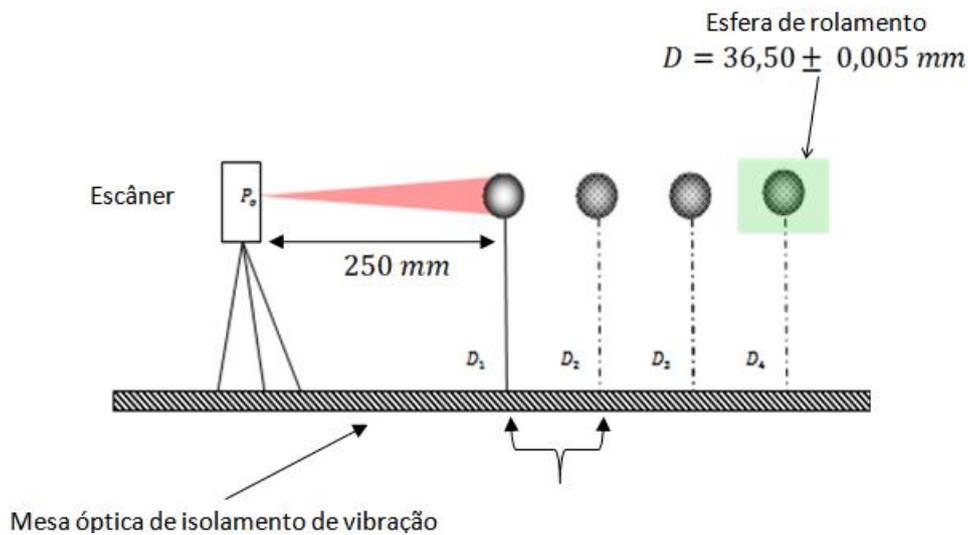
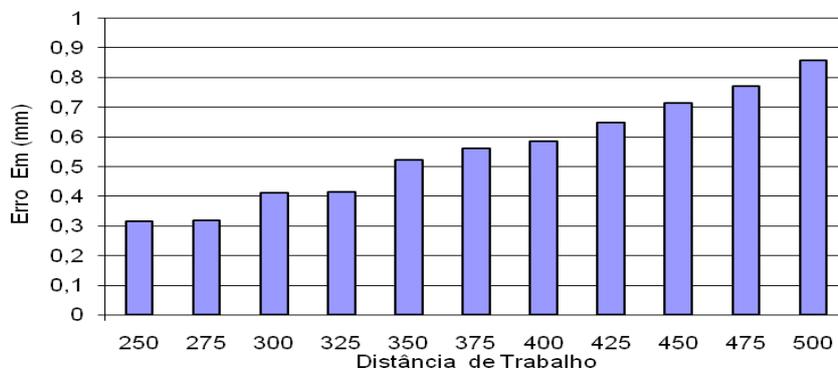


Fig. 2.4. Funcionamento do sensor de visão Fonte: Ginani, 2008.

A resolução do equipamento de digitalizador laser para diferentes distâncias é apresentada na figura (2.5). A resolução foi determinada em laboratório do GRACO<sup>‡</sup>, usando elementos padronizados como: uma mesa óptica de isolamento de vibração e uma esfera de rolamento de um gerador elétrico de ferro fundido de diâmetro ( $36,50 \pm 0,005$ ) mm. Maiores detalhes do experimento realizado estão descritos em Idrobo-Pizo (2009).



(a) Descrição do experimento



(b) Resolução do equipamento

Fig. 2.5. Digitalizador laser VISSCAN-3D.

Na figura (2.5) se destaca graficamente que o equipamento pode medir o diâmetro da esfera a diferentes distâncias com uma variação ( $\pm 0,9\text{ mm}$ ) para uma distância máxima  $250\text{ mm}$ .

<sup>‡</sup>GRACO Grupo de Automação e Controle em Processos de Fabricação

## 2.2. FILTRAGEM DA NUVEM DE PONTOS

No entanto, como em qualquer outro sistema de visão, a câmera e o ambiente geram ruído aleatório gaussiano (Gonzales e Woods, 2008). Para identificar e reduzir o ruído precisa-se de um processo de filtragem o qual permita que a amostra resultante seja mais adequada para trabalhar do que a nuvem de pontos original. Devido à incerteza associada à natureza dos dados, foram utilizadas técnicas adaptativas para atenuar ou até mesmo eliminar ruídos por meio de um critério de desempenho.

O formato de arquivo "*\*IMG.txt*" foi o padrão de organização da informação tridimensional criado e adotado para a representação das superfícies digitalizadas pelo sistema VISSCAN 3D. Esse arquivo armazena o resultado final do processo de digitalização contendo todas as informações sobre a nuvem de pontos obtida.

O arquivo "*\*IMG.txt*", é do tipo texto e apresenta as informações de coordenadas em unidade S.I. (mm). Este formato proporciona uma arquitetura de organização baseada em blocos ou linhas digitalizadas.

Uma vez conhecendo todas as informações do formato em que a nuvem de pontos se encontra armazenada, o passo seguinte consiste em realizar a atenuação do ruído através da filtragem dos dados em toda a superfície geométrica  $(x, y, z)$  ou parte dela, dependendo da aplicação que seja utilizada.

A linha da nuvem de pontos ( $\mathbf{C}_u$ ) pode ser modelada como uma sequência ordenada de  $\mathbf{u}_n$  segmentos de reta que conectam dois pontos e pode ser representada como  $\mathbf{C}_u = \mathbf{H}_u \mathbf{u}_n + \mathbf{v}_u$ , em que  $\mathbf{H}_u$  é o modelo de observação que transforma o espaço de estados reais no espaço de observações e  $\mathbf{v}_u$  é o ruído da observação, suposto um ruído branco gaussiano com média zero e matriz de variância  $\mathbf{R}_u^{\S}$ ,  $\mathbf{v}_u \sim N(0, \mathbf{R}_u)$ .

A figura (2.6) apresenta o diagrama do processo de atenuação de ruído. O processo envelopa o sinal desejado da saída do filtro  $\mathbf{G}_u = \mathbf{V}_u \mathbf{u}_n$  e a estimação do erro mediante a comparação do sinal desejado e o sinal de entrada  $\mathbf{e}_u = \mathbf{C}_u - \mathbf{G}_u = (\mathbf{H}_u - \mathbf{V}_u) \mathbf{u}_n + \mathbf{v}_u$ . Um caso ideal de filtragem do ruído seria obter  $\mathbf{H}_u = \mathbf{V}_u$ , conseqüentemente,  $\mathbf{e}_u = \mathbf{v}_u$ . O ruído seria, assim, completamente identificado e eliminado. No entanto a aproximação de  $\mathbf{V}_u$  para  $\mathbf{H}_u$  por um filtro de comprimento e precisão finita impede que o ruído seja perfeitamente modelado.

---

<sup>§</sup>  $\mathbf{R}_u$ , a covariância do ruído da observação.

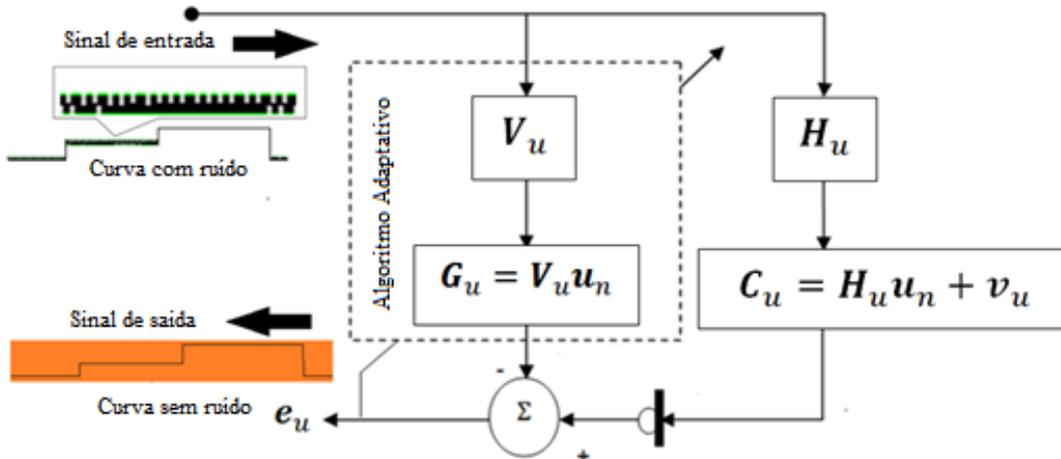


Fig. 2.6. Diagrama do processo de atenuação do ruído para curvas.

O operador  $V_u$  é obtido de forma iterativa pelo algoritmo NLMS, que é representado através da seguinte expressão:

$$V_u = V_{u-1} + \frac{\mu_{NLMS} e_u u_n}{u_n^T u_n} \quad (2.1)$$

em que  $\mu_{NLMS}$  é o valor do parâmetro de desempenho e assume valores entre [0,1].

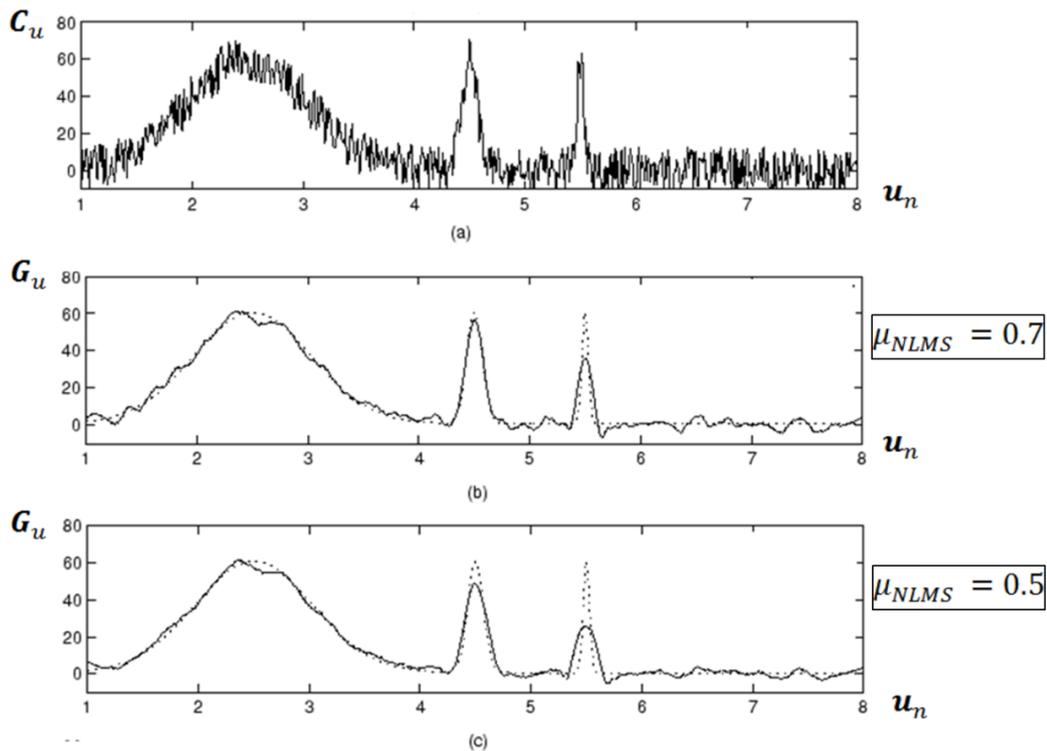


Fig.2.7. Atenuação de ruído usando diferentes critérios de desempenho. A linha pontilhada indica os pontos originais antes de aplicar o parâmetro desempenho sobre curva  $C_u$ .

A figura (2.7.a) apresenta o sinal de entrada para o filtro NLMS. As figuras (2.7.b) e (2.7.c) apresentam o sinal da saída do filtro NLMS para diferentes valores do parâmetro de desempenho. À medida que é diminuído o valor de  $\mu_{NLMS}$  a curva  $G_u$  fica mais suave em comparação da curva  $C_u$ .

### 2.3. FORMATO DE NUVEM DE PONTOS

Definir a qualidade de uma representação tridimensional do objeto é uma tarefa complexa quando não são conhecidas as relações de conectividade entre os pontos que compõem a amostra. Diversas técnicas surgiram para resolver o problema de conectividade, desde conceitos de geometria computacional até modelos baseados em equações diferenciais parciais (E.D.P.). Como guia de estudo dessas técnicas é necessário algum tipo de classificação.

No trabalho de Idrobo-Pizo (2009), é apresentada a classificação composta por cinco grupos:

- Métodos de Decomposição Espacial;
- Métodos Incrementais;
- Métodos da Família *Crust*;
- Métodos Implícitos;
- Métodos Baseados em Modelos Deformáveis.

Todas essas classificações baseiam-se nas características da forma em que se pode organizar a nuvem de pontos.

Para este trabalho, foi escolhido o método de modelos deformáveis porque apresenta uma poderosa metodologia que permite organizar uma nuvem de pontos em uma malha estruturada, através de um número reduzido de passos.

No artigo de Chui *et al.* (2008) descreve-se o método para organizar amostras por meio da deformação que experimenta uma malha triangular quando a nuvem de pontos é nela projetada.

O algoritmo está dividido em três etapas e cada etapa, por sua vez, está subdividida em várias subetapas:

#### **Etapa 1. Projeção da nuvem de pontos sobre a malha**

- Projeta-se uma nuvem de pontos de  $R^3$  para  $R^2$  sobre o plano  $\sigma$  (Fig. 2.8(a) e Fig. 2.8(b)).

- Ajusta-se a nuvem de pontos dentro de um paralelogramo de ângulo de  $60^\circ$  (Fig. 2.8(c)). Por meio deste polígono garante-se que todos os pontos da amostra sejam analisados em todos os passos posteriores do algoritmo e para que todos os triângulos da malha sejam iguais (triângulos equiláteros).
- Divide-se o polígono em linhas horizontais e verticais separadas por uma distância ( $t$ ). Esse valor influencia a resolução da reconstrução tridimensional da superfície, como pode ser observado nas Fig. 2.8(d) e Fig. 2.8(e).
- Projetam-se linhas diagonais da esquerda à direita do polígono, formando triângulos equiláteros (Fig. 2.8(f)).

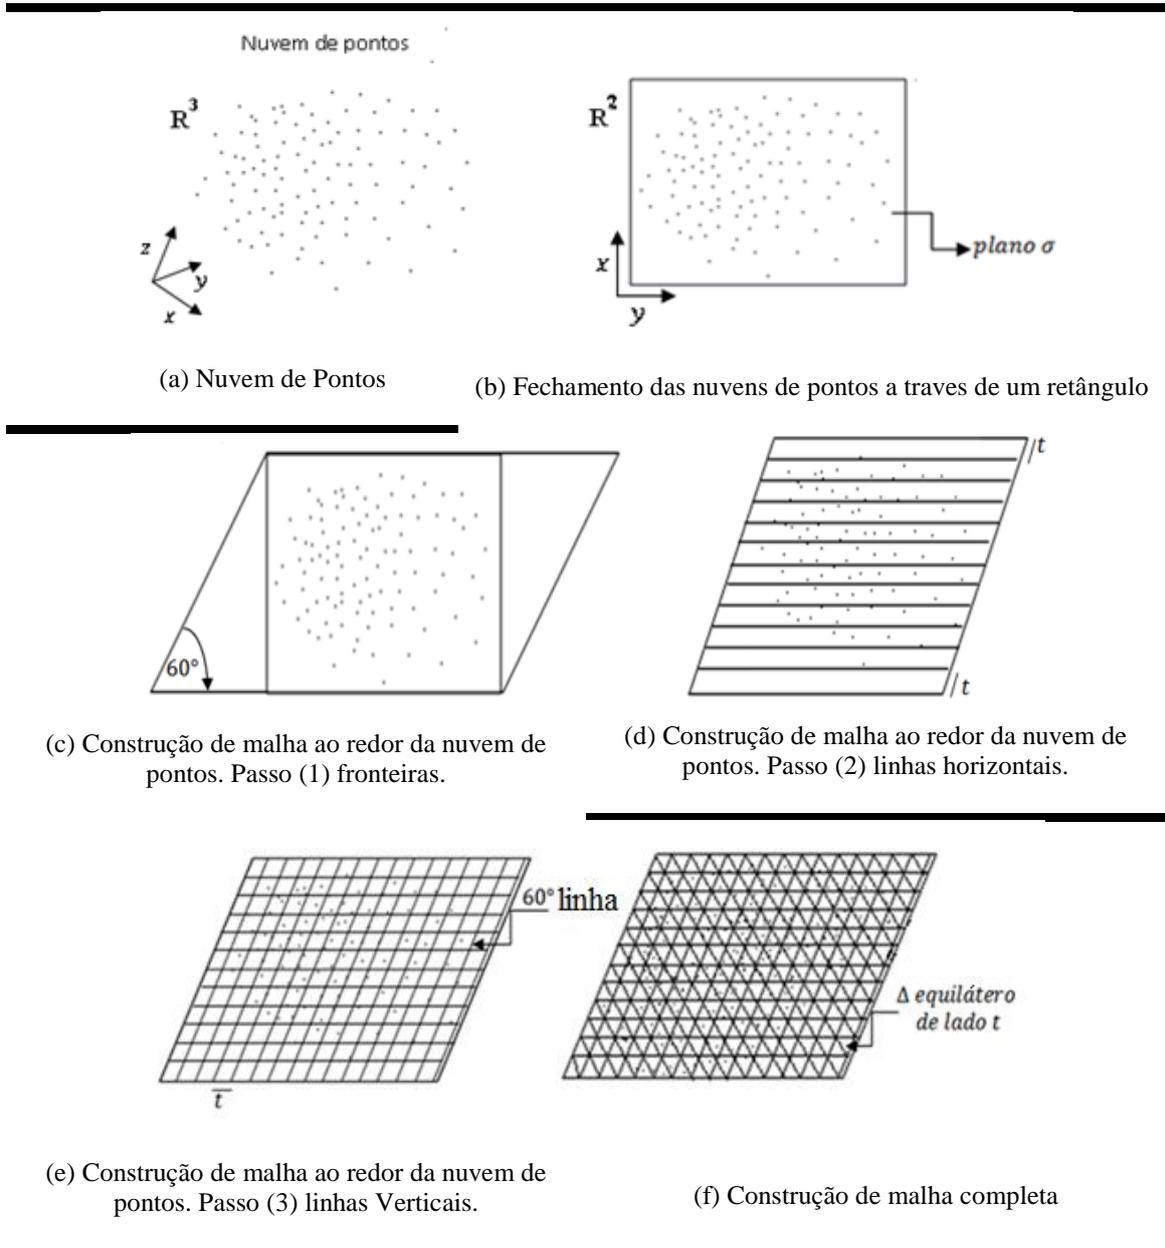


Fig. 2.8. Organização da nuvem de pontos dentro de uma malha.

## Etapa 2. Novo posicionamento de pontos nodais

O reposicionamento do ponto nodal é há essência um processo de filtragem. Em cada nó da malha (também chamado de ponto nodal) desenha-se um círculo do tamanho suficiente para ligar os pontos nodais contíguos. Isso é feito para selecionar um só ponto entre muitos que se encontram dentro da área fechada por círculo. O ponto escolhido é aquele que está mais próximo do nó da malha inscrita no círculo correspondente (Fig. 2.9). O procedimento é repetido para os outros nós e pontos. Aqueles que não tenham sido selecionados serão apagados.

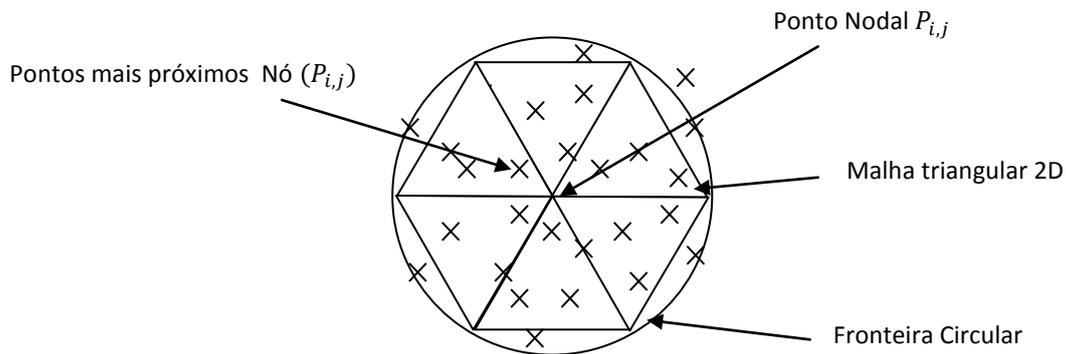


Fig. 2.9. Seleção de pontos nodais.

Por exemplo, na figura. (2.9), o ponto mais próximo projetado será considerado como a nova posição para o ponto nodal ( $p_{i,j}$ ). No entanto se houver dois ou mais pontos que satisfaçam distâncias euclidianas mais próximas, deverão ser estabelecidos os seguintes critérios:

**Critério A.** Se dois ou mais pontos projetados são iguais em distância euclidiana para ( $p_{i,j}$ ), mas estão localizados em diferentes triângulos, o ponto projetado na parte superior (ou seja, maior  $y$ ) será o escolhido.

Por exemplo, na figura (2.10), cinco pontos projetados estão em igual distância euclidiana do ponto nodal ( $p_{i,j}$ ). Os pontos que se encontram na parte superior do ponto nodal serão selecionados. A escolha da nova posição do ponto nodal será justificada utilizando-se o Critério B.

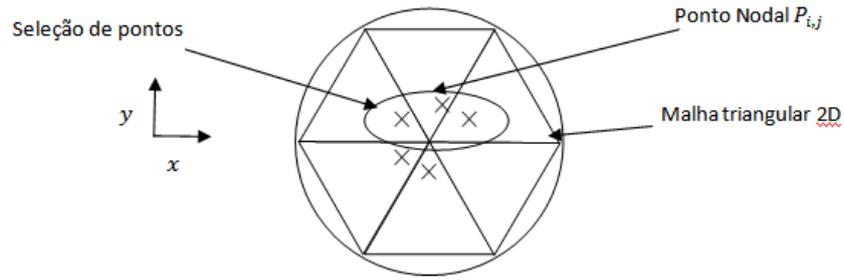


Fig. 2.10. Seleção de pontos utilizando o critério A.

**Critério B.** Se dois ou mais pontos projetados são iguais em distância euclidiana (Fig. 2.10), mas em vários triângulos diferentes, o ponto projetado do meio triângulo é escolhido como a nova posição do ponto nodal ( $p_{i,j}$ ).

**Critério C.** Se dois ou mais pontos projetados são iguais em distância euclidiana e no mesmo triângulo, o ponto projetado com maior valor ( $x$ ) será escolhido (Fig. 2.11).

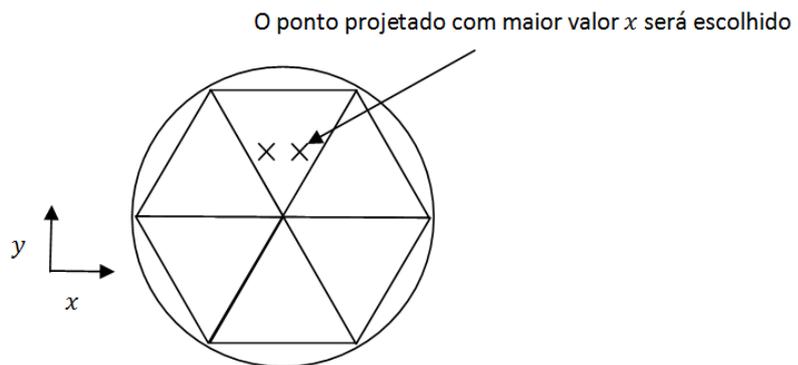


Fig. 2.11. Seleção de ponto utilizando o critério C.

### **Etapa 3. Construção da malha triangular 3D a partir da malha triangular 2D**

A malha triangular 3D pode ser reconstruída a partir do processo de deslocamento dos nós da malha 2D (Fig. 2.12) e (Fig. 2.13) e dos valores de profundidade de cada ponto nodal que foi alterado para ponto selecionado: pelo critério A, critério B ou critério C.

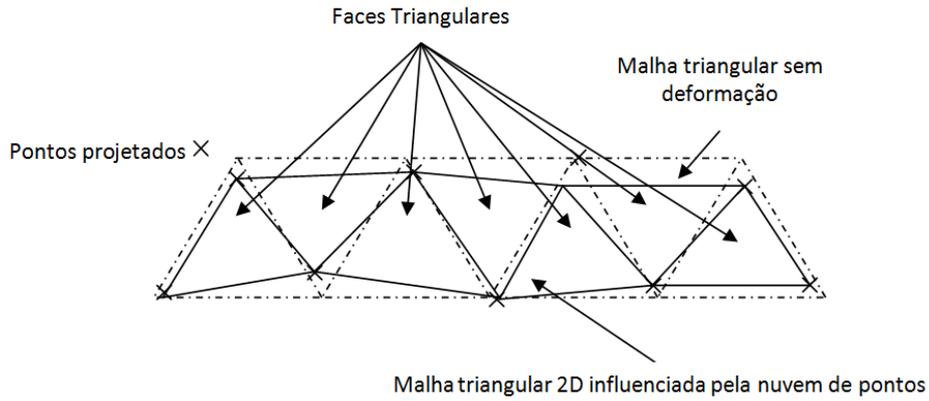


Fig. 2.12. Desenho de uma malha triangular 2D.

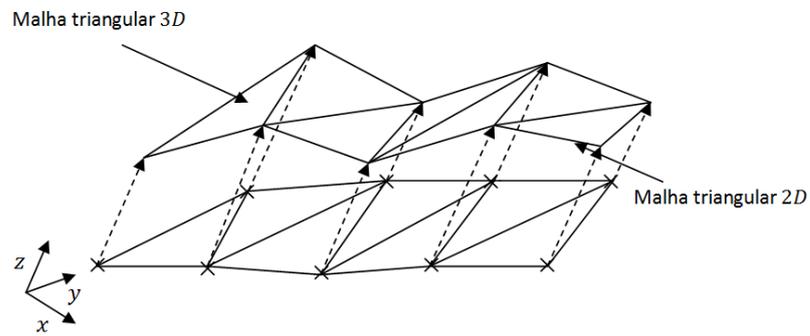


Fig. 2.13. Formação da malha triangular 3D construída em base de uma malha triangular 2D.

A figura (2.14) ilustra o processo de reconstrução de superfícies através de métodos baseados em modelos deformáveis, proposto por Chui *et al.* (2008) e testado em objetos livres em Idrobo-Pizo, 2009.

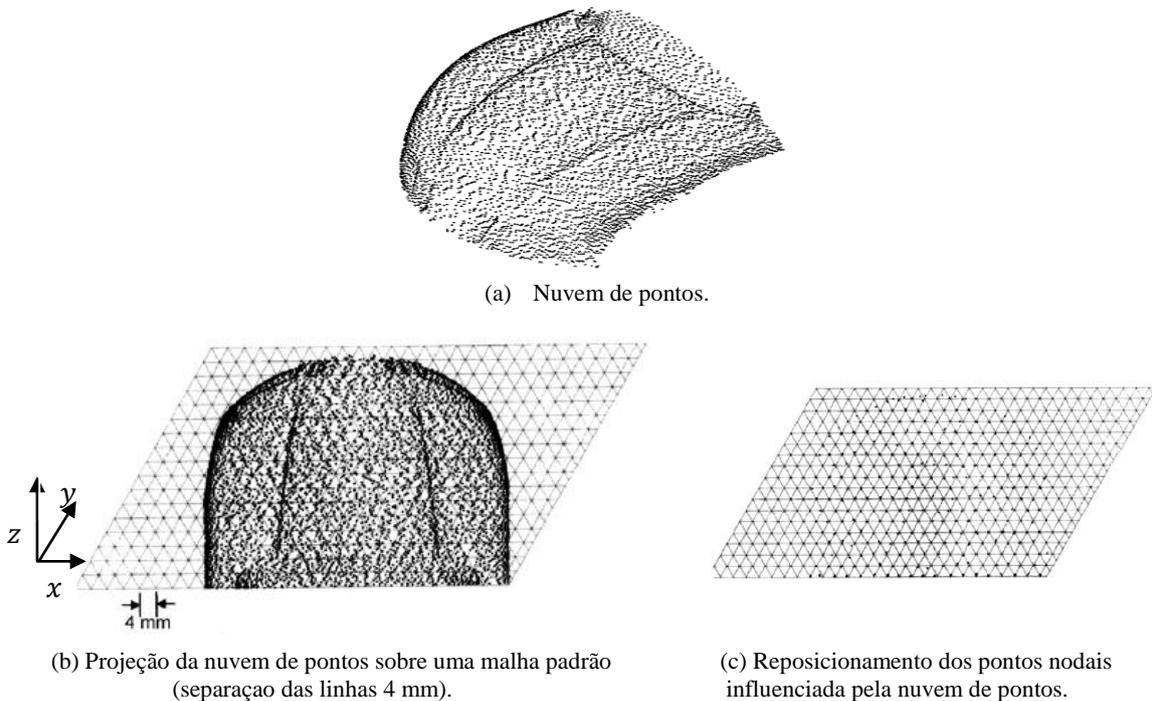
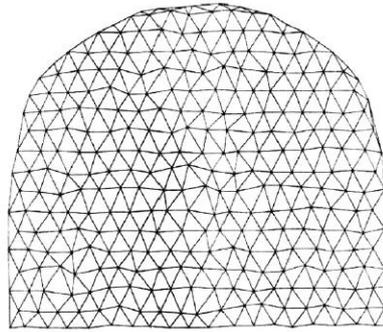
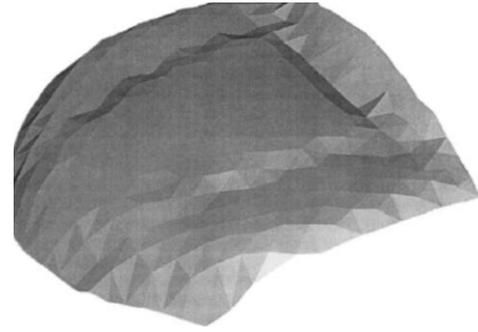


Fig. 2.14. Processo de reconstrução de superfícies através de modelos deformáveis.

Fonte: Chui *et al.*, 2008.



(d) Malha 2D triangular.



(e) Malha 3D triangular.

Fig. 2.14. Processo de reconstrução de superfícies através de modelos deformáveis.  
Fonte: Chui *et al.*, 2008.

## 2.4. REGISTRO

Uma única imagem de profundidade não é suficiente para modelar completamente um objeto de forma livre em razão das auto-oclusões. Assim sendo, múltiplas imagens devem ser adquiridas para cobrir inteiramente a superfície do objeto. Imagens capturadas podem ter em comum uma região geométrica chamada de “região de sobreposição”. Segundo (Shahar and Sagi, 2008 e Sappa, 1999), é desejável que o número de vistas necessárias para capturar a geometria completa seja mínimo para aliviar a complexidade da sua integração.

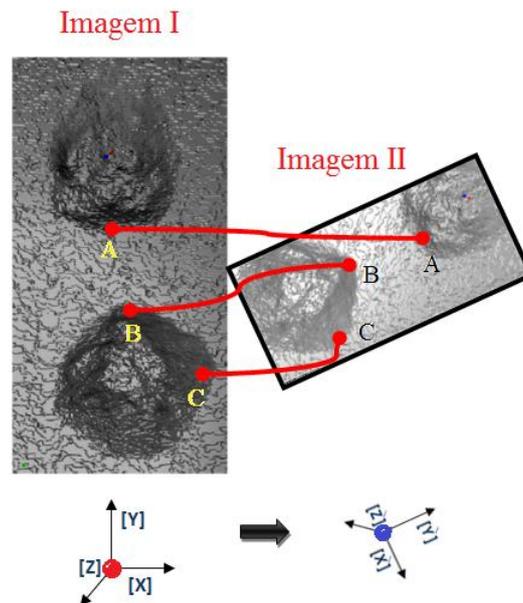


Fig. 2.15. Apresenta um exemplo de diferentes configurações de orientação, posição e escala de duas imagens de profundidade. Os pontos A,B,C são possíveis zonas correspondentes ou zonas de sobreposição entre as imagens.

Uma vez que cada imagem se encontra no seu próprio sistema local de coordenadas, para representar um único modelo 3D a partir delas, é preciso que sejam colocadas em um sistema de referência comum. Nesta fase distinguem-se duas etapas: **pré-alinhamento e alinhamento fino**. Na primeira, uma aproximação inicial do registro é estimada. Na segunda, iterações são aplicadas sobre ela para que os erros de alinhamento sejam minimizados.

**I. Pré-alinhamento:** Esta etapa consiste em duas fases: correspondência e posicionamento. Na primeira, procura-se por amostras nas duas imagens que ocupem a mesma posição no espaço do objeto. Essas amostras são conhecidas como pontos característicos correspondentes. A figura (2.15) apresenta duas vistas de imagem de profundidade (I e II). Observa-se que três pares de correspondências são marcados nas vistas. Na segunda fase (posicionamento), necessita-se de uma transformação rígida ( $\mathbf{M}$ ) que alinhe ambas as imagens sob certo erro. A matriz  $\mathbf{M}$  é composta por uma matriz de rotação,  $\mathbf{R}$ , um vetor-translação,  $\mathbf{T}$ , e  $\mathbf{S}$ , um valor que indica a mudança de escala que permite minimizar a distância quadrática entre as correspondências ( $p_i$ ) e ( $q_j$ ), onde  $p_i$  e  $q_j$  são os pontos correspondentes das imagens de profundidade I e II respectivamente. Um *conjunto mínimo de três pontos* correspondentes não colineares entre as duas vistas (incluindo seu baricentro) é suficiente para determinar o  $\mathbf{R}$ ,  $\mathbf{T}$  e  $\mathbf{S}$ , embora muitas vezes um número  $N > 3$  pontos seja usado (Aiger et al., 2008). A operação que minimiza os erros de correspondência é:

$$\lim_{min \rightarrow 0} D_{min} = \frac{1}{N} \sum_{i=0}^N \|\mathbf{S}(\mathbf{R}p_i + \mathbf{T}) - q_i\|^2 \quad (2.2)$$

Neste trabalho denominam-se de  $\mathbf{I}_1$  e  $\mathbf{I}_2$  a primeira e segunda imagem de profundidade, respectivamente.  $\mathbf{I}_1$  será a imagem a ser transformada para as coordenadas da imagem  $\mathbf{I}_2$ , após o pré-alinhamento. Denota-se o conjunto de amostras de  $\mathbf{I}_1$  como  $A_1 = A_{I_1} \cup A_{S_1}$ , e o conjunto de amostras de  $\mathbf{I}_2$  como  $A_2 = A_{I_2} \cup A_{S_2}$ , onde os subconjuntos de  $n_0$  pontos pertencentes à região de sobreposição de  $A_1$  e  $A_2$  são denotados por  $A_{S_1}$  e  $A_{S_2}$ , isto é,  $A_{S_1} = \{p_i = (x_i, y_i, z_i), i = 1, 2, 3, \dots, n_0\}$  e  $A_{S_2} = \{S(Rp_i + t), i = 1, 2, 3, \dots, n_0\}$ .

