



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA DE TELEINFORMÁTICA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA**

**NÍCOLAS SILVA PEREIRA**

**CLOUD PARTITIONING ITERATIVE CLOSEST POINT (CP-ICP): UM  
ESTUDO COMPARATIVO PARA REGISTRO DE NUVENS DE PONTOS  
3D.**

**FORTALEZA**

**2016**

NÍCOLAS SILVA PEREIRA

CLOUD PARTITIONING ITERATIVE CLOSEST POINT (CP-ICP): UM ESTUDO  
COMPARATIVO PARA REGISTRO DE NUVENS DE PONTOS 3D.

Dissertação apresentada ao Programa de Pós-graduação em Engenharia de Teleinformática do Departamento de Engenharia de Teleinformática da Universidade Federal do Ceará, como parte dos requisitos necessários para a obtenção do título de Mestre em Engenharia de Teleinformática. Área de concentração: Sinais e Sistemas.

Orientador: Prof. Dr. George André Pereira Thé

FORTALEZA

2016

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Biblioteca Universitária  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

P493c Pereira, Nicolas Silva.

Cloud Partitioning Iterative Closest Point (CP-ICP) : Um estudo comparativo para registro de nuvens de pontos 3D. / Nicolas Silva Pereira. – 2016.  
35 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2016.

Orientação: Prof. Dr. George André Pereira Thé.

1. Visão computacional. 2. Iterative Closest Point. 3. Registro de nuvens de pontos. 4. Amostragem de nuvens de pontos. I. Título.

CDD 621.38

---

NÍCOLAS SILVA PEREIRA

CLOUD PARTITIONING ITERATIVE CLOSEST POINT (CP-ICP): UM ESTUDO  
COMPARATIVO PARA REGISTRO DE NUVENS DE PONTOS 3D.

Dissertação apresentada ao Programa de Pós-graduação em Engenharia de Teleinformática do Departamento de Engenharia de Teleinformática da Universidade Federal do Ceará, como parte dos requisitos necessários para a obtenção do título de Mestre em Engenharia de Teleinformática. Área de concentração: Sinais e Sistemas.

Aprovada em: 15 / 07 / 2016.

BANCA EXAMINADORA

---

Prof. Dr. George André Pereira Thé (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Auzuir Ripardo de Alexandria  
Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

---

Prof. Dr. José Marques Soares  
Universidade Federal do Ceará (UFC)

Dedico este trabalho à Deus, à minha família,  
à minha noiva e ao meu orientador.

## AGRADECIMENTOS

À Deus, pela dávida de uma vida tão maravilhosa.

À minha noiva, Cinthya, pelo amor e companheirismo de tantos anos.

Aos meus pais, Lima e Lucilene, minhas irmãs, Lana e Thaís, e meu irmão, Dyego, pelo suporte que representam.

Ao Prof. George, pela excelente e dedicada orientação e pela amizade.

À Universidade Federal do Ceará, que já tenho como uma segunda casa.

À FUNCAP, pelo apoio financeiro com a manutenção da bolsa de auxílio.

*”Look up at the stars and not down at your feet. Try to make sense of what you see, and wonder about what makes the universe exist. Be curious.”*

(Stephen W. Hawking)

## RESUMO

Com a evolução científica e tecnológica de equipamentos como câmeras e sensores de imagens, a visão computacional se mostra cada vez mais consolidada como solução de engenharia para problemas das mais diversas áreas. Associando isto com a disseminação dos sensores de imagens 3D, o aperfeiçoamento e a otimização de técnicas que lidam com o registro de nuvens de pontos 3D, como o algoritmo clássico Iterative Closest Point (ICP), se mostram fundamentais na resolução de problemas como desvio de colisão e tratamento de oclusão. Nesse contexto, este trabalho propõe um técnica de amostragem a ser utilizada previamente ao algoritmo ICP. O método proposto é comparado com outras cinco variações de amostragem a partir de três critérios: RMSE (*root mean squared error*), a partir de uma análise de ângulos de Euler e uma métrica autoral baseada no índice de *structural similarity* (SSIM). Os experimentos foram desenvolvidos em quatro modelos 3D distintos vindos de dois diferentes *databases*, e revelaram que a abordagem apresentada alcançou um registro de nuvens mais acuraz num tempo menor que as outras técnicas.

**Palavras-chave:** Visão computacional; *Iterative Closest Point*; registro de nuvens de pontos; amostragem de nuvens de pontos.

## ABSTRACT

In relation to the scientific and technologic evolution of equipment such as cameras and image sensors, the computer vision presents itself more and more as a consolidated engineering solution to issues in diverse fields. Together with it, due to the 3D image sensors dissemination, the improvement and optimization of techniques that deals with 3D point clouds registration, such as the classic algorithm Iterative Closest Point (ICP), appear as fundamental on solving problems such as collision avoidance and occlusion treatment. In this context, this work proposes a sampling technique to be used prior to the ICP algorithm. The proposed method is compared to other five variations of sampling techniques based on three criteria: RMSE (root mean squared error), based also on an Euler angles analysis and an autoral criterion based on structural similarity index (SSIM). The experiments were developed on four distincts 3D models from two databases, and shows that the proposed technique achieves a more accurate point cloud registration in a smaller time than the other techniques.

**Keywords:** Computer vision; Iterative Closest Point; point cloud registration; point cloud sampling.

## LISTA DE FIGURAS

Figura 1 – Em a) conjunto de dados <i>Dragon</i> e em b) uma representação por nuvem de pontos . . . . .	18
Figura 2 – Representação típica de um sistema de visão computacional na indústria. . . . .	19
Figura 3 – Possíveis abordagens para o problema de verificação de qualidade com visão computacional. . . . .	20
Figura 4 – Cenário de simulação de movimento de quadrotores com obstáculos estáticos. . . . .	21
Figura 5 – Desvio de colisão de robô respeitando o espaço pessoal dos pedestres. . . . .	22
Figura 6 – Amostragem por relevância ressaltando os pontos de maior curvatura. . . . .	23
Figura 7 – Exemplo de utilização do registro de duas nuvens pelo algoritmo ICP. Em a) nuvens de pontos no alinhadas e em b) nuvens de pontos após o registro com ICP. . . . .	27
Figura 8 – Três imagens com mesmo valor de MSE. Em a) a imagem original, em b) uma imagem com contraste estendido e em c) uma compressão JPEG da imagem original. . . . .	28
Figura 9 – As cinco perspectivas analisadas para a métrica baseada em SSIM. . . . .	30
Figura 10 – Conjuntos de imagens obtidas para cada perspectiva. Em a) imagem <i>dot pattern</i> , em b) imagem cheia, em c) imagem de contorno e em d) imagem esqueleto. . . . .	31
Figura 11 – Comparação entre diferentes registros utilizando a imagem em <i>dot pattern</i> . Em a) a imagem de referência, em b) o registro com ICP . . . . .	32
Figura 12 – Representação Z-Y-X de Ângulos de Euler. . . . .	33
Figura 13 – Em a) elementos estruturantes e em b) suas representações matriciais. . . . .	35
Figura 14 – Erosão e Dilatação de imagens binárias. Em a) imagem de referência, em b) erosão da referência por um elemento estruturante em forma de losango com janela de 11 <i>pixels</i> . Em c) dilatação da referência pela mesmo elemento estruturante da imagem em b). Em d) e e) situação similar aos itens b) e c), porém utilizando um elemento estruturante na forma de quadrado. Por fim, em f) é mostrada uma extração de contorno através da subtração da imagem original por sua versão erodida. . . . .	36
Figura 15 – Amostragens aleatórias. Em a) a nuvem de pontos de referência, proveniente de STANFORD (1996), em b) amostragem aleatória utilizando 50% dos pontos. Em c) amostragem aleatória utilizando 1% dos pontos. . . . .	40

Figura 16	Em a) nuvem de pontos de referência. Em b) é apresentado o conjunto de pontos obtidos a partir da rede neural SOM que busca aprender a topologia do conjunto de dados. Em c) é apresentado somente o conjunto de pontos resultante do aprendizado de topologia a partir da rede neural SOM. . . . .	41
Figura 17	Em a) objeto utilizado como referência para aquisição de nuvens de pontos. Em b) duas perspectivas deste objeto rotacionadas entre si em 180° em torno do eixo z. . . . .	43
Figura 18	Exemplo ilustrativo da divisão de uma nuvem de pontos em 4 sub-nuvens.	43
Figura 19	Descrição do procedimento proposto. . . . .	44
Figura 20	Em a) Tempo total do registro com CP-ICP para o modelo <i>Horse</i> variando a quantidade de sub-nuvens (quantidade definida pelo parâmetro $k$ ). Em b) o tempo médio de cada iteração do CP-ICP ao variarmos o valor de $k$ . . . . .	46
Figura 21	Objetos utilizados como referência para nuvens de pontos utilizados do <i>database</i> em (ALEOTTI and RIZZINI (2014)). Em a) é mostrado o <i>Horse</i> e em b) o <i>Hammer</i> . . . . .	47
Figura 22	Objetos de referência para os modelos utilizados, presentes em (STANFORD (1996)). Em a) é mostrado o <i>Dragon</i> e em b) o <i>Buddha</i> . . . . .	48
Figura 23	Metodologia adotada para comparar os métodos de amostragem. Em (1) os métodos de amostragem são aplicados as nuvens de pontos e então estas são submetidas ao ICP. Em (2) os resultados dos registros são obtidos para cada técnica de amostragem. Em (3) os resultados são então comparados utilizando RMSE, ângulos de Euler e SSIM. . . . .	49
Figura 24	Resultado do registro para o modelo <i>Dragon</i> . Em a) ICP sem amostragem. Em b) resultado registro do método proposto CP-ICP. . . . .	51
Figura 25	Comparação dos resultados dos registro para o modelo <i>Horse</i> . Em a) o registro do ICP sem amostragem. Em b) o registro com amostragem aleatória 50% e em c) o registro do CP-ICP. . . . .	54
Figura 26	Visão ampliada dos registros para o modelo <i>Buddha</i> . Em a) registro com ICP sem amostragem, em b) registro com amostragem aleatória 50%, em c) registro com amostragem aleatória 70%, em d) registro com CP-ICP, em e) <i>ground-truth</i> do modelo <i>Buddha</i> e em f) a imagem original do modelo <i>Buddha</i> . . . . .	55
Figura 27	Modelo <i>Horse</i> : ICP . . . . .	63
Figura 28	Modelo <i>Horse</i> : CP-ICP . . . . .	63
Figura 29	Modelo <i>Horse</i> : Aleatória 50% . . . . .	64
Figura 30	Modelo <i>Horse</i> : Aleatória 70% . . . . .	64
Figura 31	Modelo <i>Horse</i> : SOM com 125 neurônios . . . . .	64

Figura 32 –Modelo <i>Horse</i> : SOM com 512 neurônios . . . . .	65
Figura 33 –Modelo <i>Hammer</i> : ICP . . . . .	65
Figura 34 –Modelo <i>Hammer</i> : CP-ICP . . . . .	65
Figura 35 –Modelo <i>Hammer</i> : Aleatória 50% . . . . .	65
Figura 36 –Modelo <i>Hammer</i> : Aleatória 70% . . . . .	66
Figura 37 –Modelo <i>Hammer</i> : SOM com 125 neurônios . . . . .	66
Figura 38 –Modelo <i>Hammer</i> : SOM com 512 neurônios . . . . .	66
Figura 39 –Modelo <i>Dragon</i> : ICP . . . . .	66
Figura 40 –Modelo <i>Dragon</i> : CP-ICP . . . . .	67
Figura 41 –Modelo <i>Dragon</i> : Aleatória 50% . . . . .	67
Figura 42 –Modelo <i>Dragon</i> : Aleatória 70% . . . . .	67
Figura 43 –Modelo <i>Buddha</i> : ICP . . . . .	68
Figura 44 –Modelo <i>Buddha</i> : CP-ICP . . . . .	68
Figura 45 –Modelo <i>Buddha</i> : Aleatória 50% . . . . .	69
Figura 46 –Modelo <i>Buddha</i> : Aleatória 70% . . . . .	69

## LISTA DE TABELAS

Tabela 1 – Condição de parada para registro suficiente de cada modelo estudado. . . . .	45
Tabela 2 – Tamanho dos conjuntos de dados. . . . .	48
Tabela 3 – Comparação de tempo em segundos entre métodos de amostragem. . . . .	50
Tabela 4 – RMSE calculado para o registro com cada técnica de amostragem. . . . .	51
Tabela 5 – Ângulos de Euler obtidos pelos registros. . . . .	52
Tabela 6 – Métrica com índice SSIM para o modelo <i>Horse</i> . . . . .	53
Tabela 7 – Métrica com índice SSIM para o modelo <i>Hammer</i> . . . . .	53
Tabela 8 – Métrica com índice SSIM para o modelo <i>Dragon</i> . . . . .	53
Tabela 9 – Métrica com índice SSIM para o modelo <i>Buddha</i> . . . . .	54
Tabela 10 – Resultados de tempo de acordo com o sentido de iteração das sub-nuvens. . . . .	57

## LISTA DE ABREVIATURAS E SIGLAS

2D	Bidimensional
3D	Tridimensional
ICP	<i>Iterative Closest Point</i>
CP-ICP	<i>Cloud Partitioning Iterative Closest Point</i>
SSIM	<i>Structure similarity</i>
RMSE	<i>Root mean squared error</i>
IIoT	<i>Industrial Internet-of-things</i>
SOM	<i>Self-organizing maps</i>
NC	<i>Numeric control</i>
NR	Norma reguladora
NDT	<i>Normal distributions transform</i>
PSNR	<i>Peak signal-to-noise ratio</i>
DOF	<i>Degree of freedom</i>
SOM 5	Amostragem por redes neurais SOM utilizando $5^3$ (125) neurônios
SOM 8	Amostragem por redes neurais SOM utilizando $8^3$ (512) neurônios

## LISTA DE SÍMBOLOS

$F(\vec{q})$	Função custo do algoritmo <i>Iterative Closest Point</i>
$N_X$	Número de pontos da nuvem de pontos alvo
$N_P$	Número de pontos da nuvem de pontos de entrada
$\vec{x}$	Nuvem de pontos alvo
$\vec{p}$	Nuvem de pontos de entrada
$R$	Matriz de rotação
$T$	Vetor de translação
$\vec{q}$	Vetor quaternion referente ao conjunto rotação e translação
$\vec{q}_R$	Vetor quaternion referente à parcela da rotação
$\vec{q}_T$	Vetor quaternion referente à parcela da translação
$C_{XP}$	Matriz de covariância cruzada dos conjunto alvo e entrada
$Q(C_{XP})$	Matriz para obtenção do quaternion referente ao registro de nuvens de pontos
$\vec{\mu}_X$	Vetor de média da nuvem de pontos alvo
$\vec{\mu}_P$	Vetor de média da nuvem de pontos de entrada
$\mu_a$	Intensidade média de uma dada imagem A
$N_a$	Número de pixels da imagem A
$a_i$	Valor de intensidade do i-ésimo pixel da imagem a
$\sigma_a$	Desvio padrão do sinal discreto extraído da média $\mu_a$
$L$	Espaço possível de valores para um pixel
$K_1$ e $C_1$	Constantes de controle para a função da luminosidade
$K_2$ e $C_2$	Constantes de controle para a função da constraste
$K_3$ e $C_3$	Constantes de controle para a função da estrutura
$\alpha$	Parâmetro da importância relativa da função de luminosidade
$\beta$	Parâmetro da importância relativa da função de constraste
$\gamma$	Parâmetro da importância relativa da função de estrutura
$\alpha_E$	Ângulo de Euler referente à rotação em torno do eixo z
$\beta_E$	Ângulo de Euler referente à rotação em torno do eixo y
$\gamma_E$	Ângulo de Euler referente à rotação em torno do eixo x
$M$	Matriz representativa de uma rotação em cada eixo
$R_Z$	Matriz de rotação em torno do eixo z
$R_Y$	Matriz de rotação em torno do eixo y
$R_X$	Matriz de rotação em torno do eixo x
$C_z$	Cosseno de $\gamma_E$ em torno do eixo z
$s_z$	Senos de $\gamma_E$ em torno do eixo z
$C_y$	Cosseno de $\beta_E$ em torno do eixo y
$s_y$	Senos de $\beta_E$ em torno do eixo y
$C_x$	Cosseno de $\alpha_E$ em torno do eixo x

$s_x$	Seno de $\alpha_E$ em torno do eixo x
$Z^2$	Espaço bidimensional dos números inteiros
$IM$ e $ES$	Imagens que são conjuntos do espaço $Z^2$
$\ominus$	Operador de erosão entre duas imagens
$\oplus$	Operador de dilatação entre duas imagens
$(ES)_j$	Operação de translação da imagem $ES$ no pixel $j$
$U$	Um dado universo amostral
$k$	Parâmetro de entrada do CP-ICP. Indica o número de sub-nuvens

## SUMÁRIO

1	INTRODUÇÃO . . . . .	18
1.1	Problemática . . . . .	19
1.2	Motivação . . . . .	21
1.3	Objetivos . . . . .	24
1.4	Publicações científicas . . . . .	24
1.5	Organização do trabalho . . . . .	25
2	FUNDAMENTAÇÃO TEÓRICA . . . . .	26
2.1	Algoritmo <i>Iterative Closest Point</i> . . . . .	26
2.2	<i>Structure similarity index</i> . . . . .	27
2.3	Métrica baseada em SSIM . . . . .	30
2.4	Ângulos de Euler . . . . .	32
2.5	Processamento morfológico de imagens . . . . .	34
2.5.1	<i>Elemento estruturante</i> . . . . .	34
2.5.2	<i>Erosão e Dilatação</i> . . . . .	35
2.6	Amostragem . . . . .	37
2.6.1	<i>Amostragem aleatória</i> . . . . .	37
2.6.2	<i>Redes neurais Self-Organizing Map (SOM)</i> . . . . .	38
3	CLOUD PARTITIONING ICP . . . . .	42
3.1	Particionamento das nuvens . . . . .	42
3.2	Registro suficiente . . . . .	44
3.3	<i>Tradeoff</i> entre soluções e tempo . . . . .	45
4	MATERIAIS E METODOS . . . . .	47
4.1	Conjuntos de dados . . . . .	47
4.2	Metodologia . . . . .	48
4.3	Métricas utilizadas . . . . .	49
5	RESULTADOS . . . . .	50
5.1	Tempo decorrido . . . . .	50
5.2	Métrica de RMSE . . . . .	50
5.3	Análise de ângulos de Euler . . . . .	52
5.4	Métrica baseada em SSIM . . . . .	52
6	LIMITAÇÕES E TRABALHOS FUTUROS . . . . .	56
6.1	Quantas sub-nuvens utilizar? . . . . .	56
6.2	Busca do registro suficiente . . . . .	56
7	CONCLUSÃO . . . . .	58
	REFERÊNCIAS . . . . .	59

**APÊNDICE A – SUPERFÍCIES GERADAS A PARTIR DOS  
MODELOS . . . . . 63**

## 1 INTRODUÇÃO

É notável que dispositivos de imagem (câmeras e sensores) estão cada vez mais presentes no dia-a-dia. Estes equipamentos tem se mostrado cada vez mais úteis, seja no contexto pessoal, com a evolução crescente das tecnologias de câmeras e de *smartphones*, ou mesmo no contexto industrial, ao lado de áreas como *Industrial Internet-of-things* (IIoT) (TORO, BARANDIARAN, and POSADA (2006)), *machine learning* e *big data* na geração de soluções na indústria de manufatura (STORK (2015)). Ao longo das últimas décadas, a visão computacional tem ganhado cada vez mais o interesse de pesquisadores, como pode ser visto em (SMITH and SMITH (2007)), e não só isso, mas também as pesquisas tem evoluído no sentido da utilização de dados 3D no lugar das clássicas imagens bidimensionais.

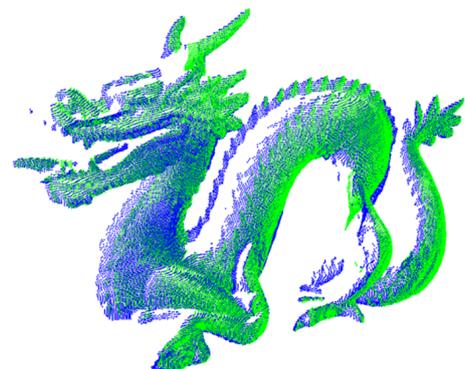
A evolução tecnológica e a inserção de sensores de imagem nos setores comerciais, além dos contextos industriais e acadêmicos, com dispositivos como o Kinect e *PlayStation Eye*, fazem com que essa transição das imagens 2D para imagens 3D vivenciada pelo usuários se torne algo natural, além de incentivar cada vez mais o desenvolvimento e estudo de tecnologias que utilizem tais ferramentas. Como resultado, vemos atualmente dispositivos de visão de alta resolução com tamanho da ordem de milímetros, como o *RealSense R200* da Intel (INTEL (2016)).

Utilizando tais dispositivos que agora tratam imagens como sinais de três dimensões, somos então introduzidos a diferentes conjuntos de dados como, por exemplo, as nuvens de pontos, que trazem consigo em diferença às imagens bidimensionais a informação da profundidade, dando espaço aos mais diversos tipos de aplicações. A figura 1 exemplifica a nuvem de pontos do conjunto de dados *Dragon*.

Figura 1 – Em a) conjunto de dados *Dragon* e em b) uma representação por nuvem de pontos



a)



b)

Fonte: a) *Stanford 3D Repository* 1996 b) Autor.

Dado o contexto de pesquisas utilizando nuvens de pontos como representação de objetos, destaca-se aqui a *Point Cloud Library* (PCL) (RUSU and COUSINS (2011)).

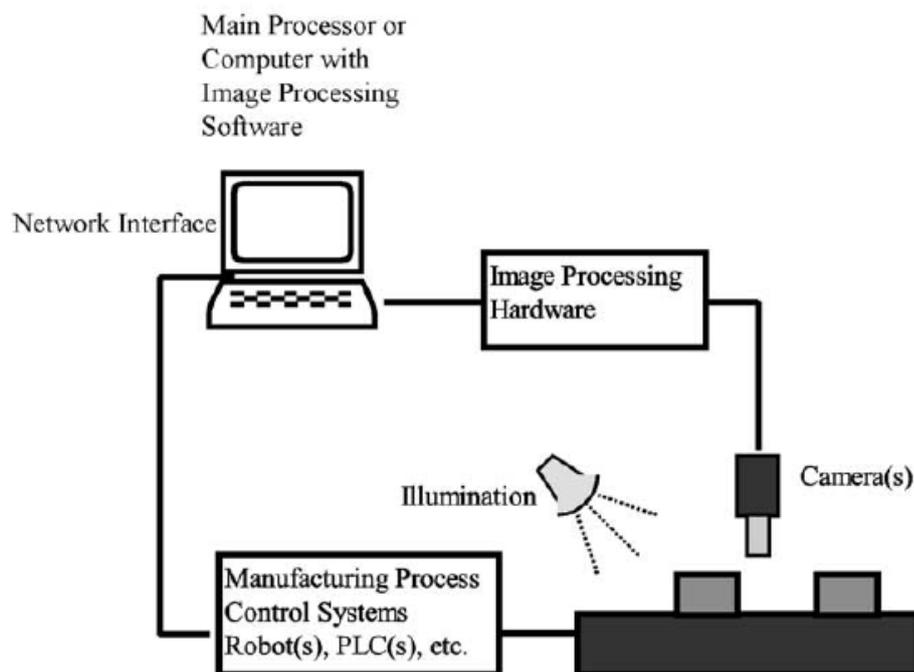
Esta é um framework largamente difundido, com reconhecimento na comunidade científica, que é utilizado para executar os processamentos de nuvens de pontos e que foi utilizado também neste trabalho. é um projeto aberto que trata de imagens 2D e 3D. Nela são contidos algoritmos de estado da arte que analisam diversas partes destes processamentos, como filtragem, registros e segmentação.

Nesta perspectiva, fica clara a necessidade da comunidade científica de desenvolver e otimizar técnicas que se utilizem destes conjuntos de dados provenientes de sensores de tecnologia de ponta, visando a solução de problemas de engenharia de um modo geral.

### 1.1 Problemática

Considerando o contexto típico de um sistema de visão computacional aplicado à indústria, tem-se a situação apresentada na figura 2.

Figura 2 – Representação típica de um sistema de visão computacional na indústria.



Fonte: Malamas (2003).

Dada a natureza da visão computacional, é imensa a gama de problemas passíveis de solução a partir da utilização de técnicas associadas a dispositivos de visão. Tomando como exemplo um problema industrial de verificação de qualidade por inspeção, as possibilidades de abordagem são diversas, conforme mostrado na figura 3, podendo, ainda, a utilização em conjunto de tais análises.

Tal flexibilidade força o pesquisador a atacar uma problemática que, ainda que vasta, seja mais específica, voltada a um dado contexto onde a visão computacional possa

Figura 3 – Possíveis abordagens para o problema de verificação de qualidade com visão computacional.



Fonte: Malamas (2003).

efetivamente operar de maneira mais direta na resolução de problemas.

Como exemplo, considere no contexto da automação industrial, a prevenção de colisão (HUTCHINSON and LEVEN), que é uma problemática bastante visitada. Nela, detectar e identificar um obstáculo é o primeiro desafio. De fato, sistemas de vigilância para ambientes não estruturados usualmente necessitam tratar de alguma forma as oclusões de objetos numa cena; é um assunto importante, e diversas soluções tem sido discutidas na literatura.

Entre as várias soluções de oclusão, fusão de imagens de diferentes perspectivas é bastante popular e consiste essencialmente em fundir descrições parciais de uma cena formando uma representação completa. Por exemplo, obter um modelo 3D a partir de aquisições da superfície de um objeto por diferentes perspectivas.

Na literatura, esta atividade foi primeiramente resolvida com o algoritmo *Iterative Closest Point* (BESL and MCKAY (1992)). O objetivo deste algoritmo é obter a transformação capaz de minimizar a distância entre dois conjuntos de dados, por exemplo, duas nuvens de pontos de uma dada aplicação, permitindo a integração de imagens adquiridas a partir de diferentes perspectivas.

Tratando da análise de resultados em trabalhos com nuvens de pontos, é de praxe a utilização de métricas baseadas em médias, como o RMSE (*root mean squared error*), em conjunto de análises qualitativas, pictóricas, a fim de convencer o leitor sobre os resultados apresentados.

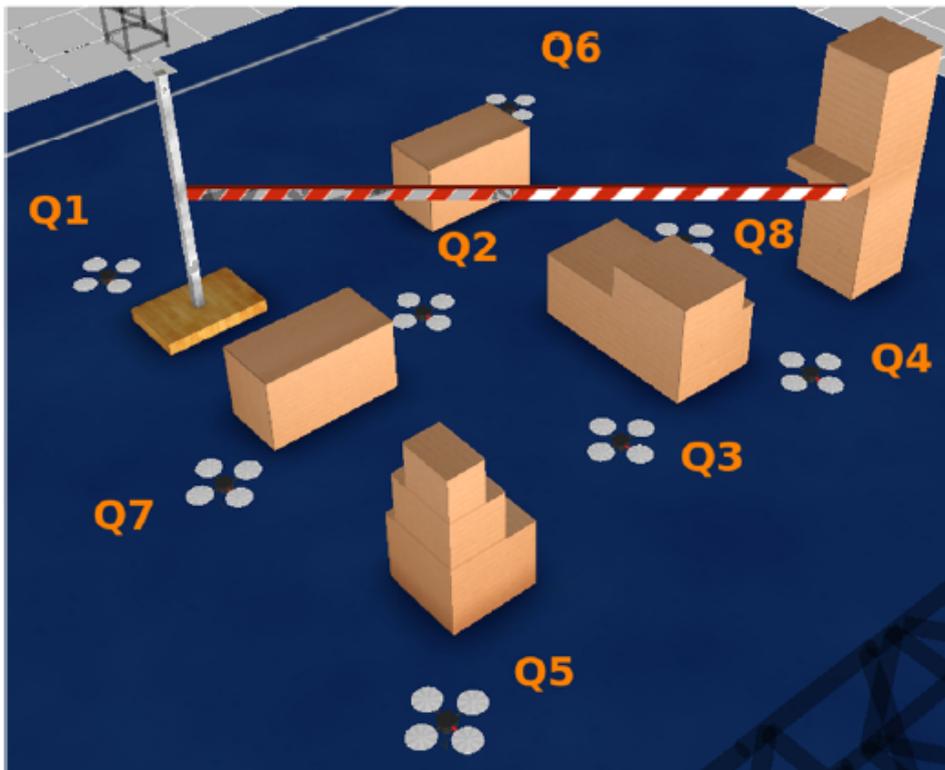
Dado este contexto, este trabalho se encaixa na problemática da utilização da visão computacional como ferramenta para uma melhor descrição de objetos sob efeito de oclusão numa dada cena. Tal abordagem vem do registro de nuvens de pontos 3D de diferentes perspectivas de cada objeto, onde registro é o termo que faz referência ao alinhamento espacial entre dois conjuntos de dados.

## 1.2 Motivação

Como citado anteriormente, a visão computacional confere a capacidade da resolução de diversos tipos de problemas de engenharia dada sua flexibilidade com relação à resolução de problemas. São descritos a seguir, a critério de motivação desta dissertação, alguns trabalhos de estado da arte referentes às áreas aqui abordadas.

Iniciando com desvio de colisão o trabalho de Tang (2015) apresenta uma nova estratégia para prevenir um desvio de colisão em máquinas NC (*Numeric Control*). Em Wang (2014) é discutida a geração da trajetória livre de colisão para voo em par de veículos aéreos em ambientes estruturados. O trabalho de Alejo (2016) aborda um método para desvio de colisão em ambientes industriais com múltiplos veículos aéreos, como na situação simulada no mesmo trabalho, ilustrada na figura 4.

Figura 4 – Cenário de simulação de movimento de quadrotores com obstáculos estáticos.



Fonte: Alejo (2016).

Estes dois últimos trabalhos são especialmente interessantes porque abrem a possibilidade para operações mesmo em ambientes não estruturados. Em (SHELLSHEAR, BERLIN, and CARLSON (2015)) é feito um estudo de caso de uma planta de manufatura da Volvo e aborda o problema de determinar por simulação computacional, se os modelos desenvolvidos para os carros efetuam um caminho livre de colisão nas células de produção, permitindo minimizar alterações em caso de eventuais modificações necessárias de design dos carros. Em (ORIOLO (2015)) é investigada a coexistência harmônica e segura entre

humanos e máquinas e em (LO, CHENG, and HUANG (2016)) é proposto um método que garante o desvio de colisão através de uma modelagem de impedância virtual. Em (SHIOMI, ZANLUNGO, and HAYASHI (2014)) é estudado o desvio de colisão entre homens e robôs móveis levando em conta fatores como o respeito pelo espaço pessoal de cada pedestre. Um exemplo é apresentado na figura 5.

Figura 5 – Desvio de colisão de robô respeitando o espaço pessoal dos pedestres.



Fonte: Shiomi (2014).

Em Cherubini (2014) é proposto um *framework* para desvio de obstáculos para navegação visual com robô móvel com rodas.

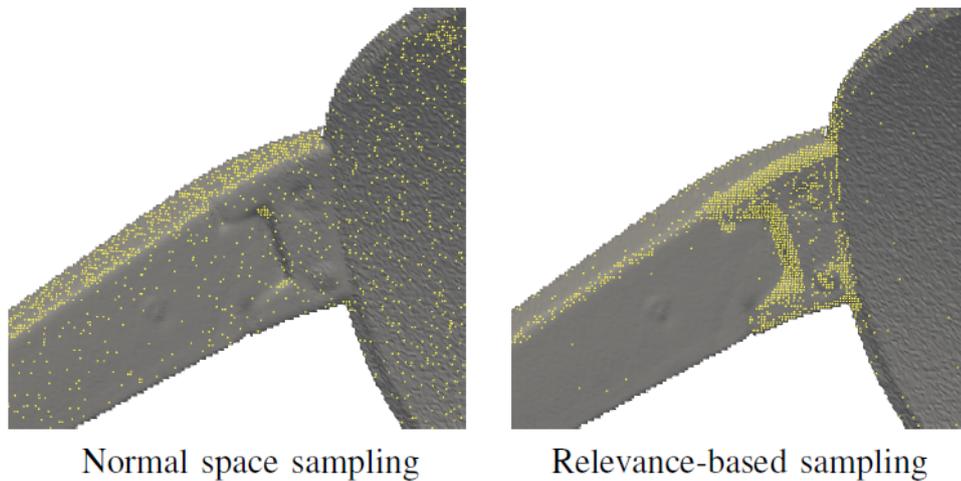
Particularmente para a indústria, a interação segura entre homem e máquina é um objetivo, considerando que pode vir a acelerar processos de manufatura, podendo, até, a eventual revisão ou atualização de protocolos e regulamentos vigentes para processos de chão de fábrica, como, por exemplo, para o Brasil, a norma reguladora (NR) 12 que regula a segurança do trabalho para máquinas e equipamentos.

Já com relação à oclusão, vê-se que em (PHAM and LEE (2015)) são abordadas as oclusões presentes na detecção e contagem de veículos em intenso tráfego. Em (SHAFIE, IBRAHIM, and RASHID (2014)) é abordado um sistema de classificação de objetos em duas categorias: humanos e carros; permitindo a identificação humana para casos de até 70% de oclusão. Em (CHENG, JIN, and CHEN (2016)) é estudada a identificação de faces humanas que lida com desafios como a oclusão. Em (OGALE, FERMULLER, and ALOIMONOS) é feito um estudo para determinar a localização de partes de uma cena que possuem movimento 3D próprio. Neste caso, oclusão são utilizadas, até, como informação, onde é dito que a partir das oclusões é possível obter informações sobre a estrutura da cena, utilizando esta informação para identificar novos tipos de objeto em movimento.

Tratando do algoritmo ICP clássico (dito clássico considerando-se que existem em torno de 400 artigos publicados nos últimos 20 anos que são relacionados ao algoritmo ICP, segundo Pomerleau (2013)), vê-se em (POMERLEAU, COLAS, and SIEGWART

(2013)) um protocolo que permite a comparação entre variantes do algoritmo clássico. Em (SERAFIN and GRISSETTI (2014)) tem-se a abordagem recente que apresenta uma nova variação do ICP e a compara com o *Generalized ICP*, presente em (SEGAL, HAHNEL, and THRUN (2009)). Já o trabalho presente em (TORSSELLO, RODOLÀ, and ALBARELLI (2011)) apresenta uma amostragem que analisa a relevância de cada ponto baseando-se na sua vizinhança. Tal análise de relevância é feita a partir da comparação do vetor normal a cada ponto aos vetores normais aos pontos vizinhos e àqueles pontos que se destacam dos demais, são atribuídos pesos de relevância maiores. A figura 6 exemplifica e compara esta amostragem por relevância com uma amostragem por *normal space*.

Figura 6 – Amostragem por relevância ressaltando os pontos de maior curvatura.



Fonte: Torsello (2011).