**II. Alinhamento fino:** consiste em um ajuste fino da matriz  $\mathbf{M}$  de pré-alinhamento, reduzindo seus erros. O método tradicional de registro fino é o algoritmo “Ponto mais

próximo por iteração” (ICP - *Iterative Closest Point*), (Besl e McKay, 1992). Esse método precisa, para sua convergência, de uma boa transformação inicial (ou seja, razoavelmente próxima da solução), a qual é tipicamente a transformação obtida no pré-alinhamento. Com essa transformação inicial, estabelecem-se pares de pontos correspondentes associando-se as amostras de  $I_1$  com suas amostras mais próximas na imagem  $I_2$ , a partir da qual uma nova transformação rígida  $M$  é calculada. Espera-se com este algoritmo que se minimize ainda mais a distância ao quadrado entre os pares correspondentes. Após isso, as amostras de  $I_1$  são transformadas pela nova matriz  $M$ . O processo é repetido para continuar ajustando os elementos da transformação. Isso é realizado até que a distância entre os pontos correspondentes seja menor ou igual a um limiar pré-definido.

De acordo com vários autores consultados Bariya *et al.*, 2012, Collet, 2009, Osaimi *et al.*, 2009, Brown e Lowe, 2007, Gomes, 2011, Wendel, 2011, Wu *et al.*, 2008, a fase de alinhamento fino é um problema resolvido, muito diferente da etapa de pré-alinhamento, cujo problema é o desconhecimento da correspondência entre as regiões de sobreposição;

#### 2.4.1. Definição do problema

O problema do pré-alinhamento pode ser dividido em dois subproblemas: o problema de correspondência, o qual consiste na identificação de um conjunto de  $N$  pares de pontos correspondentes  $(p_i, q_i)$ , em que  $p_i$  é ponto da imagem  $I_1$  e  $q_i$  é ponto da imagem  $I_2$ ; e o problema de posicionamento que consiste na obtenção da transformação rígida  $M$  que alinha ambas as imagens. A Matriz  $M$  identificada pode ser validada fazendo uso do ajuste de mínimos quadrados que minimiza os erros entre os  $N$  pares de correspondências.

Para entender a dificuldade inerente ao problema de correspondência, é preciso desmembrá-lo em duas sub-etapas:

Sub-Etapa 1. A escolha dos  $N$  pontos  $p_i$  em  $I_1$  (ou determinação do descritor-referência  $D_1$ ) (Fig. 2.16).

---

\*\* Um descritor de imagem  $D_i$  pode ser definido como uma função que extrai um vetor de características  $v$  de  $n$  dimensões. Em que  $n$  é o número de características utilizadas para descrever a imagem em questão.

Sub-Etapa 2. A busca em  $I_2$  dos  $N$  pontos correspondentes  $q_i$  para os  $p_i$  (busca do descritor-alvo  $D_2$ ) (Fig. 2.16).

Para garantir pares válidos de pontos correspondentes (Fig. 2.16) devem-se escolher os  $N$  pontos  $p_i$  dentro da região de sobreposição  $A_{S1}$ . De fato, se a escolha estiver fora da região de sobreposição, não será obtida uma matriz  $M$  correta, uma vez que os pontos estariam em uma região não comum a ambas as imagens.

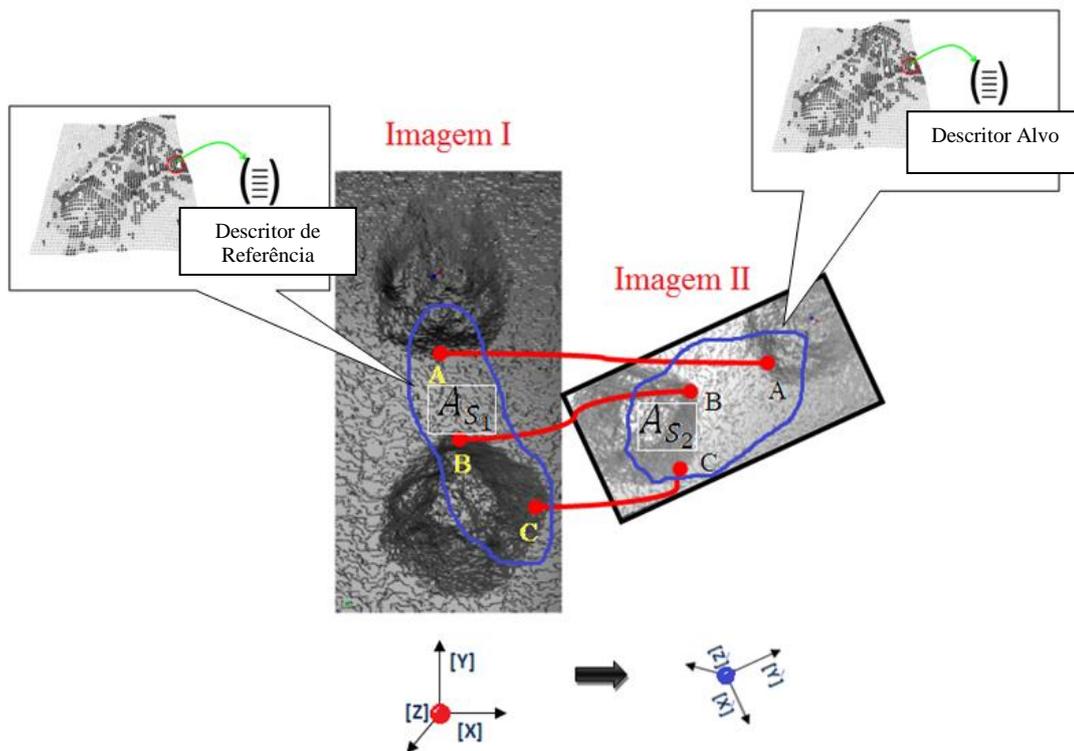


Fig. 2.16. Determinação de zonas de correspondência através de descritores.

Portanto, essa etapa torna-se um desafio: *como escolher pontos de interesse dentro da região de sobreposição, quando tal região é completamente desconhecida?* Uma solução seria considerar todas as possíveis combinações ( $C_{N_1}^N$ ), onde  $N_1$  é o número de amostras de  $I_1$  e  $N$  é o número de pontos de correspondência.

No entanto, a óbvia limitação desta opção é a ineficiência. A literatura consultada apresenta duas alternativas de solução:

- A redução do espaço de escolha, limitando-o ao uso de amostras com características especiais ou feições (Wiemann, 2010, Kovacs, 2009);
- A escolha aleatória (Serrano, 2011), (Lilles, 2009).

Por um lado, apesar de a redução ser considerável, o que resulta a favor do quesito “eficiência”, as amostras com características especiais podem estar concentradas fora da região de sobreposição ou, simplesmente, dependendo da geometria particular da superfície, podem ser raras, ou, ainda, podem não existir, dificultando e até impedindo a extração dos  $N$  pares de correspondências. Por outro lado, a maior dificuldade na escolha aleatória é a determinação do número de tentativas suficientes para escolher os  $p_i$ . De fato, é difícil determinar o número certo a garantir que os  $p_i$  estejam contidos na região de sobreposição. Novamente, a extração de  $N$  pares de correspondências poderá não ser garantida.

Quanto à segunda etapa, encontrar os  $q_i$  correspondentes para os  $p_i$  leva a considerar um problema de busca. Enquanto o problema anterior limitou-se apenas à escolha dos  $p_i$ , agora tem-se em mãos um problema de busca com dois consequentes sub-problemas: *onde se busca?*, referindo-se ao espaço de busca, e *como se busca?*, referindo-se ao procedimento de busca.

A alternativa mais trivial, e também a menos eficiente para o espaço de busca, é considerar o conjunto de todas as possíveis combinações  $C_{N_2}^N$  onde  $N_2$  é o número de amostras de  $I_2$ . Essa é a denominada busca exaustiva. A literatura apresenta como uma alternativa para ganho de eficiência, reduzir o espaço de busca, limitando-o ao uso de ( $S \ll N_2$ ) amostras com características especiais. Assim, um espaço menor de  $C_{S \ll N_2}^N$  combinações é considerado.

Quanto ao procedimento de busca, existe um consenso na literatura para estabelecer correspondências pela identificação de similaridade geométrica entre o descritor-referência e os descritores-alvo no espaço de busca de  $I_2$ . Os descritores devem ser caracterizados por propriedades geométricas invariantes a transformações rígidas, tais como, **ângulos, curvaturas e/ou distâncias** chamados de atributos topológicos. Essas características são também conhecidas como propriedades intrínsecas da superfície, pois são independentes das posições e orientações dos descritores (Dionisio, 2005). Portanto, os potenciais candidatos para descritores-alvo são aqueles que possuem métricas invariantes de similaridade, parecidas com as métricas do descritor-referência. É fortemente desejável que os descritores possuam métricas discriminantes e assim, possam reduzir a ambiguidade no processo de busca. Um descritor com baixa discriminância resulta em múltiplas correspondências ambíguas.

Ainda em relação aos descritores discriminantes, o processo de comparação pode ser afetado por variações causadas por ruído ou distorções próprias do processo de aquisição. Isso pode fazer com que as amostras ou feições, pertencentes à região de sobreposição, não se correspondam exatamente. Portanto, o procedimento de busca de correspondências deve considerar certa tolerância, o que aumenta ainda mais o número de candidatos.. O desafio é, então, um esquema de busca que seja capaz de manejar variações pequenas nos pares de pontos correspondentes na região de sobreposição, mantendo ainda a capacidade discriminante do descritor.

Mesmo com um descritor discriminante, a etapa de busca de um descritor-alvo similar a um descritor-referência conduz a uma relação (1:  $m$ ) (onde  $m$  é um número inteiro positivo), fornecendo correspondências incorretas que levam à estimativa de transformações  $M$  falsas positivas (Fig.2.17). Então, um procedimento de filtragem se faz necessário para eliminar ( $m - 1$ ) transformações e ficar com uma única  $M$ .

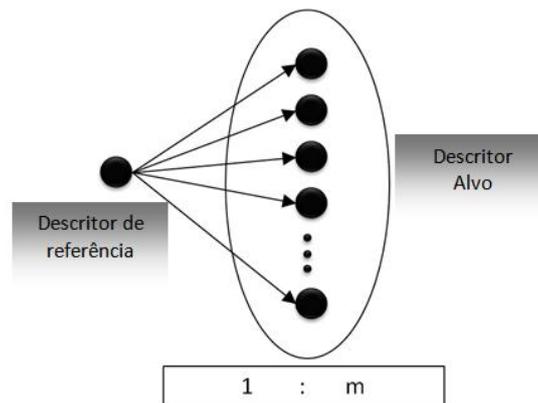


Fig. 2.17. Etapa de busca de descritores.

Para isso, as transformações candidatas devem passar por uma avaliação global para eliminar as falsas positivas através do algoritmo ICP. Usualmente essa avaliação consiste em contar o número de ajustes, ou seja, o número de amostras em  $A_1$  transformadas por  $M_i$  que têm distância até seu ponto mais próximo em  $A_2$  abaixo de um limiar pré-estabelecido. A  $M_i$  que possui o maior número de amostras ajustadas deverá ser a escolhida, resultando em uma único  $M$  que resolve o subproblema de posicionamento. Especial cuidado deve ser tido para que a transformação  $M$  que fornece a solução desejada não seja descartada neste processo.

Para evitar isso, a solução mais fácil, porém não a mais eficiente, consiste em fazer com que todas as amostras de  $A_1$  e todas as transformações candidatas  $M_i$  participem do processo de avaliação.

À luz das considerações sobre os problemas do pré-alinhamento podem-se vislumbrar dois requisitos: **existência e eficiência**. Existência é referente a assegurar que sempre se consiga extrair  $N$  pares de correspondências. Eficiência consiste na redução dos dados processados e da complexidade das operações realizadas.

#### 2.4.2. Imagens de profundidade usadas no processo de registro

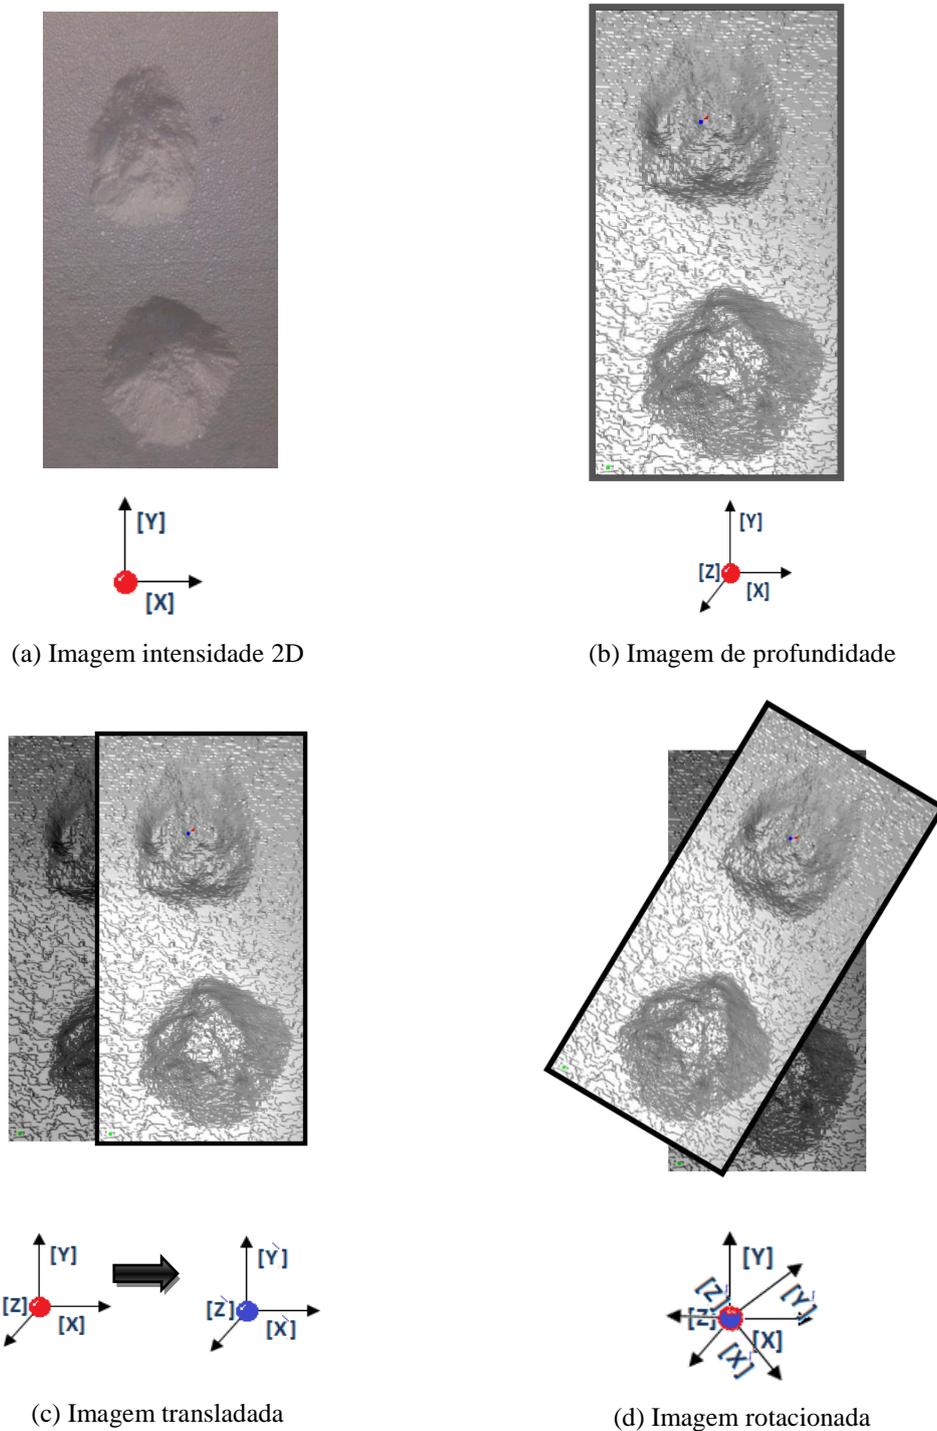
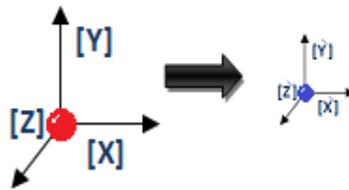
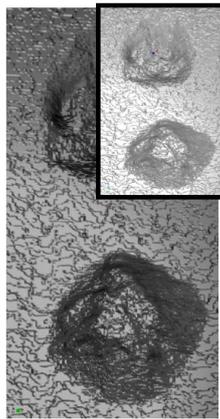


Fig.2.18. Configuração de imagens de profundidade encontradas em uma célula de trabalho.



(e) Imagem escalonada e trasladada

Fig.2.18. Configuração de imagens de profundidade encontradas em uma célula de trabalho.

Na figura (2.18), apresenta um exemplo de diferentes configurações de orientação, posição e escala de duas imagens de profundidade que compartilham zonas de sobreposição e precisam ser registradas para eliminar zonas oclusas durante o processo de captura usando o sensor VISSCAN-3D.

### 2.4.3. Hipótese para solucionar o problema de pré-alinhamento de imagens de profundidade

O sistema visual humano consegue fazer registro de objetos através da essência da sua forma. Adicionalmente, Belongie e Malik (2002) afirmam que um objeto pode ser modelado como um possível infinito conjunto de pontos, mas sua forma é essencialmente capturada por um subconjunto finito dos seus pontos. Portanto, em vez de um conjunto de dados denso, pode-se usar um conjunto esparsos de dados que aproxime a forma representada pelos dados originais. Assim, a hipótese deste trabalho é que, para realizar um pré-alinhamento, é suficiente considerar uma representação a qual, com poucas amostras, consiga exprimir a essência da forma geométrica pertencente à superfície do objeto. As superfícies alvo são superfícies de grande porte (Fig.2.19) em que a variação topográfica da mesma só existe nas zonas danificadas.



Fig. 2.19. Reparação de turbinas hidrelétricas, realizada por uma equipe de soldadores.

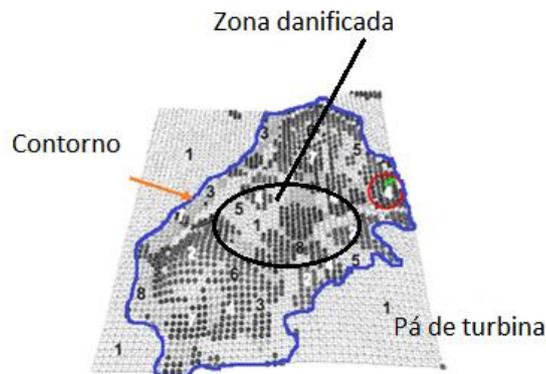


Fig.2.20. Identificação da zona danificada de uma pá de hidrelétrica.

A fronteira entre as zonas danificadas e não danificadas origina a visualização de curvas de contornos que podem ser usadas como ponto de partida no pré-alinhamento das imagens de profundidade (Fig.2.20). Extraíndo o contorno ou parte dele podem-se extrair só os pontos que indiquem a variação de curvatura, os demais pontos serão apagados. Este processo se traduz em eficiência no processo de busca de pontos característicos correspondentes entre duas imagens de profundidade.

### 3. OBJETIVOS

#### Objetivo Geral

Propor um método de pré-alinhamento que identifique características geométricas de similaridade entre duas imagens de profundidade que permita diminuir um número significativo de falsas correspondências entre pontos, com alta taxa de precisão.

#### Objetivos específicos

- ❖ Formular uma metodologia que esteja baseada na segmentação/reconstrução de imagens de profundidade para extrair as curvas de contorno do objeto;
- ❖ Projetar um descritor que detecte os pontos característicos pela variação de curvatura e que seja invariante a transformações de similaridade (escala, rotação e translação) e que seja robusto ao ruído;
- ❖ Avaliar o descritor com diferentes imagens e seus resultados e compará-los com os de outros autores com as mesmas imagens;
- ❖ Formular uma metodologia que permita, através de comparações, encontrar pontos característicos correspondentes para gerar transformações de similaridade e que, por sua vez, possa verificar a validade das transformações candidatas.

É importante destacar que a metodologia proposta será aplicável para qualquer conjunto de dados tridimensionais que possam ser projetados para duas dimensões. Nesta pesquisa, serão trabalhados dados obtidos pelo sistema de visão 3D desenvolvido no laboratório LABROVIS/GRACO/UnB e nuvens de pontos obtidos pelo digitalizador TRI\_IDENT, assim como nuvens de pontos contidas em repositórios. Portanto, os esforços serão concentrados em manipular possíveis imagens de profundidade que sejam similares a superfícies de pás de turbinas hidrelétricas que apresentem desgaste de erosão e cavitação e precisem ser restauradas pela deposição de material por soldagem robotizada.

## **4. PROPOSTA DE SOLUÇÃO – ALGORITMO DE PRÉ - ALINHAMENTO**

O pré-alinhamento automático de imagens de profundidade é um problema fundamental na área de visão computacional. Vários algoritmos têm sido propostos para este propósito, porém ainda sofrem de várias limitações, principalmente relacionadas à existência e eficiência na busca de pontos correspondentes procurados em dois mapas de profundidade que compartilham zonas de sobreposição em diferentes porcentagens. Neste capítulo se apresenta uma metodologia que permite usar as “vantagens” combinadas de diferentes descritores, tratando de contornar o problema de existência e aliviando a complexidade combinatória na busca de correspondências para realizar uma transformação de similaridade.

### **4.1. METODOLOGIA PARA A CONSTRUÇÃO DO DESCRITOR**

Um descritor com propriedades geométricas invariantes de similaridade pouco significativas resultará em múltiplas correspondências ambíguas e tornará computacionalmente caro o procedimento de identificação de uma correspondência correta. Na seção (2.4.1), na definição do problema de registro, foi discutido que um descritor será mais expressivo se conseguir incorporar o maior número possível de propriedades geométricas locais e globais nas amostras que o constituem. Além do mais, trabalha-se com a hipótese que se essa configuração for tridimensional e representar uma “região suficientemente grande” da superfície, a capacidade discriminatória do descritor poderá ser aumentada. A junção de propriedades locais e globais em um único descritor tem sido uma importante contribuição na área de reconhecimento de objetos (Tu *et al.*, 2008 e Rusinkiewicz, 2004).

#### **4.1.1. Fundamentos para construir o descritor**

Para facilitar o entendimento do descritor proposto, apresentam-se na figura (4.1) as diversas etapas em seu projeto. O processo se inicia na obtenção de nuvens de pontos através de um digitalizador a laser, seguida pela redução dos dados, bem como pela segmentação da imagem para detectar curvas de contorno através da detecção de bordas (Bellon, 1997). Em seguida, aplica-se o código de cadeia (Freeman e Davis, 1997) para a detecção de pontos característicos. Finalmente, aplica-se um descritor inédito que

classifica e gera uma assinatura que identifica o ponto característico no mapa de profundidade. A assinatura é usada para um processo de reconhecimento.

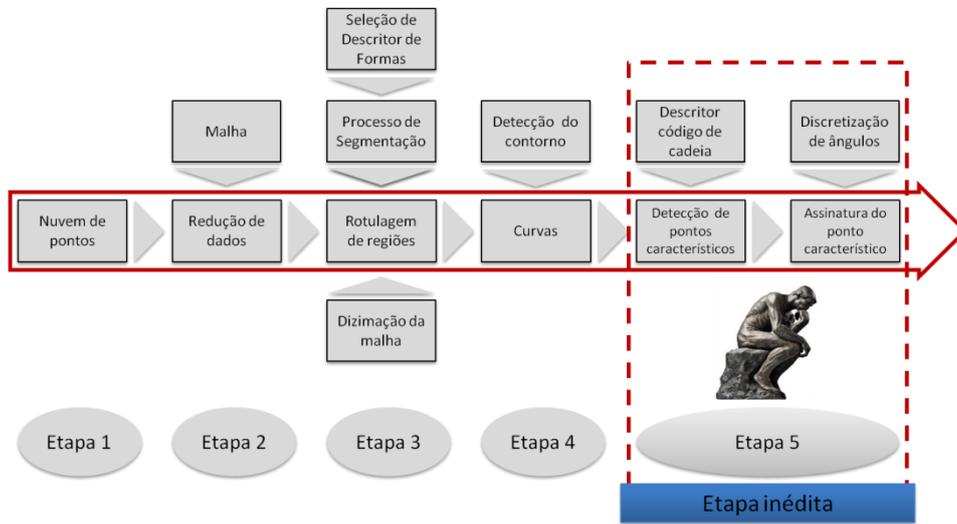


Fig. 4.1. Etapas usadas no desenho do descritor proposto.

A seguir são descritas as etapas utilizadas na metodologia para gerar o descritor, lembrando que a **Etapa 1** (nuvem de pontos) descreve o processo de obtenção de mapas de profundidade, já discutido no capítulo 2. Cada etapa vai acompanhada por resultados experimentais que permitem um melhor entendimento do procedimento realizado. Como exemplo, foram utilizadas duas imagens de profundidade obtidas de um objeto digitalizado através do digitalizador laser VISCAN3D (seção 2.1). As imagens foram obtidas a uma distância aproximada de 500 mm a partir da lente da câmera. O objeto foi suspenso em uma mesa de calibração com isolamento de vibração, normalmente empregada na montagem de experimentos ópticos. (Série 63-500 da empresa Technical Manufacturing Corporation).

As imagens de profundidade foram capturadas com uma área de sobreposição de aproximadamente de  $\sigma_s = 40\%$ , como se apresenta na figura (4.2).

Em que

- $N = 28167$  pontos    Número de pontos da imagem do cavalo completo;
- $N_{I1} = 20732$  pontos    Número de pontos da imagem de profundidade **I1**;
- $N_{sI1} = 8292$  pontos    Número de pontos sobrepostos da imagem de profundidade **I1**;
- $N_{I2} = 17800$  pontos    Número de pontos da imagem de profundidade **I2**;
- $N_{sI2} = 7120$  pontos    Número de pontos sobrepostos da imagem de profundidade **I2**;

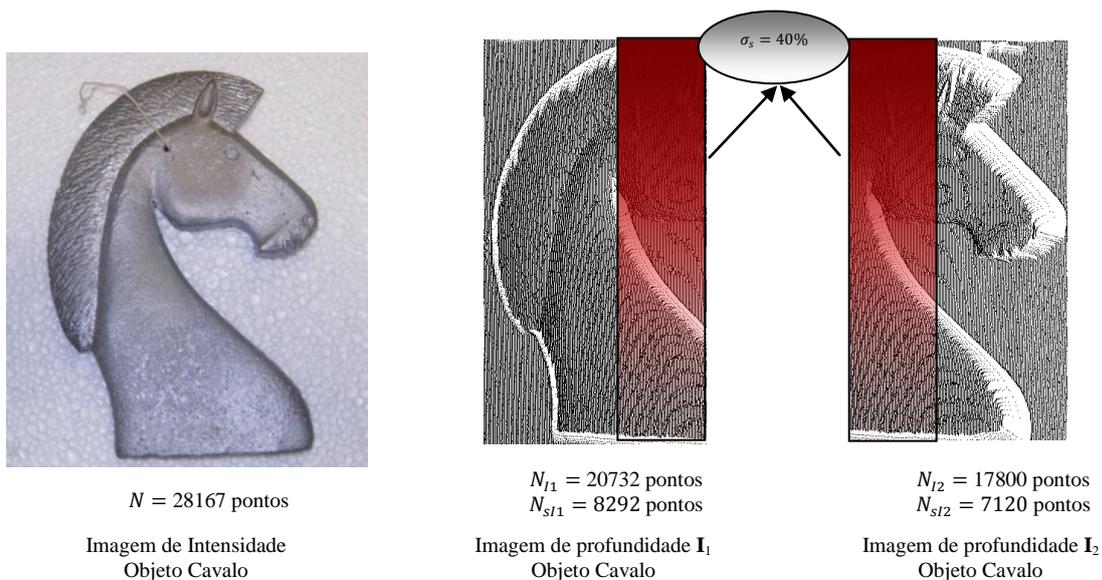


Fig.4.2. Objeto cavalo de bronze.

#### 4.1.2. Etapa 2: redução de dados

Os dados adquiridos a partir do sistema de visão 3D podem resultar em milhões de amostras, fazendo com que a construção de procedimentos eficientes para o processamento de dados seja uma tarefa desafiadora. De fato, o ponto crucial para aumentar a eficiência, nas diferentes etapas do pré-alinhamento, é a redução dos espaços de escolha dos descritores na imagem de profundidade  $I_1$  e o espaço de busca de descritores correspondentes na imagem de profundidade  $I_2$ . Essa redução se torna possível diminuindo o volume de dados das imagens de profundidade, substituindo-se o conjunto denso das suas amostras por um conjunto menor que consiga capturar a essência da forma da superfície original. Esta estratégia apresenta algumas dificuldades como: (1) restrição a classes particulares de superfícies, e (2) concentração de pontos em certas regiões da superfície e, ainda, ausência deles em outras regiões.

Visto que qualquer superfície pode ser aproximada por uma malha triangular, sugere-se alternativamente utilizar uma “malha triangular simplificada” para reduzir o volume de dados da imagem de profundidade sem perder a conectividade entre as amostras que são necessárias para avaliar erros.

No contexto deste trabalho a imagem de profundidade  $I_i$  é descrita através de uma malha triangular. De acordo com alguns testes realizados e apresentados na dissertação de Idrobo Pizo (2009) é mostrado que com esta representação pode-se conseguir uma redução do volume de dados em até 90%, o que garante o quesito eficiência e, sob ajuste adequado de parâmetros de controle, pode-se ter uma densidade adequada para preservar o quesito existência. Portanto, a proposta é usar uma malha triangular

simplificada que com um número reduzido de amostras consiga preservar as características mais salientes da geometria da imagem original de profundidade, onde partes salientes referem-se a um pequeno número de partes que caracterizam a forma do objeto (Gonzales., 2008 e Zhang., 2009).

#### 4.1.2.1. Resultado experimental etapa 2 – redução de dados

Posteriormente à captura de pontos obtidos pelos digitalizadores a laser, os pontos foram organizados através da técnica modelo deformáveis (seção 2.3), em que ocorreu redução de dados. Resultados são apresentados na figura (4.3) e na tabela (4.1).

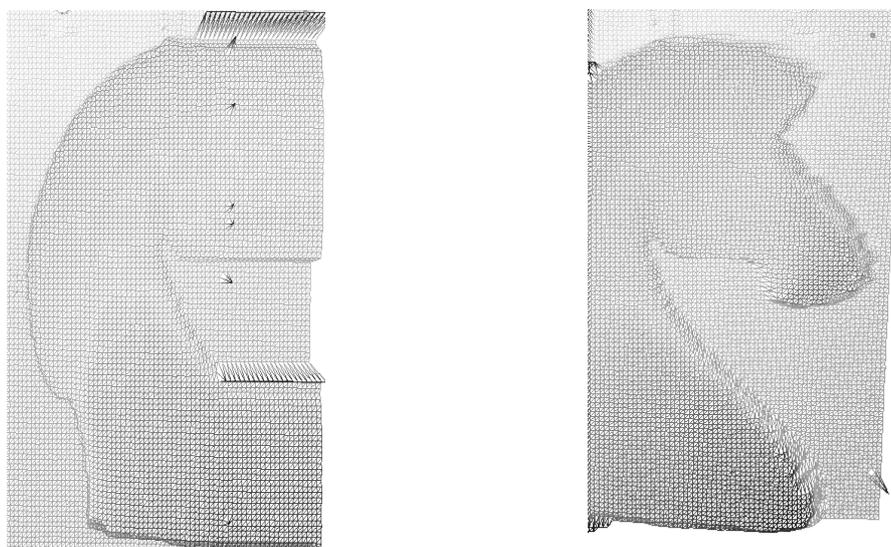


Imagem de profundidade  $I_1$  - Representação em Malha      Imagem de profundidade  $I_2$  - Representação em Malha

Fig.4.3. Imagens de profundidade do cavalo - Representação em malha  
Resolução da malha  $t = 0.90 \text{ mm}$ .

Tabela 4.1. Volume de dados reduzidos.

Imagens de profundidade	Pontos	Pontos preservados no processo de redução de dados	% Preservação da imagem de profundidade original
I1-Cavalo	20732	5256	~26
I2-Cavalo	17800	3978	~22

#### 4.1.3. Etapa 3: rotulagem de regiões

Sendo a forma uma propriedade fundamental de um objeto, esta será a peça chave para a descrição do objeto, de maneira a se encontrar um conjunto de características de similaridade que melhor descreva e discrimine a superfície em estudo. De acordo com Latecki *et al.* (2000), os descritores de forma podem ser divididos em três categorias principais: características baseadas em contorno, área e esqueleto.

**Características baseadas em contorno:** as características são extraídas a partir da representação do contorno da forma. Características baseadas em contorno de forma

exploram somente a informação do contorno e não a informação do interior da forma. Como exemplos, temos os descritores de Fourier (Arbter *et al.*, 1990), espaço-escala da curvatura (Mokhtarian *et al.*, 1997) e os descritores de momentos (Flusser., 2005 e Huang e Cohen, 1994).

**Características baseadas em área:** as características são extraídas considerando todos os pontos contidos na forma. Geralmente, os métodos baseados em área usam momentos para descrever a forma. Estes métodos incluem momentos geométricos (Martinez e Thomas, 2002), momentos de Legendre (Ahmadian *et al.*, 2003), momentos de Zernike (Kim H.K.,2000), (Khotanzad and Hong, 1990), pseudo-momentos de Zernike (Haddadnia *et al.*, 2002) e um método baseado em grade (Chakrabarti *et al.*, 2000). Estes métodos de descrição da forma exploram a informação contida na forma e não apenas a informação contida no contorno da forma.

**Características baseadas no esqueleto:** O esqueleto é um grafo que descreve a informação topológica da forma. O esqueleto é um descritor atrativo porque captura a noção das partes e dos componentes da forma. A similaridade de duas formas pode ser calculada através de algoritmos de correspondência de grafos (Dionisio, 2005, Gold e Rangarajan, 1996).

Para o caso de descritores de forma, o trabalho de Latecki e Lakämper (2000) compara os melhores descritores de cada uma das três categorias sobre um mesmo conjunto de dados.

Considerando o tipo de superfícies que é foco desta pesquisa (seção 2.4.3) **o método proposto nesta tese pertence à primeira categoria: características baseadas em contorno.** O objetivo é detectar pontos característicos pela variação de curvaturas da superfície através de variação de bordas. A detecção de bordas de imagens de profundidade gera uma descrição de mais alto nível da cena do que em imagens de intensidade luminosa, porque informação tridimensional (3D) explícita contida nas imagens de profundidade permite diversos tipos de bordas (Wani e Batchelor, 1994): borda de profundidade, borda de orientação e bordas suaves.

a) Bordas de profundidade (*step ou jump edge*);

Este tipo de borda surge a partir de uma descontinuidade significativa nos valores de profundidade entre pontos vizinhos, como se apresenta na figura (4.4). Para identificar as bordas de profundidade, pode-se calcular a máxima diferença de profundidade entre cada ponto da imagem e seus vizinhos. A magnitude deste valor está dada por:

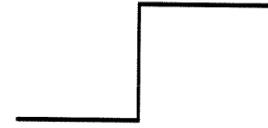


Fig.4.4. Borda de profundidade.

$$B_{profundidade}(x, y) = \max\{|z(x, y) - z(x + k, y + l)| : -1 \leq k, l \leq 1\} \quad (4.1)$$

Se este valor é maior do que um limiar estipulado, o ponto em questão é identificado como borda.

b) Bordas de Orientação (*roof ou crease edge*)

Estas bordas são formadas por pontos onde se verifica uma variação significativa na orientação de suas normais, em relação às normais de seus vizinhos, como pode ser visto na figura (4.5). As bordas de orientação são identificadas a partir do cálculo da máxima diferença angular entre as normais à superfície para cada ponto da imagem em relação a seus vizinhos. A magnitude deste valor é dada por:

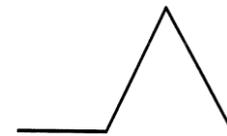


Fig. 4.5. Borda de orientação.

$$B_{orientacao}(x, y) = \max\{|\cos^{-1}(\mathbf{n}(x, y) \cdot \mathbf{n}(x + k, y + l))| : -1 \leq k, l \leq 1\} \quad (4.2)$$

Novamente, se este valor é maior do que o limiar estipulado, o pixel em questão é identificado como borda.

c) Bordas suaves (*smooth edges*)

Os pontos componentes das bordas suaves se caracterizam por uma variação gradual na orientação de suas normais em relação às normais de seus vizinhos, como mostra a figura (4.6). Sua identificação é bem mais complexa do que no caso das bordas de profundidade e orientação.



Fig. 4.6. Borda suave.

#### 4.1.3.1. Resultado experimental etapa 3 - rotulagem de regiões

Partindo dos resultados experimentais da etapa 2 (seção 4.1.2.1), realiza-se sobre a imagem de profundidade um processo de segmentação, extraindo os contornos das

regiões detectados pelas discontinuidades existentes nos valores de profundidade da superfície, bem como pela variação significativa na orientação de suas normais em relação às normais de seus vizinhos. As outras regiões são classificadas como superfícies planas, que são agrupadas fazendo uso do algoritmo de dizimação de malha que é descrito no apêndice A.

Na tabela (4.2) apresentam-se dados estatísticos obtidos durante o processo de segmentação. O número de pontos da imagem de profundidade (Fig.4.7) se reduz no processo de agrupamento. O resultado apresenta que a apesar da redução ser considerável, o que redundava a favor do quesito “eficiência” no processo de busca para encontrar pontos característicos correspondentes em ambas as imagens.

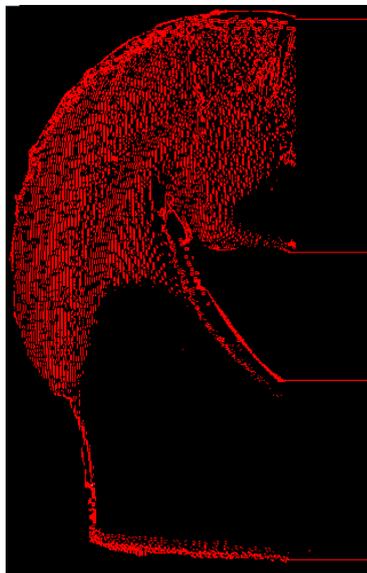


Imagem de profundidade I1

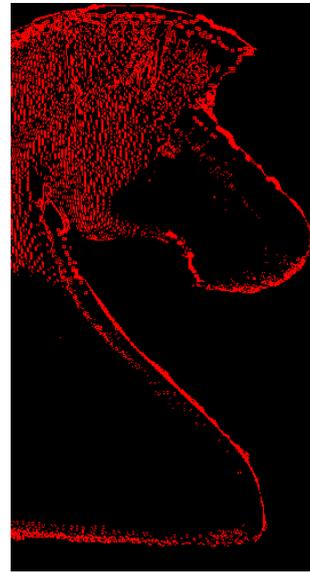


Imagem de profundidade I2

Figura 4.7. Mapa de bordas.

Tabela 4.2. Volume de dados reduzidos mapa de bordas.

Imagens de profundidade	Pontos	Pontos Imagem- modo malha	Pontos preservados no processo de segmentação	% Preservação da imagem de profundidade original
I1-Cavalo	20732	5256	1930	~9
I2-Cavalo	17800	3978	1132	~7

#### 4.1.4. Etapa 4: detecção de curvas de contorno

Uma vez atestada visualmente a qualidade da segmentação-reconstrução, a próxima etapa é criar uma representação de maior nível de abstração para as bordas. A informação do vetor normal vai atuar nesta etapa como um parâmetro de realimentação, usado para refinamento dos valores limiares que vão identificar se um ponto pertence ou

não a uma determinada borda. De acordo a (Hoover et al., 1996) os valores de limiar são obtidos, na sua maioria, por estimativas baseadas em experimentos, usando tentativa de erro.

#### 4.1.4. 1. Resultado experimental 4 - detecção de curvas de contorno

Dois tipos diferentes de bordas são identificadas no resultado experimental da etapa 3 - rotulagem de regiões: bordas de orientação, bordas de profundidade. Considerando o foco principal deste trabalho, o objetivo é a detecção de contornos originada pela identificação de bordas de profundidade. Idealmente, seria fácil realizar uma separação de bordas de profundidade, porque estas bordas só dependem da diferença de profundidade entre cada ponto e seus vizinhos. Bordas de orientação são formadas por pontos onde se verifica uma variação significativa na orientação de suas normais em relação às normais de seus vizinhos e, por eliminação as demais bordas seriam bordas suaves. Mas esta classificação não pode ser realizada de forma ideal. Experimentalmente, verifica-se que existem pontos significativos pertencentes às bordas de profundidade que se encontram na região das outras bordas. Para facilitar este trabalho de classificação de bordas de profundidade, agrupa-se em conjuntos o valor do ângulo de orientação dos vetores normais por um histograma. Para maior compressão do procedimento realizado destacam-se as seguintes equações (Bellon, 1997):

i. Normal à superfície

$$\vec{n}(u, v) = \frac{(-f_u, -f_v, 1)^T}{\sqrt{(1 + f_u^2 + f_v^2)}} \quad (4.3)$$

ii. Ângulo de orientação da normal

$$\alpha(u, v) = \tan^{-1}\left(\frac{f_u}{f_v}\right) \quad (4.4)$$

Em que,

- $f(u, v)$  é o valor de profundidade na coordenada  $(u, v)$  de um ponto na superfície;
- $f_u$ =derivada parcial de  $f(u, v)$  em relação a  $u$ ;
- $f_v$ =derivada parcial de  $f(u, v)$  em relação a  $v$ ;

Como exemplo, os histogramas descritos nas figuras (4.8) e (4.9) apresentam a informação dos ângulos de orientação ( $\alpha$ ) dos vetores normais dos pontos da imagem de

profundidade **I1** e **I2**, que assumem os valores entre [0,1] e que contêm como valor mínimo 50% da altura do ponto mais profundo da borda de profundidade.

O valor de  $\gamma$  é calculado como:

$$\gamma = \cos(\alpha) \tag{4.5}$$

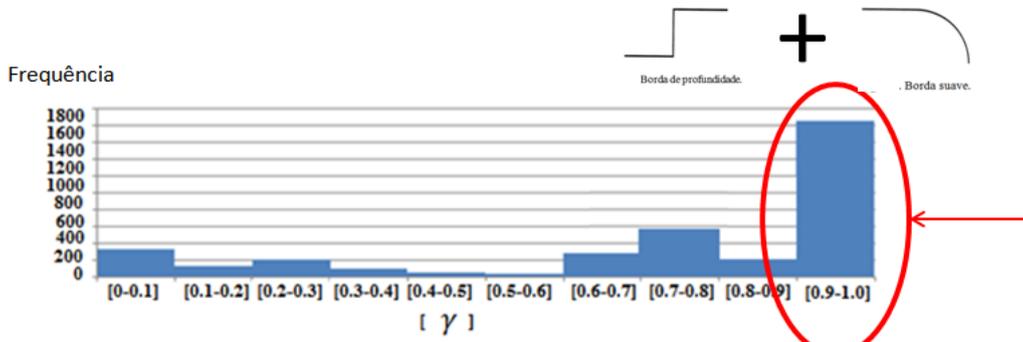


Fig. 4.8. Histograma da imagem de profundidade **I1**- imagem

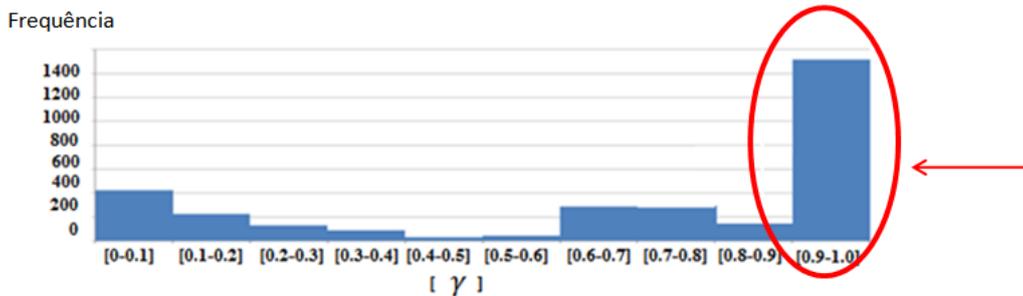


Fig. 4.9. Histograma da imagem de profundidade **I2**- imagem

Nos histogramas anteriores está descrita a variação do vetor normal de orientação. As bordas de profundidade usualmente assumem valor unitário devido em que ângulo de orientação  $\alpha$  (Eq. 4.4) assume valores próximos à zero. Pontos que contenham valor próximo a ( $\gamma = 1$ ) (Eq.4.5), representam bordas que são fisicamente próximas às bordas de profundidade. No caso deste exemplo, em particular, a faixa de valores escolhidos foi  $\gamma = [0.9 \text{ a } 1.0]$  para borda de profundidade e os demais valores fundo. Estes parâmetros foram escolhidos para selecionar grandes contornos de regiões contínuas com alta atenuação de ruído. Para outra combinação de valores de  $\gamma$  (Eq.4.5) as bordas das imagens estariam acompanhadas de ruídos que poderiam futuramente confundir a representação de zonas. Na figura (4.10), apresentam-se os resultados experimentais que ilustram a aplicabilidade do método de segmentação e representação desenvolvido para construir o mapa de contorno. Nesta imagem se destaca a identificação clara do contorno objeto (linha vermelha). As informações que traz as

curvas que representa o contorno serão usadas para determinar a correspondência entre duas superfícies que se deseja alinhar.



Imagem de profundidade  $I_1$



Imagem de profundidade  $I_2$

Figura 4.10. Refinamento da imagem segmentada- construção do mapa de contorno.

Na etapa 3 (rotulagem de regiões) e etapa 4 (detecção de curvas de contorno) foram apresentados resultados experimentais que ilustram a aplicabilidade do método de segmentação. A existência de bordas de profundidade e de orientação identificadas no processo de segmentação atuam como características de controle para extrair mapas de contorno de regiões. Com emprego do algoritmo da dizimação (Apêndice A) da malha e uso dos histogramas, o método de segmentação apresentado se torna eficiente pelos seguintes motivos :

- Utiliza uma redução de pontos para representar uma imagem;
- Preserva as bordas naturais do objeto, devido às informações de borda inseridas no processo de agrupamento;

#### 4.1.5. Etapa 5: detecção de pontos característicos de um mapa de curvas de contorno

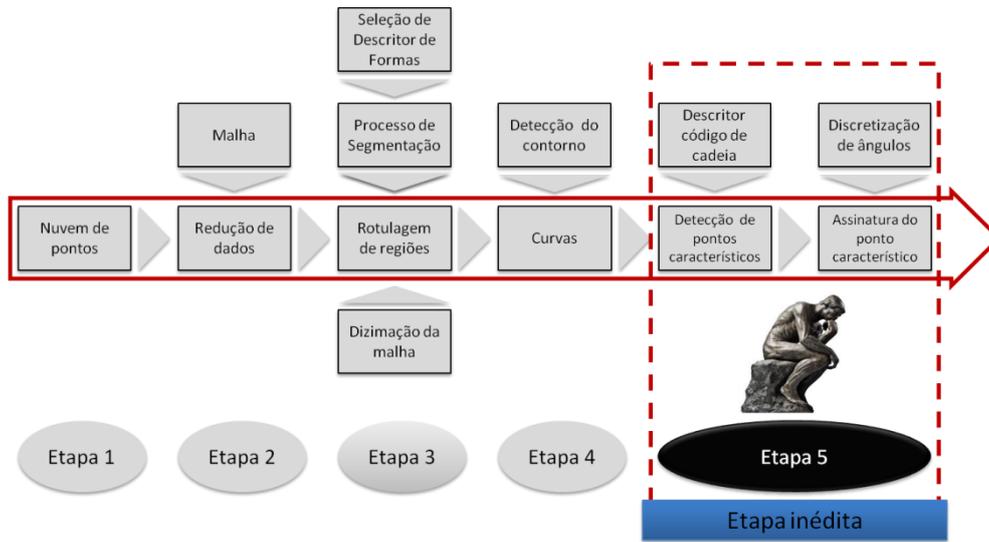


Fig. 4.11. Etapas usadas no desenho do descritor proposto- Etapa 5.

De acordo com Arrebola e Sandoval (2005), a caracterização de curvatura se classifica em dois grandes grupos: ajuste de curvas (Sato, 1992), e algoritmos baseados em curvatura (Rosenfeld e Johnston, 1973, Freeman e Davis, 1977, Beus and Tiu, 1987). A literatura fornece diferentes métodos para ajustes de curvas digitais, que se caracterizam por adaptar sobre uma curva um polígono que seja formado por um número mínimo de lados. Por outro lado, os algoritmos baseados em curvatura caracterizam o segmento de curva ponto a ponto, identificando pontos característicos pela variação descontínua de curvatura. Intervalos de curvatura nula correspondem a segmentos de reta e intervalos com variação de curvatura contínua correspondem a círculos ou arcos.

Analisando o tipo de contorno que se deve analisar (seção 2.4.3) se encontra que o contorno pode estar constituído por segmentos de curvatura abertas e/ou fechadas. A melhor opção a ser escolhida para que o descritor seja utilizado para múltiplos casos é utilizar um descritor que caracterize e classifique curvas ponto a ponto. De acordo com este critério, a seleção pode ser dada por descritores baseados em curvatura. Vários autores têm trabalhado na análise da vizinhança de um ponto. Rosenfeld e Johnston (1973) detectaram pontos característicos usando k-coseno como estimativa para o valor da curvatura dos pontos do contorno de um objeto. Rosenfeld e Weszka (1975) propuseram uma modificação de Rosenfeld e Johnston 1973, usando média de k-cosenos. Asada e Brady (1984) usaram suavização Gaussiana e B-Splines cúbicas para

calcular os pontos característicos de uma curva. Freeman e Davis (1977) detectaram pontos característicos analisando a variação da curvatura ao mover um segmento de linha reta ao longo da curva, de forma que diferenças angulares entre sucessivos segmentos foram usadas para medir a curvatura local. A técnica de Beus e Tiu (1987) é similar à técnica de Freeman e Davis (1977) exceto por um parâmetro que limita o tamanho do segmento de reta. Chetverikov e Szabo (1999) (2003) propôs um rápido e eficiente algoritmo, referenciado como IPAN, que consiste em classificar como ponto característico aqueles pontos que têm um ângulo de abertura específico e que obedecem a um espaçamento mínimo de pontos característicos adjacentes. A maioria dos métodos anteriores faz uso do algoritmo código de cadeia. Existem outros trabalhos que usam a transformada de Hough, Wavelets e redes neurais como ferramentas para detectar pontos característicos.

Apesar do grande número de estudos publicados nas últimas décadas, a detecção de pontos característicos é ainda um campo fértil para o avanço de pesquisas. São poucos os algoritmos robustos a ruídos.

No presente trabalho será abordada uma nova metodologia para superar parcialmente esta limitação. O objetivo é usar um filtro linear para suavizar os valores da curvatura dos pontos do contorno. Esse filtro deve ser capaz de suavizar os pontos ruidosos e preservar os pontos de alta curvatura que representam os pontos característicos. Um tipo importante de filtros que satisfazem esse critério são os filtros adaptativos (Bruno e Netto, 2007).

Por outro lado, cabe mencionar que não se encontrou na literatura nenhum resultado sobre classificação de pontos característicos que forneça a posição do ponto no mapa de profundidade e que seja invariante a transformações de similaridade. Este processo facilitara a orientação e acelera sistemas de busca para alinhar duas imagens de profundidade. Estes dois pontos serão a contribuição que se fará na construção de um descritor para pré-alinhamento de imagens de profundidade.

#### **4.1.5. 1. Algoritmo código de cadeia (Freeman e Davis, 1977)**

Qualquer curva contínua aberta ou fechada pode ser digitalizada e representada como uma curva discreta  $C(u)$  que, por sua vez, pode ser representada por uma sequência ordenada de segmentos de reta que conectam dois pontos, tal que  $C_u = u_1 u_2 \dots u_n$ , em que  $\{u_i: 1 \leq i \leq n\}$ , onde  $n$  indica o número de elementos da curva, e  $u_i$  pode ser representado por oito estados. Os estados associados a cada elemento  $u_i$

representam a direção relativa entre dois pontos característicos ao longo da curva, aproximada a uma das direções múltiplas de 45 graus (Fig. 4.12).

O código de cadeia (Freeman e Davis, 1977) é gerado ao mesmo tempo em que se percorrem os elementos. A figura (4.13) apresenta um exemplo do processo para representar uma curva através de uma sequência de estados. O processo se inicia na extremidade sombreada.

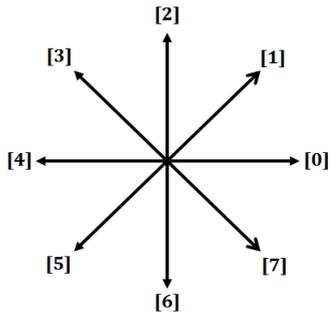


Fig. 4.12. Código direcional de 8 estados.

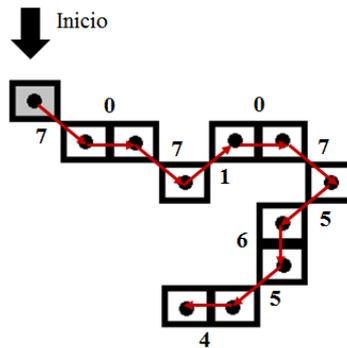


Fig. 4.13. Exemplo de código da cadeia (c.8) 7071075654.

No caso de curvas fechadas, o código termina quando o traçado da curva retorna ao ponto inicial. A codificação descrita é absoluta, no sentido de que cada estado representa uma direção constante com referência ao ponto inicial. De acordo com Gonzáles (2008) o método apresenta varias limitações: **(1)** a cadeia de códigos resultantes é muito longa, **(2)** qualquer pequena perturbação ao longo da fronteira, devido a ruído ou a segmentação imperfeita causa variações no código que podem não estar necessariamente relacionadas à forma da fronteira. **(3)** o código da cadeia depende do ponto inicial escolhido (no caso de curvas abertas, há apenas ambiguidade quanto à extremidade inicial);

#### 4.1.5.2. Otimização do algoritmo código de cadeia para determinar pontos característicos

A partir daqui descreve-se um novo algoritmo para contornar as limitações do código de cadeia. Inicialmente apresentam-se passos do algoritmo proposto para filtrar ruídos, determinar pontos característicos, e a seguir cada ponto característico é assinalado por uma assinatura que o relaciona diretamente ao seu vizinho. A assinatura atribuída a cada ponto é invariante a transformações de similaridade. O descritor proposto é baseado em operações com números inteiros, o que traz benefícios por ser

simples de programar em qualquer tipo de hardware (microcontroladores, FPGAs, microprocessadores, entre outros) e ser eficiente computacionalmente.

A seguir apresentam-se os passos do algoritmo proposto para descrever pontos característicos de uma curva:

Passo[1]. Suavize a curva  $C(u)$  atenuando o ruído através do filtro adaptativo NLMS (seção 2.2);

Passo[2]. Represente os segmentos  $u_n$  da curva num gráfico *estado vs segmentos* (Fig. 4.14).

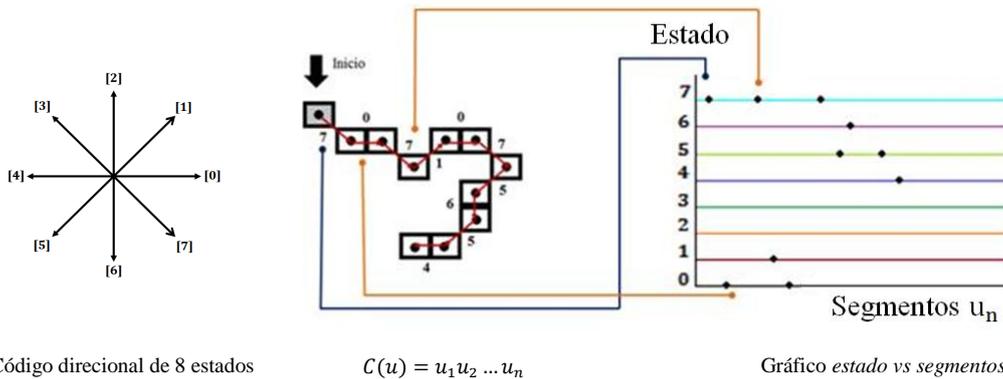


Fig.4.14. Representação de dados *estado vs segmentos*.

Passo[3]. Calcule a variação de direção dos segmentos por meio do ângulo  $\alpha(u_n)$  que se formam entre pontos (Eq. 4.6): a estratégia geral para construir o descritor não será de determinar os pontos locais, mas sim os valores definidos pelos pontos que refletem a variação de estado (Fig. 4.15).

$$\alpha(u_n) = \text{abs} \left[ \tan^{-1} \left( \frac{u_{n+1}}{u_n} \right) \right] \quad (4.6)$$

Existe um ponto característico, se  $\alpha(u_n) \neq 0$ ;

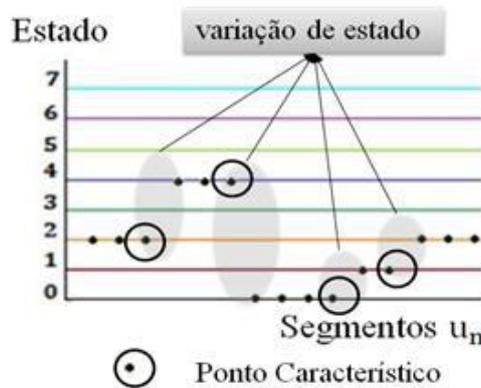


Fig.4.15. Detecção de pontos característicos no gráfico *estado vs segmentos*.

Passo[4]. Identifique sobre a curva origem  $C(u)$  os pontos característicos  $p_i$  que foram detectados no gráfico *estado vs segmentos*. Ligue os pontos característicos através de segmentos de retas  $\vec{v}_m$ :

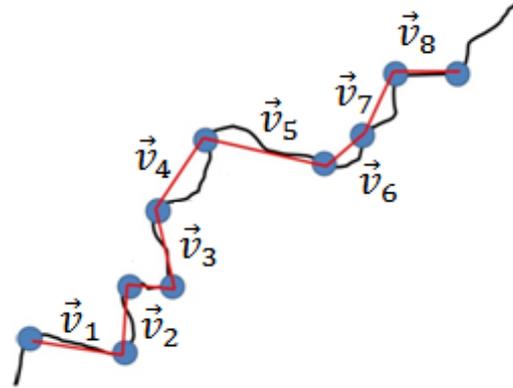
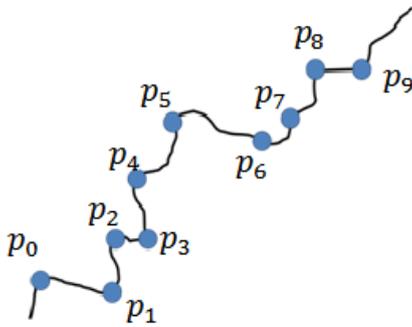


Fig.4.16. Pontos característicos identificados sobre uma curva.

Fig. 4.17. Ligação de pontos característicos entre segmentos.

Passo[5]. Calcule a variação de direção dos segmentos (ângulo  $\sigma_m$ ) entre  $\vec{v}_m$  e  $\vec{v}_{m+1}$  através do produto escalar:

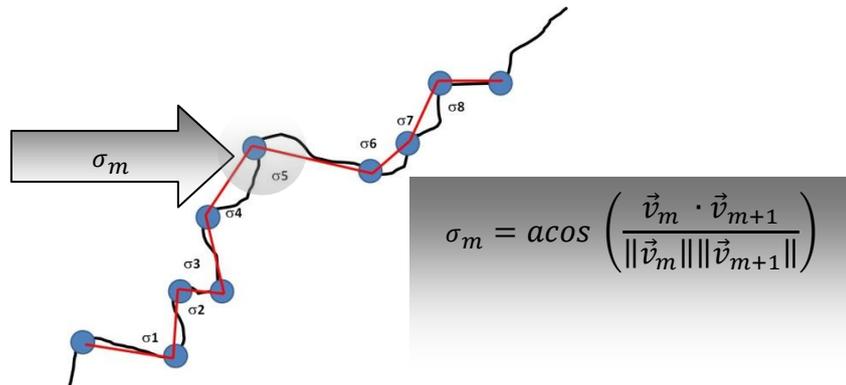


Fig.4.18. Cálculo do ângulo de variação dos segmentos que conecta os pontos característicos.

Passo[6]. Discretize os ângulos  $\sigma_m$  através do código direcional de 4 estados (Tab.4.3) e realize uma representação gráfica de *ângulo discreto*  $(\sigma_d)_{4E}^{\dagger\dagger}$  através do código de barras. Como exemplo de visualização pode-se assinalar uma cor para cada estado;

<sup>††</sup> o símbolo  $(\sigma_d)_{4E}$  → Significa que o ângulo foi discretizado através do código direcional de 4 estados (4E)

Tab. 4.3. Valores discretos através do código direcional de 4 estados.

Varição de ângulo ( $\sigma_m$ )	Ângulo discreto ( $\sigma_d$ ) <sub>4E</sub>	Cor representativa
$\sigma_m < 45^\circ$	$\sigma_d = 0$	Amarelo
$45^\circ \leq \sigma_m < 90^\circ$	$\sigma_d = 1$	Azul
$90^\circ \leq \sigma_m < 135^\circ$	$\sigma_d = 2$	Verde
$135^\circ \leq \sigma_m < 180^\circ$	$\sigma_d = 3$	Vermelho

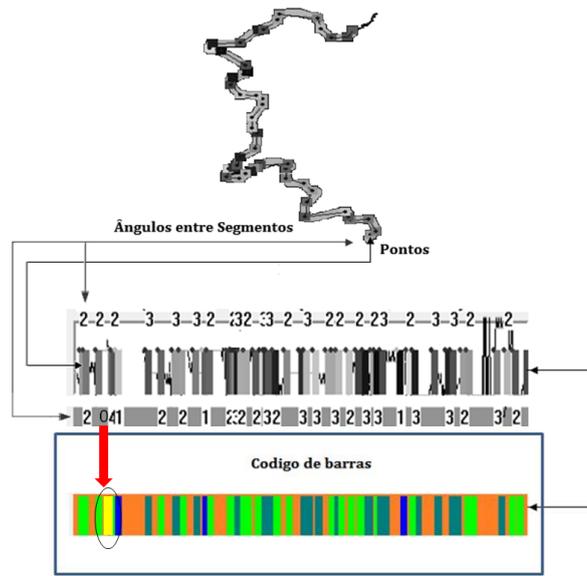


Fig. 4.19. Detecção de ponto característico semente.

Para o caso particular do exemplo anterior existe um único ponto no código de barras que se destaca entre os demais. O ponto pertence ao estado zero (cor amarela) e está indicado a através de uma seta. Esse ponto característico particular pode ser o ponto semente para realizar um pré-alinhamento rápido entre imagens de profundidade. O mesmo processo pode acontecer para um sem número de curvas.

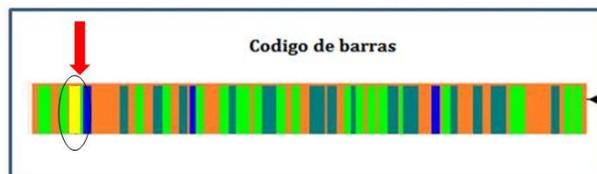


Fig. 4.20. Detecção de ponto característico semente no gráfico código de barras.

Os pontos selecionados como pontos correspondentes precisam levar consigo um código numérico de verificação que identifique a região a que pertence. Esse código foi denominado, neste trabalho de assinatura do ponto característico.

Passo[7]. Para gerar a assinatura, coleta-se informação da vizinhança, conectando o ponto característico **PP** a seus seis pontos vizinhos mais próximos, também

pontos característicos. O processo pode ser visto graficamente na figura (4.21).

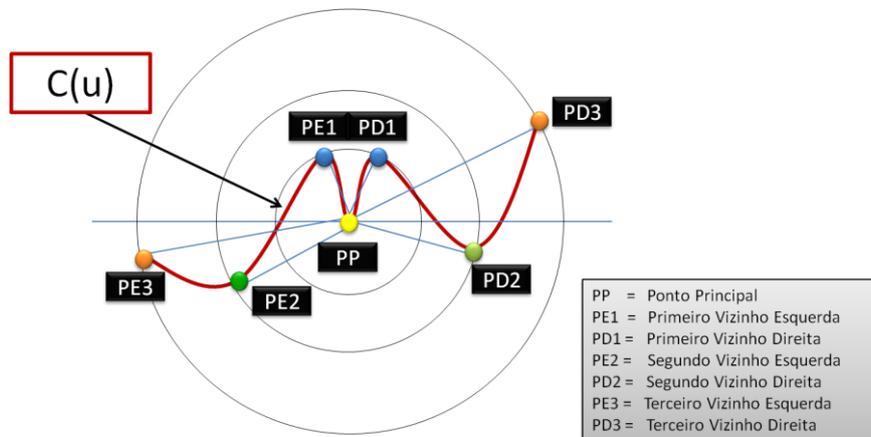


Fig. 4.21. Processo de geração de assinatura de um ponto característico. Etapa: coleta de informação.

Passo[8]. Calcula-se sucessivamente a variação da direção dos segmentos próximos através do produto escalar, na forma da tabela abaixo.

Tab. 4.4. Dados dos ângulos formados entre pontos característicos para formar uma assinatura.

		Ângulo entre os pontos				
		PE1 PP PD1	PE1 PP PE2	PE2 PP PE3	PD1 PP PD2	PD2 PP PD3
$(\sigma_m)$						

Como exemplo e caso particular da curva  $C(u)$  (Fig. 4.21) os valores dos ângulos formados entre pontos característicos podem ser:

Tab. 4.5. Dados dos ângulos formados entre pontos característicos para formar uma assinatura - curva  $C(u)$ .

		Ângulo entre os pontos				
		PE1 PP PD1	PE1 PP PE2	PE2 PP PE3	PD1 PP PD2	PD2 PP PD3
$(\sigma_m)$	Ângulo Principal	$\sim 33^\circ$	$\sim 98^\circ$	$\sim 18^\circ$	$\sim 87^\circ$	$\sim 52^\circ$

Passo[9]. Ordenam-se os valores dos ângulos em ordem crescente. A ordenação dos ângulos tem início a partir do ângulo principal. Ordenar os ângulos permite que o descritor proposto seja invariante a rotações;

Tab. 4.6. Dados Organizados dos ângulos usados para formar uma assinatura - curva  $C(u)$ .