Com relação à análise de resultados de registros de nuvens de pontos 3D, em (DAMODARAN, SUDHEER, and KUMAR (2015)) é feita uma análise das versões *point-to-point* e *point-to-plane* do ICP a partir de registros de nuvens adquiridos de um sensor Kinect. As análises de qualidade dos registros deste trabalho se baseiam na comparação dos valores de RMSE para as iterações de cada versão do ICP e se sustentam também em comparações quantitativas de imagens de nuvens de pontos registradas. Em (MAGNUS-SON, NUCHTER, and LORKEN (2009)) é feita uma comparação entre os algoritmos ICP e NDT (*normal distributions transform*) (BIBER (2003)), onde estes são comparados utilizando-se de medidas de tempo e análises qualitativas de imagens de registro. Em (YANG, LI, and CAMPBELL (2015)) é apresentado o Go-ICP, um versão do ICP que visa fugir dos problemas de mínimos locais do algoritmo clássico ao propor uma abordagem de otimização global. Neste último são feitas análises de RMSE, análises de tempo e considerações qualitativas por inspeção de imagens de nuvens de pontos registradas. Em (MANOJ, BINGBING, and RUI (2015)) é estendida uma formulação prévia da covariância do ICP em 2D para sua versão 3D. Tal trabalho é feito na possibilidade de explorar a covariância do ICP em 3D com objetivo de guiar este algoritmo de um mínimo

local para um mínimo global. As conclusões deste trabalho se sustentam em comparações dos valores da covariância para os mínimos local e global e em análises qualitativas de imagens de registros de nuvens de pontos. Por fim, em (BOUAZIZ, TAGLIASACCHI, and PAULY) é apresentado o *Sparse ICP*, que visa atacar o problema de registros de nuvens de pontos em situações onde os conjuntos de dados possuem *outliers* ou faltam partes das nuvens de pontos. Similarmente aos outros trabalhos, este se baseia em análise de RMSE e análises qualitativas de imagens para concluir seus resultados.

Portanto, neste trabalho apresentamos um método de amostragem a ser aplicado previamente ao algoritmo ICP. Nós comparamos esta técnica proposta com o ICP clássico e com o ICP associado de outras duas técnicas de amostragem, nomeadamente amostragem aleatória e amostragem baseada numa quantização vetorial a partir de uma rede neural de *self-organizing map* (SOM) (KOHONEN (1990)). Os métodos foram comparados quantitativamente usando RMSE, ângulos de Euler e uma abordagem autoral baseada em SSIM (WANG, BOVIK, and SHEIKH (2004)).

A partir desta revisão bibliográfica, vê-se que a comunidade científica visa estudar tal problemática e que este trabalho se encontra inserido no contexto do estado da arte.

### 1.3 Objetivos

Este trabalho visa como objetivo geral a criação de uma técnica de amostragem, de desempenho satisfatório, a ser utilizada previamente ao ICP no intuito do registro de nuvens de pontos 3D. Para que se alcance tal objetivo, são listados como objetivos específicos:

- Analisar as etapas envolvidas no algoritmo ICP clássico de registro de nuvens de pontos;
- Identificar alguma etapa ou parcela do algoritmo ICP clássico que possa vir a usufruir de melhoria de desempenho;
- Propor a técnica que vise auxiliar o algoritmo ICP clássico na questão de desempenho;
- Comparar a técnica proposta com técnicas já existentes na literatura por meio de diferentes critérios;
- Apresentar os resultados e conclusões de forma objetiva, clara e didática.

### 1.4 Publicações científicas

Ao longo do desenvolvimento do trabalho, foram publicados e apresentados em congressos os seguintes trabalhos:

1. Pereira, N. S. & Nunes, J. L. & Thé, G. A. P. (2014). Planejamento de caminho livre de colisão para robô SCARA em ambiente monitorado por sensor de imagem,

Anais do XX Congresso Brasileiro de Automática (XX CBA), Belo Horizonte-MG, páginas 3946-3953.

2. Pereira, N. S. & Carvalho, C. R. & Thé, G. A. P. (2015). *Point cloud partitioning approach for ICP improvement*, apresentado em *21st International Conference on Automation and Computing (ICAC)*, Glasgow-Escócia.

## 1.5 Organização do trabalho

O restante deste trabalho está organizado em capítulos conforme descrito abaixo:

- Capítulo 2: É apresentada a fundamentação teórica do trabalho. São descritos, de modo matemático, todos os conceitos fundamentais à compreensão do trabalho. O foco principal é com relação ao algoritmo ICP.
- Capítulo 3: O algoritmo proposto, agora em diante nomeado de *Cloud Partitioning ICP* (ou CP-ICP), é apresentado e discutido.
- Capítulo 4: É neste capítulo onde os materiais são apresentados e os métodos empregados são descritos. Por materiais, entende-se os conjuntos de dados utilizados como referência. Por métodos, são aqueles utilizados para avaliar as técnicas comparadas no trabalho e quais critérios de avaliação foram adotados.
- Capítulo 5: São discutidos os resultados obtidos a partir da metodologia empregada, utilizando das diversas métricas de comparação e de análises de imagens e tabelas referentes aos diversos conjuntos de dados.
- Capítulo 6: É desenvolvida uma discussão acerca das limitações da técnica apresentada e, conseqüentemente, são levantadas hipóteses de trabalhos futuros nos tópicos discutidos, visando sempre o engrandecimento do trabalho.
- Capítulo 7: As conclusões do trabalho são apresentadas.

Por fim, são apresentadas as referências bibliográficas e um apêndice que se utiliza da tecnologia de realidade aumentada para conferir uma visibilidade tridimensional de resultados obtidos.

## 2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta o embasamento teórico necessário para a compreensão das técnicas e algoritmos envolvidos no presente trabalho.

### 2.1 Algoritmo *Iterative Closest Point*

O algoritmo ICP foi proposto em 1992 por Besl e Mckay (1992) e objetiva encontrar a transformação que otimiza a rotação e translação entre dois conjuntos de dados (conjuntos de segmentos de retas, curvas implícitas, conjuntos de triângulos, superfícies implícitas, superfícies paramétricas, conjuntos de pontos, etc). O algoritmo utiliza um dos conjuntos de dados como referência, chamado aqui de agora em diante como **conjunto alvo**, e aplica rotações e translações ao outro conjunto, chamado aqui de agora em como **conjunto de entrada**, visando minimizar a função custo apresentada na equação (1):

$$F(\vec{q}) = \frac{1}{N} \sum_{i=1}^N \|\vec{x}_i - (\mathbf{R}(\vec{q}_R)\vec{p}_i + \mathbf{T})\|^2 \quad (1)$$

Onde:

- $N$  = número de pontos;
- $\vec{x}_i$  =  $i$ -ésimo vetor relacionado ao conjunto alvo;
- $\vec{p}_i$  =  $i$ -ésimo vetor relacionado ao conjunto entrada;
- $\mathbf{R}$  = matriz de rotação obtida pelo ICP;
- $\mathbf{T} = \vec{q}_T$  = vetor de translação obtido pelo ICP.

O método apresentado em (BESL and MCKAY (1992)) se baseia numa análise do vetor quaternion  $\vec{q} = [\vec{q}_R | \vec{q}_T]^t$ , onde  $\vec{q}_R = [q_0, q_1, q_2, q_3]$  representa o vetor responsável por mapear a rotação e  $\vec{q}_T = [q_4, q_5, q_6]$  é o vetor responsável pela translação. O vetor  $\vec{q}_R$  representa o autovetor correspondente ao máximo autovalor da matriz  $Q(C_{XP})$  presente em (2), onde  $C_{XP}$  representa a matriz de covariância cruzada dos conjuntos  $\vec{x}$  e  $\vec{p}$ .

$$Q(C_{XP}) = \begin{pmatrix} tr(C_{XP}) & \Delta^T \\ \Delta & C_{XP} + C_{XP}^T - tr(C_{XP})\mathbf{I}_3 \end{pmatrix} \quad (2)$$

Onde  $\Delta = [A_{23}, A_{31}, A_{12}]^T$  é obtido da matriz  $A = C_{XP} - C_{XP}^T$ .

Os valores de  $\vec{q}_R$  são, então, aplicados a matriz  $\mathbf{R}$  presente em (3) a fim de obter a rotação ótima da iteração presente.

$$R = \begin{pmatrix} q_0^2 + q_1^2 - q_2^2 - q_3^2 & 2(q_1q_2 - q_0q_3) & 2(q_1q_3 + q_0q_2) \\ 2(q_1q_2 + q_0q_3) & q_0^2 + q_2^2 - q_1^2 - q_3^2 & 2(q_2q_3 - q_0q_1) \\ 2(q_1q_3 - q_0q_2) & 2(q_2q_3 + q_0q_1) & q_0^2 + q_3^2 - q_1^2 - q_2^2 \end{pmatrix} \quad (3)$$

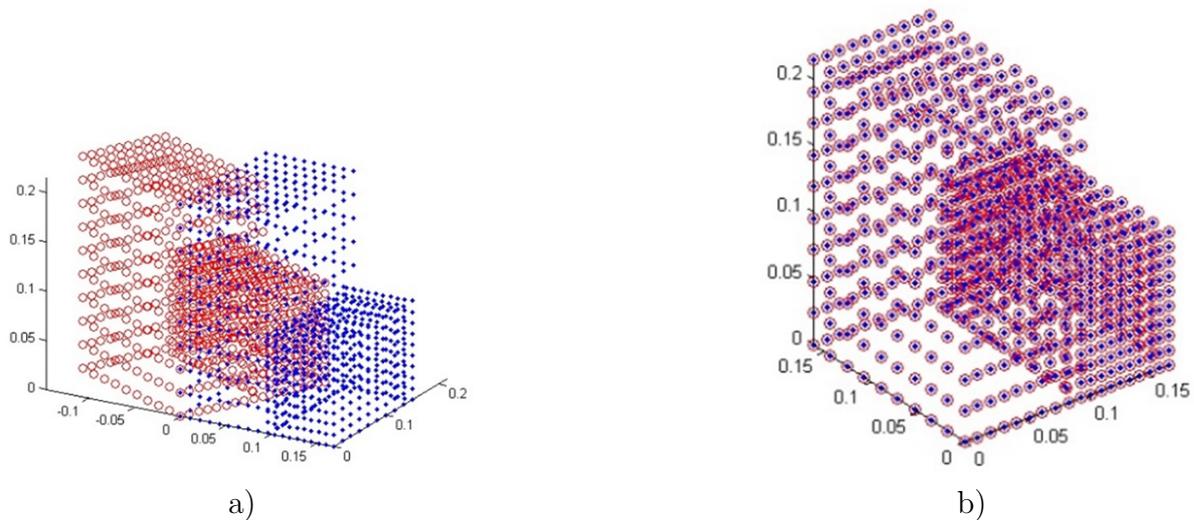
Por fim, o vetor  $\vec{q}_T = T$ , o qual representa a translação ótima, é obtido por:

$$\vec{q}_T = \vec{\mu}_X - R(\vec{q}_R)\vec{\mu}_P \quad (4)$$

em que  $\vec{x}$  e  $\vec{p}$  representam os vetores de média dos respectivos conjuntos. A cada iteração são obtidas uma rotação e uma translação. O processo iterativo se encerra quando a diferença entre os erros quadráticos médios entre duas iterações consecuentes dos conjuntos de dados se tornar inferior a um limiar determinado pela aplicação. O fim do processo indica o **registro** das nuvens de pontos.

A figura 7 mostra um exemplo de utilização do algoritmo ICP. Em a) tem-se um exemplo de dois conjuntos de dados (nuvens de pontos) como sendo uma configuração inicial para o aplicação do ICP e em b) tem-se um resultado de sucesso do alinhamento entre os dois conjuntos de dados, alinhamento este, também denominado de **registro**.

Figura 7 – Exemplo de utilização do registro de duas nuvens pelo algoritmo ICP. Em a) nuvens de pontos no alinhadas e em b) nuvens de pontos após o registro com ICP.



Fonte: Autor.

## 2.2 Structure similarity index

As técnicas mais tradicionais de análise de qualidade de imagens são a análise de *mean squared error* (MSE) junto com a razão de *peak signal-to-noise* (PSNR). Tais métodos são interessantes por sua simplicidade de cálculo junto com uma clareza no que seus valores expressam, porém não são métricas que consigam expressar a subjetividade da qualidade de uma imagem. A figura 8, obtida em (WANG, BOVIK, and SHEIKH (2004)), ilustra o que é afirmado acima. Dos itens a) ao c), vemos: a) a imagem original, b) uma imagem com contraste estendido e c) a compressão JPEG da imagem original. Os valores de MSE entre a imagem original e cada variação presente nos itens b) e c) da

figura 8 são ambos 210, apesar da clara discrepância de qualidade entre elas.

Figura 8 – Três imagens com mesmo valor de MSE. Em a) a imagem original, em b) uma imagem com contraste estendido e em c) uma compressão JPEG da imagem original.



a)



b)



c)

Fonte: Wang (2004).

Tendo em mente as limitações de tais métodos clássicos como o MSE, como visto na figura 8, Wang (2014) visou uma nova abordagem de análise de imagens. Diferentemente da comparação puramente algébrica entre valores de erro, o algoritmo *Structured similarity index* (SSIM *index*) analisa a imagem por sua estrutura, similarmente ao modo como o próprio olho humano consegue identificar padrões numa cena. O método do SSIM se baseia em analisar o par de imagens mediante três componentes: a luminância, o contraste e a estrutura.

Primeiramente é analisada a luminância que, assumindo os sinais como sendo discretos, é estimada como a intensidade média, conforme (5).

$$\mu_a = \frac{1}{N_a} \sum_{i=1}^{N_a} a_i \quad (5)$$

De tal forma que a função de comparação de luminância  $l(a, b)$  é função de  $\mu_a$  e  $\mu_b$ . Em seguida é analisado o contraste. Como estimativa deste, é utilizado o desvio padrão do sinal discreto extraído de sua média, conforme (6).

$$\sigma_a = \left( \frac{1}{N_a - 1} \sum_{i=1}^{N_a} (a_i - \mu_a)^2 \right)^{1/2} \quad (6)$$

A função contraste  $c(a, b)$  é então a comparação de  $\sigma_a$  e  $\sigma_b$ . Por fim, para a análise de estrutura, cada sinal é normalizado pelo seu desvio padrão, tornando-os sinais de desvio padrão unitário. Assim a comparação de estrutura  $s(a, b)$  é conduzida nestes sinais normalizados, conforme (7).

$$a = \frac{a - \mu_a}{\sigma_a} \quad e \quad b = \frac{b - \mu_b}{\sigma_b} \quad (7)$$

As três componentes são então combinadas a fim de mensurar a similaridade num total, como mostra na equação (8).

$$S(a, b) = f(l(a, b), c(a, b), s(a, b)) \quad (8)$$

Segundo Wang (2004), as funções  $l(a, b)$ ,  $c(a, b)$  e  $s(a, b)$  são definidas conforme as equações (9-11).

$$l(a, b) = \frac{2\mu_a\mu_b + C_1}{\mu_a^2 + \mu_b^2 + C_1} \quad | \quad C_1 = (K_1L)^2, K_1 \ll 1 \quad (9)$$

$$c(a, b) = \frac{2\sigma_a\sigma_b + C_2}{\sigma_a^2 + \sigma_b^2 + C_2} \quad | \quad C_2 = (K_2L)^2, K_2 \ll 1 \quad (10)$$

$$s(a, b) = \frac{\sigma_{ab} + C_3}{\sigma_a\sigma_b + C_3} \quad | \quad C_3 = (K_3L)^2, K_3 \ll 1 \quad (11)$$

Onde  $C_1$ ,  $C_2$  e  $C_3$  são constantes adicionadas a cada termo e  $L$  como sendo o *range* de valores para cada pixel (255 para imagens de 8-bits de tons de cinza) e cada  $K_1$ ,  $K_2$  e  $K_3$  valores constantes bem inferiores a 1, como mostrado nas equações (9-11). Além disso,  $\sigma_{xy}$  pode ser estimado através de (12).

$$\sigma_{ab} = \frac{1}{N_a - 1} \sum_{i=1}^{N_a} (a_i - \mu_a)(b_i - \mu_b) \quad (12)$$

Combinando as contribuições de (9-11), é formada a métrica SSIM, conforme (13).

$$SSIM(a, b) = [l(a, b)]^\alpha \cdot [c(a, b)]^\beta \cdot [s(a, b)]^\gamma \quad (13)$$

Onde  $\alpha > 0$ ,  $\beta > 0$  e  $\gamma > 0$  são parâmetros utilizados para ajustar a importância relativa de cada componente. No trabalho de (WANG, BOVIK, and SHEIKH (2004)), são selecionados os valores  $\alpha = \beta = \gamma = 1$  e  $C_3 = C_2/2$ . A métrica, enfim, tem sua forma representada pela equação (14).

$$SSIM(a, b) = \frac{(2\mu_a\mu_b + C_1)(2\sigma_{ab} + C_2)}{(\mu_a^2 + \mu_b^2 + C_1)(\sigma_a^2 + \sigma_b^2 + C_2)} \quad (14)$$

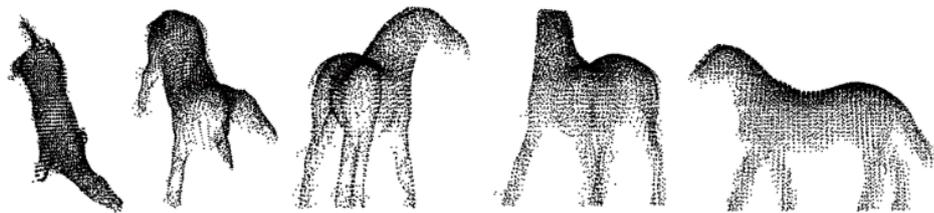
Utilizando como referência as imagens do barco presentes na figura 8, o SSIM obteve como resultado os valores 0,9168 e 0,6949 para as imagens b) e c), respectivamente, ao utilizarmos a imagem em a) como referência.