		Ângulo entre os pontos									
		PE1 PP PD1	PE2 PP PE3	PD2 PP PD3	PD1 PP PD2	PE1 PP PE2					
$(\sigma_m)$	Ângulo Principal ~33°	~18°	~52°	~87°	~98°						

Passo[10]. Discretizar os ângulos  $\sigma_m$  fazendo uso dos valores do código direcional de 4 estados (Tab. 4.7). Gera-se, então, uma assinatura completa formando um código numérico através da ordenação dos dígitos dos ângulos discretizados ( $\sigma_d$ ), (Tab. 4.8).

Tab. 4.7. Valores discretos através do código direcional de 4 estados.

Variação de ângulo ( $\sigma_m$ )	Ângulo discreto ( $\sigma_d$ ) <sub>4E</sub>
$\sigma_m < 45^\circ$	$\sigma_d = 0$
$45^\circ \leq \sigma_m < 90^\circ$	$\sigma_d = 1$
$90^\circ \leq \sigma_m < 135^\circ$	$\sigma_d = 2$
$135^\circ \leq \sigma_m < 180^\circ$	$\sigma_d = 3$

Tab. 4.8. Ângulos discretos fazendo uso do código direcional de 4 estados – assinatura completa.

		Ângulo entre os pontos									
		PE1 PP PD1	PE2 PP PE3	PD2 PP PD3	PD1 PP PD2	PE1 PP PE2					
$(\sigma_m)$	Ângulo Principal ~33°	~18°	~52°	~87°	~98°						
$(\sigma_d)_{4E}$	0 1° Dígito	0 2° Dígito	1 3° Dígito	1 4° Dígito	2 5° Dígito						
Assinatura Completa PP		<b>0 0 1 1 2</b> 1° Dígito 2° Dígito 3° Dígito 4° Dígito 5° Dígito									

Passo[11]. Com o código reduzido, gera-se uma assinatura reduzida. A tabela (4.9) ilustra o processo de redução.

Tab. 4.9. Ângulos discretos fazendo uso do código direcional de 4 estados assinatura reduzida.

		Ângulo entre os pontos				
		PE1 PP PD1	PE2 PP PE3	PD2 PP PD3	PD1 PP PD2	PE1 PP PE2
$(\sigma_m)$	Ângulo Principal ~33°	~18°	~52°	~87°	~98°	
$(\sigma_d)_{4E}$	0 1° Dígito	0 2° Dígito	1 3° Dígito	1 4° Dígito	2 5° Dígito	
Assinatura Completa PP		0 0 1 1 2 1° Dígito 2° Dígito 3° Dígito 4° Dígito 5° Dígito				
Assinatura Reduzida PP		0 1 2				

Quando se caracteriza a curva  $C(u)$ , este algoritmo de otimização não impede que haja curvas fechadas. Para evitar isso, pode-se incluir um passo a mais.

Passo[12]. Quando pontos iniciais e finais são iguais, finaliza-se o algoritmo.

O descritor proposto extrai os pontos característicos de uma curva e são representados numericamente de tal modo que são invariantes a qualquer transformação geométrica de similaridade. O algoritmo reduz as limitações do algoritmo do código de cadeia original. A tabela a seguir apresenta uma comparação entre dois descritores.

Tab. 4.10. Comparação técnica de descritores.

Representação de Curvaturas		
Limitação do Descritor Código de Cadeia (Gonzales e Woods, 2008)		Descritor Proposto (Solução)
1	A cadeia de códigos resultantes pode ser muito longa.	Só pontos característicos recebem uma assinatura pelo código de cadeia.
2	Qualquer pequena perturbação ao longo da fronteira, devido a ruído ou a segmentação imperfeita causa variações no código que podem não estar necessariamente relacionadas à forma da fronteira.	Ruído é atenuado através filtros adaptativos.
3	O código da cadeia depende do ponto inicial escolhido (no caso de curvas abertas, há apenas ambiguidade quanto à extremidade inicial).	O código gerado para cada ponto característico não depende do ponto inicial.

#### 4.1.5.3. Critério de Similaridade

Uma das principais características que se demanda do descritor é sua adequação para utilizar uma medida que favoreça uma correta diferenciação das correspondências obtidas com o propósito de evitar a aparição de falsas correspondências. Atendendo a

este requisito, projetou-se uma medida de similaridade que pretende aumentar o poder descritivo do descritor para encontrar uma correspondência válida.

Para ilustrar o processo de similaridade, faz-se uso de dois segmentos de curva, graficamente idênticas (Fig.4.22) e (Fig.4.23). Simula-se o caso em que o processo de detecção de pontos característicos não registra um ponto característico de uma das curvas. Ao realizar a identificação do ponto característico por uma assinatura, é observado que o código numérico gerado em uma das curvas não representa numericamente a mesma assinatura do ponto característico na outra curva, como se pode observar na tabela (4.11) e tabela (4.12).

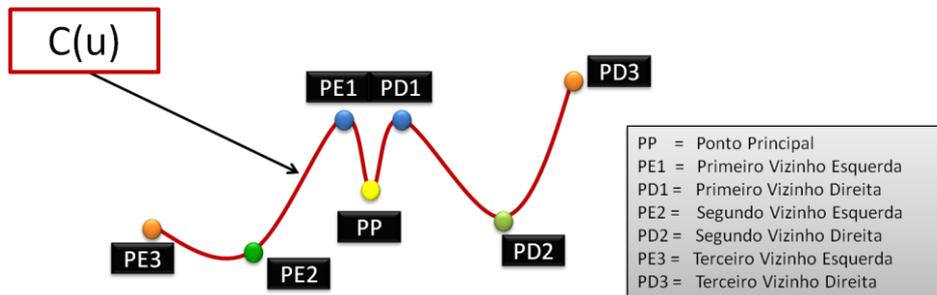


Fig.4.22. Gráfico da curva número 1.

Tab. 4.11. Informação da assinatura completa e reduzida do ponto característico da curva número 1.

		Ângulo entre os pontos				
		PE1 PP PD1	PE2 PP PE3	PD2 PP PD3	PD1 PP PD2	PE1 PP PE2
$(\sigma_m)$	Ângulo Principal ~33°	~18°	~52°	~87°	~98°	
$(\sigma_d)_{4E}$	0 1° Dígito	0 2° Dígito	1 3° Dígito	1 4° Dígito	2 5° Dígito	
Assinatura Completa <b>PP</b>		0 0 1 1 2 1° Dígito 2° Dígito 3° Dígito 4° Dígito 5° Dígito				
Assinatura Reduzida <b>PP</b>		0 1 2				

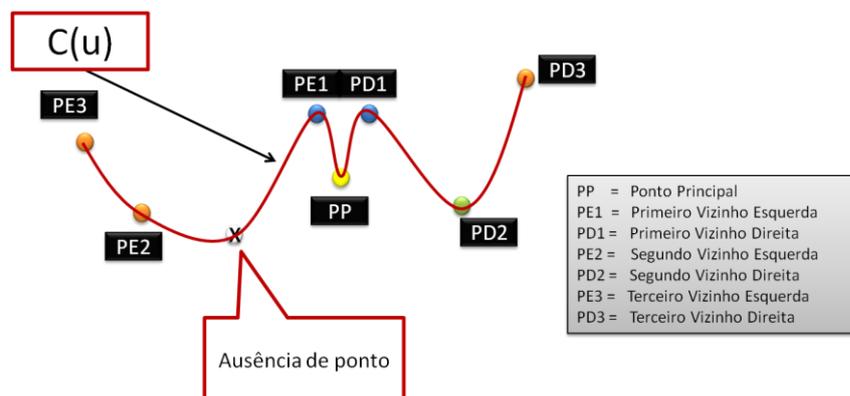


Fig.4.23. Gráfico da curva número 2.

Tab. 4.12. Informação da assinatura completa e reduzida do ponto característico da curva número 2.

	Ângulo entre os pontos				
	PE1 PP PD1	PE2 PP PE3	PD2 PP PD3	PE1 PP PE2	PD1 PP PD2
$(\sigma_m)$	Ângulo Principal ~33°	~15°	~52°	~82°	~87°
$(\sigma_d)_{4E}$	0 1° Dígito	0 2° Dígito	1 3° Dígito	1 4° Dígito	1 5° Dígito
Assinatura Completa PP			0 0	1 1	1
			1° Dígito 2° Dígito	3° Dígito 4° Dígito	5° Dígito
Assinatura Reduzida PP			0 1		

Para evitar a perda de informação desta possível correspondência, pode-se analisar os dígitos que compõem as assinaturas. Verifica-se se o primeiro dígito de duas assinaturas completas são iguais e, em seguida, se dois dígitos situados em qualquer posição dentro de uma das assinaturas completas são iguais a dois dígitos também situados em qualquer posição da outra assinatura que está sendo comparada. Por exemplo, a assinatura completa da figura (4.24) tem o primeiro dígito com valor (0) igual ao valor do primeiro dígito da assinatura completa a comparar. Observa-se que o segundo dígito (0) também é igual ao dígito na segunda posição da assinatura completa a comparar. E o terceiro dígito (1) aparece em várias posições sucessivas na assinatura completa a comparar.

	Segundo Valor dígito comum
Assinatura completa (Tab. 4.11)	1 Dígito 2 Dígito 3 Dígito 4 Dígito 5 Dígito 0 0 1 1 2
Assinatura completa a comparar (Tab. 4.12)	1 Dígito 2 Dígito 3 Dígito 4 Dígito 5 Dígito 0 0 1 1 1

Fig.4.24. Comparação de assinaturas.

O mínimo de três dígitos em comum em ambas as assinaturas permite que o descritor descreva a mesma região com acerto de pelo menos 60%.

Para aumentar o grau de confiabilidade foi proposto realizar uma discretização fina localizada, fazendo uso do código direcional de 8 estados (Tab.4.13) para que gere uma nova assinatura completa a ser comparada.

Tab. 4.13. Valores discretos através do código direcional de 8 estados.

Variação de ângulo ( $\sigma_m$ )	Ângulo discreto ( $\sigma_d$ ) <sub>8E</sub>
$\sigma_m < 22.5^\circ$	$\sigma_d = 0$
$22.5^\circ \leq \sigma_m < 45^\circ$	$\sigma_d = 1$
$45^\circ \leq \sigma_m < 67.5^\circ$	$\sigma_d = 2$
$67.5^\circ \leq \sigma_m < 90^\circ$	$\sigma_d = 3$
$90^\circ \leq \sigma_m < 112.5^\circ$	$\sigma_d = 4$
$112.5^\circ \leq \sigma_m < 135^\circ$	$\sigma_d = 5$
$135^\circ \leq \sigma_m < 157.5^\circ$	$\sigma_d = 6$
$157.5^\circ \leq \sigma_m < 180^\circ$	$\sigma_d = 7$

Realizando uma análise mais fina do processo, pode-se ter um maior grau de certeza que dois pontos característicos principais representam a mesma região quando três ou mais dígitos estejam presentes em ambas as assinaturas (Tab. 4.14) e (Tab. 4.15).

Tab. 4.14. Informação da assinatura completa e reduzida fazendo uso do código direcional de 8 estados para curva número 1.

		Ângulo entre os pontos				
		PE1 PP PD1	PE2 PP PE3	PD2 PP PD3	PD1 PP PD2	PE1 PP PE2
$(\sigma_m)$	Ângulo Principal ~33°	~18°	~52°	~87°	~98°	
$(\sigma_d)_{8E}$	1 1° Dígito	0 2° Dígito	2 3° Dígito	3 4° Dígito	4 5° Dígito	
Assinatura Completa		1 0 2 3 2 1° Dígito 2° Dígito 3° Dígito 4° Dígito 5° Dígito				
Assinatura Reduzida		1 0 2 3 2				

Tab. 4.15. Informação da assinatura completa e reduzida fazendo uso do código direcional de 8 estados para curva número 2.

		Ângulo entre os pontos				
		PE1 PP PD1	PE2 PP PE3	PD2 PP PD3	PE1 PP PE2	PD1 PP PD2
$(\sigma_m)$	Ângulo Principal ~33°	~15°	~52°	~82°	~87°	
$(\sigma_d)_{4E}$	1 1° Dígito	0 2° Dígito	2 3° Dígito	3 4° Dígito	3 5° Dígito	
Assinatura Completa		1 0 2 3 3 1° Dígito 2° Dígito 3° Dígito 4° Dígito 5° Dígito				
Assinatura Reduzida		1 0 2 3				

De acordo com o procedimento anterior, pode-se dizer que a discretização fina de ângulos será utilizada para casos onde existe ambiguidade de resultados. Uma ambiguidade é caracterizada quando três dígitos de cinco são encontrados em ambas as assinaturas, ou no caso em que apareçam múltiplas assinaturas completas. A discretização fina, então, favorecerá uma correta diferenciação das correspondências obtidas. Ao utilizar este processo, um ponto ruidoso detectado como ponto característico ou a ausência de um ponto característico só afetará as assinaturas de seus seis pontos vizinhos.

## **4.2. DISCUSSÃO**

- O descritor proposto representa pontos característicos de uma curva através de assinatura numérica de cinco dígitos;
- A assinatura é invariante à escala devido ao fato de que utiliza ângulos como parâmetros característicos;
- A assinatura é invariante à rotação devido a que ângulos discretos são ordenados.

## 5. AVALIAÇÃO DO DESCRITOR

Neste capítulo será analisado o desempenho da técnica proposta em detectar pontos característicos verdadeiros e falsos em contornos com ou sem ruído a nível multiescala. E também será apresentado o algoritmo de pré-alinhamento de imagens de profundidade e os resultados experimentais obtidos na pesquisa.

### 5.1. TRATAMENTO DE RUÍDO

A tarefa de comparar resultados não é fácil, uma vez que classificar um ponto depende em grande medida da aplicação ou do ponto de vista do usuário.

O parâmetro utilizado pelo detector proposto nesse trabalho é o parâmetro de desempenho  $\mu_{NLMS}$  (Eq. 2.1), cuja função é minimizar a influência de ruído e remover irregularidades. Assim, o parâmetro de desempenho a ser selecionado depende da quantidade de ruído presente no contorno que se quer minimizar.

Em busca de resultados comparativos com outras técnicas de detecção de pontos característicos foi selecionado o trabalho de Dmitry e Zsolt (1999), que agrupa resultados de outros autores como: Ronsel e Jonhston (1973), Ronsel e Weszka (1975), Freeman e Davis (1977) e Beus e Tiu (1987). Para testar o descritor proposto, as imagens de teste foram retiradas do mesmo artigo de Dmitry e Zsolt (1999), impressas e posteriormente digitalizadas (Fig. 5.1). Cabe destacar que durante o processo de digitalização, involuntariamente, existe uma adição de ruído nas imagens. Estas imagens servirão como parâmetro de entrada para testar a robustez do algoritmo em relação a ruído.

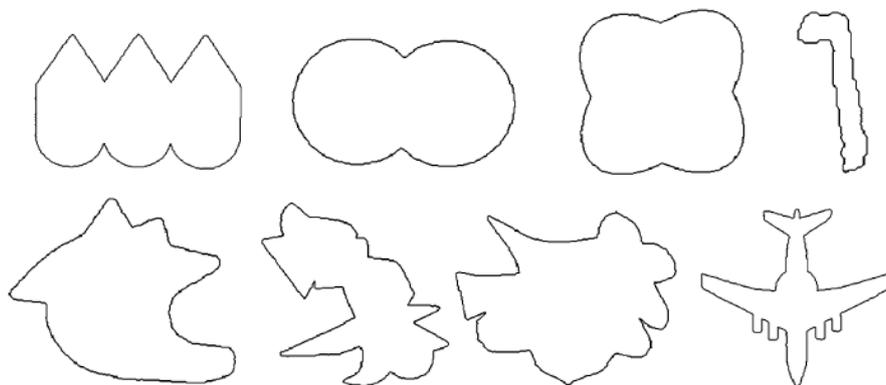


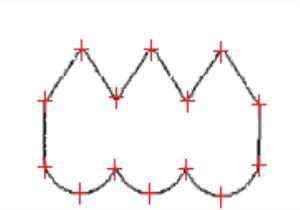
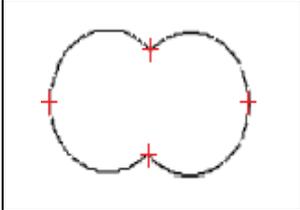
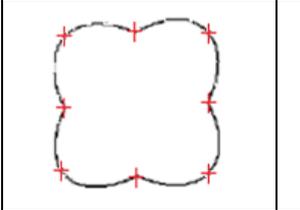
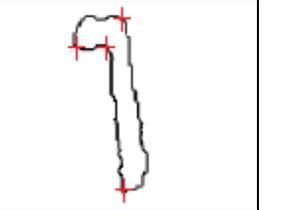
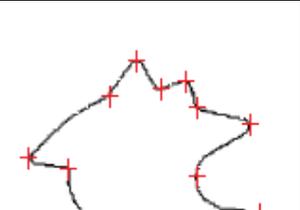
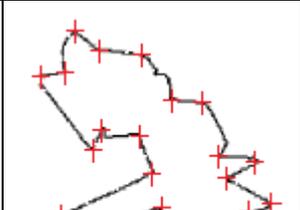
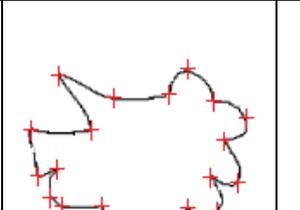
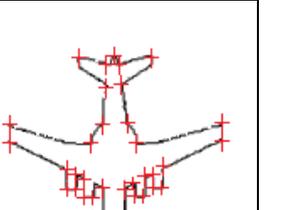
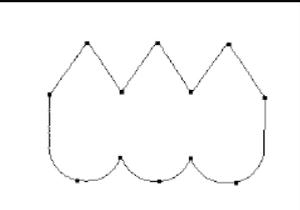
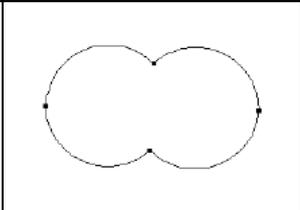
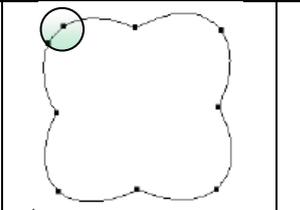
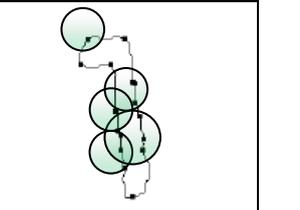
Fig.5.1. Oito exemplos de imagens usadas no teste.

Nestes testes não se programaram os algoritmos de cada técnica para detectar os pontos característicos, apenas utilizaram-se, de modo comparativo, os resultados já publicados no trabalho de (Dmitry e Zsolt, 1999), expostos na tabela (5.1).

Para avaliar o descritor proposto com relação ao desempenho de uma melhor detecção em contornos com ruídos, o descritor será comparado com os resultados obtidos com um parâmetro de seletividade, que classifica número de pontos verdadeiros (V) e número de pontos falsos (F), por cada técnica, quando a imagem resultante é comparada com uma imagem de referência. Uma imagem de referência apresenta os pontos característicos esperados que seriam detectados através de seletividade manual, independente do nível do ruído. A seguir, são apresentados os resultados obtidos durante esta pesquisa. Os pontos característicos falsos estão marcados com um círculo.

Seletividade	V	X
	F	X

Tabela 5.1. Tabela de comparação de resultados entre o algoritmo desenvolvido e demais técnicas.

IMAGENS DE REFERÊNCIA																			
																			
Seletividade <table border="1"><tr><td>V</td><td>14</td></tr><tr><td>F</td><td>0</td></tr></table>	V	14	F	0	Seletividade <table border="1"><tr><td>V</td><td>4</td></tr><tr><td>F</td><td>0</td></tr></table>	V	4	F	0	Seletividade <table border="1"><tr><td>V</td><td>8</td></tr><tr><td>F</td><td>0</td></tr></table>	V	8	F	0	Seletividade <table border="1"><tr><td>V</td><td>4</td></tr><tr><td>F</td><td>0</td></tr></table>	V	4	F	0
V	14																		
F	0																		
V	4																		
F	0																		
V	8																		
F	0																		
V	4																		
F	0																		
																			
Seletividade <table border="1"><tr><td>V</td><td>12</td></tr><tr><td>F</td><td>0</td></tr></table>	V	12	F	0	Seletividade <table border="1"><tr><td>V</td><td>21</td></tr><tr><td>F</td><td>0</td></tr></table>	V	21	F	0	Seletividade <table border="1"><tr><td>V</td><td>19</td></tr><tr><td>F</td><td>0</td></tr></table>	V	19	F	0	Seletividade <table border="1"><tr><td>V</td><td>34</td></tr><tr><td>F</td><td>0</td></tr></table>	V	34	F	0
V	12																		
F	0																		
V	21																		
F	0																		
V	19																		
F	0																		
V	34																		
F	0																		
DESCRITOR RONSELF E JONHSTON, (1973)																			
																			

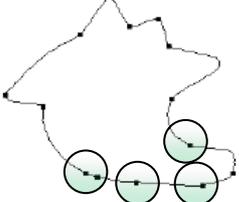
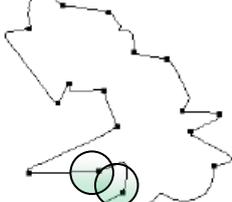
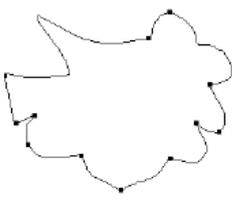
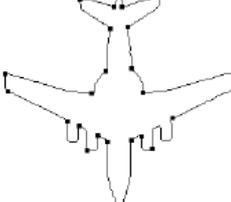
Seletividade	V	13	Seletividade	V	4	Seletividade	V	8	Seletividade	V	4
	F	0		F	0		F	1		F	10
Seletividade	V	12	Seletividade	V	18	Seletividade	V	17	Seletividade	V	17
	F	0		F	0		F	0		F	1

DESCRITOR RONSELF E WESZKA, (1975)

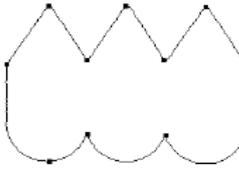
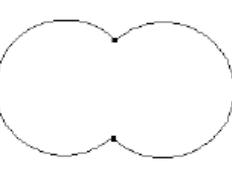
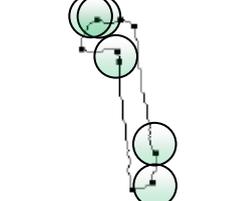
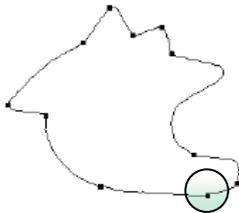
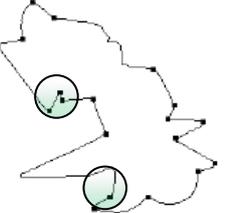
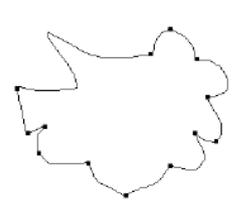
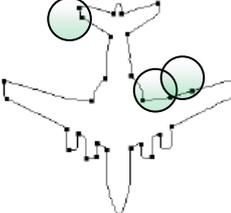
Seletividade	V	10	Seletividade	V	4	Seletividade	V	8	Seletividade	V	4
	F	3		F	0		F	0		F	12
Seletividade	V	9	Seletividade	V	18	Seletividade	V	19	Seletividade	V	19
	F	4		F	1		F	0		F	0

DESCRITOR FREEMAN E DAVIS, (1977)

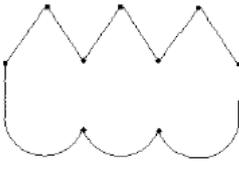
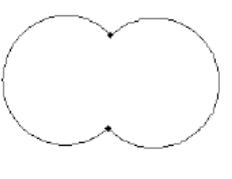
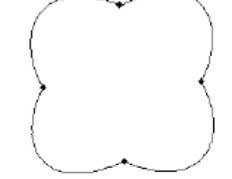
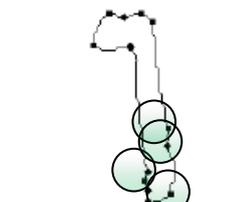
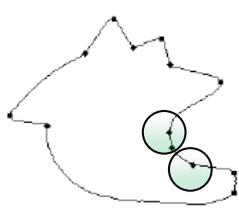
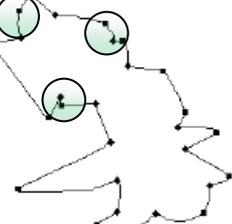
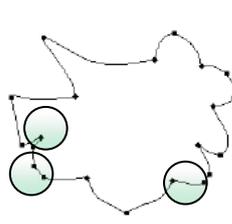
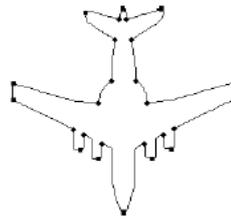
Seletividade	V	11	Seletividade	V	2	Seletividade	V	4	Seletividade	V	4
	F	0		F	0		F	0		F	4

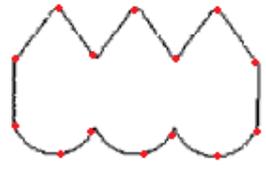
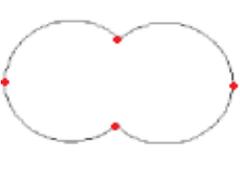
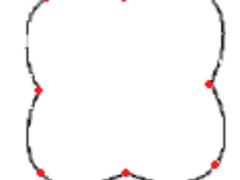
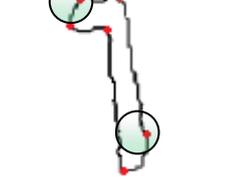
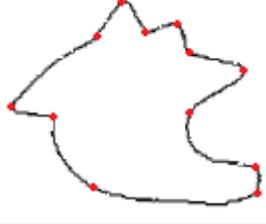
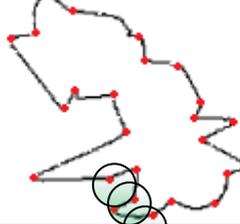
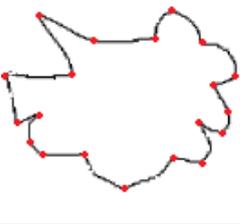
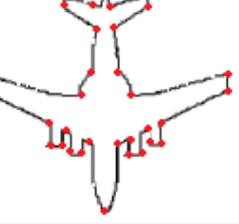
																			
Seletividade <table border="1"><tr><td>V</td><td>9</td></tr><tr><td>F</td><td>4</td></tr></table>	V	9	F	4	Seletividade <table border="1"><tr><td>V</td><td>16</td></tr><tr><td>F</td><td>2</td></tr></table>	V	16	F	2	Seletividade <table border="1"><tr><td>V</td><td>11</td></tr><tr><td>F</td><td>0</td></tr></table>	V	11	F	0	Seletividade <table border="1"><tr><td>V</td><td>21</td></tr><tr><td>F</td><td>0</td></tr></table>	V	21	F	0
V	9																		
F	4																		
V	16																		
F	2																		
V	11																		
F	0																		
V	21																		
F	0																		

DESCRITOR BEUS E TIU (1987)

																			
Seletividade <table border="1"><tr><td>V</td><td>11</td></tr><tr><td>F</td><td>0</td></tr></table>	V	11	F	0	Seletividade <table border="1"><tr><td>V</td><td>2</td></tr><tr><td>F</td><td>0</td></tr></table>	V	2	F	0	Seletividade <table border="1"><tr><td>V</td><td>4</td></tr><tr><td>F</td><td>0</td></tr></table>	V	4	F	0	Seletividade <table border="1"><tr><td>V</td><td>4</td></tr><tr><td>F</td><td>5</td></tr></table>	V	4	F	5
V	11																		
F	0																		
V	2																		
F	0																		
V	4																		
F	0																		
V	4																		
F	5																		
																			
Seletividade <table border="1"><tr><td>V</td><td>10</td></tr><tr><td>F</td><td>0</td></tr></table>	V	10	F	0	Seletividade <table border="1"><tr><td>V</td><td>15</td></tr><tr><td>F</td><td>1</td></tr></table>	V	15	F	1	Seletividade <table border="1"><tr><td>V</td><td>13</td></tr><tr><td>F</td><td>0</td></tr></table>	V	13	F	0	Seletividade <table border="1"><tr><td>V</td><td>24</td></tr><tr><td>F</td><td>3</td></tr></table>	V	24	F	3
V	10																		
F	0																		
V	15																		
F	1																		
V	13																		
F	0																		
V	24																		
F	3																		

DESCRITOR CHETVERIKOV E SZABO, (1999)

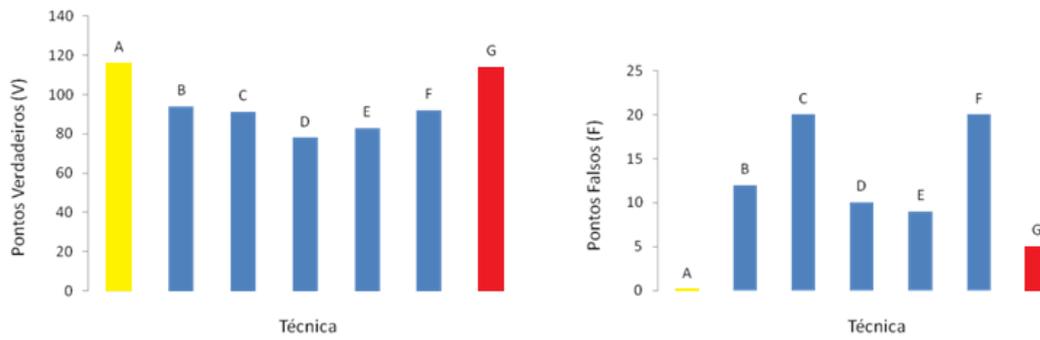
																			
Seletividade <table border="1"><tr><td>V</td><td>9</td></tr><tr><td>F</td><td>0</td></tr></table>	V	9	F	0	Seletividade <table border="1"><tr><td>V</td><td>2</td></tr><tr><td>F</td><td>0</td></tr></table>	V	2	F	0	Seletividade <table border="1"><tr><td>V</td><td>4</td></tr><tr><td>F</td><td>0</td></tr></table>	V	4	F	0	Seletividade <table border="1"><tr><td>V</td><td>4</td></tr><tr><td>F</td><td>9</td></tr></table>	V	4	F	9
V	9																		
F	0																		
V	2																		
F	0																		
V	4																		
F	0																		
V	4																		
F	9																		
																			

<table border="1"> <tr><td>Seletividade</td><td>V</td><td>11</td></tr> <tr><td></td><td>F</td><td>2</td></tr> </table>	Seletividade	V	11		F	2	<table border="1"> <tr><td>Seletividade</td><td>V</td><td>20</td></tr> <tr><td></td><td>F</td><td>4</td></tr> </table>	Seletividade	V	20		F	4	<table border="1"> <tr><td>Seletividade</td><td>V</td><td>16</td></tr> <tr><td></td><td>F</td><td>5</td></tr> </table>	Seletividade	V	16		F	5	<table border="1"> <tr><td>Seletividade</td><td>V</td><td>26</td></tr> <tr><td></td><td>F</td><td>0</td></tr> </table>	Seletividade	V	26		F	0
Seletividade	V	11																									
	F	2																									
Seletividade	V	20																									
	F	4																									
Seletividade	V	16																									
	F	5																									
Seletividade	V	26																									
	F	0																									
<b>DESCRITOR PROPOSTO (2014)</b>																											
																											
<table border="1"> <tr><td>Seletividade</td><td>V</td><td>14</td></tr> <tr><td></td><td>F</td><td>0</td></tr> </table>	Seletividade	V	14		F	0	<table border="1"> <tr><td>Seletividade</td><td>V</td><td>4</td></tr> <tr><td></td><td>F</td><td>0</td></tr> </table>	Seletividade	V	4		F	0	<table border="1"> <tr><td>Seletividade</td><td>V</td><td>8</td></tr> <tr><td></td><td>F</td><td>0</td></tr> </table>	Seletividade	V	8		F	0	<table border="1"> <tr><td>Seletividade</td><td>V</td><td>4</td></tr> <tr><td></td><td>F</td><td>2</td></tr> </table>	Seletividade	V	4		F	2
Seletividade	V	14																									
	F	0																									
Seletividade	V	4																									
	F	0																									
Seletividade	V	8																									
	F	0																									
Seletividade	V	4																									
	F	2																									
																											
<table border="1"> <tr><td>Seletividade</td><td>V</td><td>12</td></tr> <tr><td></td><td>F</td><td>0</td></tr> </table>	Seletividade	V	12		F	0	<table border="1"> <tr><td>Seletividade</td><td>V</td><td>21</td></tr> <tr><td></td><td>F</td><td>3</td></tr> </table>	Seletividade	V	21		F	3	<table border="1"> <tr><td>Seletividade</td><td>V</td><td>19</td></tr> <tr><td></td><td>F</td><td>0</td></tr> </table>	Seletividade	V	19		F	0	<table border="1"> <tr><td>Seletividade</td><td>V</td><td>32</td></tr> <tr><td></td><td>F</td><td>0</td></tr> </table>	Seletividade	V	32		F	0
Seletividade	V	12																									
	F	0																									
Seletividade	V	21																									
	F	3																									
Seletividade	V	19																									
	F	0																									
Seletividade	V	32																									
	F	0																									

Para ter uma maior representação dos dados apresentados na tabela anterior, foi feito um levantamento de dados estatísticos de todos os pontos identificados como pontos verdadeiros e pontos falsos pertencentes a cada técnica. No gráfico (5.2) apresentam-se os resultados obtidos no processo de registro de informação.

Em uma comparação dos resultados se observa que a técnica proposta oferece maior número de pontos correspondentes verdadeiros e baixo número de pontos característicos falsos, aproximando-se muito dos resultados obtidos na identificação manual. Cabe mencionar que o descritor proposto utilizou como valor de parâmetro de desempenho,  $\mu_{NLMS} = 0.9$ , (Eq. 2.1) para todas as imagens. Este valor foi escolhido por existir um baixo nível de ruído nas imagens.

Para avaliar o desempenho do descritor em múltiplas escalas as imagens de referência foram reduzidas a duas escalas diferentes como se apresenta na tabela (5.2).