### 2.3 Métrica baseada em SSIM

O índice de *structural similarity* (SSIM) é uma abordagem que atualmente é utilizada para medir qualidade de uma imagem. Também pode ser interpretado como um identificador de similaridade entre duas imagens em tom de cinza, onde uma delas é tratada como a imagem de referência.

Neste trabalho, foi aplicado o índice SSIM para medir a similaridade entre imagens binárias de diferentes perspectivas de cada objeto estudado. Para cada objeto são analisadas cinco perspectivas. Para exemplificar, o resultado de um dos registros para o modelo *Horse* é visto pelas cinco perspectivas na figura 9.

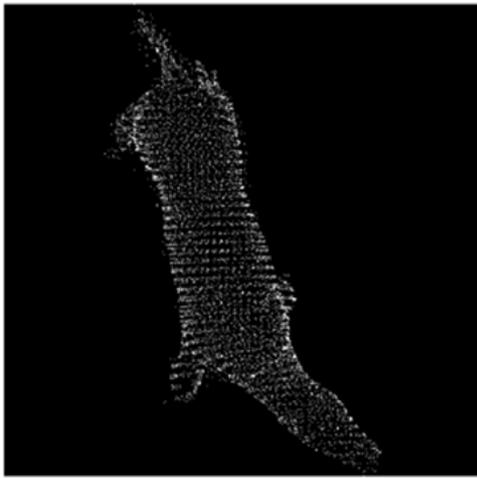
Figura 9 – As cinco perspectivas analisadas para a métrica baseada em SSIM.



Fonte: Autor.

O uso do índice SSIM aqui se baseia na geração de quatro imagens para cada uma das perspectivas: imagem em *dot pattern*, imagem cheia, contorno e esqueleto, cada uma com uma resolução de 512x512 *pixels*. A imagem em *dot pattern* é obtida através da quantização dos conjuntos de pontos em cada perspectiva, ao passo que os outros três tipos de imagem são obtidos através de transformações morfológicas aplicadas na imagem em *dot pattern*. A figura 10 mostra este conjunto de imagens utilizando como exemplo a primeira perspectiva apresentada na figura 9. Da figura 10a até 10d é mostrado, respectivamente, *dot pattern*, imagem cheia, contorno e esqueleto.

Figura 10 – Conjuntos de imagens obtidas para cada perspectiva. Em a) imagem *dot pattern*, em b) imagem cheia, em c) imagem de contorno e em d) imagem esqueleto.



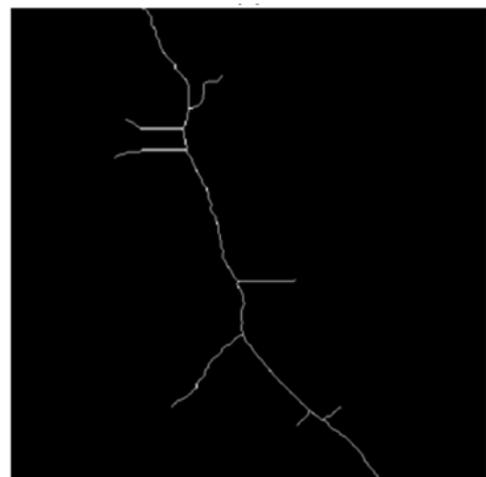
a)



a)



a)



b)

Fonte: Autor.

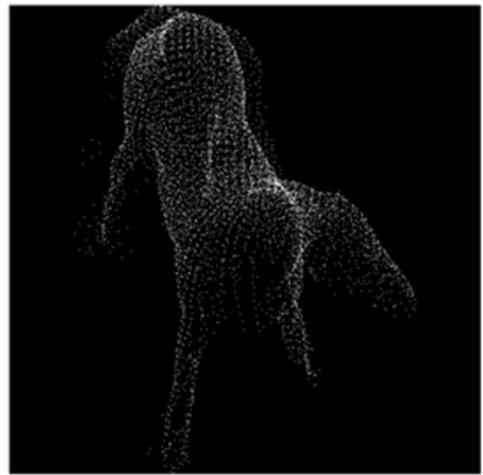
O objetivo desta métrica proposta é analisar a similaridade entre uma imagem de referência e as imagens obtidas através dos processos de registro das diferentes técnicas de amostragem. Idealmente, é necessário um *ground-truth* (um modelo 3D para compararmos), como acontece para o caso dos modelos *Dragon* e *Buddha*. Entretanto, na ausência deste, como por exemplo para os modelos *Horse* e *Hammer*, foi utilizada como a imagem de referência para o SSIM a nuvem de pontos considerada alvo para o algoritmo ICP. Na figura 11 vê-se uma das perspectivas do modelo *Horse* como imagem em *dot pattern*. Em a) tem-se a imagem de referência, em b) o resultado do registro através do ICP clássico (sem amostragem), em c) o resultado do CP-ICP e em d) o resultado obtido com a amostragem por rede SOM com 512 neurônios.

Similarmente a técnica SSIM, o resultado da comparação se apresenta como um valor entre 0 e 1, onde 1 representa a igualdade entre duas imagens e 0 representa a

Figura 11 – Comparação entre diferentes registros utilizando a imagem em *dot pattern*. Em a) a imagem de referência, em b) o registro com ICP



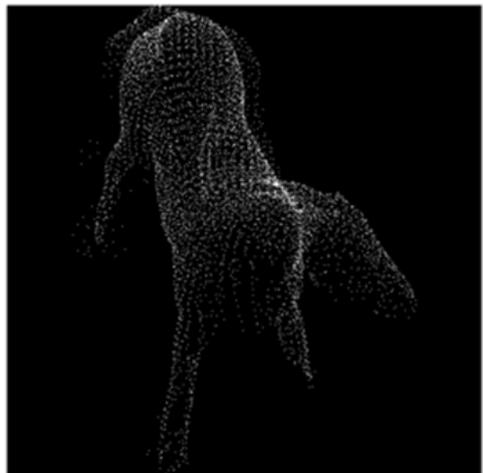
a)



b)



c)



d)

Fonte: Autor.

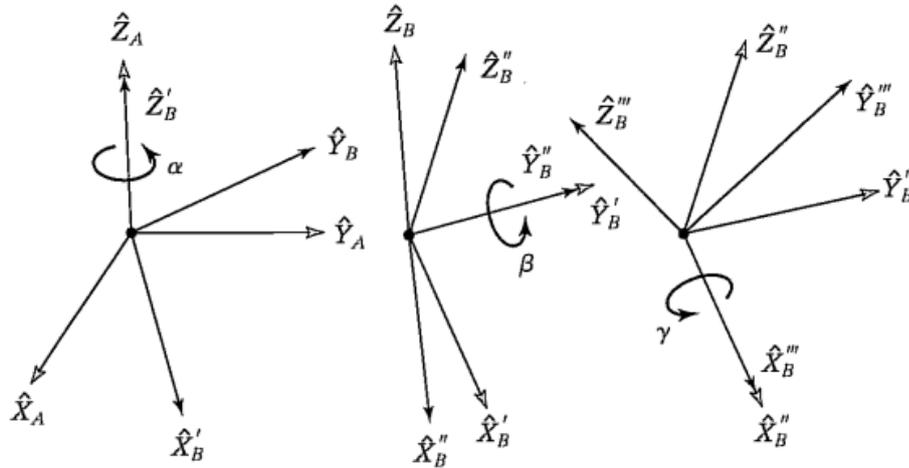
máxima diferença.

## 2.4 Ângulos de Euler

Existem diversas formas para se descrever a orientação de um corpo tridimensional rígido. A descrição por ângulos de Euler é uma composição em três ângulos para descrever as rotações aplicadas neste corpo para os três eixos. Diferentemente da descrição em ângulos fixos, o eixo da rotação seguinte é influenciado pelas rotações anteriores. Na figura 12, vê-se o exemplo da representação Z-Y-X de ângulos de Euler, onde são rotacionados os ângulos  $\alpha_E$ ,  $\beta_E$  e  $\gamma_E$  dos eixos x, y e z, respectivamente.

Como vê-se na figura 12, o eixo da rotação seguinte é influenciado pela rotação prévia, característica da descrição por ângulos de Euler. Diversas são as possibilidades de

Figura 12 – Representação Z-Y-X de Ângulos de Euler.



Fonte: Craig (2005).

descrição por ângulos de Euler, sendo algumas delas: Z-Y-X, Z-Y-Z e Z-X-Z.

Uma exemplo de utilidade desta análise é, a partir de uma matriz de rotação tridimensional nos três eixos x,y e z, obter-se os ângulos de Euler que, quando aplicados de modo sucessivo de acordo com a representação escolhida, compõem a dada matriz de rotação. Utilizando como exemplo a matriz presente na equação (15).

$$M = \begin{bmatrix} 0,9132 & -0,4075 & -0,0036 \\ 0,4075 & 0,9132 & -0,0050 \\ 0,0054 & 0,0031 & 1 \end{bmatrix} \quad (15)$$

A matriz  $M$  representa uma conjunto de rotações nos eixos X, Y e Z do sistema de coordenadas cartesianas. Utilizando a representação Z-Y-X dos ângulos de Euler, pode-se reescrever a matriz  $M$  como em (16-18).

$$M = R_Z(\gamma_E)R_Y(\beta_E)R_X(\alpha_E) \quad (16)$$

$$M = \begin{bmatrix} c_z & -s_z & 0 \\ s_z & c_z & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} c_y & 0 & s_y \\ 0 & 1 & 0 \\ -s_y & 0 & c_y \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & c_x & -s_x \\ 0 & s_x & c_x \end{bmatrix} \quad (17)$$

$$M = \begin{bmatrix} c_y c_z & c_z s_x s_y - c_x s_z & s_x s_z + c_x c_z s_y \\ c_y s_z & c_x c_z + s_x s_y s_z & c_x s_y s_z - c_z s_x \\ -s_y & c_y s_x & c_x c_y \end{bmatrix} \quad (18)$$

Em que:

$$c_x = \cos(\alpha_E) \quad | \quad c_y = \cos(\beta_E) \quad | \quad c_z = \cos(\gamma_E) \quad (19)$$

$$s_x = \text{sen}(\alpha_E) \quad | \quad s_y = \text{sen}(\beta_E) \quad | \quad s_z = \text{sen}(\gamma_E) \quad (20)$$

Comparando as matrizes presentes em (15) e (18), e tomando os elementos M(3,1), M(3,2) e M(2,1), por exemplo, vê-se:

$$-s_y = 0,0054 \quad | \quad \beta = -0,3094^\circ \quad (21)$$

$$c_y s_x = 0,0031 \quad | \quad \alpha = 0,1776^\circ \quad (22)$$

$$c_y s_z = 0,4075 \quad | \quad \gamma = 24,0483^\circ \quad (23)$$

Obtém-se, então, os ângulos  $0,1776^\circ$ ,  $-0,3094^\circ$  e  $24,0483^\circ$  para os eixos X, Y e Z, respectivamente. Dessa forma, a partir da representação dos ângulos de Euler, pode-se separar a matriz  $M$  num conjunto de três rotações, como mostra na equação (24).

$$M = R_Z(24,0483^\circ)R_Y(-0,3094^\circ)R_X(0,1776^\circ) \quad (24)$$

## 2.5 Processamento morfológico de imagens

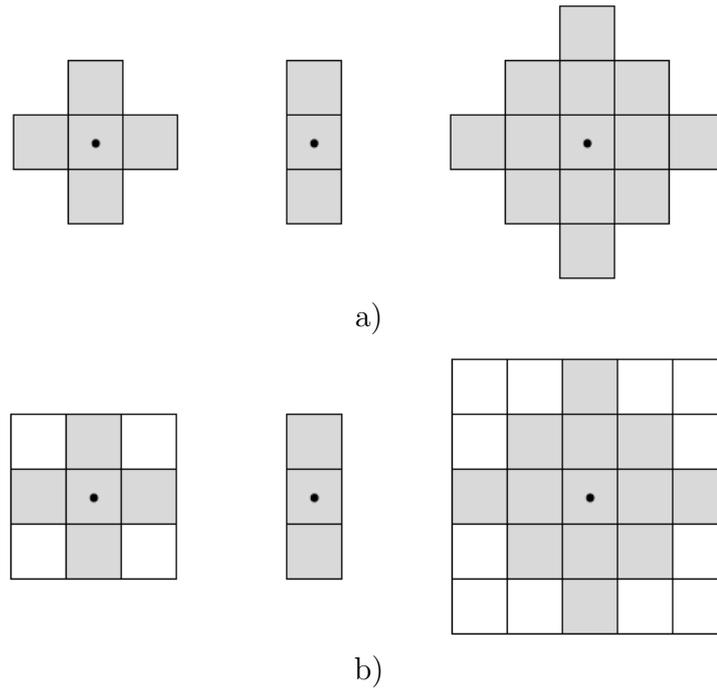
Dentre as diversas formas de processamento de imagens digitais, aquela que atua como uma ferramenta para extrair componentes úteis na representação e descrição de formas (fronteiras, feixo convexo, entre outras) é o processamento morfológico de imagens. São técnicas que compreendem etapas como pré ou pós-processamento de imagens que auxiliam a identificar os diferentes conjuntos presentes em uma imagem.

Dado o vasto número de técnicas relacionadas ao processamento morfológico de imagens, é apresentado aqui somente algumas técnicas básicas. Para mais referências, veja Gonzalez (2010).

### 2.5.1 *Elemento estruturante*

Elementos estruturantes são pequenos conjuntos ou subimagens usadas para examinar uma imagem buscando propriedades de interesse (GONZALEZ and WOODS (2010)). Tais elementos são essenciais para o processamento morfológico e sua forma influencia diretamente o resultado do processamento. Utilizando-os para processamento de imagens, os elementos estruturantes necessitam possuir uma forma matricial retangular. A figura 13 mostra exemplos de elementos estruturantes e suas representações matriciais. Em a) vê-se exemplos de elementos estruturantes e em b) suas representações matriciais.

Figura 13 – Em a) elementos estruturantes e em b) suas representações matriciais.



Fonte: Autor.

### 2.5.2 Erosão e Dilatação

Erosão e dilatação são duas operações fundamentais para processamento morfológico, tendo em vista que muitos dos algoritmos morfológicos são obtidos a partir de associações destas operações. Em imagens binárias, os conjuntos em questão são do espaço 2D de números inteiros  $Z^2$ , sendo assim, considere  $IM$  e  $ES$  como conjuntos de  $Z^2$ . Neste contexto,  $IM$  é a imagem a ser analisada e  $ES$  é o elemento estruturante. A erosão e dilatação de  $IM$  por  $ES$  são dadas pelas equações (25-26), respectivamente:

$$IM \ominus ES = \{j | (ES)_j \cap IM^c = \emptyset\} \quad (25)$$

$$IM \oplus ES = \{j | (\hat{ES})_j \cap IM \neq \emptyset\} \quad (26)$$

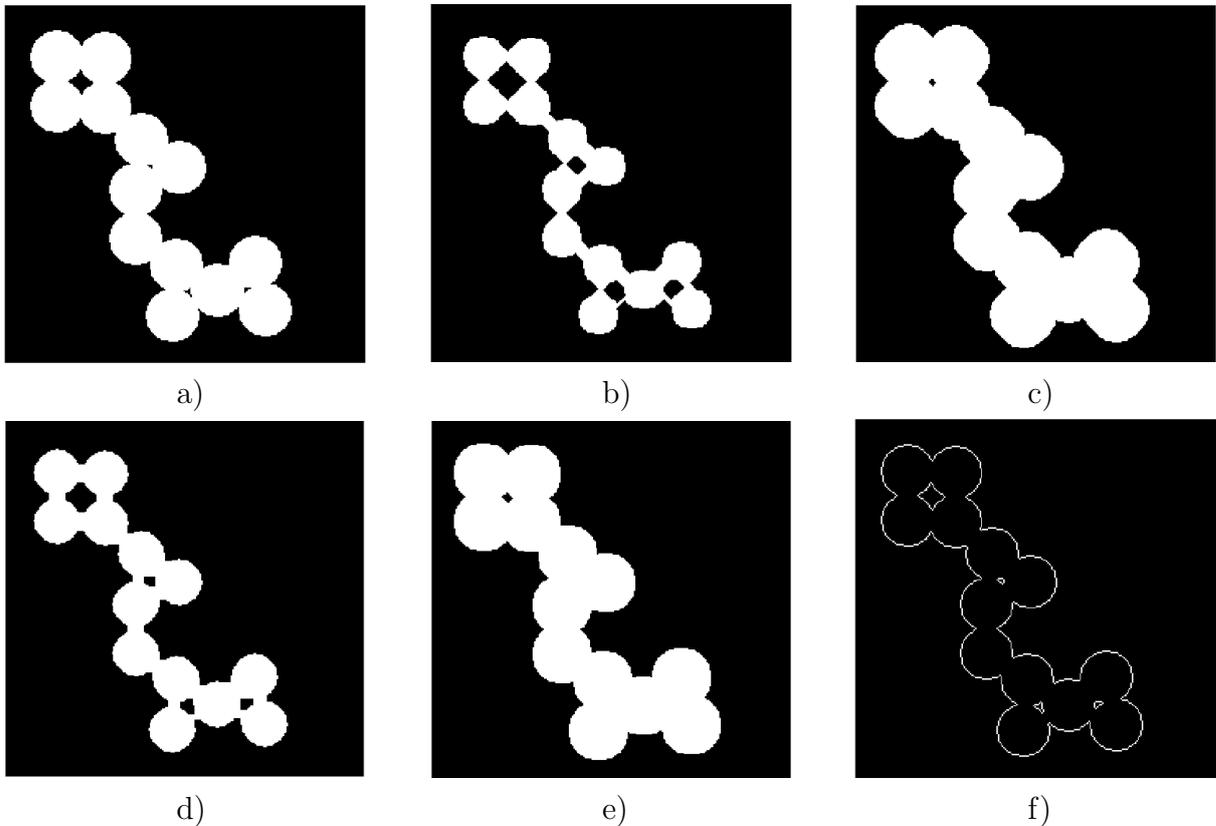
Onde  $j$  representa o *pixel*  $j = (j_1, j_2)$  pelo qual ocorre a translação de  $ES$ , definida como  $(ES)_j$ .