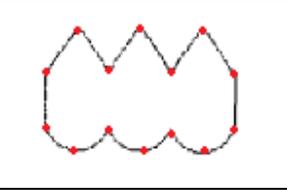
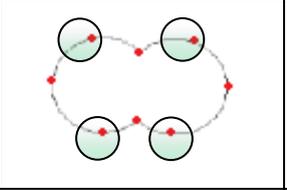
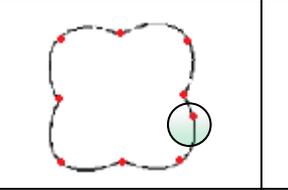
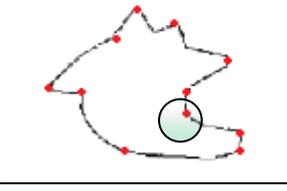
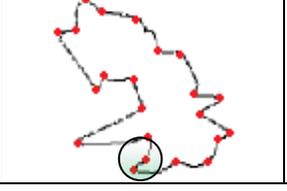
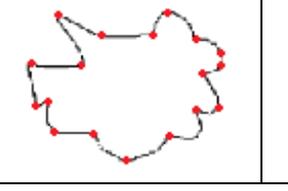
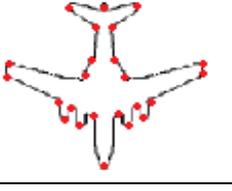
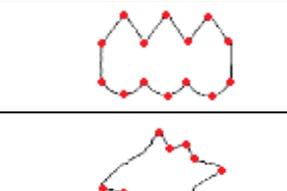
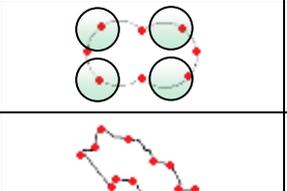
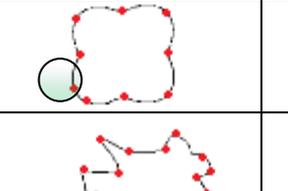
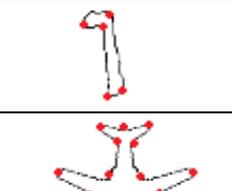
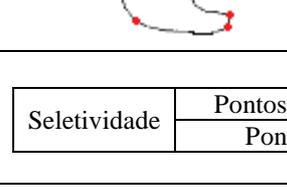
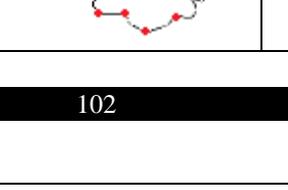
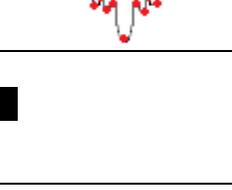


TÉCNICA	SÍMBOLO	PONTOS VERDADEIROS	PONTOS FALSOS
IDENTIFICAÇÃO MANUAL	A	116	0
DESCRITOR RONSELF E JONHSTON, (1973)	B	94	12
DESCRITOR RONSELF E WESZKA, (1975)	C	91	20
DESCRITOR FREEMAN E DAVIS, (1977)	D	78	10
DESCRITOR BEUS E TIU (1987)	E	83	9
DESCRITOR CHETVERIKOV E SZABO (1999)	F	92	20
DESCRITOR PROPOSTO (2014)	G	114	5

Fig. 5.2. Dados estatísticos da tabela 5.1.

Tab. 5.2. Desempenho do descritor em diferentes escalas.

Descritor Proposto (2014)			
Escala 1:1			
Seletividade	Pontos Verdadeiros	5	114
	Pontos Falsos	5	

ESCALA 1:0.75			
			
			
Seletividade	Pontos Verdadeiros	105	
	Pontos Falsos	7	
ESCALA 1:0.50			
			
			
Seletividade	Pontos Verdadeiros	102	
	Pontos Falsos	5	

De acordo os resultados experimentais da tabela (5.2) o parâmetro de seletividade indica que existe uma variação baixa na detecção de pontos verdadeiros e falsos nas três escalas.

A seguir se apresentam os resultados obtidos em imagens com ruído elevado (Fig.5.3).

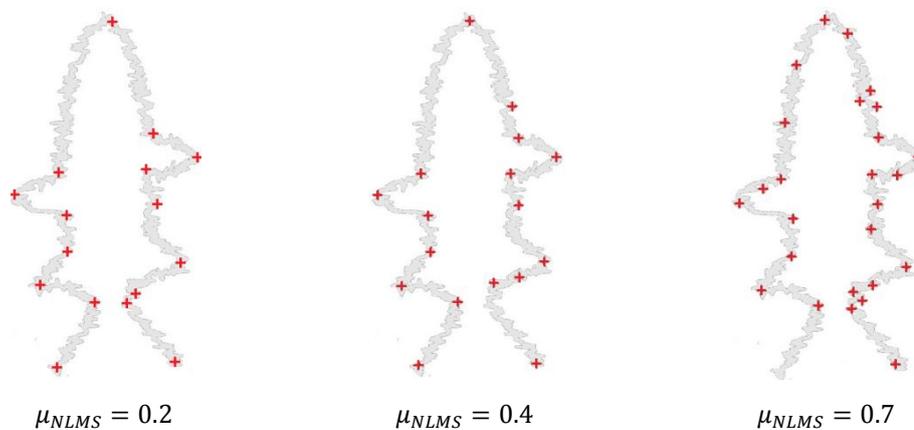


Fig.5.3. Seleção do parâmetro de desempenho  $\mu_{NLMS}$ .

Na figura (5.3) pode-se observar que, ao aumentar o valor do parâmetro de desempenho, os pontos característicos aparecem seguindo o contorno da figura. Este processo é típico de algoritmos adaptativos. Para o processo de alinhamento de duas imagens de profundidade, recomenda-se ter uma grande quantidade de pontos em ambas as imagens, já que se tem maior probabilidade de encontrar assinaturas correspondentes. O parâmetro de desempenho também permite regular o número de pontos de um contorno.

Outro procedimento realizado para verificar o desempenho do descritor proposto foi utilizar imagens que contivessem um grau de perspectiva. Inicialmente foi selecionada uma imagem de referência e, posteriormente, através do descritor proposto, detectados os pontos característicos. Estes pontos foram identificados como pontos de referência através do símbolo (◆) ver figura (5.4).

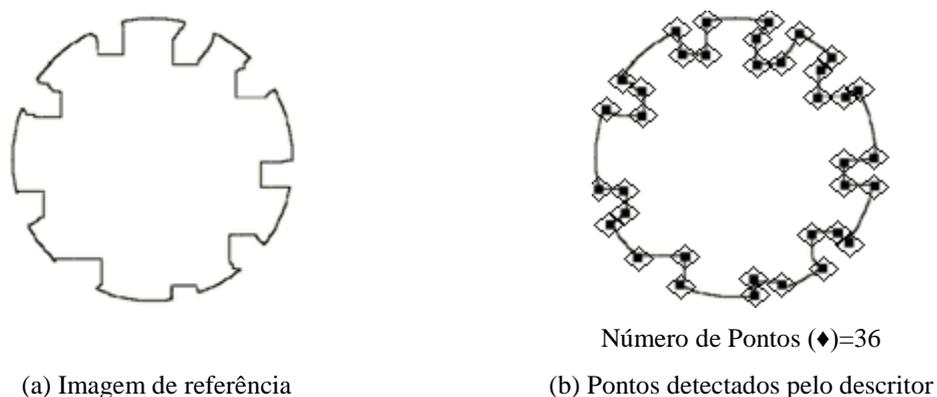
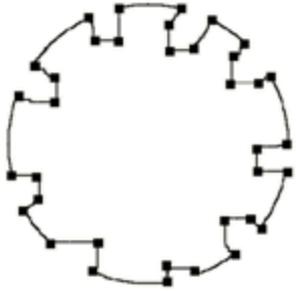
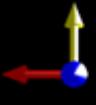
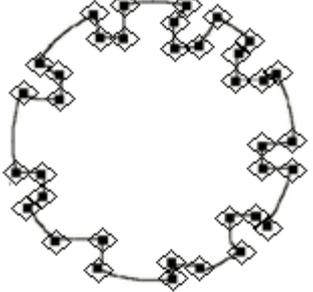
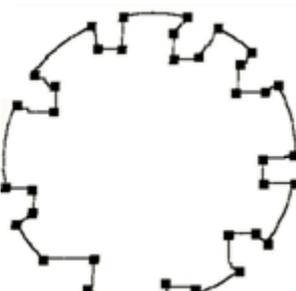
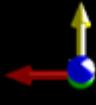
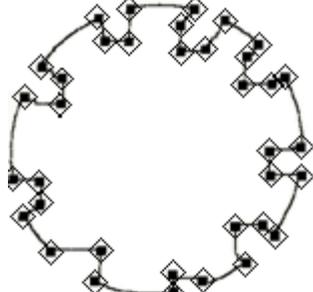
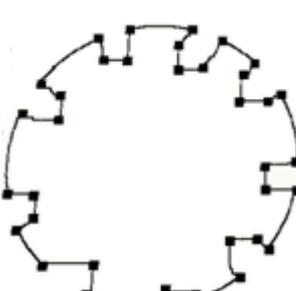
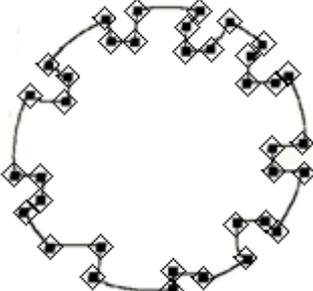
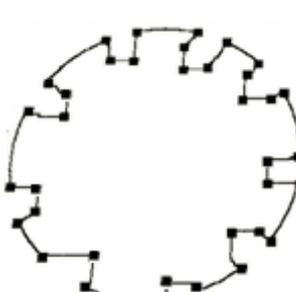
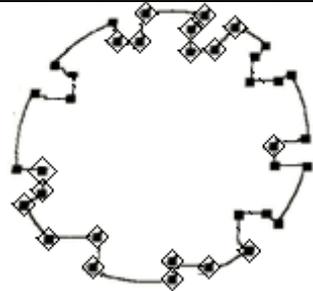
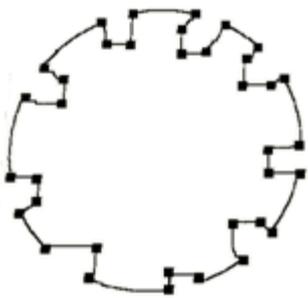
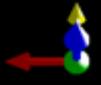
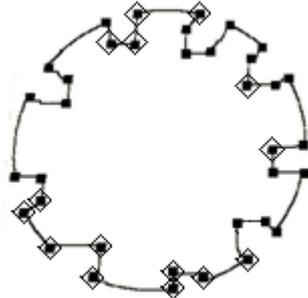
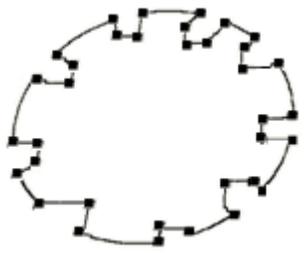
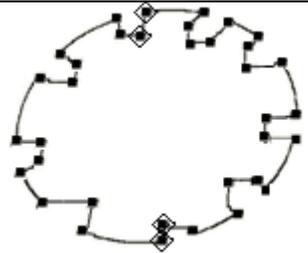
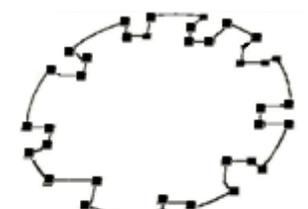
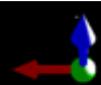
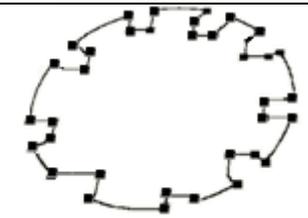


Fig.5.4. Imagens de referência para avaliar o desempenho do descritor quando trabalha com imagens com diferentes graus de perspectiva ( $\mu_{NLMS} = 1.0$ ).

Em seguida, a imagem foi girada em torno do seu centro geométrico em diferentes ângulos ( $\theta_i$ ). Para cada imagem foi então aplicado o algoritmo proposto e em seguida os pontos característicos foram identificados e comparados com os pontos da imagem de referência (Fig. 6.4b) usando o símbolo (◆). Na identificação dos pontos não se utilizou o critério de similaridade para conhecer o comportamento do descritor em imagens que apresentem perspectiva. A seguir são apresentados os resultados na tabela (5.3).

Tab. 5.3. Desempenho do descritor em imagens com diferentes graus de perspectiva

Pontos detectados pelo descritor	Orientação da imagem. Ângulo ( $\theta_i$ )	Reconhecimento de pontos
	$0^{\circ}$ 	 Número de Pontos (◆)=36
	$5^{\circ}$ 	 Número de Pontos (◆)=36
	$10^{\circ}$ 	 Número de Pontos (◆)=36
	$15^{\circ}$ 	 Número de Pontos (◆)=19

	$20^{\circ}$ 	 Número de Pontos (♦)=15
	$25^{\circ}$ 	 Número de Pontos (♦)=4
	$30^{\circ}$ 	 Número de Pontos (♦)=0

Os ângulos de rotação em função do número de pontos identificados estão apresentados na tabela (5.3). Observa-se que o número de pontos característicos diminui quando o ângulo de rotação aumenta (Fig. 5.5), como esperado.

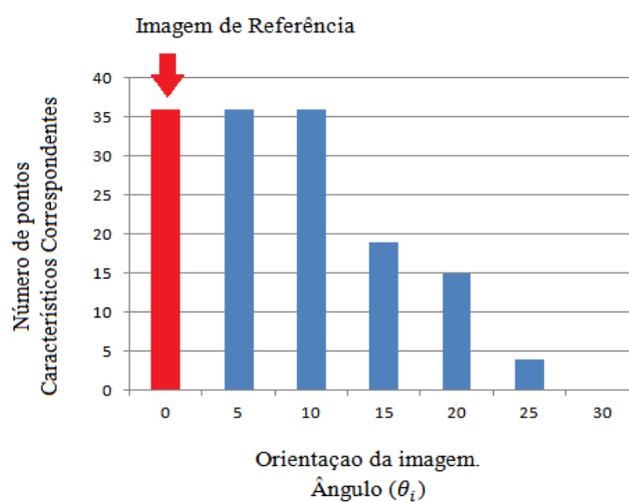


Fig.5.5. Gráfico ângulo de rotação vs número de pontos característicos correspondentes.

Este último procedimento foi repetido para diferentes tipos de curvas e o resultado foi o mesmo. A técnica proposta consegue identificar pontos de uma mesma imagem, quando está girada até um valor máximo de  $20^{\circ}$  sem fazer uso o critério de similaridade.

### 5.1.1. Resultados experimentais

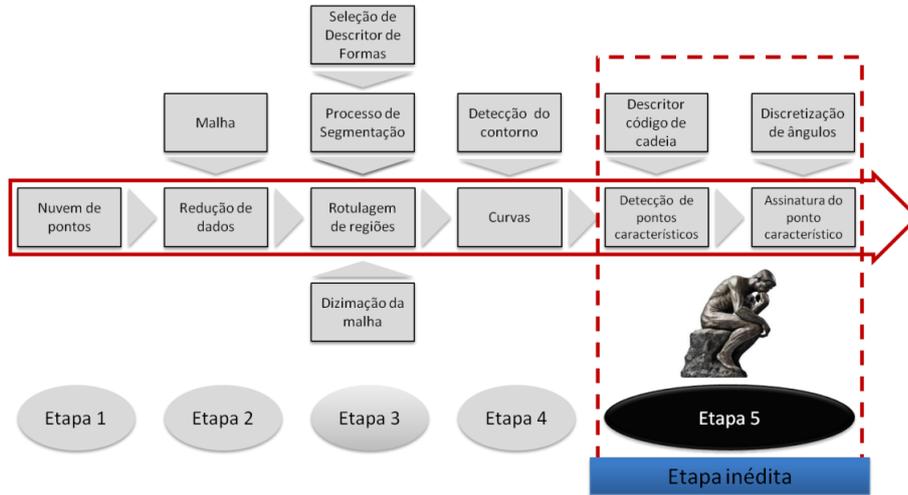
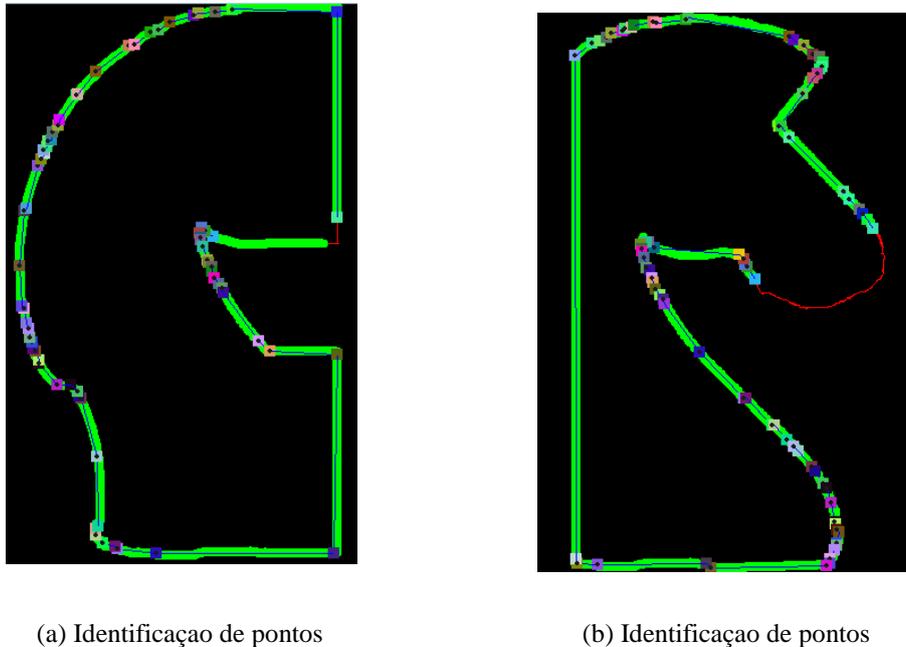


Fig. 5.6 Etapas usadas no desenho do descritor proposto- Etapa 5.

Apresentam-se, neste item, os resultados experimentais do processo proposto para o projeto do descritor (Fig.5.6), com os procedimentos experimentais para a identificação de pontos característicos das imagens de contorno do cavalo.



(a) Identificação de pontos

(b) Identificação de pontos

Fig.5.7. Deteção de pontos do contorno da imagem de profundidade. Objeto cavalo

Na figura (5.7), mostra-se a deteção de variação de direção da curvatura,

descrita por meio dos ângulos que se formam entre as linhas que conectam os pontos.

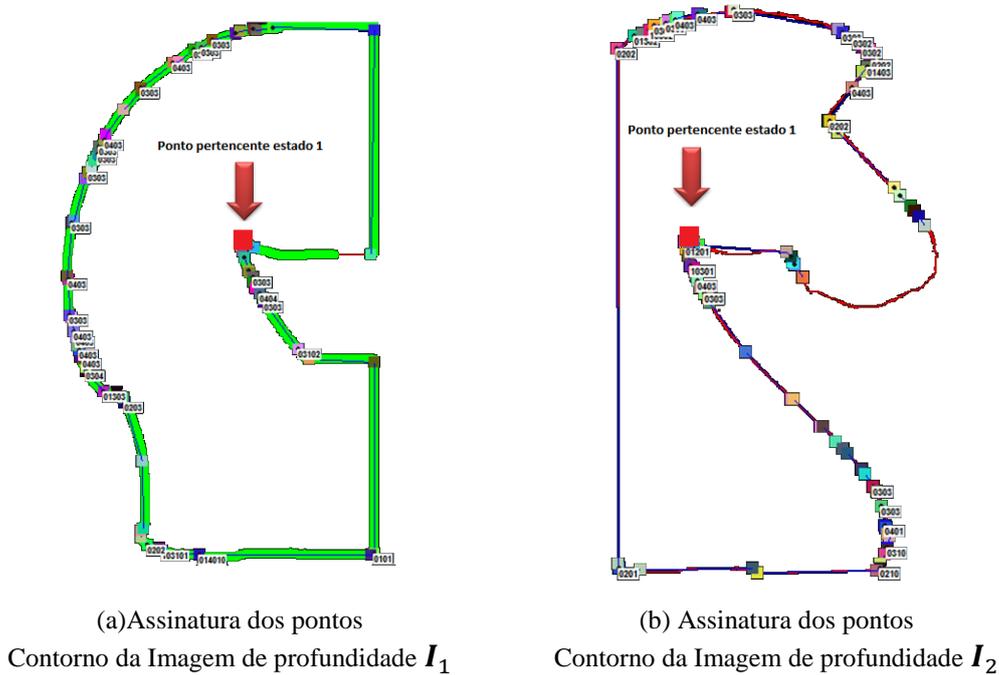


Fig.5.8 Detecção de pontos do contorno da imagem de profundidade – Cavallo.

Na tabela (5.4), são mostradas algumas assinaturas completas e reduzidas da imagem de contorno  $I_1$  e da imagem de contorno  $I_2$ . Para facilitar a visualização dos dados, foram identificadas manualmente, com a mesma cor, assinaturas correspondentes que descrevem o mesmo ponto nas duas imagens de profundidade (Fig. 5.8).

Tabela 5.4. Obtenção de assinaturas completa e reduzida da imagem de profundidade – Cavallo.

IMAGEM DE PROFUNDIDADE $I_1$		IMAGEM DE PROFUNDIDADE $I_2$	
Assinatura completa	Assinatura reduzida	Assinatura completa	Assinatura reduzida
31000	31	20123	2123
20123	2123	11223	1123
11223	3023	30023	3023
30023	3023	30003	303
30003	303	30013	3013
30013	313	30023	3023
30023	323	30003	303
30003	303	30013	3013
30013	313	30003	303
30003	303	30023	3023
30023	323	30013	3013
30123	30123	30023	3023
30012	312	30003	303
30004	304	30013	3013

## 5.2. ALGORITMO DE BUSCA DE PONTOS CORRESPONDENTES

Uma etapa no processo de busca de correspondências é a seleção dos pontos de interesse, ou seja, aqueles pontos que têm uma especial relevância dentro de cada nuvem de pontos ou simplifiquem a busca. Existe um grande número de técnicas de

busca que permitem encontrar correspondências. Estas técnicas são subdivididas em diversos ramos, sendo os principais: Aprendizagem de máquina, IA simbólica, Redes Neurais Artificiais (RNA), dentre outros. O foco deste trabalho é a utilização de técnicas de aprendizagem de máquina, em particular, uma adaptação técnicas baseadas na regra do vizinho mais próximo K-NN (*K-Nearest Neighbor*). O K-NN possui um parâmetro chamado K, que indica o número de vizinhos que serão usados. O parâmetro K faz com que algoritmo consiga uma classificação mais refinada, porém o valor ótimo de K varia de um problema para o outro, o que faz com que, para cada base de dados, sejam testados vários valores diferentes de forma a descobrir qual o melhor valor de K para determinado problema.

### 5.2.1 Algoritmo K-NN para identificar pontos característicos correspondentes

O algoritmo que classifica dois pontos característicos correspondentes se baseia na densidade de probabilidade de votos dados pelos *k*-anteriores e próximos vizinhos que rodeia os ditos pontos;

O algoritmo de classificação proposto para este trabalho de pesquisa é o seguinte:

- Passo [1]. Selecione duas imagens de contorno,  $I_1$  e  $I_2$ ;
- Passo [2]. Obtenha para cada mapa de contorno assinaturas dos pontos característicos usando o descritor proposto;
- Passo [3]. Reúna, organize e quantifique em uma tabela o conjunto de assinaturas (completa ou reduzida) que pertença ao mesmo estado. A figura (5.9) descreve o processo. O primeiro dígito do código indica o estado a que pertence cada assinatura. Realize este mesmo procedimento para ambas as imagens de contorno.

A coluna **Quantidade** indica o número de assinaturas pertencentes a cada estado.

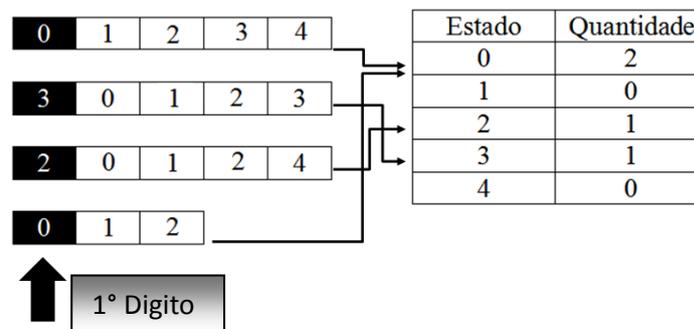


Fig.5.9. Exemplo de organização e quantificação de assinaturas.



<i>IF</i>	(assinaturas completas são iguais)
	Selecione os $K_{i2}$ próximos vizinhos da imagem do contorno $I_2$ e verifique assinaturas completas vizinhas correspondentes;
<i>IF</i>	(assinaturas completas vizinhas são iguais)
	Realize uma comparação de assinaturas completas usando o critério de similaridade;
<i>IF</i>	(Assinaturas completas cumprem o critério de similaridade)
	Ponto correspondente +=1;
<i>ELSE</i>	
	Realize uma comparação de assinaturas completas usando o critério de similaridade;
	<i>IF</i> (Assinaturas completas cumprem o critério de similaridade)
	Ponto correspondente com ruído +=1;
<i>ELSE</i>	
	Realize uma comparação de assinaturas completas usando o critério de similaridade;
<i>IF</i>	(Assinaturas completas cumprem o critério de similaridade)
	Selecione os $K_{i2}$ próximos vizinhos da imagem do contorno $I_2$ e verifique assinaturas completas vizinhas correspondentes;
<i>IF</i>	(Assinaturas completas cumprem o critério de similaridade)
	Ponto correspondente com ruído +=1;
<i>IF</i>	(Ponto correspondente =0 e Ponto correspondente com ruído=0)
	Continue com outra assinatura em $I_1$ . A assinatura pode pertencer ao conjunto de assinaturas do mesmo estado. No caso que não exista, continue com o estado que contenha igual o maior número de assinaturas, (Fig.6.12). Vá para o passo [4] e repita o processo;
<p>The figure shows a bar chart with two columns: 'Estado' (State) and 'Quantidade' (Quantity). The 'Estado' column has 8 categories labeled 0 through 7. The 'Quantidade' column has 8 rows labeled 0 through 7. The bars for each state are colored: 0 (orange), 1 (green), 2 (blue), 3 (red), 4 (purple), 5 (yellow), 6 (brown), 7 (grey). The bars for state 3 are the tallest, indicating the highest frequency. An arrow labeled 'Ponto Selecionado' points to the bar for state 3.</p>	
<p>Fig.5.12. Detecção do ponto cujo estado esteja representado em maior proporção que o ponto detectado da Fig.(5.10).</p>	
<i>END</i>	

Como já foi comentado nos capítulos anteriores, a busca de correspondências entre as duas nuvens de pontos é a parte do algoritmo de alinhamento que apresenta mais dificuldade. Utilizando o descritor proposto e o critério de similaridade (seção 4.1.5.3), foi desenvolvido um algoritmo que busca a correspondência aproximada entre pontos de interesse de duas nuvens de pontos que se deseja alinhar. Como vários pontos correspondentes devem aparecer, várias transformações serão determinadas. Para verificar a validade das transformações candidatas, cada uma delas passa por uma avaliação de erros de ajuste entre as duas imagens de profundidade através do algoritmo ICP. A transformação que alinha o maior número de pontos é considerada a solução.

### 5.2.2. Resultado experimental do algoritmo de pré-alinhamento

Seguindo o procedimento apresentado do algoritmo K-NN e aplicado nas imagens do contorno do cavalo  $I_1$  e  $I_2$ , foram obtidos os resultados apresentados na figura (5.13) e tabela (5.5).

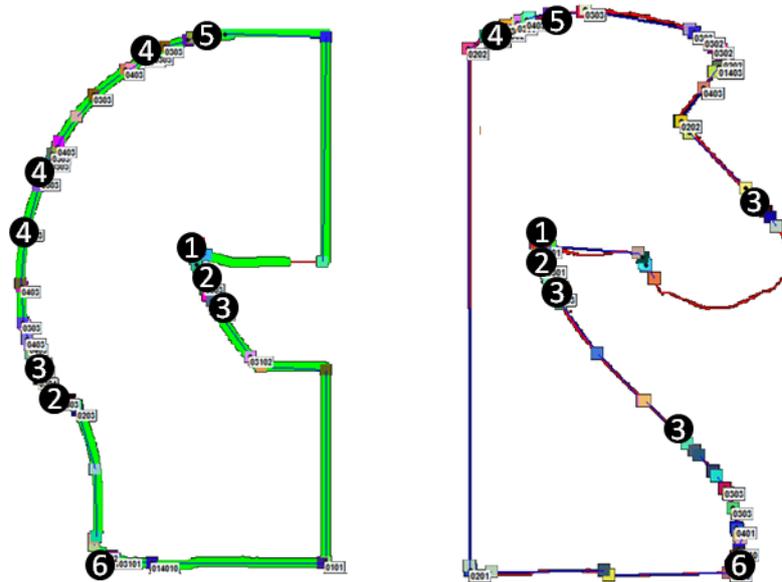


Fig. 5.13. Identificação de pontos correspondentes usando algoritmo K-NN.

Tab. 5.5. Número de pontos correspondentes identificados - Imagem do cavalo.

Pontos correspondentes	6
Pontos correspondentes com ruído	29

Na identificação de assinaturas da figura (5.14) aparecem vários pontos que contêm o mesmo de código de assinatura, mas que representam diferentes regiões do objeto. Para atenuar esta ambiguidade, a solução proposta é utilizar novamente o algoritmo K-NN, que permite determinar se dois pontos pertencem a uma mesma região, em função da proximidade de outros vizinhos. Posteriormente, valida-se cada correspondência utilizando o algoritmo ICP (Fig. 5.14).

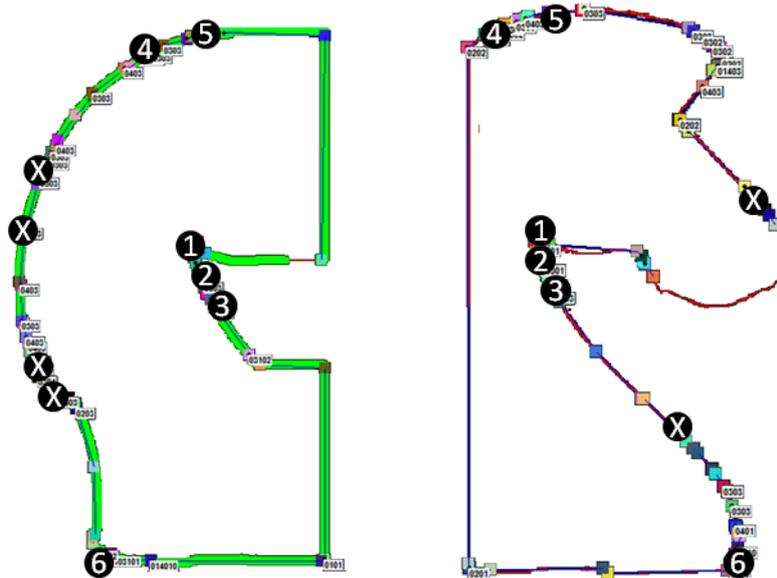


Fig. 5.14. Eliminação de pontos correspondentes usando algoritmo K-NN.

### 5.3. DISCUSSÃO

Neste capítulo foi descrito um conjunto de experimentos realizados para avaliar o desempenho da técnica proposta em detectar pontos característicos em contornos com ruído. Desta forma, foram apresentados resultados obtidos de pontos característicos correspondentes, fazendo uso de uma adaptação do algoritmo K-NN baseada na regra do vizinho mais próximo. Os resultados obtidos foram favoráveis para uma imagem de profundidade particular. Para ratificar os resultados de forma geral, no capítulo seguinte apresenta-se o tratamento de imagens de profundidade de outros objetos. O processo de alinhamento automático não é um processo que se trabalha nesta pesquisa, pois cada etapa é conferida manualmente.

## 6. ALINHAMENTO FINO

Neste ponto da tese o registro de imagens de profundidade é um problema que ainda não foi resolvido. Ainda falta realizar um tratamento da informação ao redor dos pontos característicos correspondentes encontrados, de tal forma que a metodologia a ser usada possa selecionar pontos correspondentes que sejam plenamente confiáveis. Neste trabalho a metodologia utilizada para alinhamento foi dividida em duas partes: Pré-alinhamento e alinhamento fino. A primeira parte já foi discutida e a segunda parte será apresentada neste capítulo.

### 6.1. METODOLOGIA

Um dos algoritmos mais utilizados para realizar o procedimento de ajuste fino é o ICP (*Iterative Closest Point*) (Besl e McKay em 1992). Através de um processo iterativo, o algoritmo original ICP cria pares de pontos  $p_i$  e  $q_i$  correspondentes nas duas imagens de profundidade ( $I_1$  e  $I_2$ ), usando como critério a distância euclidiana, e encontra uma transformação que minimiza a distância entre os pares de pontos correspondentes. A transformação encontrada é aplicada aos pontos da malha  $I_1$  ou  $I_2$  e o processo é repetido até que as transformações encontradas sejam desprezíveis (i.e. próximas da identidade). Um dos requisitos iniciais deste algoritmo é que as malhas tenham uma estimativa inicial do alinhamento. A qualidade do resultado do algoritmo ICP está diretamente ligada à qualidade deste posicionamento inicial.

Destaca-se que a principal contribuição deste trabalho é o desenvolvimento da técnica de pré-alinhamento e a integração desta técnica com a técnica de alinhamento fino, definindo de forma geral uma metodologia completa para registro e reconstrução de modelos tridimensionais.

A seguir é apresentado o método utilizado para encontrar a matriz de transformação que o algoritmo ICP deve receber como parâmetro de entrada.