A equação (25) expressa que o conjunto  $ES$  transladado por  $j$  não possui nenhuma intersecção com o fundo, expressado pelo complemento de  $IM$ . Já para a dilatação, a equação (26) mostra que a reflexão de  $ES$  em torno de sua origem ( $\hat{ES}$ ) transladada por  $j$  não possui pontos em comum com  $A$ . Em outras palavras, a erosão trata do conjunto de todos os deslocamentos  $j$  onde o elemento estruturante ( $\hat{ES}$ ) está contido por completo em  $IM$ , enquanto a dilatação é o conjunto de todos os deslocamentos

$j$  onde  $\hat{E}S$  e  $IM$  se sobreponham em pelo menos um pixel.

Como exemplo, veja a figura 14. Em a) tem-se uma imagem binária de 256x256 *pixels* que é utilizada como referência. Em b) e c) vê-se o resultado de uma erosão e uma dilatação, respectivamente, quando considerado um elemento estruturante na forma de um losango com uma janela de dimensão de 11 *pixels*. Já as figuras 14d e 14e mostram o resultado de erosão e dilatação, respectivamente, quando utilizado um elemento estruturante da forma de um quadrado com uma janela de dimensão de 11 *pixels*. Por fim, a figura 14f mostra um exemplo de aplicação com as técnicas de erosão e dilatação, onde pode-se ver um modo de realizar uma extração de contorno pelo simples procedimento de subtrair uma imagem original por sua versão erodida. Para a imagem 14f, foi utilizado um elemento estruturante de forma de losango com janela de dimensão de 3 *pixels*.

Figura 14 – Erosão e Dilatação de imagens binárias. Em a) imagem de referência, em b) erosão da referência por um elemento estruturante em forma de losango com janela de 11 *pixels*. Em c) dilatação da referência pela mesmo elemento estruturante da imagem em b). Em d) e e) situação similar aos itens b) e c), porém utilizando um elemento estruturante na forma de quadrado. Por fim, em f) é mostrada uma extração de contorno através da subtração da imagem original por sua versão erodida.



Fonte: Autor.

## 2.6 Amostragem

Quando uma parte de um conjunto é utilizada para a realização de alguma inferência sobre o conjunto por completo, tem-se uma amostragem. Esse modo de pensar é presente no cotidiano de qualquer pessoa, seja ao experimentar uma sopa a fim de inferir sobre os temperos, ou ao provar uma bebida a fim de analisar a temperatura desta. A ideia é: a partir de uma conclusão obtida com base numa parcela do conjunto, poder afirmar o que acontece no conjunto por completo.

No meio científico não é diferente. Independente da área de pesquisa, o auxílio das técnicas de amostragem é notório. Diversas são as situações onde nos deparamos com um universo amostral super dimensionado onde as técnicas de amostragem podem ser não somente úteis, mas essenciais. Os tópicos seguintes tratam de duas abordagens utilizadas para realizar a amostragem de um conjunto de dados.

### 2.6.1 *Amostragem aleatória*

Considere um universo amostral  $U$ . A situação onde cada elemento de  $U$  possui a mesma probabilidade de ser selecionado como uma amostra é denominada de amostragem aleatória. Algumas das vantagens da amostragem aleatória são a simplicidade de implementação e a não necessidade de conhecimento prévio do universo  $U$ . Por mais clássica que seja, ainda é uma técnica de amostragem largamente utilizada.

Similarmente ocorre em processamento de nuvens de pontos, em Nazem (2014) uma amostragem aleatória selecionando 70% dos conjuntos de dados é utilizada como etapa do processo registro de imagens de ultrassom de fígado para auxílio em procedimento cirúrgico. Em Ghayab (2016) vê-se a amostragem aleatória sendo utilizada para auxiliar classificadores a determinar se uma pessoa possui epilepsia a partir de um exame de eletroencefalograma. Já em Wright (2014) vê-se uma estratégia de amostragem aleatória estratificada sendo utilizada para monitoramento de animais mamíferos terrestres.

A figura 15 exemplifica a amostragem aleatória considerando 50% e 1% do total de pontos.

Uma das possíveis aplicações da amostragem aleatória se dá na representação do conjunto de dados com uma magnitude inferior a do conjunto original. Como vê-se na figura 15b, com 50% do conjunto amostrado aleatoriamente ainda é preservado, em certa parte, o conjunto de dados apresentado na figura 15a. A medida que é reduzido o tamanho no qual desejamos representar nosso conjunto, menor é a facilidade de identificação do conjunto inicial, como vê-se na figura 15c.

### 2.6.2 Redes neurais Self-Organizing Map (SOM)

Rede neural artificial é o nome que se dá aos diversos modelos matemáticos inspirados nos conjuntos de neurônios biológicos, sistema nervoso central, de cada indivíduo. Estes modelos visam, então, modelar a capacidade de inferência presente em qualquer ser vivo, de tal forma que são utilizados para estimar, ou aproximar, funções, geralmente desconhecidas, baseando-se em conjuntos de entradas.

Segundo Haykin (1999), alguns dos benefícios ao se trabalhar com redes neurais são: a capacidade do processamento de dados não lineares; o mapeamento de entrada-saída dos dados, onde a partir de treinamento por exemplos, uma rede neural é capaz de atuar de modo similar a uma função desconhecida; e a capacidade de tratamento de informação contextual.

Dentre os tipos de rede neural, existem os mapas auto-organizáveis (*self-organizing maps*) de Kohonen (1990), que consistem de redes neurais com treinamento não-supervisionado e aprendizado competitivo, diferente de outros modelos de rede neural, como a tradicional MLP (*multi-layer perceptron*) que trabalham com aprendizado a partir de correção de erro.

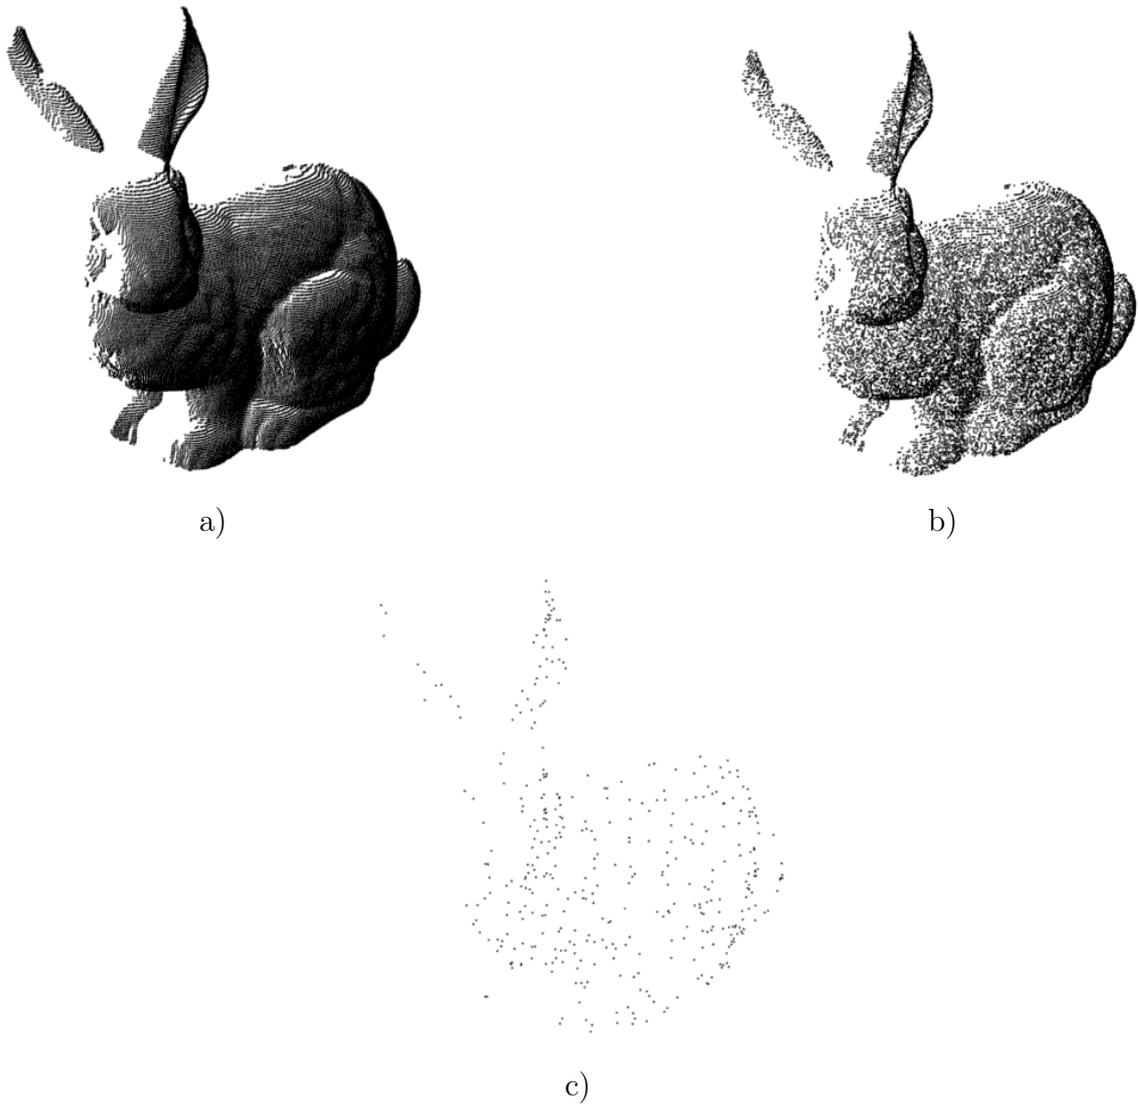
Segundo (KOHONEN (1990)), a principal diferença entre as redes neurais SOM e os demais tipos de rede neural é a ênfase na consideração da organização espacial enquanto as demais técnicas focam o processamento distribuído, permitindo com que redes neurais SOM obtenham efetivamente uma organização espacial das várias características das entradas.

Dadas as características das redes SOM, uma de suas aplicações mais populares é a representação de topologia de conjunto de dados. São citados a seguir alguns artigos relacionados começando por Astudillo (2014), onde é feita uma revisão de variações da rede SOM orientadas à preservação de topologia apresentadas no últimos anos e também são feitas comparações delas em si com relação às suas propriedades. Em Mohebi (2016) é apresentado o CSOM (*Constrained SOM*) que modifica o algoritmo de aprendizado da versão de Kohonen (1990) com o intuito de otimizar a preservação de topologia e a qualidade de mapeamento em comparação com a versão clássica do algoritmo. Em Elghazel (2014) é analisando o trabalho de *clustering* de redes SOM mediante diferentes paradigmas: a partir de técnicas de particionamento, técnicas hierárquicas e técnicas de coloração de grafos; onde é concluído que a integração de redes SOM às estratégias de coloração aumenta a qualidade do *clustering*. Por fim, em Rois (2015), redes SOM são utilizadas para modelagem da predição de séries temporais a partir da preservação da topologia dos sinais, onde como uma das conclusões é dito que os resultados de predição podem ser otimizados de acordo com a escolha da função de aprendizado da rede SOM.

Usualmente, os mapas obtidos como resultado das redes SOM são utilizados como referência para atribuir grupos, ou *clusters*, aos elementos do conjunto de entrada a

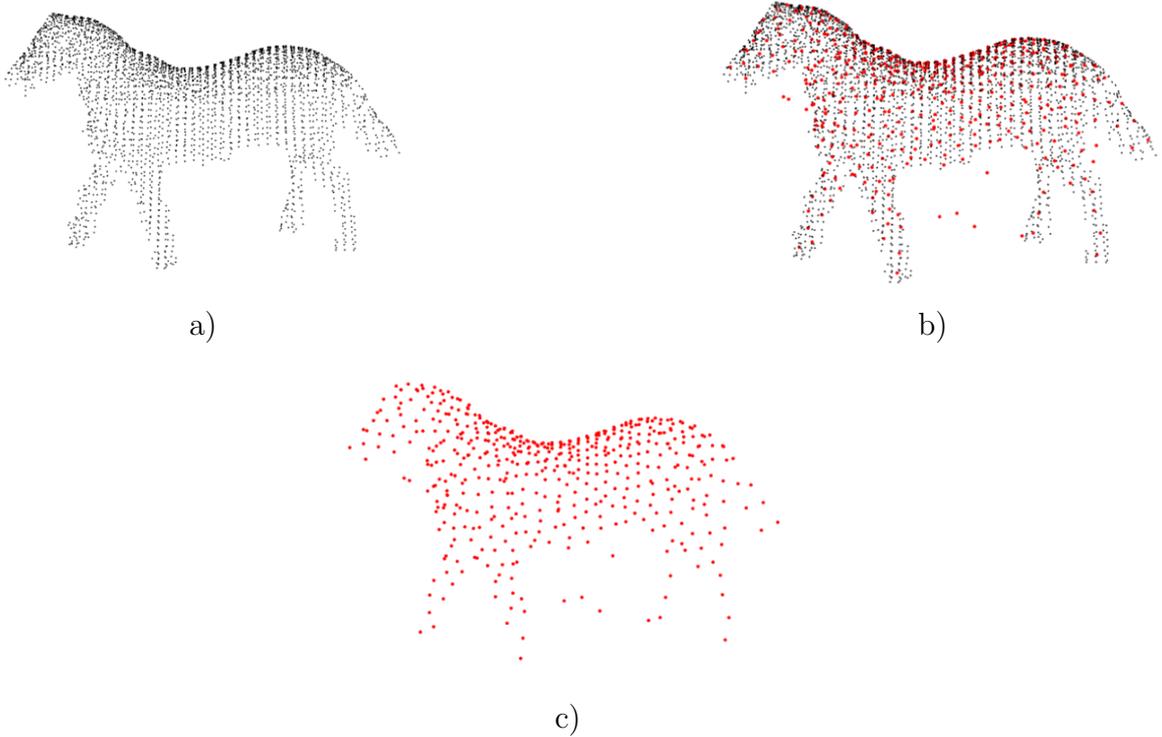
partir de análises de vizinhança. No contexto deste trabalho, o objetivo da representação por mapas auto-organizáveis é a utilização da representação do conjunto de dados numa menor quantidade de pontos, visando acelerar o processo de registro do algoritmo ICP. A figura 16 mostra a utilização da rede SOM para representar tridimensionalmente um conjunto de dados.

Figura 15 – Amostragens aleatórias. Em a) a nuvem de pontos de referência, proveniente de STANFORD (1996), em b) amostragem aleatória utilizando 50% dos pontos. Em c) amostragem aleatória utilizando 1% dos pontos.



Fonte: a) STANFORD (1996), b) e c) Autor.

Figura 16 – Em a) nuvem de pontos de referência. Em b) é apresentado o conjunto de pontos obtidos a partir da rede neural SOM que busca aprender a topologia do conjunto de dados. Em c) é apresentado somente o conjunto de pontos resultante do aprendizado de topologia a partir da rede neural SOM.



Fonte: a) Aleotti 2014, b) e c) Autor.

### 3 CLOUD PARTITIONING ICP

A partir da descrição do algoritmo ICP, deve ser claro que o custo computacional é um tanto dependente do tamanho da nuvem de pontos; claramente, quão maior o tamanho dos conjuntos de dados referentes às nuvens de entrada e objetivo, maior o tempo para determinar o grupo de pontos mais próximos e, em consequência, maior o tempo de registro. Tendo isto em mente, naturalmente alguém poderia pensar em amostrar o conjunto de dados como passo inicial, acelerando, então, o processo de registro da nuvens de pontos. De fato, na literatura um vasto número de abordagens de amostragem foi reportado até então. Por exemplo, em Torsello (2011) é proposto um método de amostragem o qual seleciona os pontos a partir da sua relevância com sua vizinhança. Em Gelfand (2003) é proposto um método de amostragem o qual melhora a estabilidade geométrica do algoritmo ICP.

Alinhado a isto, neste trabalho é proposto um algoritmo de particionamento de nuvens de pontos a ser utilizado previamente a execução do algoritmo ICP (CP-ICP). A ideia por trás do CP-ICP é separar o conjunto total de pontos em grupos menores ( $k$  grupos no total) nomeados agora em diante de sub-nuvens, e então repetir o processo de registro para cada sub-nuvem até que um critério de parada seja respeitado, como será explicado na seção 3.2. Ao fazer isto, são reduzidas consideravelmente a quantidade de operações devido ao fato das nuvens de pontos estarem reduzidas em tamanho.

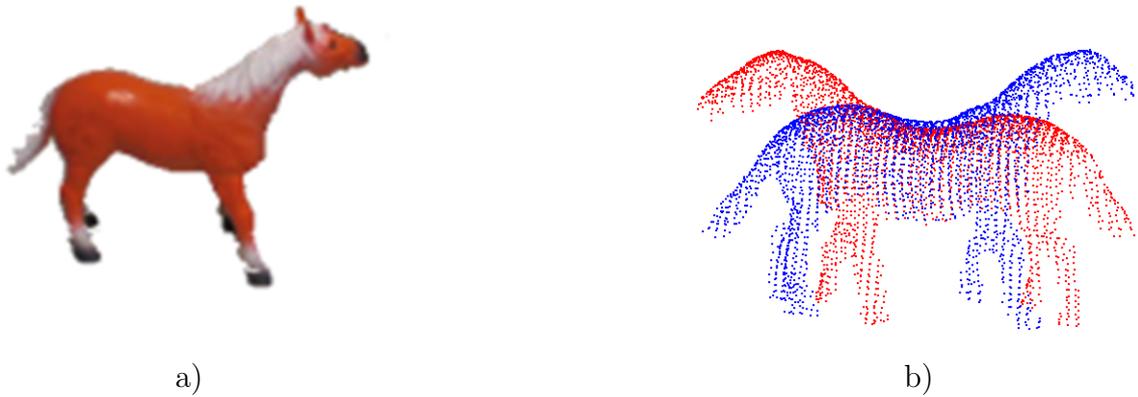
Para uma melhor visualização da afirmação acima, considere  $N_X$  e  $N_P$  como os tamanhos de duas nuvens de pontos sob registro pelo ICP. O custo computacional para o cálculo dos pontos mais próximos no ICP clássico é  $O(N_X N_P)$  (BESL and MCKAY (1992)), ao passo que utilizando o particionamento em sub-nuvens faz o custo computacional desta mesma etapa variar entre  $O(\frac{N_X N_P}{k^2})$  e  $kO(\frac{N_X N_P}{k^2})$ . Nesta análise, é considerado somente o cálculo dos pontos mais próximos, por ser a etapa que mais consome tempo do algoritmo ICP.

#### 3.1 Particionamento das nuvens

Tendo em mente que as nuvens de pontos serão submetidas a um particionamento, a abordagem adotada na implementação foi da divisão dos conjuntos de dados baseando-se no eixo de referência da rotação entre as diferentes perspectivas dos objetos. A figura 17 mostra em a) um dos objetos dos quais foi feita a aquisição das nuvens de pontos e em b) duas nuvens de pontos resultantes de perspectivas diferentes ( $180^\circ$  entre elas) do objeto presente no item anterior.

Dessa forma, como o eixo de rotação é conhecido para cada objeto (graças ao modo da aquisição das imagens de profundidade) cada nuvem de dados é particionada ao longo deste eixo (eixo z, para os objetos em questão) e sub-nuvens de mesmo índice são

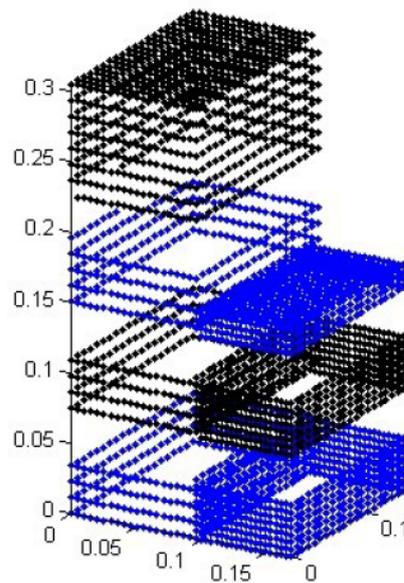
Figura 17 – Em a) objeto utilizado como referência para aquisição de nuvens de pontos. Em b) duas perspectivas deste objeto rotacionadas entre si em  $180^\circ$  em torno do eixo z.



Fonte: a) Aleotti 2014, b) Autor.

comparadas entre si. A figura 18 evidencia como o particionamento de nuvens atua numa dada nuvem de pontos considerando que se deseja obter 4 sub-nuvens.

Figura 18 – Exemplo ilustrativo da divisão de uma nuvem de pontos em 4 sub-nuvens.



Fonte: Autor.

Algumas questões surgem naturalmente a este ponto: a) como o CP-ICP resulta em  $k$  matrizes de transformação, qual deles representa um registro suficiente, em termos de qualidade, para todo o conjunto de pontos? b) como o CP-ICP requer, em pior caso, repetir o ICP para cada uma das  $k$  sub-nuvens, é possível encontrar um compromisso entre a quantidade de matrizes de transformação e o tempo decorrido para o algoritmo como um todo? Os próximos tópicos discutem estas questões, detalhando a operação do algoritmo proposto.

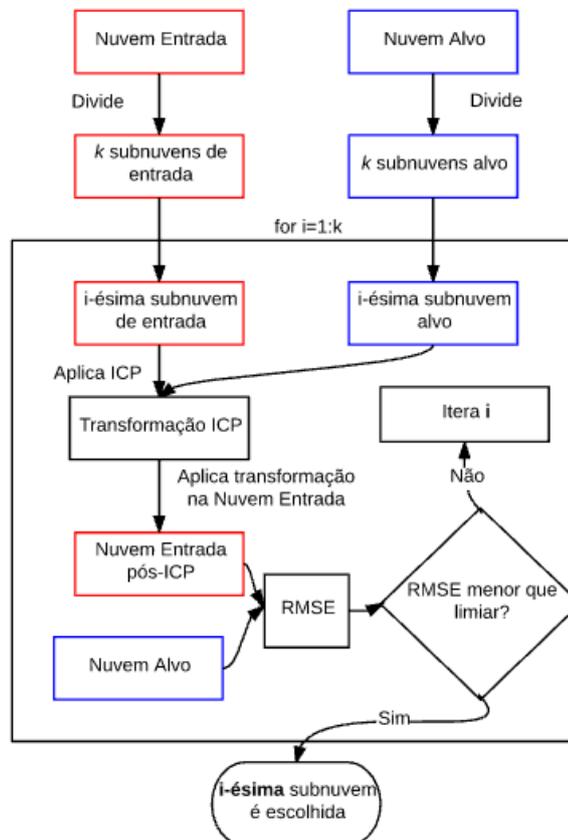
### 3.2 Registro suficiente

Considere duas nuvens de pontos: uma nuvem de **entrada** e uma *nuvem* alvo. O objetivo é realizar com sucesso um **registro**, o que significa aplicar transformações de rotação e translação na nuvem de entrada de tal forma que ela se sobreponha, espacialmente, de um modo ótimo na nuvem alvo. Para aplicarmos o método do CP-ICP, são seguidos os seguintes passos:

1. Divide-se cada conjuntos de dados (entrada e alvo) em  $k$  sub-nuvens;
2. Para cada uma das  $k$  iterações, calcula-se o algoritmo ICP para um par de sub-nuvens;
3. Aplica-se a transformação obtida para a nuvem de pontos de entrada (nomeada a partir de agora como nuvem de entrada pós-ICP), corrigindo, assim, o alinhamento;
4. A nuvem de entrada pós-ICP é então comparada com a nuvem alvo, utilizando o RMSE a cada iteração;
5. Caso o valor de RMSE obtido numa dada iteração seja aceitável (a partir do critério de parada) o algoritmo se encerra e o registro desejado é obtido.

Para ilustrar todos esses passos, a figura 19 mostra o algoritmo numa forma de fluxograma.

Figura 19 – Descrição do procedimento proposto.



Fonte: Autor.

Com relação ao critério de parada, trata-se de um valor limiar de RMSE que

é definido para cada par de nuvens de pontos. Quaisquer valores inferiores a este critério de parada, representam registros considerados suficientes. Neste trabalho, estes valores de parada foram obtidos a partir de experimentos sucessivos para cada par de nuvens de pontos a ser registrado.

A tabela 1 apresenta os valores utilizados como critério de parada para cada um dos modelos estudados.

Tabela 1 – Condição de parada para registro suficiente de cada modelo estudado.

<b>Modelo</b>	<b>Valor de RMSE de parada</b>
<i>Horse</i>	$1,05 \cdot 10^{-2}$
<i>Hammer</i>	$0,70 \cdot 10^{-2}$
<i>Dragon</i>	$0,20 \cdot 10^{-2}$
<i>Buddha</i>	$0,29 \cdot 10^{-2}$

Fonte: Autor.

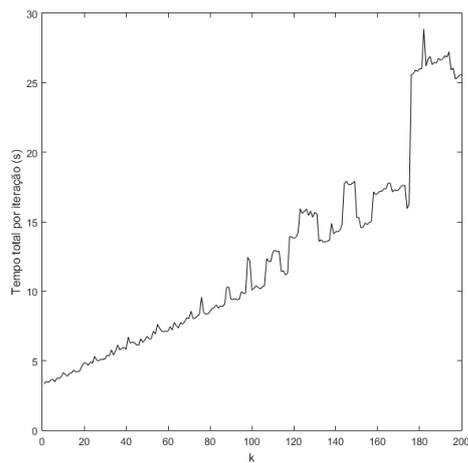
### 3.3 *Tradeoff* entre soluções e tempo

Considerando o método do CP-ICP como mostrado na figura 19, pode-se notar que quão maior o número de sub-nuvens, maior a quantidade de matrizes de transformação que são obtidas como solução, o que aumenta a quantidade de possíveis registros aceitáveis. Entretanto, o consumo de tempo também aumenta, o que é um inconveniente, e revela um *tradeoff* entre o número de soluções e o consumo de tempo.

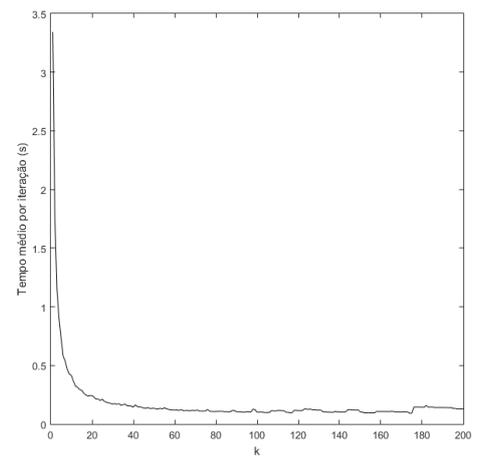
Para a melhor compreensão da influência da quantidade de sub-nuvens na performance de tempo, a figura 20a apresenta o tempo total decorrido do método CP-ICP para diferentes valores de sub-nuvens e utilizando o modelo *Horse*. Já na figura 20b é mostrado o consumo de tempo médio de cada iteração do CP-ICP para vários valores de  $k$  para o mesmo modelo.

A partir da figura 20b pode-se observar uma baixa flutuação de tempo consumido para valores excedendo  $k = 100$ . Isto revela que não há ganho em tempo em efetuar um particionamento excessivo, especialmente por que como mostrado na figura 20a o tempo total aumenta de acordo.

Figura 20 – Em a) Tempo total do registro com CP-ICP para o modelo *Horse* variando a quantidade de sub-nuvens (quantidade definida pelo parâmetro  $k$ ). Em b) o tempo médio de cada iteração do CP-ICP ao variarmos o valor de  $k$ .



a)



b)

Fonte: Autor.

## 4 MATERIAIS E METODOS

### 4.1 Conjuntos de dados

A performance do método proposto CP-ICP foi avaliada utilizando dois diferentes *databases*. O primeiro é um *database* privado gentilmente cedido pelo professor Aleotti apresentado em (ALEOTTI and RIZZINI (2014)) e consiste de diversas nuvens de pontos adquiridas a partir de um braço robótico 6DOF (Comau SMART six) equipado com uma pinça com dois dedos paralelos (*two-finger parallel gripper*) (Schunk PG-70) e um *scanner* a laser de distância de alta resolução (SICK LMS 400), ambos montados no pulso do braço robótico. Deste *database* foram utilizados dois modelos nos experimentos, nomeadamente o modelo *Horse* e o modelo *Hammer*, ilustrados na figura 21.

Figura 21 – Objetos utilizados como referência para nuvens de pontos utilizados do *database* em (ALEOTTI and RIZZINI (2014)). Em a) é mostrado o *Horse* e em b) o *Hammer*.



Fonte: Aleotti (2014)

As perspectivas avaliadas destes objetos são nomeadas de acordo com o ângulo de aquisição do sensor na cena. Para o modelo *Horse* foram consideradas as perspectivas de  $0^\circ$  e  $180^\circ$ . Para o modelo *Hammer* foram consideradas as perspectivas de  $0^\circ$  e  $45^\circ$ .

O segundo *database* é o repositório de escaneamento 3D de Stanford (1996), o qual é um *database* público com diversos modelos 3D. Deste repositório foram utilizados dois modelos nos experimentos, nomeadamente o modelo *Dragon* e o modelo *Buddha*, ilustrados na figura 22.

Similarmente, as perspectivas disponíveis destes objetos são relacionadas aos ângulos de aquisição. Para ambos os conjuntos de dados, foram consideradas as perspectivas de  $0^\circ$  e  $24^\circ$ .

A tabela 2 mostra o tamanho das nuvens de pontos 3D para cada modelo apresentado.

Figura 22 – Objetos de referência para os modelos utilizados, presentes em (STANFORD (1996)). Em a) é mostrado o *Dragon* e em b) o *Buddha*.



a)



b)

Fonte: *Stanford 3D Repository* (1996)

Tabela 2 – Tamanho dos conjuntos de dados.

<b>Modelo</b>	<b>Número de pontos</b>
<i>Horse</i>	3335 e 3298
<i>Hammer</i>	1852 e 2024
<i>Dragon</i>	41841 e 34836
<i>Buddha</i>	78056 e 75582

Fonte: Autor.

## 4.2 Metodologia

Como apontado anteriormente, o objetivo deste trabalho é introduzir um novo método de amostragem a ser utilizado previamente ao algoritmo ICP (CP-ICP). Para avaliar o método proposto, o CP-ICP foi comparado com método de amostragem aleatória (variando entre 50% e 70% do tamanho total da nuvem de pontos) e também com uma abordagem de quantização vetorial, uma rede neural de *self-organizing maps* (SOM). Duas arquiteturas de redes neurais foram utilizadas: a primeira com 3 camadas de 5 neurônios cada e a segunda com 3 camadas de 8 neurônios cada. Ambas foram treinadas por 200 épocas. Em adição, também foi considerado o caso sem amostragem, o qual é o utilizado no método clássico do ICP em (BESL and MCKAY (1992)).

### 4.3 Métricas utilizadas

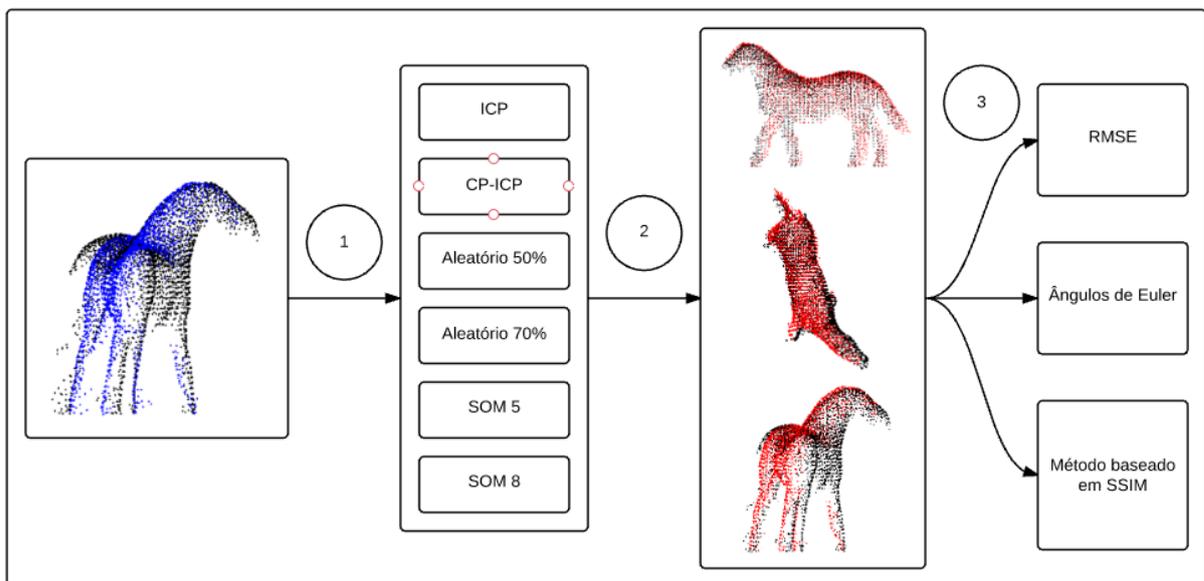
Para avaliar a qualidade dos registros 3D do algoritmo ICP e os métodos de amostragem sob estudo, foram utilizadas três diferentes métricas: A primeira é baseada no RMSE entre as seguintes nuvens de pontos:

- A nuvem de pontos alvo e;
- A nuvem de pontos transformada pelo ICP com as diferentes técnicas de amostragem.

A segunda métrica é baseada na comparação dos ângulos de Euler de cada matriz de transformação obtida através do ICP. Isto só é possível para o modelos *Dragon* e *Buddha*, já que somente estes modelos possuem um *ground-truth*.

A última métrica é baseada no índice SSIM. Neste trabalho, foi proposto um método que cria imagens 2D a partir de diferentes perspectivas dos modelos 3D, onde então é calculado o índice SSIM para cada uma destas imagens bidimensionais. A figura 23 apresenta a metodologia empregada.

Figura 23 – Metodologia adotada para comparar os métodos de amostragem. Em (1) os métodos de amostragem são aplicados as nuvens de pontos e então estas são submetidas ao ICP. Em (2) os resultados dos registros são obtidos para cada técnica de amostragem. Em (3) os resultados são então comparados utilizando RMSE, ângulos de Euler e SSIM.



Fonte: Autor

## 5 RESULTADOS

Nesta seção são comparadas a eficiência do método proposto CP-ICP às outras técnicas de amostragem na tarefa do registro de nuvens de pontos. A análise se apóia na comparação entre os tempos decorridos do registro por completo, assim como na sua qualidade, medida através das métricas já listadas.