#### 6.1.1. Modelo de matriz de transformação

Supõe-se que um ponto ( $p$ ) identificado na etapa de pré-alinhamento e localizado em  $\begin{bmatrix} x_{11} \\ y_{11} \end{bmatrix}$  da imagem de profundidade  $I_1$  pode ser encontrado em  $I_2$  através de uma transformação linear de similaridade representada por:

$$\begin{bmatrix} x_{12} \\ y_{12} \end{bmatrix} = \begin{bmatrix} S_x & 0 \\ 0 & S_y \end{bmatrix} \begin{bmatrix} 1 & r \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \cos \varphi & -\sin \varphi \\ \sin \varphi & \cos \varphi \end{bmatrix} \begin{bmatrix} x_{11} \\ y_{11} \end{bmatrix} + \begin{bmatrix} e \\ f \end{bmatrix} \quad (6.1)$$

, onde  $\begin{bmatrix} x_{12} \\ y_{12} \end{bmatrix}$  representa as coordenadas do ponto,  $S_x$  e  $S_y$  são fatores de escala para os eixos  $x$  e  $y$  respectivamente,  $r$  é um fator de não ortogonalidade entre eixos,  $\varphi$  é o ângulo de rotação sobre o plano e  $\begin{bmatrix} e \\ f \end{bmatrix}$  são fatores de translação.

A matriz de transformação da equação (6.1) pode ser reescrita como:

$$\begin{bmatrix} x_{12} \\ y_{12} \end{bmatrix} = \begin{bmatrix} a & b \\ c & d \end{bmatrix} \begin{bmatrix} x_{11} \\ y_{11} \end{bmatrix} + \begin{bmatrix} e \\ f \end{bmatrix} \quad (6.2)$$

em que :

$$a = S_x(\cos \varphi + r \sin \varphi);$$

$$b = S_x(-\sin \varphi + r \cos \varphi);$$

$$c = S_y \sin \varphi;$$

$$d = S_y \cos \varphi;$$

### I. Fatores da matriz de transformação

Para encontrar os coeficientes do vetor de transformação de forma experimental foi inserido em cada uma das imagens de profundidade  $I_1$  e  $I_2$ , um triângulo formado por três pontos  $p \begin{bmatrix} x_{1i} \\ y_{1i} \end{bmatrix}$ ,  $p \begin{bmatrix} x_{2i} \\ y_{2i} \end{bmatrix}$  e  $p \begin{bmatrix} x_{3i} \\ y_{3i} \end{bmatrix}$ . O objetivo é encontrar a área do triângulo inscrito em cada imagem e posteriormente ajustar e comparar o tamanho e orientação dos mesmos através de um marco de referência comum. Área pode ser obtida a partir de:

$$Area (\Delta_i) = \frac{1}{2} \begin{vmatrix} x_{1i} & y_{1i} & 1 \\ x_{2i} & y_{2i} & 1 \\ x_{3i} & y_{3i} & 1 \end{vmatrix} \quad (6.3)$$

Os fatores  $S_x$  e  $S_y$  se ajustam dependendo da proporção que exista entre os valores da área dos triângulos.

### II. Ajuste de Escala

Para este trabalho os mapas de profundidade de maior tamanho foram ajustados ao menor tamanho. O procedimento de comparação entre triângulos permitiu encontrar o ângulo de rotação ( $\varphi$ ), entre as imagens de profundidade. A Fig. 6.1 esquematiza o processo realizado.

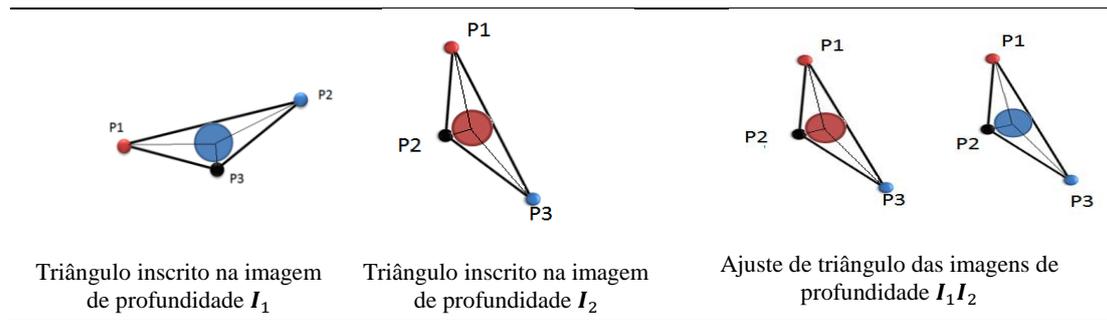


Fig. 6.1 Triângulos inscritos na imagem de profundidade para obter os coeficientes do vetor de transformação.

## 6.2. ADAPTAÇÃO DO ALGORITMO ICP

Uma vez calculada a matriz de transformação, são estabelecidos pontos correspondentes que são utilizados para calcular uma nova matriz de transformação, que será otimizada de maneira iterativa.

A seguir são apresentados os passos realizados, adaptando o algoritmo ICP para este trabalho.

Passo [1]	Aplica-se a matriz de transformação para a imagem de profundidade de maior escala, pelo contrario aplica-se para qualquer das imagens de profundidade;
Passo [2]	Para cada célula sobreposta $(i, j)$ da malha $I_1$ e $I_2$ : <ul style="list-style-type: none"> <li>(a) Escolhem-se os pontos característicos correspondentes detectados pelo algoritmo de pré-alinhamento <math>I_1 \Rightarrow \{p_{1i,j,k}\}</math>;</li> <li>(b) Para cada ponto selecionado <math>p_{1i,j}</math> busca-se o ponto mais próximo na célula <math>(i, j)</math> de <math>I_2</math>. Este ponto, <math>p_{2i,j,k}</math>, deve cumprir o seguinte: <ul style="list-style-type: none"> <li>❖ O ângulo que forma sua normal, <math>n_{2i,j,k}</math>, com o ponto <math>p_{1i,j,k}</math> deve ser menor que um valor prefixado (nesta implementação escolheu-se <math>1^\circ</math>);</li> <li>❖ A distância ao ponto <math>p_{1i,j,k}</math> deve ser menor que a distância máxima (<math>d_{max}</math>) entre os pontos correspondentes no passo anterior ;</li> <li>❖ Dá-se um peso <math>w_{i,j,k} = j</math> a cada correspondência <math>(p_{1i,j,k}, p_{2i,j,k})</math>:  <math>w = 0</math>; faixa distância <math>(0, 0.25 \cdot d_{max}]</math>  <math>w = 0.5</math>; faixa distância <math>(0.25 \cdot d_{max}, 0.5 \cdot d_{max}]</math>  <math>w = 0.75</math>; faixa distância <math>(0.5 \cdot d_{max}, 0.75 \cdot d_{max}]</math>  <math>w = 1</math>; faixa distância <math>(0.75 \cdot d_{max}, d_{max}]</math></li> <li>❖ Adicionam-se as correspondências e os pesos aos conjuntos <math>\{p_{1C}, p_{2C}\}</math> e <math>w</math>;</li> </ul> </li> </ul>
Passo [3]	Calcula-se a distância $D_c$ para o conjunto de pontos correspondidos: $D_c = \sqrt{\frac{1}{N_c} \cdot \sum_{k=1}^{N_c} w_k \cdot \ p_{1Ck} - p_{2Ck}\ ^2}$ , sendo $N_c$ o número de correspondências encontradas;
Passo [4]	Com o conjunto de correspondências $\{p_{1C}, p_{2C}\}$ e seus pesos associados $\{w\}$ se encontra a nova matriz de transformação rígida correspondente;
Passo [5]	Aplica-se a nova matriz de transformação na imagem de profundidade $I_1$ ;
Passo [6]	Volta-se ao passo [2] se a diferença entre os dois últimos valores de $D_c$ é maior que um valor prefixado. Se não, o algoritmo finaliza.

Ao atribuir a cada correspondência um peso  $w_k$  no cálculo da transformação das correspondências, são avaliadas aquelas correspondências que estejam afastadas. Deste modo, trata-se de evitar que o erro do alinhamento seja maior nesses pontos.

### 6.2.1. Medida do erro cometido no alinhamento aproximado

Se  $\mathbf{R}_c$  é denominada a matriz de rotação aproximada obtida pelo algoritmo de pré-alinhamento e  $\mathbf{R}_{ICP}$  a matriz de transformação obtida mediante o algoritmo ICP, no caso ideal:

$$\mathbf{R}_{ICP}^T \cdot \mathbf{R}_c = \mathbf{I}_{3 \times 3} \quad (6.4)$$

Como a matriz  $\mathbf{R}_c$  é uma aproximação, a equação anterior dá como resultado uma matriz  $\mathbf{E}_R$  que deveria ser aproximadamente igual à matriz identidade. Como a matriz  $\mathbf{I}_{3 \times 3}$  pode ser considerada uma matriz de rotação em que os ângulos de Euler ZXY são todos nulos, podemos obter para uma matriz  $\mathbf{E}_R$  seus ângulos correspondentes,  $(\alpha_R, \beta_R, \gamma_R)$ , e comparar com a solução ideal. Portanto, podemos calcular o erro de rotação com a seguinte expressão:

$$e_R = \sqrt{\frac{1}{3}(\alpha_R^2 + \beta_R^2 + \gamma_R^2)} \quad (6.5)$$

e o erro de translação pode ser calculado através da expressão:

$$e_T = \sqrt{\frac{1}{3}(e_x^2 + e_y^2 + e_z^2)} \quad (6.6)$$

em que  $e_x = (\mathbf{t}_{cx} - \mathbf{t}_{ICPx})$ ,  $e_y = (\mathbf{t}_{cy} - \mathbf{t}_{ICPy})$  e  $e_z = (\mathbf{t}_{cz} - \mathbf{t}_{ICPz})$

### 6.3. RESULTADOS OBTIDOS

A figura (6.2), apresenta visualmente o registro de um par de imagens de profundidade (cavalo de bronze). A tabela (6.1) apresenta as variáveis que contribuem para a incerteza de medição, com o símbolo adotado e a respectiva distribuição de probabilidades (ISO GUM, 2008).

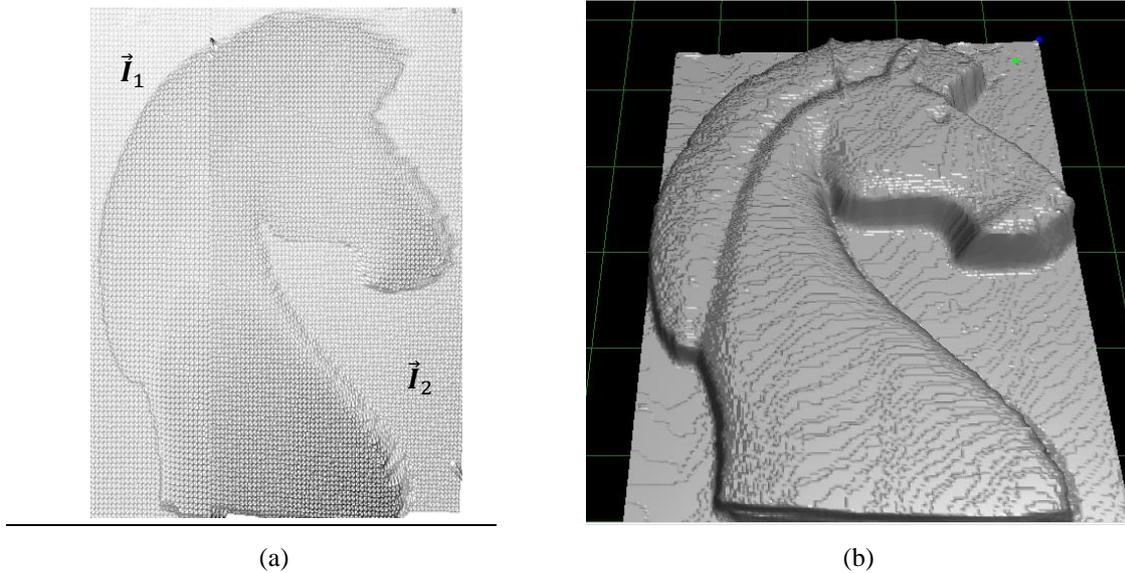


Fig. 6.2 Imagem de profundidade  $I_{\text{registro}}$ . (a) apresenta o resultado de alinhamento fino utilizando ICP de par de imagens de profundidade  $I_1$  e  $I_2$ .  $e_R = 0.89^0$  e  $e_T=1.15$ . (b) Representação da superfície utilizando entalhes Nurbs.

Tab. 6.1. Fontes de incerteza na medição –  $I_{\text{registro}}$

Comp.	Tp	$\bar{x}$	s	v	PDF	u	$U_{95\%}$ $K = 2$
$e_R$	A	$0.89^0$	$0,061^0$	15	N	$0,00406^0$	0.00812
$e_T$	A	1.15 (mm)	0,173 (mm)	15	N	0,01153 (mm)	0.02306

Em que:

Comp.	→	Componentes
Tp.	→	Tipo de função
$\bar{x}$	→	Valor médio
s	→	Desvio padrão
v	→	Graus de liberdade
PDF	→	Função densidade de probabilidade
u	→	Incerteza padrão.
N	→	Distribuição Normal
U	→	Incerteza expandida

A tabela (6.1) informa a incerteza que o experimento teve ao registrar as imagens de profundidade  $I_1$  e  $I_2$  em ( $I_{\text{registro}}$ ). Para conhecer qual foi a incerteza do procedimento em comparação com a imagem do cavalo completa ( $I_{\text{completa}}$ ) capturada com uma só imagem de profundidade (Fig. 4.2) (seção 4.1.1). Utilizou-se a mesma metodologia de alinhamento fino usada para as imagens de profundidade usada para ( $I_{\text{registro}}$ ) com a diferença que no passo [2] do algoritmo ICP (seção 6.2) foram escolhidos aleatoriamente 40 dos pontos de ambas as imagens ( $I_{\text{registro}}$  e  $I_{\text{completa}}$ ), os resultados foram os seguintes (Tab.6.2).

Tab. 6.2. Fontes de incerteza na medição – objeto cavalo.

Comp.	Tp	$\bar{x}$	s	v	PDF	u	$U_{95\%}$ $K = 2$
$e_R$	A	0.12 <sup>o</sup>	0,011 <sup>o</sup>	40	N	0,00027 <sup>o</sup>	0,000135
$e_T$	A	0.09 (mm)	0,105 (mm)	40	N	0,00262 (mm)	0,001414

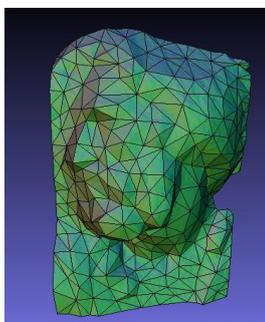
Em que:

Comp.	→	Componentes
Tp.	→	Tipo de função
$\bar{x}$	→	Valor médio
s	→	Desvio padrão
v	→	Graus de liberdade
PDF	→	Função densidade de probabilidade
u	→	Incerteza padrão.
N	→	Distribuição Normal
U	→	Incerteza expandida

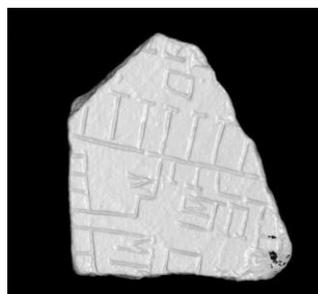
Os valores obtidos foram realmente os esperados a imagem reconstruída  $I_{registro}$ , similarmemente ocupa o mesmo espaço da imagem  $I_{completa}$ .

#### 6.4. AVALIAÇÃO DO MÉTODO DE ALINHAMENTO DE IMAGENS PROPOSTO

Dado o caráter experimental da implementação do algoritmo proposto, busca-se fundamentalmente a funcionalidade do programa, em razão do mesmo não estar suficientemente otimizado. De forma análoga ao estudo comparativo de Salvi (2007), não será feita a análise da eficiência do algoritmo, uma vez que este é dependente da implementação. Desta forma, os resultados foram analisados em termos da eficácia do algoritmo, que se caracteriza por uma medida do erro na matriz de transformação que alinha, de forma aproximada, as duas nuvens de pontos. Para realizar esta avaliação, foram utilizadas imagens de profundidade sintéticas (Fig. 6.3) obtidas da base de dados do software de visualização 3D ScanView.



(a). Imagem de Profundidade Matteonorb



(b). Imagem FUR-202



(c). Imagem de Profundidade Bunny

Fig. 6.3. Imagens de profundidade do repositório <<https://graphics.stanford.edu/software/scanview/>> .

Cada imagem de profundidade original anterior foi dividida em duas nuvens de pontos parciais não alinhadas com diferentes porcentagens de sobreposição. Para obter a primeira nuvem de pontos, foram eliminadas da imagem de profundidade original os  $N_1$  primeiros pontos, enquanto que na segunda nuvem de pontos, foram eliminados os  $N_2$  últimos. Se a nuvem de pontos originais tem  $N$  pontos, então o número de pontos sobrepostos entre as duas imagens,  $N_s$ , será calculado como  $N_s = N - (N_1 - N_2)$ . Portanto, a porcentagem de pontos sobrepostos entre as duas nuvens será obtida através da expressão:

$$A_s = \frac{N_s}{N} \cdot 100\% = \left(1 - \frac{N_1 - N_2}{N}\right) \cdot 100\% \quad (7.3)$$

Em princípio, as duas nuvens de pontos estarão alinhadas. Posteriormente, em uma das nuvens, será realizada uma transformação aleatória de rotação (os três ângulos de Euler ZXY) e de translação. Uma vez aplicada a transformação, modifica-se a posição dos pontos adicionando ruído aleatório com um desvio padrão de 2%. A figura (7.3) apresenta as imagens utilizadas. Na figura (6.4) apresenta-se a curva de comportamento do algoritmo de alinhamento quando opera com duas imagens de profundidade com diferentes graus de sobreposição.

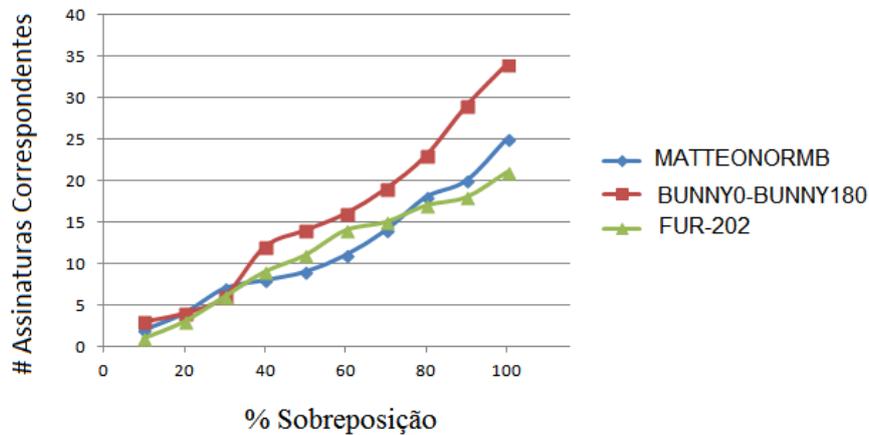


Fig. 6.4. Comportamento do algoritmo de alinhamento com duas imagens de profundidade.

De acordo com a forma dos objetos da figura (6.3) e com o gráfico da figura (6.4), o algoritmo proposto determina mais de dez pontos correspondentes quando a porcentagem de sobreposição supera os 40%.

## 6.5. ALINHAMENTO DE NUVENS DE PONTOS DO DIGITALIZADOR TRI\_IDENT

Os algoritmos de pré-alinhamento e alinhamento fino foram também testados com nuvens de pontos capturadas com o digitalizador laser TRI\_IDENT (Fig. 6.5). Os detalhes do funcionamento do sistema estão descritos no apêndice B.

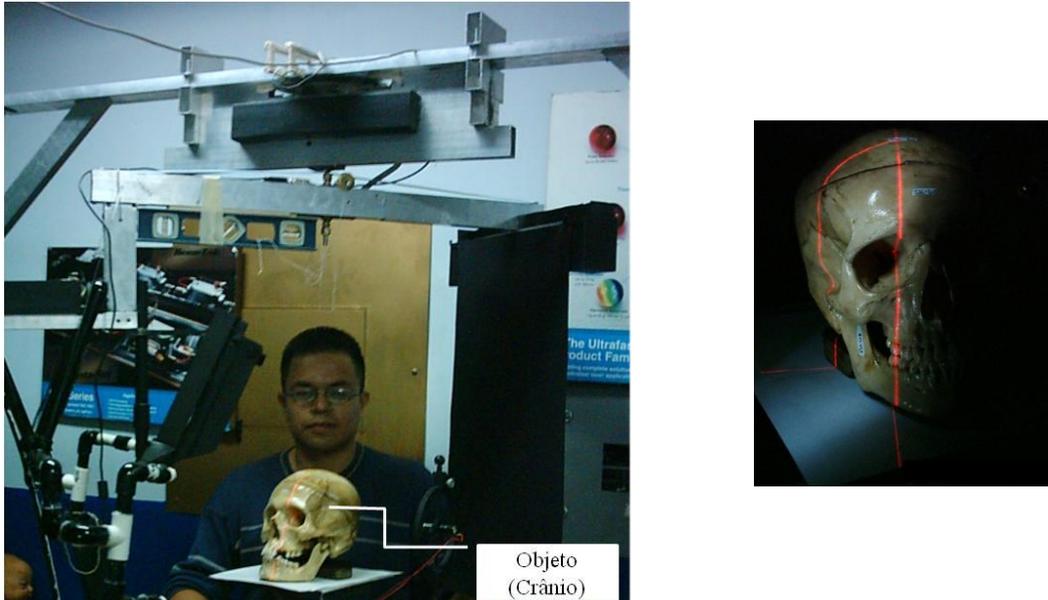


Fig.6.5. Digitalizando um objeto (crânio) através do TRI\_IDENT

Seguindo a metodologia utilizada no pré-alinhamento de imagens de profundidade (seção 4.1), representada na figura (6.6), os resultados obtidos no pré-alinhamento de imagens do crânio são mostrados a seguir:

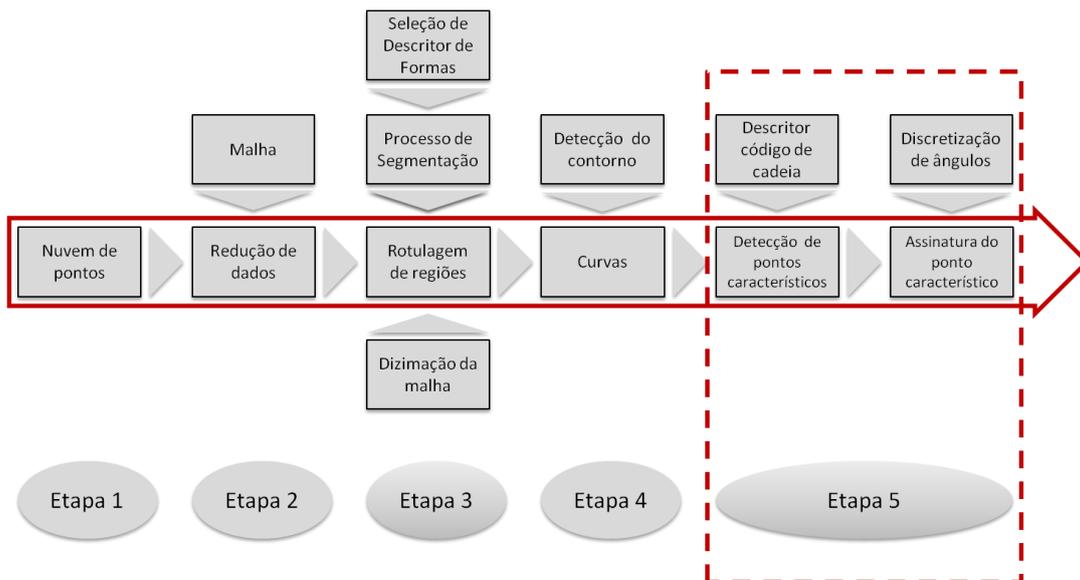


Fig. 6.6. Metodologia usada no pré-alinhamento de imagens de profundidade.

**Etapa 1** (nuvem de pontos): as imagens de profundidade obtidas pelo digitalizador laser se apresentam na figura (6.7). Para este processo, foram obtidos 38.831 pontos que representam o mapa de profundidade  $I_1$  e 35.653 pontos para o mapa de profundidade  $I_2$ .



Imagem de profundidade do crânio  $I_1$



Imagem de profundidade do crânio  $I_2$

Fig.6.7. Imagem de profundidade do crânio - Nuvem de pontos.

**Etapa 2** (redução de dados): posteriormente à captura de pontos obtidos pelo digitalizador laser, os pontos foram organizados através da técnica de modelo deformáveis (seção 2.3), onde existiu redução dos dados. Os resultados são apresentados nas figuras a seguir.

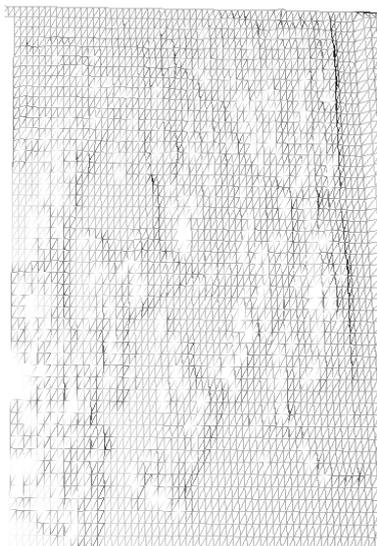


Imagem de profundidade  $I_1$ - Representação em Malha

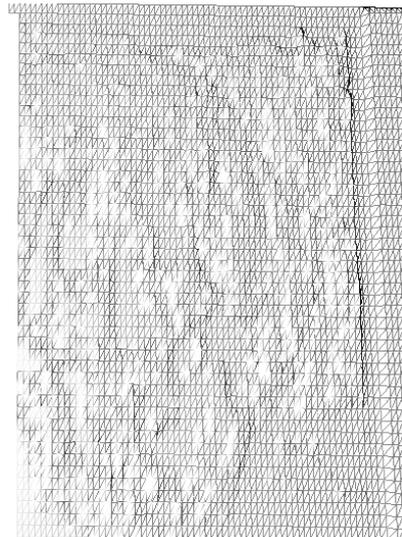


Imagem de profundidade  $I_2$ - Representação em Malha

Fig. 6.8. Imagens de profundidade do crânio - Representação em malha (Resolução da malha  $t = 0.60 \text{ mm}$ ).

**Etapa 3** (rotulagem de regiões): partindo dos resultados anteriores, realiza-se na imagem de profundidade um processo de detecção de bordas de profundidade.

Tab. 6.3. Volume de dados reduzidos- crânio

Imagens de profundidade	Pontos	Pontos preservados no processo de segmentação	% Preservação da imagem de profundidade original
I1- Crânio	37831	27789	~73
I2-Crânio	38653	27960	~72

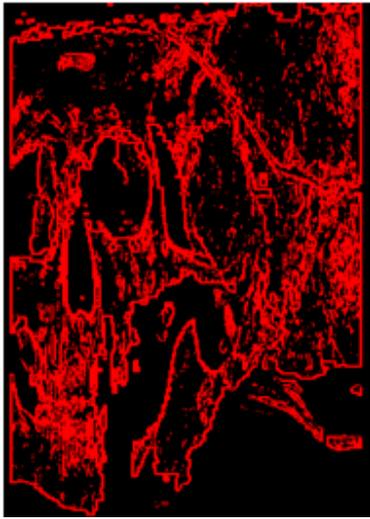


Imagem de profundidade  $I_1$

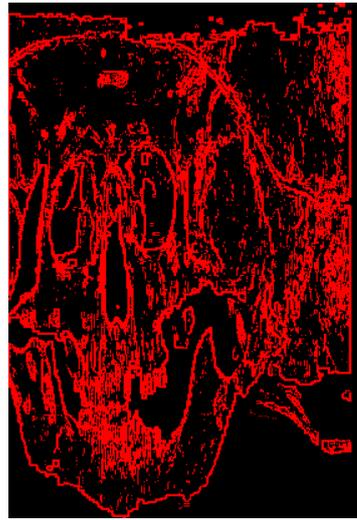


Imagem de profundidade  $I_2$

Figura 6.9. Mapa de bordas – crânio.

**Etapa 4** (curvas): uma vez que o mapa de profundidade esteja construído adequadamente, o próximo passo é modificá-lo para construir um mapa de contorno.

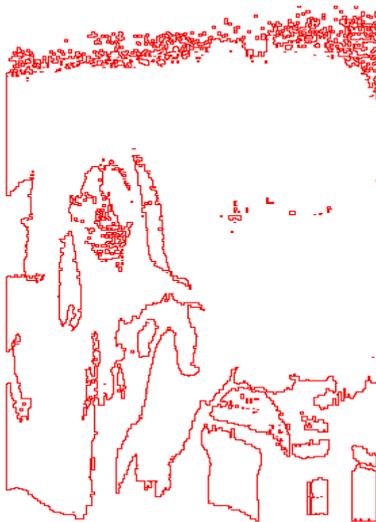


Imagem de profundidade  $I_1$

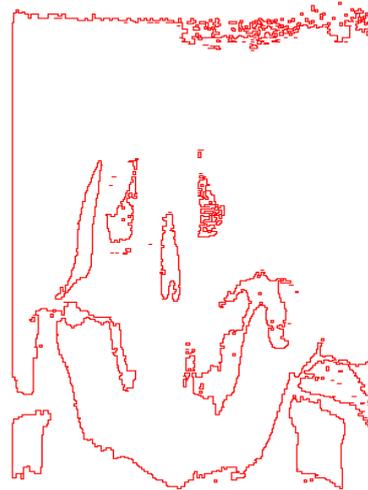


Imagem de profundidade  $I_2$

Fig.6.10. Refinamento da imagem segmentada- Construção do mapa de contorno do objeto crânio.

**Etapa 5** (detecção das assinaturas dos pontos correspondentes): a figura (6.11) apresentam alguns pontos característicos correspondentes detectados e indicados por números. A figura (6.12) apresenta o resultado final do alinhamento e incerteza.



Fig.6.11. Detecção das assinaturas dos pontos correspondentes - Imagem do crânio.

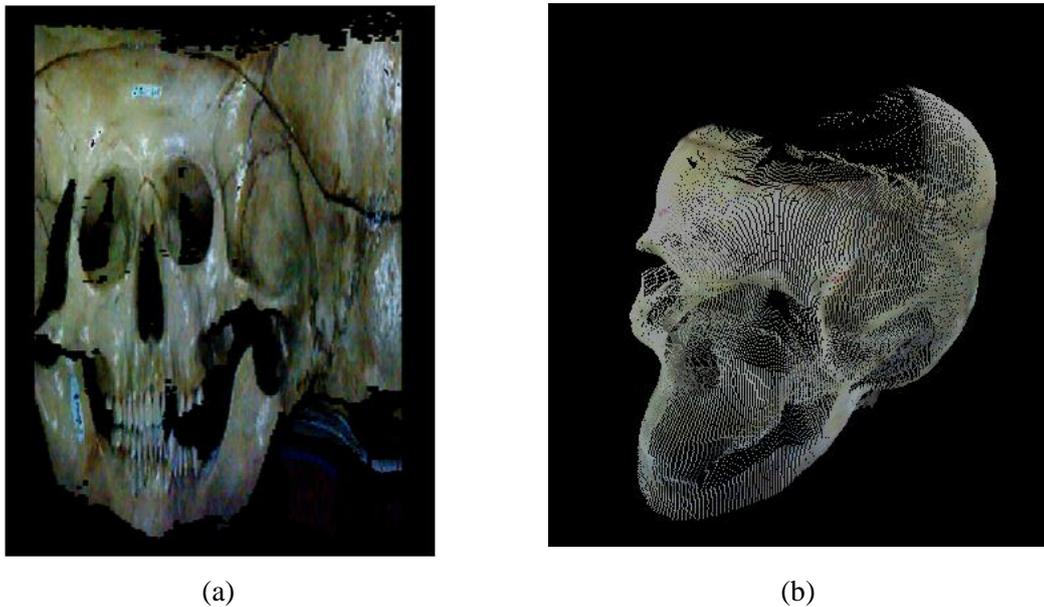


Fig. 6.12 (a) apresenta o resultado de alinhamento fino utilizando ICP de par de imagens de profundidade  $I_1$  e  $I_2$ .  $e_R = 0.35^0$  e  $e_T=0.77\text{mm}$ .

A tabela (6.4) apresenta a incerteza de medição do processo de alinhar as imagens de profundidade. Os resultados obtidos foram os esperados devido a que o erro de translação e rotação se ajusta com a resolução do sistema de visão usado no digitalizador TRI\_IDENT (Apêndice B).

Tab. 6.4. Fontes de incerteza na medição – objeto crânio.

Comp.	Tp	$\bar{x}$	s	v	PDF	u	$U_{95\%}$ $K = 2$
$e_R$	A	0.35 <sup>o</sup>	0,044 <sup>o</sup>	32	N	0,00137 <sup>o</sup>	0.00274
$e_T$	A	0.77(mm)	0,029 (mm)	32	N	0,00625 (mm)	0.0125
Em que:							
Comp.	→	Componentes					
Tp.	→	Tipo de função					
$\bar{x}$	→	Valor médio					
s	→	Desvio padrão					
v	→	Graus de liberdade					
PDF	→	Função densidade de probabilidade					
u	→	Incerteza padrão.					
N	→	Distribuição Normal					
U	→	Incerteza expandida					

## 6.6. ALINHAMENTO DE NUVENS DE PONTOS DE UMA PÁ DE TURBINA HIDRELÉTRICA DANIFICADA

A seguir será analisada uma imagem de profundidade digitalizada de uma turbina hidrelétrica. A superfície da turbina apresenta erosão por cavitação, que precisa ser restaurada pela deposição de material por soldagem. Estas superfícies, pelo tamanho (Fig. 2.19), devem ser mapeadas várias vezes para que a área a ser reparada possa ser descrita de forma completa. Durante os experimentos realizados em laboratório foram obtidas imagens de profundidade, capturadas por um sistema digitalizador montado sobre um robô de cinco graus de liberdade com duas juntas rotativas, um atuador linear e um pulso *pan-tilt*. Através de um sistema de controle embarcado em uma FPGA (*Field Programmable Gate Arrays*) é possível deslocar o digitalizador laser a diferentes posições. A trajetória do digitalizador laser está relacionada com a estrutura cinemática do robô. No capítulo de livro (Pizo, G.A. e Mota, J.M, 2012), é apresentado o modelo cinemático do robô e resultados experimentais do sistema de controle de movimento desenvolvido. Com a ajuda do sistema robotizado, foram obtidas imagens com área de sobreposição maior do que 50%, valor que garante pelo menos cinco correspondências. Na figura (6.13) são mostradas a imagem de intensidade 2D e na figura (6.14) as imagens de profundidade na forma de pontos. Na figura (6.15) e figura (6.16) se apresentam os resultados do registro das imagens de profundidade representados através de entalhes paramétricos NURBS. A representação da peça virtual foi localizada em uma célula de trabalho de soldagem virtual. A tabela (6.5) apresenta os resultados estatísticos do registro obtido.