### 5.1 Tempo decorrido

A tabela 3 sintetiza a performance de tempo das várias abordagens de amostragem; como é claro a partir dos resultados, o método proposto de amostragem (CP-ICP) obteve a melhor performance para cada modelo 3D estudado; por outro lado o método baseado em redes neurais SOM obteve os piores resultados de tempo. O leitor deve notar a diferença na ordem de grandeza dos tamanhos das nuvens de pontos para os modelos *Dragon* e *Buddha* (razão que justifica por quê o método baseado em redes SOM não foi posteriormente aplicado a estes modelos). Tal performance do método proposto confirma a expectativa sobre a redução do custo computacional no algoritmo de registro de nuvens, como mencionado no capítulo 3.

Tabela 3 – Comparação de tempo em segundos entre métodos de amostragem.

	<i>Horse</i> ( $k=200$ )	<i>Hammer</i> ( $k=50$ )	<i>Dragon</i> ( $k=100$ )	<i>Buddha</i> ( $k=100$ )
ICP	3,34	2,02	37,98	87,82
CP-ICP	0,32	0,08	0,91	7,64
Aleatoria 50%	2,10	1,10	44,40	162,46
Aleatoria 70%	2,68	1,50	58,25	201,58
SOM 5	24,39	15,42	-	-
SOM 8	100,94	66,13	-	-

Fonte: Autor.

Estes números são importantes pois enfatizam que o método proposto resolve a tarefa num tempo menor que a abordagem clássica.

### 5.2 Métrica de RMSE

Como explicado anteriormente, em adição a análise de tempo, também foram analisadas métricas quantitativas da qualidade do registro. Como primeira opção, foram utilizados os valores de RMSE entre a nuvem de entrada pós-ICP e a nuvem alvo.

Na tabela 4 são listados o RMSE obtido para as diferentes abordagens de amostragem e para os diferentes modelos 3D estudados. O leitor deve notar que os valores relacionados ao *ground-truth* são relacionados às medições dos modelos do *Dragon* e *Buddha* considerando que a o ângulo de rotação entre as duas perspectivas, de cada modelo, é conhecida como  $24^\circ$ .

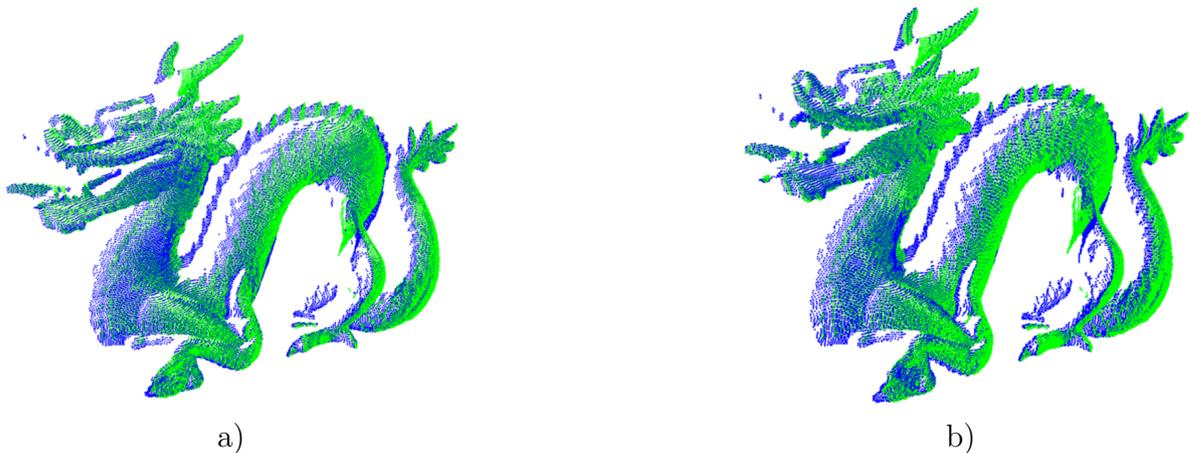
Tabela 4 – RMSE calculado para o registro com cada técnica de amostragem.

	<i>Horse</i> ( $k=200$ )	<i>Hammer</i> ( $k=50$ )	<i>Dragon</i> ( $k=100$ )	<i>Buddha</i> ( $k=100$ )
<i>Ground truth</i>	-	-	$0,18 \cdot 10^{-2}$	$0,27 \cdot 10^{-2}$
ICP	$0,97 \cdot 10^{-2}$	$0,57 \cdot 10^{-2}$	$0,18 \cdot 10^{-2}$	$0,22 \cdot 10^{-2}$
CP-ICP	$1,02 \cdot 10^{-2}$	$0,60 \cdot 10^{-2}$	$0,19 \cdot 10^{-2}$	$0,28 \cdot 10^{-2}$
Aleatoria 50%	$0,98 \cdot 10^{-2}$	$0,58 \cdot 10^{-2}$	$0,18 \cdot 10^{-2}$	$0,22 \cdot 10^{-2}$
Aleatoria 70%	$0,97 \cdot 10^{-2}$	$0,58 \cdot 10^{-2}$	$0,18 \cdot 10^{-2}$	$0,22 \cdot 10^{-2}$
SOM 5	$1,02 \cdot 10^{-2}$	$0,63 \cdot 10^{-2}$	-	-
SOM 8	$1,03 \cdot 10^{-2}$	$0,62 \cdot 10^{-2}$	-	-

Fonte: Autor.

A partir da tabela 4, pode-se ver que o método CP-ICP e os outros métodos obtiveram resultados semelhantes. Apesar da métrica RMSE estar entre as mais utilizadas, o problema dela é que não se trata de uma medida absoluta para análise de tendência (ou seja, é necessária uma grande discrepância entre valores de RMSE para se assegurar que um resultado é de fato melhor que outro), isso implica que, dependendo do contexto, um valor de RMSE de  $0,35 \cdot 10^{-2}$  pode ser aceitável, por exemplo. Como exemplo, veja a figura 24 onde em a) tem-se o registro para o modelo *Dragon* utilizando ICP sem amostragem e em b) o registro para o mesmo modelo utilizando-se CP-ICP.

Figura 24 – Resultado do registro para o modelo *Dragon*. Em a) ICP sem amostragem. Em b) resultado registro do método proposto CP-ICP.



Fonte: Autor.

Apesar do resultado para o ICP ser numericamente superior, conforme tabela 4, qualitativamente isto não é claro, conforme figura 24. De fato, até mesmo o *ground-truth* para o modelo *Buddha*, presente na tabela 4, apresentou um valor de RMSE inferior ao do ICP sem amostragem, o que é algo incoerente já que o *ground-truth* é a própria referência de resultado. Desta forma, o valor absoluto do RMSE não discrimina bem a qualidade de um registro, o que é motivação para se buscar outros métodos que quantifiquem quão bom foi o registro entre duas nuvens de pontos.

A associação usual de métricas quantitativas (RMSE) e qualitativas (inspeção) serviu de motivação para a busca de alternativas para análise dos registros. Os tópicos seguintes buscam suprir essa necessidade de outras referências para os resultados obtidos.

### 5.3 Análise de ângulos de Euler

Considerando a não tão precisa análise pelo RMSE, buscamos outra métrica quantitativa que pudesse expressar a qualidade do registro das nuvens de pontos. De tal forma, a tabela 5 apresenta os ângulos de Euler obtidos para as matrizes de transformação obtidas pelas técnicas de amostragem estudadas para os modelos *Dragon* e *Buddha*. Ressalta-se novamente que somente estes modelos são analisados neste tópico por serem os únicos a possuir um *ground-truth*. As perspectivas analisadas de cada modelo possuem um ângulo de  $24^\circ$  em torno do eixo Z.

Tabela 5 – Ângulos de Euler obtidos pelos registros.

	Dragon			Buddha		
	Eixo Z	Eixo Y	Eixo X	Eixo Z	Eixo Y	Eixo X
ICP	23,86°	0,01°	0,11°	17,58°	-0,10°	-0,46°
CP-ICP	23,45°	-0,31°	0,17°	24,05°	-0,30°	0,17°
Aleatória 50%	23,86°	0,03°	0,09°	17,54°	-0,10°	-0,48°
Aleatória 70%	23,86°	0,01°	0,10°	17,52°	-0,11°	-0,46°

Fonte: Autor.

Como vemos na tabela 5, o método proposto CP-ICP mostrou-se superior também num posto de vista quantitativo. O leitor deve notar especialmente a coluna relacionada ao eixo z do modelo *Buddha* onde vemos que enquanto o CP-ICP errou por  $0,05^\circ$ , todos as outras técnicas erraram por mais de  $5^\circ$ . Estes resultados mostram claramente o potencial da técnica proposta que, apesar de simples, é capaz de otimizar o processo de registro tanto em tempo como em qualidade, tendo em vista que, para o modelo *Buddha*, em menos de 1 décimo do tempo do ICP sem amostragem (7,64s do CP-ICP versus 87,82s do ICP, vide tabela 3) conseguiu um resultado com erro de 0,21% no eixo z em comparação aos 26,75% deste último.

### 5.4 Métrica baseada em SSIM

As tabelas 6 a 9 mostram a análise das cinco perspectivas de cada um dos modelos 3D estudados, utilizando a métrica baseada no índice SSIM. Os valores apresentados representam o valor médio entre as perspectivas. As tabelas 6 e 7 são relacionadas com os modelos *Horse* e *Hammer*, os modelos com menor quantidade de pontos. Já as tabelas 8 e 9 fazem referência aos modelos *Dragon* e *Buddha*, os modelos com quantidade de pontos maior. Como os modelos *Dragon* e *Buddha* são os únicos que possuem *ground-truth*, a expectativa é um resultado mais confiável desta métrica para estes dois modelos.

Tabela 6 – Métrica com índice SSIM para o modelo *Horse*.

<b>Amostragem</b>	<i>Dot pattern</i>	<b>Cheia</b>	<b>Contorno</b>	<b>Esqueleto</b>	<b>Média</b>
ICP	0,7165	0,8814	0,8636	0,9096	0,8428
CP-ICP	0,7018	0,8797	0,8688	0,9088	0,8398
Aleatoria 50%	0,7153	0,8769	0,8595	0,9073	0,8398
Aleatoria 70%	0,7057	0,8802	0,8628	0,9088	0,8394
SOM 5	0,7076	0,8594	0,8489	0,9022	0,8295
SOM 8	0,6929	0,8669	0,8548	0,9018	0,8291

Fonte: Autor.

Tabela 7 – Métrica com índice SSIM para o modelo *Hammer*.

<b>Amostragem</b>	<i>Dot pattern</i>	<b>Cheia</b>	<b>Contorno</b>	<b>Esqueleto</b>	<b>Média</b>
ICP	0,8096	0,9011	0,8934	0,9373	0,8853
CP-ICP	0,8078	0,8985	0,8921	0,9356	0,8835
Aleatoria 50%	0,8093	0,9012	0,8929	0,9367	0,8850
Aleatoria 70%	0,8085	0,9014	0,8924	0,9269	0,8848
SOM 5	0,8084	0,8995	0,8926	0,9385	0,8848
SOM 8	0,8128	0,9046	0,8994	0,9372	0,8885

Fonte: Autor.

Conforme mostram as tabelas 8 e 9, similarmente aos resultados com os ângulos de Euler, a abordagem proposta teve um resultado inferior para o modelo *Dragon* e superior para o modelo *Buddha*, apesar de que, diferente do modelo *Buddha*, não fomos capazes de notar qualitativamente a inferioridade do algoritmo proposto para o modelo *Dragon*, conforme figura 24.

Tabela 8 – Métrica com índice SSIM para o modelo *Dragon*.

<b>Amostragem</b>	<i>Dot pattern</i>	<b>Cheia</b>	<b>Contorno</b>	<b>Esqueleto</b>	<b>Média</b>
ICP	0,7658	0,9748	0,9646	0,9561	0,9153
CP-ICP	0,6932	0,9580	0,9414	0,9408	0,8833
Aleatoria 50%	0,7647	0,9746	0,9642	0,9539	0,9144
Aleatoria 70%	0,7588	0,9734	0,9628	0,9542	0,9123

Fonte: Autor.

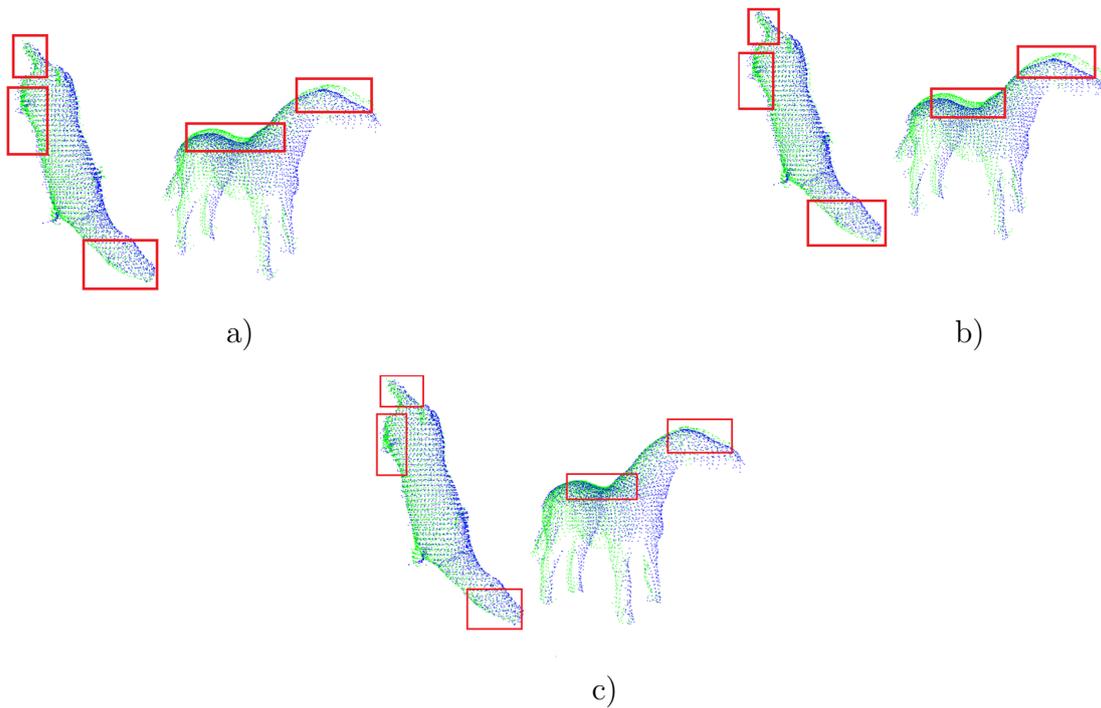
Para ilustrar, a figura 25 mostra o resultado do registro em a) ICP sem amostragem, em b) amostragem aleatória com 50% dos pontos e em c) CP-ICP. As regiões destacadas da figura 25 revelam que o registro obtido pela abordagem proposta CP-ICP obteve um melhor resultado qualitativo, apesar de quantitativamente o ICP ter se apresentado melhor para as métricas RMSE e SSIM.

A figura 26 mostra os resultados de registro para o modelo *Buddha*. Tem-se, em a) o registro com ICP sem amostragem, em b) o registro com amostragem aleatória 50%, em c) o registro com amostragem aleatória 70%, em d) o registro com CP-ICP e em e) é mostrada uma vista ampliada dos pés do *ground-truth* do modelo *Buddha*. Para este modelo pode-se ver claramente que os resultados apresentados pelo CP-ICP foram

Tabela 9 – Métrica com índice SSIM para o modelo *Buddha*.

<b>Amostragem</b>	<i>Dot pattern</i>	<b>Cheia</b>	<b>Contorno</b>	<b>Esqueleto</b>	<b>Média</b>
ICP	0,7503	0,9309	0,9057	0,9279	0,8787
CP-ICP	0,7818	0,9527	0,9334	0,9426	0,9026
Aleatoria 50%	0,7487	0,9307	0,9054	0,9265	0,8778
Aleatoria 70%	0,7481	0,9307	0,9056	0,9256	0,8775

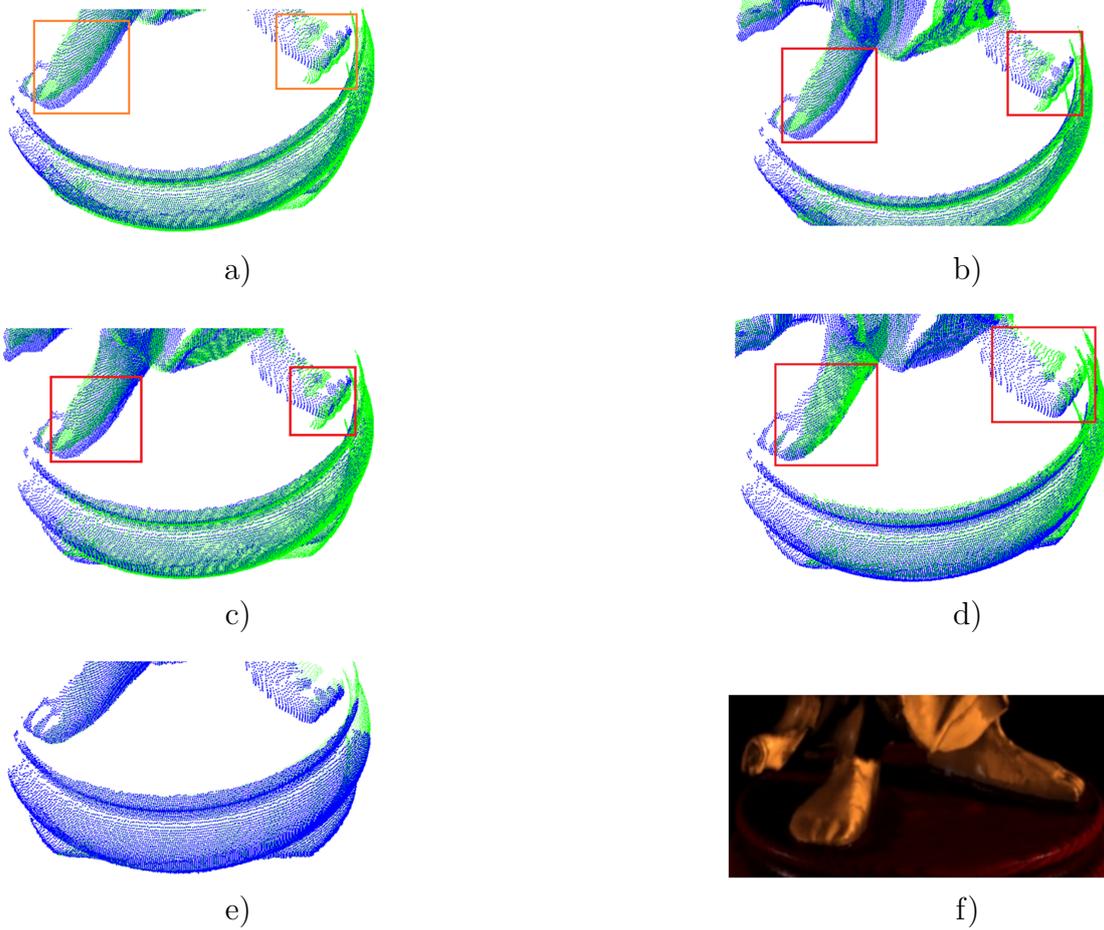
Fonte: Autor.