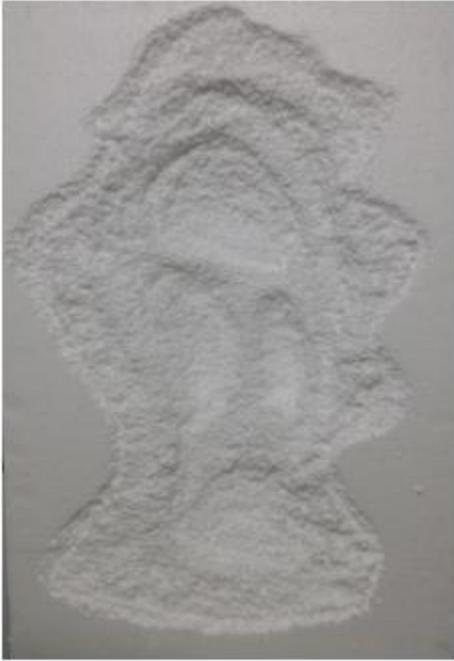


Fig. 6.13. Imagem de intensidade–  
Molde em isopor obtido a partir de uma pá turbina hidrelétrica.

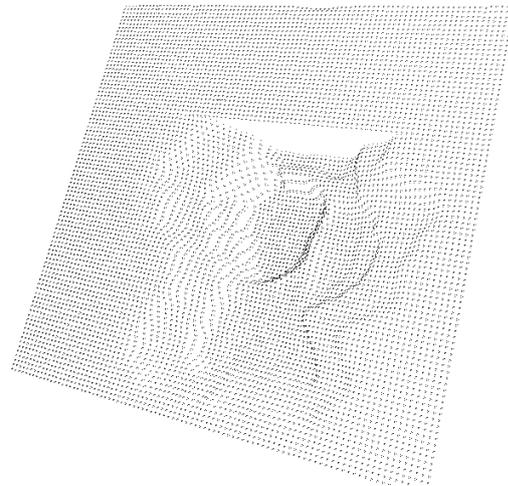
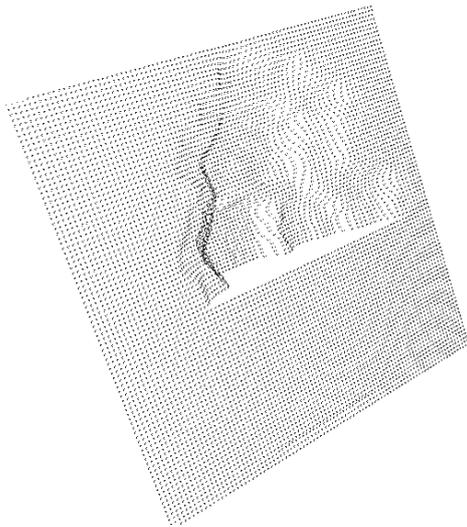


Imagem de profundidade  $I_1$ -modo pontos

Imagem de profundidade  $I_2$ -modo pontos

Fig. 6.14. Representação de imagens em pontos – Pás de turbina.

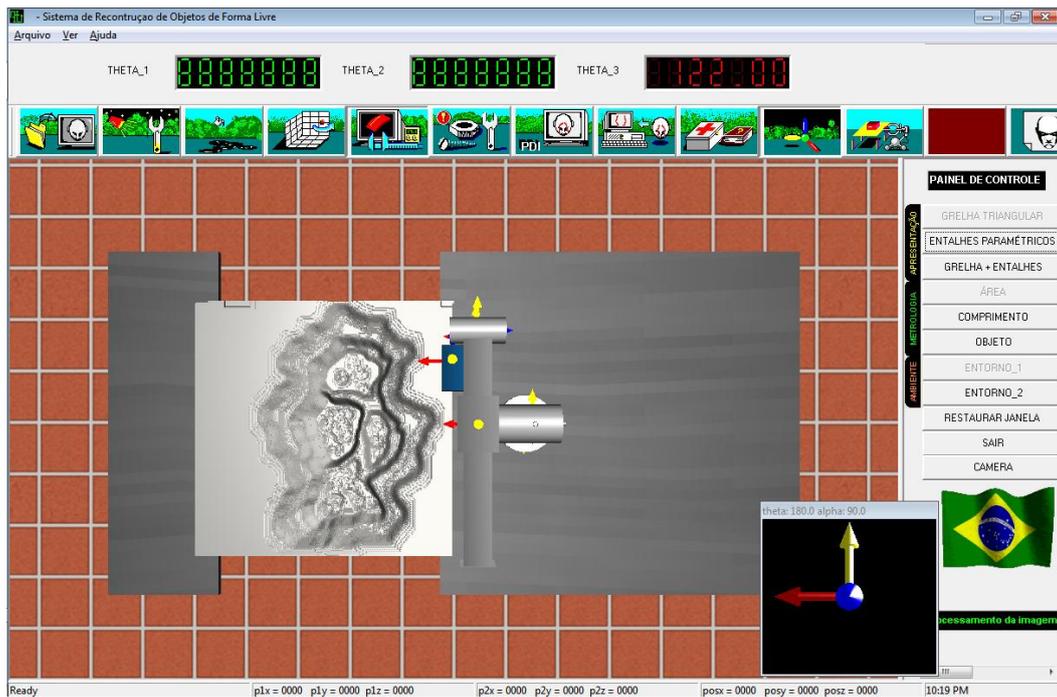


Fig. 6.15. Imagem de profundidade representada através de entalhes paramétricos Nurbs. A Pá de turbina hidrelétrica está localizada numa célula de trabalho virtual (Perspectiva A).

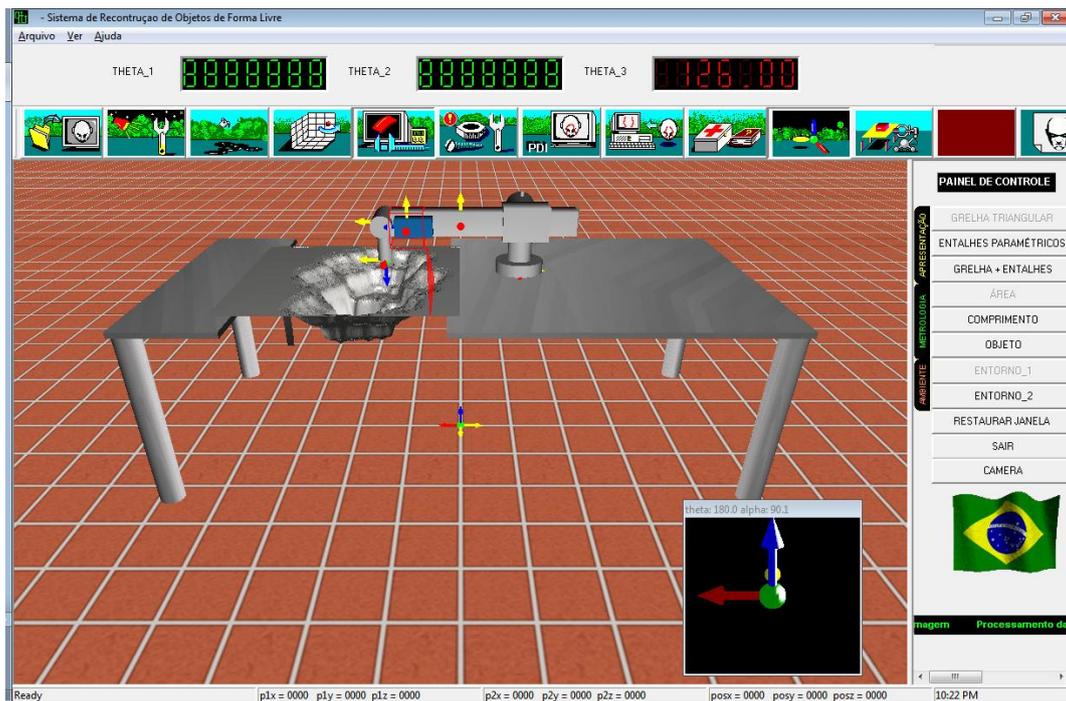


Fig. 6.16. Imagem de profundidade representada através de entalhes paramétricos Nurbs. A Pá de turbina hidrelétrica está Localizada numa célula de trabalho virtual (Perspectiva B).

Tabela 6.5. Fontes de incerteza na medição – Pás de turbina hidrelétrica.

Comp.	Tp	$\bar{x}$ (mm)	s (mm)	v	PDF	u (mm)	$U_{95\%}$ $K = 2$
$e_R$	A	0,77 <sup>0</sup>	0,055	18	N	0,00305	0.00610
$e_T$	A	0,95	0,091	18	N	0,00505	0.01011
Em que:							
Comp.	→	Componentes					
Tp.	→	Tipo de função					
$\bar{x}$	→	Valor médio					
s	→	Desvio padrão					
v	→	Graus de liberdade					
PDF	→	Função densidade de probabilidade					
u	→	Incerteza padrão.					
N	→	Distribuição Normal					
U	→	Incerteza expandida					

Os resultados da tabela (6.5) são ótimos, se comparamos que o valor do erro é menor que o diâmetro do arame do cobalto (1.1mm) que é usada na tocha de soldagem para reparar as turbinas hidrelétricas.

## 6.7 DISCUSSÃO

Várias propostas de redução de dados têm surgido nos últimos anos. No entanto, uma avaliação minuciosa das suas características com objetivo de aplicar alguns desses descritores para o alinhamento de imagens de profundidade de superfícies, semelhantes às superfícies das pás de turbinas hidráulicas afetadas por cavitação, permite a identificação de algumas limitações, principalmente as relacionadas com o casamento de pontos correspondentes quando as imagens contêm ruído, baixo índice de sobreposição, falta de critério de medida quantitativa que evite falsas correspondências e reduza o tratamento combinatório no processo de busca.

O descritor proposto está construído sobre uma malha que substitui o conjunto denso de dados por uma representação reduzida da imagem de profundidade. A representação reduzida retém os vértices nas regiões de alta variação de curvatura, e adéqua a densidade de vértices nas regiões com variações mais suaves de curvatura. Este critério reduz a complexidade combinatória na busca de correspondências. A identificação de pontos característicos das curvaturas em uma região depende exclusivamente de uma vizinhança de quatro pontos e utiliza um critério de similaridade que permite identificar pontos correspondentes verdadeiros. O descritor usa o ângulo como medida invariante de similaridade.

Resultados experimentais mostram que o descritor proposto pode ser usado como uma ferramenta para realizar um registro de imagens de profundidade que se possam projetar de 3D para 2D . A tabela (6.6) apresenta características principais do descritor:

Tab.6.6. Características principais do descritor proposto

Nome da técnica (Descritor proposto )	Descritor Pizo_Motta
Espaço de escolha do descritor	Pontos que indiquem variação de curvatura do contorno da superfície
Configuração dos descritores	N= 5 amostras sem estrutura definida;
Métricas invariantes do descritor	Ângulos;
Transformação geométrica	Similaridade;
Sensível Ruído	Baixo;
Procedimento filtragem	Filtros adaptativos NLMS;
Avaliação das correspondências	Critério de similaridade: Comparação de assinaturas através do código direcional de 8 estados.

Planitz et al. (2005) e Mercedes (2009) elaboram um trabalho de análise e comparação de várias técnicas que realizam pré-alinhamento. A tabela (6.7) apresenta uma visão geral comparativa deste trabalho em relação aos existentes na literatura.

Tab. 6.7. Tabela comparativa dos principais trabalhos presentes na literatura com a nova proposta.

TÉCNICA	ESPAÇO DE ESCOLHA DESCRITOR REFERÊNCIA	CONFIGURAÇÃO DOS DESCRITORES	MÉTRICAS INVARIANTES DOS DESCRITORES	ESPAÇO DE BUSCA DO DESCRITOR-ALVO	PROCEDIMENTO FILTRAGEM	TRANSFORMAÇÃO GEOMÉTRICA SIMILARIDADE			REGIÃO SOBREPOSIÇÃO (RS)
						Translação	Rotação	Escala Uniforme	Baixa (RS <25%) Média (25<RS<50%) Alta (50<RS<100%)
Assinatura de Pontos (Chua e Jarvis,1997)	Todas as amostras ( $I_1$ )	Utiliza estrutura circular utilizando $N > 3$ amostras	Ângulo e Distâncias	Todas as amostras ( $I_2$ )	Avaliação de ajuste de pontos especiais de ( $I_1$ ).	SIM	NÃO	NÃO	Baixa
<i>Spin Image</i> Johnson (1997)	Todas as amostras ( $I_1$ )	$N > 3$ amostras sem estrutura definida	Histogramas Composto por Distâncias Acumuladas	Todas as amostras ( $I_2$ )	Avaliação de ajuste de alguns pontos de ( $I_1$ ).	SIM	SIM	NÃO	Baixa
Histograma Geométrico (Huanga <i>et al.</i> , 2008 )	Todas as amostras ( $I_1$ )	$N > 3$ amostras sem estrutura definida	Histograma composto Distância e Ângulo	Todas as amostras ( $I_2$ )	Avaliação de ajuste de pontos especiais de ( $I_1$ ).	SIM	SIM	NÃO	Baixa
Imagens de Forma Harmônica (Zhang, 2009)	Malha associada a ( $I_1$ )	Entalhes de Superfície	Centro de Massa	Malha associada a ( $I_2$ )	Avaliação de ajuste da malha associada a ( $I_1$ ), porém só de algumas transformações candidatas.	SIM	SIM	SIM	Alta
Contexto em 3D (Belongie <i>et al.</i> , 2002)	Todas as amostras ( $I_1$ )	Utiliza estrutura circular dividida em setores $N > 3$ amostras	Distâncias e Setores Preenchidos	Todas as amostras ( $I_2$ )	Avaliação de ajuste de pontos especiais de ( $I_1$ ).	SIM	SIM	NÃO	Baixa
Alinhamento <i>Log-Polar</i> (Masuda., 2006)	Todas as amostras ( $I_1$ )	Utiliza estrutura circular dividida em setores $N > 3$ amostras	Distâncias Logarítmicas e Setores preenchidos	Todas as amostras ( $I_2$ )	Avaliação de ajuste de alguns pontos de ( $I_1$ ).	SIM	SIM	SIM	Baixa
<i>Splash</i> (Stein, 1992)	Todas as amostras ( $I_1$ )	Com Estrutura Circular Definida $N > 3$ amostras	Radio, Ângulo	Todas as amostras ( $I_2$ )	Avaliação de ajuste de pontos especiais de ( $I_1$ ).	SIM	SIM	SIM	Baixa
Integral de Volume (Gelfand <i>et al.</i> , 2005)	Todas as amostras ( $I_1$ )	Operações de integração para obter o volume	Radio	Todas as amostras ( $I_2$ )	Avaliação de ajuste de pontos especiais de ( $I_1$ ).	SIM	SIM	SIM	Baixa
PCA (Luo e Oubong, 2009)	Todas as amostras ( $I_1$ )	Cálculo dos Autovetores da matriz de covariância $N > 3$ amostras	Centro de Massa	Todas as amostras ( $I_2$ )	Avaliação de ajuste de pontos especiais de ( $I_1$ ).	SIM	SIM	SIM	Alta
Método de Pingi (Chu-Song,1999)	Pontos de máximo valor local	$N > 3$ amostras sem estrutura definida	Histogramas Composto por Distâncias Acumuladas	Pontos de valor máximo em ( $I_2$ )	Avaliação de ajuste de pontos especiais de ( $I_1$ ).	SIM	SIM	SIM	Baixa

TÉCNICA	ESPAÇO DE ESCOLHA DESCRITOR REFERÊNCIA	CONFIGURAÇÃO DOS DESCRITORES	MÉTRICAS INVARIANTES DOS DESCRITORES	ESPAÇO DE BUSCA DO DESCRITOR-ALVO	PROCEDIMENTO FILTRAGEM	TRANSFORMAÇÃO GEOMÉTRICA SIMILARIDADE			REGIÃO SOBREPOSIÇÃO (RS)
						Translação	Rotação	Escala Uniforme	Baixa (RS <25%) Média (25<RS<50%) Alta (50<RS<100%)
SIFT (Lowe, 1999)	Pontos de máximo valor local	Utiliza estrutura circular dividida em setores (oitavas) $N > 3$ amostras	Distâncias e Ângulos	Todas as amostras ( $I_2$ )	Avaliação de ajuste de pontos especiais de ( $I_1$ ).	SIM	SIM	SIM	Média
Curvas Bitangentes (Vandem e Van, 2002)	Pontos que indiquem variação de curvatura	Quadrilateral (dada pelos pontos extremos de dois segmentos)	Distância	Pontos Bitangentes ( $I_2$ )	Avaliação de ajuste de uma subamostragem de ( $I_1$ ).	SIM	SIM	NÃO	Média
Curvas Intrínsecas (Feldmar e Ayache, 1994)	Pontos que indiquem variação de curvatura	Linear (dada pelos pontos extremos de N segmentos)	Distância	Pontos de Curvatura	Avaliação de ajuste de pontos especiais de ( $I_1$ ).	SIM	SIM	NÃO	Média
RBD (Chu-Song, 1999)	Todas as amostras ( $I_1$ )	Triangular (três amostras)	Distâncias	Todas as amostras ( $I_2$ )	Avaliação de ajuste de vizinhança e subamostragem de ( $I_1$ ).	SIM	SIM	NÃO	Média
Emparelhamento de Pontos Intrínsecos (Chua and Jarvis, 1997)	Pontos de curvatura	Linear (dada pelos pontos extremos de N segmentos)	Distância	Pontos associados nas curvas de ( $I_2$ )	Avaliação de ajuste de pontos especiais de ( $I_1$ ).	SIM	NÃO	NÃO	Média
Emparelhamento de Grafos (Cheng and Don, 1991)	Malha associada a ( $I_1$ )	Triangular (três amostras)	Distâncias	Escolhe os pontos Candidatos	Avaliação de ajuste de vizinhança e subamostragem de ( $I_1$ ).	SIM	SIM	NÃO	Média
4PCS (Aigner et al., 2008)	Todas as amostras ( $I_1$ )	$N=4$	Distância	Escolhe os pontos Candidatos	Pontos intermediários de cruze de linhas retas	SIM	SIM	SIM	Baixa
ASM (Tarel et al., 1998)	Todas as amostras ( $I_1$ )	Polinomial	Distância e Ângulos	Todas as amostras ( $I_2$ )	Mínimos quadrados	SIM	SIM	SIM	Média
Line-Based Algorithm (Stamos e Leordeanu, 2008)	Escolhe os pontos estão uma linha retas	Linear	Distância	Pontos associados a linhas Retas ( $I_2$ )	Geometria	SIM	SIM	NÃO	Alta
Correspondência Baseada na Teoria de Campo Médio (Brunnstrom and Stoddart., 1996)	Todas as amostras ( $I_1$ )	$N > 3$ amostras sem estrutura definida	Distância	Todas as amostras ( $I_2$ )	Probabilidade	SIM	SIM	NÃO	Média
Imagem de Atributo Esférico (SAI) (Higuchi et al., 1994).	Malha associada a ( $I_1$ )	Estrutura associada a uma curva $N > 3$	Ângulos	Escolhe os pontos Candidatos de uma malha associada a ( $I_2$ )	Imagens esféricas	SIM	SIM	SIM	Média
Correspondência Baseada em Algoritmos Genéticos (Stoddart and Brunnstrom, 1996)	Escolhe os pontos Candidatos	$N > 3$ amostras sem estrutura definida	Distância e Ângulos	Escolhe os pontos Candidatos	Minimizar uma função de distância	SIM	SIM	SIM	—
Descritor Proposta de solução PIZO_MOTTA	Pontos que indiquem variação de curvatura do contorno da superfície	$N= 5$ amostras sem estrutura definida	Ângulos	Pontos que indiquem variação de curvatura do contorno da superfície	Filtros adaptativos NLMS;	SIM	SIM	SIM	Média

## 7. CONCLUSÃO

O pré-alinhamento automático de imagens de profundidade é um problema fundamental na área de visão computacional. Vários algoritmos têm sido propostos para este propósito, porém ainda sofrem de várias limitações, principalmente relacionadas à existência de pontos correspondentes e eficiência na sua busca em dois mapas de profundidade parcialmente sobrepostos de objetos rígidos. Nesta tese se apresenta uma metodologia que permite usar as “vantagens” combinadas de diferentes descritores, tratando de contornar o problema de existência e aliviando a complexidade combinatória na busca de correspondências para realizar uma transformação de similaridade. Por esse motivo, a proposta deste trabalho foi contribuir na busca de uma solução mais eficaz ao problema, com o menor número de restrições possível.

Para isso chegou-se a obter um conjunto de requisitos que garantam tanto a existência, no sentido de ser capaz de sempre extrair  $n$  pares de correspondências, quanto à eficiência nos procedimentos de busca.

O principal problema do pré-alinhamento é o desconhecimento da correspondência entre as regiões de sobreposição; por tal motivo, a solução mais usual é escolher pontos que tenham alguma característica que os distinga do resto. Considerando o tipo de superfícies a ser tratado (seção 2.3), propôs-se uma metodologia que está baseada na segmentação/reconstrução de imagens de profundidade fazendo uso da técnica de detecção de bordas aliada à técnica de agrupamento usando dizimação de malhas. Optou-se por extrair as curvas de contorno do objeto. O objetivo foi projetar um descritor que detecte os pontos característicos pela variação de curvatura e que seja invariante a transformações de similaridade (escala, rotação e translação).

As características principais do descritor são:

- ❖ Gera como dado de saída uma assinatura que relaciona o ponto característico diretamente com a disposição geométrica de sua vizinhança. A assinatura resultante fornece a posição do ponto dentro da imagem de profundidade, aumentando a eficiência nas correspondências entre os pontos, facilitando a identificação de possíveis zonas de sobreposição;
- ❖ Cada assinatura completa associada a um ponto característico é representada por apenas cinco dígitos, reduzindo o tempo de busca e o número de conjuntos de dados de entrada;

- ❖ A assinatura é invariante a escala, em razão de utilizar ângulos;
- ❖ A assinatura é invariante a rotação, uma vez que se utiliza de ângulos discretos que são ordenados;
- ❖ O descritor demonstrou ser tolerante a transformações afins, uma vez que considera ângulos em valores discretizados, ou seja, a variações de perspectiva das imagens até próximo de 20°.
- ❖ O descritor proposto possui métricas invariantes que ajudam a reduzir a ambiguidade no processo de busca;
- ❖ A combinação do descritor com um filtro de Kalman linear permite diminuir a existência de pontos característicos falsos. O parâmetro de desempenho proposto nesta pesquisa reduziu a influência de ruído. O parâmetro de desempenho a ser selecionado depende da quantidade de ruído presente no contorno que se quer eliminar;
- ❖ O descritor proposto é baseado em operações com números inteiros, o que traz benefícios por ser simples de programar em qualquer tipo de hardware (microcontroladores, FPGAs, microprocessadores, entre outros);
- ❖ O descritor pode ser usado para curvas fechadas e/ou abertas.

O descritor foi avaliado com diferentes imagens e seus resultados foram comparados com os de outros autores com as mesmas imagens. A técnica proposta gerou um maior número de pontos correspondentes verdadeiros e um baixo número de pontos característicos falsos, aproximando-se muito dos resultados obtidos numa identificação manual. Os resultados experimentais obtidos durante a pesquisa demonstram que o descritor pode ser usado para detectar pontos característicos em contornos com ou sem ruído.

A busca de correspondências entre duas nuvens de pontos é realizada através de comparações de assinaturas. Como vários pontos correspondentes devem ser encontrados, várias transformações de similaridade serão determinadas. Para verificar a validade das transformações candidatas, cada uma delas passa por uma avaliação de erros de ajuste entre as duas imagens de profundidade através do algoritmo ICP (*iterative closest point*). A transformação que alinha o maior número de pontos é considerada a solução.

Mesmo com um descritor discriminante, ou seja, que indique pontos característicos correspondentes, a etapa de busca entre assinaturas correspondentes pode conduzir à

uma associação de uma assinatura com  $m$  outras assinaturas correspondentes, fornecendo, portanto,  $(m-1)$  correspondências incorretas que levem à estimativa de transformações falsas positivas. Para diminuir o tempo e a complexidade combinatória para encontrar uma matriz de transformação de similaridade correta, foi adicionada uma nova etapa entre as etapas usuais e consolidadas na literatura para o pré-alinhamento e o alinhamento fino. Esta etapa é o algoritmo do k-vizinho mais próximo para filtrar pontos característicos correspondentes.

Destaca-se que a principal contribuição deste trabalho é o desenvolvimento de uma técnica de pré-alinhamento e a sua integração com uma técnica de alinhamento fino, definindo de forma geral uma metodologia completa para registro e reconstrução de modelos tridimensionais.

Os resultados experimentais mostraram que a técnica proposta pode ser usada independentemente do digitalizador utilizado.

## 8. TRABALHO FUTUROS

Propostas para trabalhos futuros mais imediatos, como forma de complementar aos resultados obtidos por esta pesquisa, podem ser listados como:

- [1]. Verificar o comportamento da aplicação do descritor em diferentes superfícies com diferentes graus de curvatura e fazer os ajustes necessários de forma a manter as características de baixo tempo de convergência, pequena quantidade de erros de alinhamento e capacidade de fácil detecção observadas nas aplicações em superfícies quase planas;
- [2]. Testar os algoritmos na atribuição de assinaturas à curvas com uso do descritor combinado a diferentes filtros lineares e não lineares com objetivo de otimizar o processo.
- [3]. Incorporar num sistema único as coordenadas de referência da base do robô e as coordenadas de referência do digitalizador laser para ratificar as divergências entre a posição observada pelo usuário, que usa a referência do digitalizador a laser, e a posição indicada para o robô pelo mapa virtual tridimensional. Este sistema único de coordenadas possibilitaria assim, diminuição da acumulação de erros no alinhamento de imagens de profundidade, pela eliminação da diferença entre as referências entre os dois mapas.

## 9. REFERÊNCIAS BIBLIOGRÁFICAS

- ❖ Ahmadian, A., Faramarzi, E. and Sayadian R., (2003). “Image indexing and retrieval using Gabor wavelet and Legendre moments”. In: 25th Annual International Conference on Engineering in Medicine and Biology Society. Proceedings. Cancun, Mexico, 2003. Vol. 1, p. 560–563.
- ❖ Aiger D., Cohen, O. e Mitra, N., (2008). “4-points congruent sets for robust pairwise surface registration”. In: Siggraph 2008, ACM Transactions on Graphics, Vol. 27, Article No. 85.
- ❖ Arbter, K., Snyder, W. and Burkhardt, G., (1990). “Applications of affine invariant Fourier descriptors to recognition of 3-d objects”. In: IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 12, Issue 7, p.p. 640–646.
- ❖ Arebola F. and Sandoval F., 2005. “Corner detection and curve segmentation by multiresolution chain-code linking”. *Pattern Recognition Society*. Published by Elsevier Ltd. Vol. 38, issue 10, p.p. 1596–1614.
- ❖ Asada, I. and Brady, M., (1984). “The Curvature Primal Sketch”. *Acquisition of Visual Motion Guided Behaviors*.
- ❖ Bariya, P., Novatnack, J., Schwartz, G., Nishino, Ko., (2012). “3D Geometric Scale Variability in Range Images: Features and Descriptors”. *International Journal of Computer Vision*. September 2012, Volume 99, Issue 2, pp 232-255.
- ❖ Bellon, O.R.P., (1997). *Imagens de Profundidade: Segmentação e Representação por superfícies Planares*. Tese de Doutorado, Universidade Estadual de Campinas, Campinas, São Paulo, Brasil.
- ❖ Belongie, S., Malik, J. and Puzicha, J., (2002). “Shape matching and object recognition using shape contexts”. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 24, Issue. 4, p.p, 509-522.
- ❖ Besl, P and McKay, N., (1992). “A method for registration of 3-D shapes”. *IEEE Transaction on Pattern Analysis and Machine Intelligence*. Vol. 14, Issue 2, p.p 239–256.
- ❖ Beus, H. L. and Tiu, S. S. H., 1987. “An improved corner detection algorithm based on chain-coded plane curves”. *Pattern Recognition*, v. 20, issue 3, p.p 291–296, 1987.

- ❖ Bruno, C. and Netto, S., (2007). “Comparação de algoritmos adaptativos para cancelamento de eco acústico”. In: XXV Simpósio Brasileiro de Telecomunicações. URL. <<http://www.lps.ufrj.br/profs/sergioln/papers/BC14.pdf>>.
- ❖ Brunnstrom, K and Stoddart, A. J., (1996)., “Free-form surface matching using meaneld theory”. In: British Machine Vision Conference, Vienna, Austria.
- ❖ Chakrabarti, K. *et al.*,(2000).“Similar shape retrieval in mars”. In: IEEE International Conference on Multimedia and Expo. Proceedings. NY, USA, 2000. v. 2, p. 709–712.
- ❖ Chua, C. and Jarvis, R., (1997). “Point signatures: a new representation for 3d object recognition”. *Journal International Journal of Computer Vision*. Volume 25. Issue 1. Pages 63 – 85.
- ❖ Cheng, J.C. and Don, H.S. (1991)., “A graph matching approach to 3-d point correspondences”.*International Journal of Pattern Recognition and Artificial Intelligence*. DOI: 10.1142/S0218001491000223.
- ❖ Chui, K. L., Chiu, W. K. e Yu, K. M. (2008). “Direct 5-Axis Tool-path Generation from Point Cloud Input Using 3D Biarc Fitting.” *Robotics and Computer-Integrated Manufacturing*. Department of Industrial and Systems Engineering, Vol.24, Issue 2, pp 270–286.
- ❖ Chu-Song Chen (1999). “Ransac-based darces: A new approach to fast automatic registration of partially overlapping range images”. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Volume:21 , Issue: 11, pages, 1229-1234.
- ❖ Collet, A., (2009). “Object recognition and full pose registration from a single image for robotic manipulation" In: IEEE International Conference on Robotics and Automation. ICRA 2009.
- ❖ Csetverikov Dmitrij (2003). Basic Algorithms for Digital Image Analysis:a course. <[http://www.inf.u-szeged.hu/ssip/2003/lectures/chetverikov/edge\\_detection.pdf](http://www.inf.u-szeged.hu/ssip/2003/lectures/chetverikov/edge_detection.pdf)> Data de acesso 10 agosto 2012.
- ❖ Dionisio, C. R. P., (2005). *Características de formas planas invariantes sob-transformações de similaridade e afim*. Tese (Doutorado) – Escola Politécnica, Universidade de São Paulo, São Paulo, São Paulo.
- ❖ Dmitry C., and Zsolt S., 1999. “A simple and efficient algorithm for detection of high curvature points in planar curves”. CiteSeer. <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.55.5752>>.Data de acesso 10 agosto 2012.

- ❖ Feldmar, J and Ayache, N., (1996). “Rigid, affine and locally new registration of free-form surfaces”. *Journal International Journal of Computer Vision*. Volume 18 Issue 2. Pages 99 – 119.
- ❖ Flusser, J., (2005). “Moment Invariants in Image Analysis”. *World Academy of Science, Engineering and Technology*.
- ❖ Freeman, H., and Davis, L. S.(1977). “A Corner Finding Algorithm for Chain Coded Curves”. In: *IEEE Transactions in Computing*, Vol. 26, issue 3, pp 297–303.
- ❖ Garland, M., (1999). *Simplification Using Quadric Error Metrics*. PhD thesis, School of Computer Science Carnegie Mellon University, New York, USA.
- ❖ Gelfand *et al.*, (2005). “Robust global registration”. In: *Symposium on Geometry Processing*. Article No. 197.
- ❖ Ginani, L.S. (2008)., *Desenvolvimento de um Sistema de Digitalização Tridimensional de Superfícies Baseado em Visão Computacional com Varredura a Laser para Uso em Metrologia Dimensional*. Dissertação de Mestrado em Sistemas Mecatrônicos, Publicação ENM.DM-18A/2008, Departamento de Engenharia Mecânica, Universidade de Brasília, Brasília, DF, 187p.
- ❖ Gold, S., Rangarajan, A., (1996). “A graduated assignment algorithm for graph Matching”. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 18, n. 4, p. 377–388, 1996.
- ❖ Gonzales Márquez Mercedes Rocío., (2009). *Pré-alinhamento de Imagens de Profundidade via Malhas Simplificadas*. Tese de Doutorado Faculdade de Engenharia Elétrica Universidade de Campinas.
- ❖ Gonzalez, R and Woods, R., (2008). *Digital Image Processing – 3rd Edition*. Prentice Hall.
- ❖ Gomes, Leonardo., (2011). *Alinhamento automático de imagens de profundidade para modelagem 3d de objetos*. Dissertação. Programa de Pós-Graduação em Informática, Setor de Ciências Exatas, Universidade Federal do Paraná.
- ❖ Haddadnia, J., Ahmadi, M. and Faez, K., (2002). “An efficient method for recognition of human faces using higher orders pseudo Zernike moment invariant”. In: *Fifth IEEE, International Conference on Automatic Face and Gesture Recognition*. Proceedings. Washington, USA, 2002. p. 315–320.
- ❖ Higuchi, K., Hebert, M. and Ikeuchi, K., (1994). “Building 3d models from unregistered range images”. In: *Proceedings of IEEE Conference on Robotics and Automation (ICRA '94)*, volume 3, pages 2248- 2253.

- ❖ Hoover, A., Baptiste, G., Jiang, X. and Flynn, P.J. (1996). “An Experimental Comparison of Range Image Segmentation Algorithms”. In: IEEE transactions on pattern analysis and machine intelligence, Vol. 18, issue. 7, pp 673 – 689.
- ❖ Huang, Chun-Rong *et al.*, (2008).”Contrast context histogram: An efficient discriminating local descriptor for object recognition and image matching”. *Pattern recognition*. Volume 41, Issue 10, Pages 3071–3077.
- ❖ Huang, Z. and Cohen, F. S. (1994). “Affine-invariant B-spline moments for curve matching”. *Computer Vision and Pattern Recognition*. Pp. 587–592.
- ❖ Idrobo-Pizo, G. A., (2009)., *Sistema Computacional para Tratamento de Nuvens de Pontos e Reconstrução Tridimensional de Superfícies Baseada em Modelos Deformáveis*. Dissertação de Mestrado em Sistemas Mecatrônicos, Publicação Agosto/2009, Departamento de Engenharia Mecânica, Universidade de Brasília, Brasília, DF, 126 p.
- ❖ ISO GUM (2008). *Guide to the expression of uncertainty in measurement - Propagation of distributions using a Monte Carlo method*. Geneve, First edition.
- ❖ Johnson A., (1997). *Spin-Images: A Representation for 3-D Surface Matching*. Pittsburgh. These: Robotics Institute, Carnegie Mellon University.
- ❖ Latecki, L. J and Lakämper, R. (2000) “Shape similarity measure based on correspondence of visual parts”. *IEEE Trans. PAMI*, v. 22, n. 10, p. 1185–1190.
- ❖ Khotanzad, A. and Hong, Y. H. (1990). “Invariant image recognition by Zernike moments”. In: IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 12, issue. 5, p.489–497.
- ❖ Kim, H.K., (2000). “A modified Zernike moment shape descriptor invariant to translation, rotation and scale for similarity-based image retrieval”. In: IEEE International Conference On Multimedia and Expo, 2000. Proceedings. NY, USA, 2000. V. 1, p.p 307–310.
- ❖ Kovacs, A., (2009). “Local contour descriptors around scale-invariant keypoints”. In: IEEE International Conference on Image Processing .
- ❖ Lilles Jr., (2009). *Detecção de mudanças e recuperação de forma em mapas 3d baseados em nuvens de pontos*. Dissertação. Ciência da Computação do Instituto de Ciências Exatas da Universidade Federal de Minas Gerais. Brasil.
- ❖ Lowe, D. G., (1999). “Object recognition from local scale-invariant features”. The Proceedings of the Seventh IEEE International Conference on Computer Vision. Vol. 2.

- ❖ Luo Juan and Oubong Gwun.,(2009). “A Comparison of SIFT, PCA-SIFT and SURF”. *International Journal of Image Processing*. Volume(3), Issue(4). Pp 143-152.
- ❖ Masuda, T and Yokota, N., (1995). “Robust method for registration and segmentation of multiple range images”.*Computer Vision and Image Understanding*. Volume 61, Issue 3, pages 295–307.
- ❖ Martinez, J. and Thomas, F., (2002). “Efficient computation of local geometric moments”. In: *IEEE Transactions on Image Processing*, vol. 11, issue. 9, p. 1102–1111.
- ❖ Mercedes R. (2009). *Pré-alinhamento de Imagens de Profundidade via Malhas Simplificadas*. Tese: Faculdade de Engenharia Elétrica e de Computação. UNICAMP. Campinas, SP- Brasil.
- ❖ Mokhtarian, F., Abbasi, S. and Kittler, J.,(1997). “Efficient and robust retrieval by shape content through curvature scale space”. In: *Proceedings*. Singapore: World Scientific Publishing. p.p. 51–58.
- ❖ Osaimi, A., Bennamoun, M. e Mian A., (2009). “An Expression Deformation Approach to Non-rigid 3D Face Recognition”. *International Journal of Computer Vision March*, Volume 81, Issue 3, pp 302-316.
- ❖ Pizo, G.A. e Mota, J.M. (2012). Design and implementation of a motion controller for a spherical welding robot specially constructed for repairing damaged hydraulic turbines using a 3-d vision surface map. *ABCAM Symposium Series in Mechatronics*. 5ed.Vol. 5, p. 1174-1184.
- ❖ Planitz, B. M., *et al.*, (2005). “The correspondence framework for 3d surface matching algorithms”. *Computer Vision and Image Understanding*. Volume 97, Issue 3, Pages 347–383.
- ❖ Rosenfeld. H., e Johnston. E., 1973. Angle Detection on Digital Curves. In: *IEEE Transactions on Computers*, Vol. C-22, issue 9, pages 875–878.
- ❖ Rosenfeld. A., e Wezka. J. S.,1975., An Improved Method of Angle Detection on Digital Curves. In: *IEEE Transactions on Computers*, Vol. C-24, issue 9, pages 940–941.
- ❖ Rusinkiewicz, Szymon., (2004). “Estimating curvatures and their derivatives on triangle meshes”. *Proceedings of the 3D Data Processing, Visualization, and Transmission*, pp. 486–493, Washington,DC,USA.

- ❖ Sappa, A. (1999). *Automatic generator of 3D geometric model from Range Images*. Tese de Doutorado, Universidade de Catalunha, Catalunha, Barcelona, Espanha.
- ❖ Sato, Y. (1992). “Piecewise linear approximation of plane curves by perimeter optimization”. *Pattern Recognition*. Vol. 25, issue (1992), pp1535–1543.
- ❖ Serrano Talamantes., (2011). *Recuperación de imágenes mediante rasgos descriptores globales y locales*. Tesis, Doctor en Ciencias de la Computación, Instituto Politécnico Nacional, Ciudad de México, México.
- ❖ Shahar, B. e Sagi, F., (2008). “Keypoint based autonomous registration of terrestrial laser point-clouds”. *Journal of Photogrammetry and Remote Sensing*, Vol.63, pp.19-35.
- ❖ Stamos, I. and Leordeanu, M., (2003). “Automated feature-based range registration of urban scenes of large scale”. In: IEEE Computer Society Conference on Computer Vision and Pattern Recognition, vol. 2, pp. 555–561.
- ❖ Stoddart, A. and Brunnstrom, K., (1996). “Genetic algorithms for free-form surface matching”. In: Proceedings of the International Conference on Pattern Recognition. Volume 4, pages 689-693.
- ❖ Tu, Z., Zheng, S. and Yuille, A., (2008). “Shape matching and registration by data-driven”. *Computer Vision and Image Understanding*, Vol. 109, issue3, pp 290–304.
- ❖ Vanden, J. e Van, G. (2002). “Automatic crude patch registration: toward automatic 3D model building”. *Journal Computer Vision and Image Understanding - Registration and fusion of range images*. Volume 87 Issue 1-3. Pages 8 – 26.
- ❖ Wani and Batchelor, (1994). “Edge region-based segmentation of range images”. In: IEEE trans. on PAMI , Vol. 16, No 3., PP 314-319.
- ❖ Wendel, A., (2011). “Automatic alignment of 3D reconstructions using a Digital Surface Model”. In: IEEE Computer Society Conference on Computer Vision and Pattern Recognition.
- ❖ Wu, C., Clipp, B., Li, X., Frahm, J and Pollefeys, M., (2008). “3D Model Matching with Viewpoint-Invariant Patches (VIP)” In : IEEE Conference on Computer Vision and Pattern Recognition.
- ❖ Zhang G., (2009). “Review of shape representation and description techniques.”, *Pattern Recognition*. Vol. 37, issue.1, p. 1-19.

## 10. APÊNDICES

### APÊNDICE A – DIZIMAÇÃO DE UMA MALHA

No trabalho de Garlam (1999), é apresentado um algoritmo de dizimação que usa o princípio de contração de bordas de uma imagem de profundidade que seja representada por malhas. Este princípio estabelece crescimento de regiões, realizando a contração de bordas  $(v_i v_j)$  a um ponto  $(v)$  conforme ilustrado na figura (A.1). Este trabalho foi utilizado nesta pesquisa.

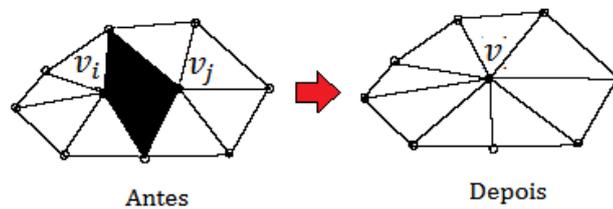


Fig. A.1. Contração de aresta

O algoritmo busca preservar ao máximo a geometria da superfície, pela minimização dos erros introduzidos na simplificação. Isto é, em cada iteração do algoritmo, uma borda é substituída pelo ponto que introduz o menor erro em relação à malha da iteração anterior. O erro quadrático  $E(v)$  é utilizado para avaliar as discrepâncias. O erro quadrático  $E$  associado a um vértice  $v$  é definido como a soma das distâncias quadradas do vértice a todas suas faces adjacentes

$$E(v) = \sum_k D_k^2(v) \quad (\text{A.1})$$

onde a distância quadrática de  $v$  a uma face adjacente  $k$ , é representada por  $\langle \mathbf{n}_k, v \rangle = d$ , que pode ser expressa por Garlam (1999):

$$D_k^2(v) = (\mathbf{n}_k^t v + d)^2 = v^t (\mathbf{n}_k \mathbf{n}_k^t) v + 2d \mathbf{n}_k^t v + d^2 \quad (\text{A.2})$$

sendo  $\mathbf{n}_k^t$  o vetor normal ao plano (face  $k$ ) e  $d$  um escalar constante. Esta distância pode também ser escrita em forma quadrática como:

$$Q(v) = v^t \mathbf{A} v + 2\mathbf{b}^t v + c = D^2(v) \quad (\text{A.3})$$

Fazendo  $\mathbf{A} = (\mathbf{n}_k \mathbf{n}_k^t)$ ,  $\mathbf{b}^t = 2d \mathbf{n}_k^t$ ,  $c = d^2$ ,  $Q$ , então, pode ser definido como o triplo  $Q = (\mathbf{A}, \mathbf{b}, c)$ , onde  $\mathbf{A}$  é uma matriz 3x3,  $\mathbf{b}$  um vetor de 3 escalares, e  $c$  um escalar. Por propriedade de quádricas, a adição de quádricas é realizada componente a componente,

assim:  $Q_1(v) + Q_2(v) = (Q_1 + Q_2)(v)$  onde  $(Q_1 + Q_2) = (\mathbf{A}_1 + \mathbf{A}_2, \mathbf{b}_1 + \mathbf{b}_2, c_1 + c_2)$ . Com isso, a soma das distâncias quadráticas de um vértice  $v$  até suas faces adjacentes é igual a uma quádriga  $Q$ :

$$E(v) = \sum_k D_k^2(v) = \sum_k Q_k(v) = Q(v) \quad (\text{A.4})$$

Para determinar o ponto  $v$  que introduz o menor erro na contração de uma aresta  $(v_i v_j)$ , é preciso modelar o erro da aresta e minimizá-lo. Pela propriedade de soma de quádrigas, o erro quadrático da borda  $(v_i v_j)$  é dado pela função quádriga:

$$Q_1(\bar{v}) + Q_2(\bar{v}) = Q(\bar{v}) \quad (\text{A.5})$$

onde  $Q_1$  e  $Q_2$  são erros quádrigos associados aos vértices  $v_i$  e  $v_j$ , respectivamente. A minimização desta função fornece o vértice  $v$  que substitui a aresta  $(v_i v_j)$ . Já que  $Q(v)$  é quádrigo, encontrar seu mínimo é um problema linear; o mínimo ocorre quando  $\partial Q/\partial x = \partial Q/\partial y = \partial Q/\partial z = 0$ . Calculando as derivadas parciais de  $Q(\bar{v}) = v^t A v + 2b^t v + c$ , tem-se o gradiente de  $Q$ .

$$\Delta Q(v) = 2Av + 2b \quad (\text{A.6})$$

Resolvendo para  $\Delta Q(v) = 0$ , encontra-se:

$$v = -\mathbf{A}^{-1}\mathbf{b} \quad (\text{A.7})$$

Assim,  $v$  é o vértice que introduz o menor erro, o que representa a contração ótima para a aresta  $(v_i v_j)$ . De acordo com Gonzales Marques (2009), para determinar, dentre todas as arestas da malha triangular, a aresta cuja eliminação introduzirá o menor erro em relação à malha triangular da iteração anterior, deve-se, primeiro, calcular a contração ótima  $v$  de cada aresta e seu erro  $E(v)$  e, segundo, escolher para contração a aresta que apresenta o menor erro  $E$ . O processo é repetido, até que uma determinada quantidade de triângulos seja alcançada. Por exemplo, na figura. (A.2) foi realizada disseminação de uma superfície representando a superfície original por um menor número de pontos.

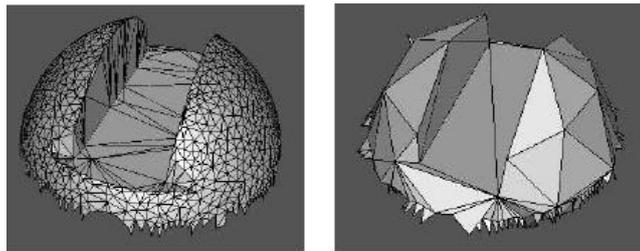
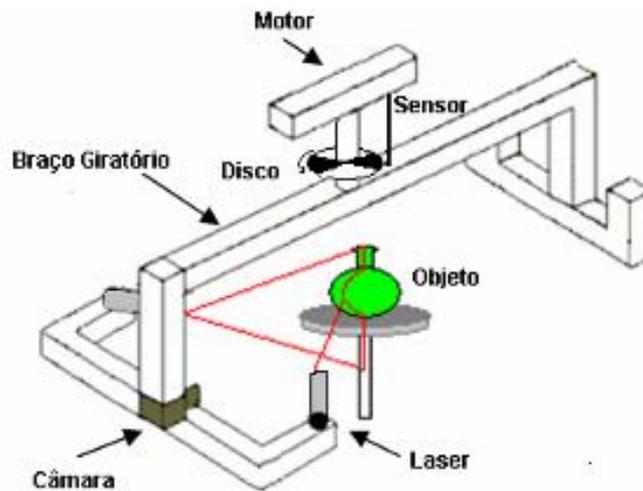


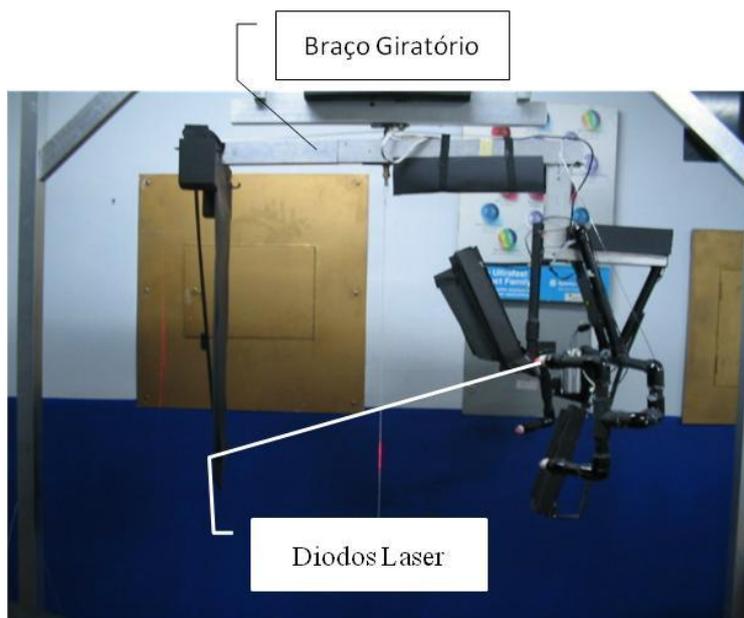
Fig.A.2 Dizimação da malha de uma imagem de profundidade

## APÊNDICE B – DIGITALIZADOR TRI\_IDENT

Os algoritmos de pré-alinhamento e alinhamento fino foram também testados com nuvens de pontos capturadas com o digitalizador laser que se apresenta na seguinte figura.



(a) Desenho Esquemático



(b) Montagem do Sistema

Fig. B.1. Digitalizador laser –TRI\_IDENT

O sistema está composto de três módulos:

**Modulo I.** Sistema de aquisição de imagens: A aquisição de imagens se realiza mediante a utilização de uma câmera colorida, BQ´ 3410. Para aquisição e processamento das imagens utiliza-se uma placa aceleradora gráfica 256 MB de memória. O tamanho da imagem obtida é de 640 x 480 píxeis.

**Modulo II.** Projetor laser: O sistema utiliza dois diodos lasers que emitem um feixe que se transforma, através de uma lente, em um plano de luz. A deformação deste padrão de luz, quando projetado sobre a superfície do objeto, permite o cálculo, através de um processo de triangulação, da profundidade dos pontos da superfície do objeto a reconstruir. O comprimento de onda do laser usado é de 632 nm. O motivo de utilizar dois lasers é para eliminar regiões desconhecidas, que aparecem quando se interpõe o plano de luz laser e o plano de observação detectado pela câmera.

**Modulo III.** Braço giratório: Facilita a varredura da superfície dum objeto com o plano laser, o que permite a obtenção de sua geometria. O braço se move impulsionado por um motor de passo, com movimento angular em uma faixa de  $[0^\circ, 270^\circ]$  e comprimento de 200 cm. O sistema giratório é movido via software, através de instruções de sinais de controle de posição. A frequência do movimento do braço giratório é 50 s / volta (0,02Hz).

**Modulo VI.** Unidade de controle de posicionamento angular: esta unidade pode ser observada esquematicamente na figura (B.2a) e está constituída por um microcontrolador 16F84a, uma barra leds de oito unidades, um optacoplador de referência ITR 8103 e um choper.

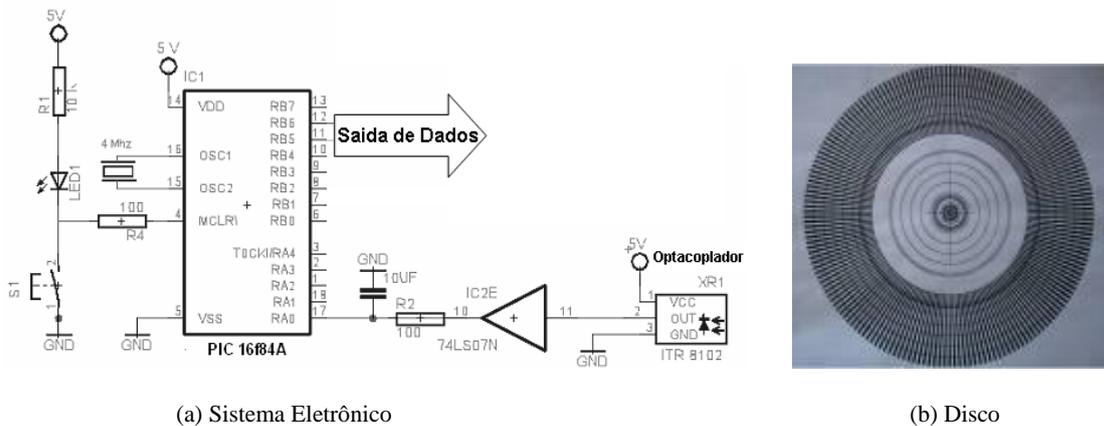


Fig.B.2. Unidade de controle de posicionamento angular.

O choper é um disco circular Figura (B.2b) que tem 90 zonas translúcidas e 90 zonas opacas alternadamente, com um raio de (7.5 cm) e que espacialmente se encontra localizado na parte superior do braço giratório figura (B.2). O propósito é detectar e referenciar instantaneamente a posição do braço através de um transdutor eletro-óptico. Esse sensor permite a conversão do sinal da luz infravermelha para um sinal elétrico

quando aquela é interrompida pelas zonas escuras do disco. Esse sensor envia uma tensão que é previamente conhecida. Aquele sinal é filtrado, amplificado e digitalizado na faixa TTL (circuito esquemático da figura (B.2a) e imediatamente o circuito informa ao computador (porta USB) para que a câmera capture a imagem). O sistema eletrônico permite a contagem de 360 estados que corresponde a 360 graus do giro completo do braço giratório, ou seja, para cada estado captura-se uma imagem.

A resolução do disco, de acordo o fabricante, é de  $5,23 \pm 0,15$ mm de arco por faixa (preta ou branca), e a frequência máxima de captura de dados pelo sensor eletro-óptico é de 50 MHz . Sabendo-se que o braço gira a frequência muito menor que a velocidade de resposta do sensor, o erro estimado de posicionamento ( $E_{encoder}$ ) angular do sistema Encoder (Disco + sensor eletro - óptico ) é dado por:  $E_{encoder} = (0.15mm) \frac{(360^\circ)}{2\pi(75mm)} = 0.11^\circ$ , onde 0,15mm é o erro de posicionamento do disco e 75mm é o raio do disco. A resolução do encoder é, portanto, de  $1^\circ \pm 0.11^\circ$ . Cabe acrescentar que os sistemas de aquisição, câmera, placa de processamento, projetor laser e braço giratório estão sensoreados e interconectados por um PC e controlados por software especificamente desenvolvido, que se ocupa de comunicar, proporcionar e executar os comandos que fazem funcionar cada parte do sistema de modo automático.

## APÊNDICE C – DEFINIÇÕES

Nesta seção se apresenta um conjunto definições e nomenclaturas

### Amostragem

Uma amostragem de uma variedade  $M$  é um conjunto finito de pontos.

### Amostragem uniforme

Uma amostragem é dita  $\varepsilon$ -uniforme se para todo  $q$  pertencente à superfície original existe um ponto  $p$  da amostra tal que  $\|p - q\| < \varepsilon$ .

### Diagrama de Voronoi

Seja  $P \subset \mathbb{R}^n$  um conjunto de pontos. Para cada  $p$  e  $q \in P$ , seja  $B(p, q) = \{x: \|x - p\| \leq \|x - q\|\}$ , contendo  $p$ , e  $D(p, q)$  é o semi-espaco que contém  $q$ . Define se por  $VR(p, P) = \cap_{q \in P, q \neq p} D(p, q)$  a região de Voronoi.

O Diagrama de Voronoi de  $P$  é definido por:  $V(P) = \cup_{p, q \in P, p \neq q} VR(p, P) \cap VR(q, P)$ .

A figura (C.1) apresenta um exemplo de Diagrama de Voronoi:

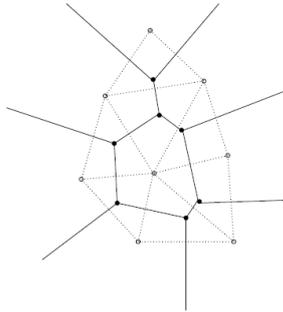


Fig. C.1. Diagrama de Voronoi (dois pontos sem preenchimento) em linhas contínuas. Em linhas pontilhadas, seu dual, a Triangulação de Delanuy.

### $\varepsilon$ -amostragem :

Uma  $\varepsilon$ -amostragem é definida a partir do local-feature size  $f(x)$  da seguinte forma: seja um ponto  $x$  sobre a superfície original, sempre deve existir um ponto  $p$  na amostragem tal que  $\|p - x\| \leq \varepsilon f(x)$ . Ou seja, para cada ponto da superfície deve existir um ponto na amostra a uma distância proporcional ao local-feature size.

### Eixo medial

Define se como eixo medial de uma superfície  $M$  o conjunto de pontos que definem os centros de esferas que tangenciam  $M$  em ao menos dois pontos.

### Entalhe paramétrico

Patches NURBS.

### Descritor

Um descritor de imagem  $D$  pode ser definido como uma função que extrai um vetor de características  $v$  de  $n$  dimensões. Em que  $n$  é o número de características utilizadas

para descrever a imagem em questão.

### Face

Se  $\sigma$  é um  $n$ -simplexo formado pelos pontos  $X = \{x_0, \dots, x_n\}$  qualquer  $l$ -simplexo dado por um subconjunto de  $l+1$  com  $l < n$  elementos de  $X$  é face de  $\sigma$ .

### Fecho convexo

Dado um conjunto de pontos  $P \subset \mathbb{R}^n$ , o conjunto de todas as combinações lineares convexas, dada pela seguinte equação, exprime a definição de fecho convexo (Fig. C.2).

$$\text{Conv}(P) = \left\{ \sum_{i=0}^n \lambda_i p_i, \sum_{i=0}^n \lambda_i = 1, \lambda_i \geq 0, \lambda_i \in \mathbb{R}, p_i \in P \right\} \quad (\text{C.1})$$

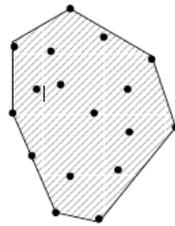


Fig. C.2. Exemplo bidimensional do fecho convexo de um conjunto de pontos.

O fecho convexo  $\text{Conv}(P)$  pode ser visto como o menor conjunto convexo que contém os pontos de  $P$ .

### Homeomorfismo

Sejam os conjuntos  $U \subset \mathbb{R}^n$  e  $V \subset \mathbb{R}^m$ . Afirma-se que uma função  $f: U \rightarrow V$  é um homeomorfismo, se  $f$  e  $f^{-1}$  são contínuas. Nesse caso  $U$  e  $V$  são ditos homeomorfos.

### ISO

O "ISO" de uma câmera (em inglês "ISO setting" ou "ISO speed") é um padrão que descreve a sua sensibilidade absoluta à luz.

### Local Feature Size

A local Feature Size é a distância de um ponto na superfície até o eixo medial.

### Quádrlica

Conjunto dos pontos do espaço tridimensional cujas coordenadas formam um polinômio de segundo grau de no máximo três variáveis denominada de equação cartesiana da superfície:

$$x^2 + By^2 + Cz^2 + Dxy + Eyz + Fxz + Gx + Hy + Iz + J = 0 \quad (\text{C.2})$$

### Malhas estruturadas

São Malhas que apresentam a mesma conectividade para todos os vértices internos. Seus nós internos formam tipicamente quadriláteros ou hexaedros, seus algoritmos geralmente empregam métodos complexos de suavização na tentativa de alinhar os elementos internos com os elementos das bordas do domínio.

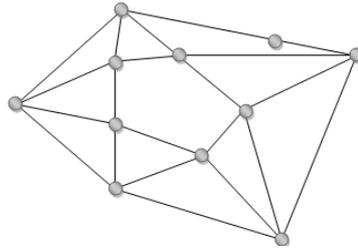


Fig. C.3 Uma malha estruturada, todos os nos internos têm grau quatro.

### Malhas não estruturadas

São malhas que apresentam maior liberdade na conectividade dos vértices internos, podendo apresentar qualquer número de arestas incidentes. Os elementos de uma malha não estruturada são tipicamente triângulos ou tetraedros.

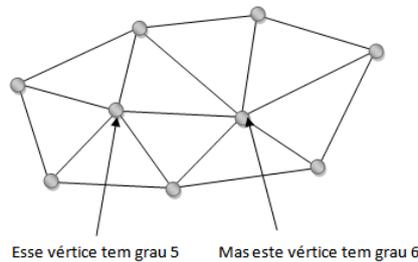


Fig. C.4 Uma malha não estruturada, os nós internos possuem graus diferentes.

### Pontos característicos

Pontos de alta curvatura, que concentram mais informações que os outros pontos do contorno de um objeto de uma imagem (Attneave, 1954). Esses pontos são importantes para várias aplicações na área de processamento de imagens, tais como: registro de imagens, aproximação poligonal (Shearer e Zou, 2005) e análise de movimento (Richefeu, 2003). Para descrição de formas (Torres Falcão, 2007; Pedrosa et al., 2008) pontos característicos são bastante proveitosas, uma vez que elas têm a habilidade de representar um objeto de maneira compacta, invariante à rotação e translação. A figura seguinte mostra os pontos característicos de uma estrela.

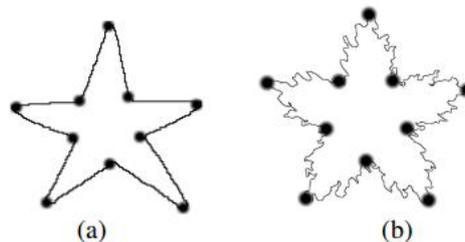


Fig C.5. Pontos característico de uma estrela: (a) sem ruído, (b) com ruído.

Pontos Característicos têm alto valor de curvatura, mas nem todos os pontos de alta curvatura são pontos característicos, tais como pontos ruidosos. Um detector de pontos característicos deve ser capaz de detectar pontos característicos mesmo em imagens com alto nível de ruído. Além disso, um detector de pontos característicos deve satisfazer outros importantes critérios (Mokhtarian e Suomela, 1998), tais como: todos os pontos característicos devem ser detectados; nenhuma falso ponto característico

deve ser detectada e o detector deve ser eficiente computacionalmente.

### Triangulação de Delaunay

Seja  $X = \{x_0, \dots, x_k\} \subset \mathbb{R}^n, n \leq k$ , afirma-se que uma triangulação de  $X$  é de Delaunay se a circunferência de todo  $n$ -simplexo não contém nenhum outro ponto de  $X$  em seu interior.

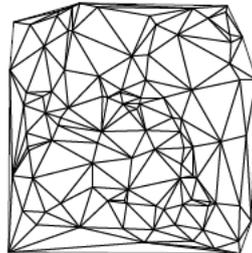


Fig. C.6. Exemplo de uma Triangulação de Delaunay de um conjunto de 100 pontos no plano euclidiano.

### Simplexo

Um  $n$ -simplexo  $\sigma \subset \mathbb{R}^n$  é o fecho convexo de  $n + 1$  pontos em posição geral (fig. C.7).

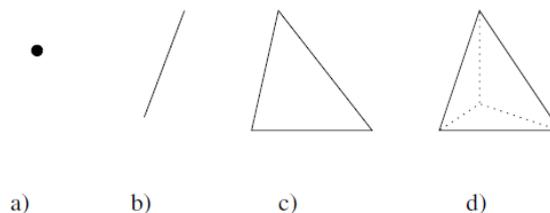


Fig. C.7. (a) simplexo (b)1-simplexo (c)2-simplexo (d)3-simplexo

### Superquadrica

Trata-se de uma generalização das quádricas donde se adicionam parâmetros que afetam o grau da equação implícita, com aquilo se obtém variações interessantes da forma. Por exemplo Super-elipse será uma variante do elipse, donde se adiciona um parâmetro  $n$  que afeta o grau da equação. Na figura (C.8), se pode observar os efeitos das mudanças em  $n$ .

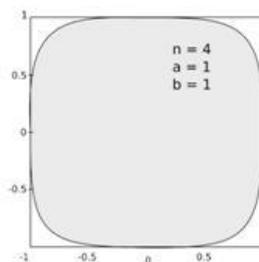


Fig. C.8. Uma super elipse para  $n = 4, a = b = 1$  se aproxima a um quadrado arredondado.

### RBFs (Função-base radial)

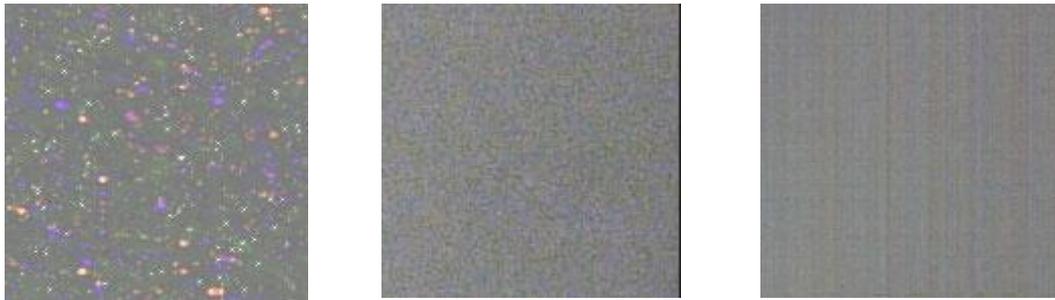
Uma função-base radial é uma função simétrica em relação à vizinhança radial de um ponto (centro).

## Ruído em Imagens Digitais

Para as imagens digitais, o ruído aparece como manchas aleatórias em uma superfície originalmente suave e pode degradar a qualidade da imagem significativamente.

### Tipos de ruído

Câmeras digitais produzem três tipos mais comuns de ruído: aleatório, de 'padrão fixo' e de bandas. As três imagens abaixo mostram exemplos qualitativos pronunciados de casos isolados de cada um dos tipos de ruído contra um fundo cinza.



**Ruído com Padrão Fixo**  
Exposição Longa  
Baixo ISO

**Ruído Aleatório**  
Exposição Curta  
Alto ISO

**Ruído em Bandas**  
Câmera Suscetível  
Sombras Clareadas

Fig. C.9. Ruído dentro de uma imagem.

## Variedade

O conjunto  $M \subset \mathbb{R}^k$  é uma variedade de dimensões  $n$  classe  $C^r$  se para todo  $x \in M$  existe uma vizinhança aberta  $U \ni x$ , com  $U \subset \mathbb{R}^k$ ,  $V$  aberto de  $\mathbb{H}^n$  e um difeomorfismo de classe  $C^r$   $\varphi: U \cap M \rightarrow V$  (Fig. C. 10).

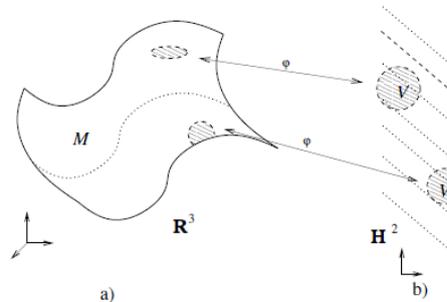


Fig. C.10. Exemplo de uma variedade de dimensão 2 imersa em  $\mathbb{R}^3$ .

## Vizinhança Natural.

Sejam  $X = \{x_0, \dots, x_n\}$  uma amostra obtida sobre uma superfície  $S$  e  $p$  um ponto qualquer. A vizinhança natural de  $p$  é dada pelos pontos interligados a  $p$  na Triangulação de Delanuy de  $X \cup p$ .