Figura 25 – Comparação dos resultados dos registro para o modelo *Horse*. Em a) o registro do ICP sem amostragem. Em b) o registro com amostragem aleatória 50% e em c) o registro do CP-ICP.

Fonte: Autor.

os melhores, como denotado nas regiões destacadas na figura 26.

Figura 26 – Visão ampliada dos registros para o modelo *Buddha*. Em a) registro com ICP sem amostragem, em b) registro com amostragem aleatória 50%, em c) registro com amostragem aleatória 70%, em d) registro com CP-ICP, em e) *ground-truth* do modelo *Buddha* e em f) a imagem original do modelo *Buddha*.



Fonte: Autor.

## 6 LIMITAÇÕES E TRABALHOS FUTUROS

Os resultados mostram que o CP-ICP obteve registros de nuvens mais rápidos e mais fiéis mediante as métricas apresentadas. Apesar disto, estamos cientes das diversas limitações inerentes ao algoritmo e este capítulo é utilizado para discutir tais pontos, assim como levantar possibilidades de melhorias visando justamente suprir as necessidades levantadas.

### 6.1 Quantas sub-nuvens utilizar?

A seção 3.3 trata justamente do *tradeoff* que se observa com o aumento do número de sub-nuvens. Quão maior for o número de sub-nuvens, mais soluções se encontram disponíveis a fim de obtermos um registro suficiente, em contrapartida, com o acréscimo de  $k$ , o custo computacional máximo aumenta. Essa relação de compromisso entre número de soluções e custo computacional mostra uma fragilidade na escolha do valor de  $k$ . No presente trabalho, a abordagem foi da escolha empírica: selecionar algum valor baseando-se em testes e determinar, dentre os testes executados, o valor de  $k$  que obteve os resultados mais interessantes. Numa situação ideal, a escolha do parâmetro  $k$  se dá mediante algum critério de otimização. A complexidade da situação se dá no fato de que a seleção do valor de  $k$  pode vir a depender de diversos fatores como a geometria e o tamanho da nuvem de pontos, características muitas vezes imprevisíveis (a geometria, por exemplo).

Obviamente, dada a natureza do algoritmo que é de dividir o conjunto em porções menores, é lógico dizer que o valor de  $k$  é limitado (não é possível, dada nossa definição, dividir uma nuvem com 100 pontos em 101 sub-nuvens), de tal forma que o espaço de possibilidades para o valor de  $k$  é conhecido.

### 6.2 Busca do registro suficiente

Na seção 3.2 é tratado do registro suficiente, onde por suficiente faz-se referência ao registro que obtenha um valor de métrica inferior a um *threshold* específico. Nesta etapa, pôde-se identificar duas limitações: o modo de busca e o valor de *threshold*. Quando dividida, a nuvem de pontos é submetida a  $k$  execuções do ICP e cada sub-nuvem sofre um processo de registro que é mensurado e comparado ao valor de referência. A ordem na qual as sub-nuvens são iteradas e selecionadas para terem suas métricas de registro calculadas se mostrou crucial para a velocidade do algoritmo. Dessa forma, para o mesmo par de sub-nuvens, utilizando o mesmo valor de  $k$ , dependendo se as nuvens fossem iteradas do começo ao fim ou do fim ao começo, o resultado de tempo era consideravelmente diferente. A tabela 10 ilustra essa questão para os modelos estudados.

Os únicos modos de iteração aqui explorados foram o crescimento e decresci-

Tabela 10 – Resultados de tempo de acordo com o sentido de iteração das sub-nuvens.

<b>Modelo</b>	<b>k</b>	<b>Sentido de iteração</b>	<b>CP-ICP (s)</b>	<b>ICP clássico (s)</b>
<i>Horse</i>	50	1 → 50	2,210	3,346
<i>Horse</i>	50	50 → 1	0,386	3,346
<i>Hammer</i>	50	1 → 50	0,081	2,021
<i>Hammer</i>	50	50 → 1	1,944	2,021
<i>Dragon</i>	100	1 → 100	0,915	37,983
<i>Dragon</i>	100	100 → 1	33,461	37,983
<i>Buddha</i>	100	1 → 100	56,664	87,828
<i>Buddha</i>	100	100 → 1	7,643	87,828

Fonte: Autor.

mento monotônicos, conforme mostrado na tabela 10. O que estes resultados indicam é que há um  $k$  ótimo para cada registro entre um par de nuvens, em outras palavras, existem regiões nas nuvens de pontos que são responsáveis por obtermos o registro suficiente, e, o modo com o qual iteramos dentre as diversas sub-nuvens vai influenciar diretamente no tempo de busca de um registro suficiente. Por exemplo, para o caso do modelo *Dragon*, a sub-nuvem que apresentou o registro suficiente possui um índice próximo do valor 1 de tal forma que a busca crescente rapidamente obtém um registro suficiente, em contrapartida, a busca decrescente tarda a localizar uma sub-nuvem com registro satisfatório.

A outra limitação se encontra no valor de *threshold* para o fim da busca de registros satisfatórios. É notória a subjetividade desse valor, dado que a expressão "satisfatório" pode variar de acordo com a aplicação. Esse valor foi obtido a partir de experimentação para cada par de nuvens de cada modelo. A situação ideal, e prospecção de trabalhos futuros, se dá na obtenção automática deste valor de limiar, dado um par de nuvem de pontos.

## 7 CONCLUSÃO

Neste trabalho é apresentado um método para amostragem de dados em registro de nuvens de pontos. Mais especificamente, um método iterativo, que consiste no particionamento de nuvens de pontos, é apresentado como etapa de amostragem, prévia ao algoritmo ICP. A abordagem proposta é comparada a outras cinco alternativas de amostragem utilizando métrica RMSE, uma análise por ângulos de Euler que se baseia no *ground-truth* dos conjuntos, daqueles que a possuem, e uma métrica autoral baseada no índice SSIM. Os resultados mostram que, em comparação aos outros métodos estudados, a abordagem proposta alcançou um registro de nuvem com mais fidelidade quantitativa e qualitativa, conseguindo, ainda, ser mais rápida. A técnica proposta é, então, uma etapa de pré-processamento promissora a ser utilizada em conjunto com o algoritmo ICP.

As limitações do trabalho são apresentadas e discutidas no intuito da prospecção de trabalhos futuros. As principais limitações observadas pelos autores são: o número ótimo de sub-nuvens a se utilizar e a obtenção de um registro suficiente. Com relação à primeira problemática, é feita uma discussão da relação de compromisso: tempo de processamento *versus* quantidade de registros. É proposto, então, como trabalho futuro, a obtenção deste valor ótimo do número de nuvens. Vale ressaltar que uma das complexidades inerentes ao problema é o fato da forma geométrica das nuvens de pontos, que é imprevisível de acordo com o problema, ter um papel essencial na obtenção de registros suficientes. Com relação à segunda problemática, são propostos como trabalhos futuros, a obtenção ótima do valor de *threshold* de registro suficiente de acordo com as nuvens de pontos e numa outra perspectiva a análise de possíveis métodos de busca além dos monotônicos, a fim de analisar o tempo de busca do registro suficiente dentre as  $k$  possibilidades.

## REFERÊNCIAS

- ALEJO, D.; COBANO, J. A.; HEREDIA, G. A Reactive Method for Collision Avoidance in Industrial Environments. *Journal of Intelligent and Robotic Systems*, 2016.
- ALEOTTI, J.; RIZZINI, D. L. Perception and Grasping of Object Parts from Active Robots Exploration. *Journal of Intelligent and Robotic Systems*, v. 76, p. 401–425, 2014.
- ASTUDILLO, C. A.; OOMMEN, B. J. Topology-oriented self-organizing maps: a survey. *Pattern Analysis and Applications*, v. 17, p. 223–248, 2014.
- BESL, P. J.; MCKAY, N. D. A Method for Registration of 3-D Shapes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 14, 1992.
- BIBER, P. The Normal Distributions Transform: A New Approach to Laser Scan Matching. *International Conference on Intelligent Robots and Systems*, 2003.
- BOUAZIZ, S.; TAGLIASACCHI, A.; PAULY, M. Sparse Iterative Closest Point. *Eurographics Symposium on Geometry Processing*, v. 32, 2014.
- CHENG, Y.; JIN, Z.; CHEN, H. A fast and robust face recognition approach combining Gabor learned dictionaries and collaborative representation. *International Journal of Machine Learning and Cybernetics*, v. 7, p. 47–52, 2016.
- CHERUBINI, A. Autonomous Visual Navigation and Laser-based Moving Obstacle Avoidance. *IEEE Transactions on Intelligent Transportation Systems*, 2014.
- CRAIG, J. J. *Introduction to Robotics: Mechanics and Control*. 3. ed. Pearson, 2005.
- DAMODARAN, S.; SUDHEER, A. P.; KUMAR, T. K. S. An Evaluation of Spatial Mapping of Indoor Environment Based on Point Cloud Registration Using Kinect Sensor. *International Conference on Control, Communication & Computing*, 2015.
- ELGHAZEL, H.; BENABDESLEM, K. Different Aspects of Clustering The Self-Organizing Maps. *Neural Processing Letters*, v. 39, p. 97–114, 2014.
- GARCÍA-ROIS, J.; BURGUILLO, J. C. Topology-based analysis of self-organizing maps for time series prediction. *Soft Computing*, 2015.
- GELFAND, N.; IKEMOTO, L.; RUSINKIEWICZ, S. Geometrically Stable Sampling for the ICP Algorithm. *Proceedings of the Fourth International Conference on 3-D Digital Imaging and Modeling*, 2003.
- GHAYAB, H. R. A.; LI, Y.; ABDULLA, s. Classification of epileptic EEG signals based

- on simple random sampling and sequential feature selection. *Bran Informatics*, v. 3, p. 85–91, 2016.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento Digital de Imagens*. Pearson, 2010.
- HAYKIN, S. *Redes Neurais: Princípios e prática*. Prentice Hall, 1999.
- HUTCHINSON, S.; LEVEN, P. *Planning collision-free paths using probabilistic roadmaps, in Handbook of Geometric Computing: Applications in Pattern Recognition, Computer Vision, Neural Computing and Robotics*. Springer, 2000.
- INTEL. Embedded Infrared Assisted Stereovision 3D Imaging System with Color Camera. 2016. Product Datasheet.
- KOHONEN, T. The Self-Organizing Map. *IEEE*, v. 78, p. 1464–1480, 1990.
- LO, S.; CHENG, C.; HUANG, H. Virtual Impedance Control for Safe Human-Robot Interaction. *Journal of Intelligent and Robotic Systems*, v. 82, p. 3–19, 2016.
- MAGNUSSON, M.; NUCHTER, A.; LORKEN, C. Evaluation of 3D Registration Reliability and Speed - A Comparison of ICP and NDT. *IEEE International Conference on Robotics and Automation*, 2009.
- MALAMAS, E. N.; PETRAKIS, E. G. M.; ZERVAKIS, M. A survey on industrial vision systems, applications and tools. *Image and Vision Computing*, v. 21, p. 171–188, 2003.
- MANOJ, P. S.; BINGBING, L.; RUI, Y. A Closed-form Estimate of 3D ICP Covariance. *International Conference on Machine Vision Applications*, 2015.
- MOHEBI, E.; BAGIROV, A. Constrained Self Organizing Maps for Data Clusters Visualization. *Neural Processing Letters*, v. 43, p. 849–869, 2016.
- NAZEM, F.; AHMADIAN, A.; SERAJ, N. D. Two-stage point-based registration method between ultrasound and CT imaging of the liver based on ICP and unscented Kalman filter: a phantom study. *International Journal of Computer Assisted Radiology and Surgery*, v. 9, p. 39–48, 2014.
- OGALE, A. S.; FERMULLER, C.; ALOIMONOS, Y. *Detecting Independent 3D Movement, in Handbook of Geometric Computing: Applications in Pattern Recognition, Computer Vision, Neural Computing and Robotics*. Springer, 2000.
- ORIOLO, G. A case study of safe human/robot coexistence, 2015. Disponível em: <<http://www.dis.uniroma1.it/labrob/theses/theses.html>>. Acesso em: 10 junho 2016.
- PHAM, V. H.; LEE, B. R. Front-view Car Detection and Counting with Occlusion in

Dense Traffic Flow. *International Journal of Control, Automation, and Systems*, v. 13(5), p. 1150–1160, 2015.

POMERLEAU, F.; COLAS, F.; SIEGWART, R. Comparing ICP variants on real-world data sets. *Autonomous Robots*, v. 34, p. 133–148, 2013.

RUSU, R. B.; COUSINS, S. 3D is here: Point Cloud Library (PCL). *ICRA Communications*, 2011.

SEGAL, A. V.; HAEHNEL, D.; THRUN, S. Generalized-ICP. *Proceedings of Robotics: Science and Systems*, 2009.

SERAFIN, J.; GRISETTI, G. Using Augmented Measurements to Improve the Convergence of ICP. *Simulation, Modeling, and Programming for Autonomous Robots*, p. 566–577, 2014.

SHAFIE, A. A.; IBRAHIM, A. B. M.; RASHID, M. M. Smart Objects Identification System for Robotic Surveillance. *International Journal of Automation and Computing*, v. 11(1), p. 59–71, 2014.

SHELLSHEAR, E.; BERLIN, R.; CARLSON, J. S. Maximizing Smart Factory Systems by Incrementally Updating Point Clouds. *IEEE Computer Graphics and Applications*, p. 62–69, 2015.

SHIOMI, M.; ZANLUNGO, F.; HAYASHI, K. Towards a Socially Acceptable Collision Avoidance for a Mobile Robot Navigating Among Pedestrians Using a Pedestrian Model. *International Journal of Social Robotics*, v. 6, p. 443–455, 2014.

SMITH, M. L.; SMITH, L. N. Computer vision applications - Special issue. *Image and Vision Computing*, v. 25, p. 1035–1036, 2007.

STANFORD, Stanford University Computer Graphics Laboratory. The Stanford 3D Scanning Repository, 1996. Disponível em: <<http://graphics.stanford.edu/data/3Dscanrep/>>. Acesso em: 2 de fevereiro 2015.

STORK, A. Visual Computing Challenges of Advanced Manufacturing and Industrie 4.0. *IEEE Computer Graphics and Applications*, p. 21–25, 2015.

TANG, T. D.; BOHEZ, E. L. J. A new collision avoidance strategy and its integration with collision detection for five-axis NC machining. *The International Journal of Advanced Manufacturing Technology*, v. 81, p. 1247–1258, 2015.

TORO, Carlos; BARANDIARAN, Iigo; POSADA, Jorge. **Aprendendo a aprender:** introdução à metodologia científica. 19. ed. Petrópolis: Vozes, 2006.

TORSELLO, A.; RODOLÀ, E.; ALBARELLI, A. Sampling Relevant Points for Surface Registration. *International Conference on 3D Imaging, Modeling, Processing, Visualization and Transmission*, 2011.

WANG, G.; GE, S. S. General Flight Rule-based Trajectory Planning for Pairwise Collision Avoidance in a Known Environment. *International Journal of Control, Automation, and Systems*, v. 12(4), p. 813–822, 2014.

WANG, Z.; BOVIK, A. C.; SHEIKH, H. R. Image Quality Assessment: From Error Visibility to Structural Similarity. *IEEE Transactions on Image Processing*, v. 13, p. 600–612, 2004.

WRIGHT, L. J.; NEWSON, S. E.; NOBLE, D. G. The value of a random sampling design for annual monitoring of national populations of larger British terrestrial mammals. *European Journal of Wildlife Research*, v. 60, p. 213–221, 2014.

YANG, J.; LI, H.; CAMPBELL, D. Go-ICP: A Globally Optimal Solution to 3D ICP Point-Set Registration. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015.

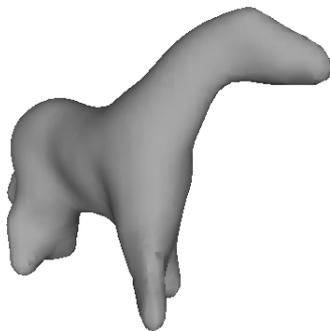
## APÊNDICE A – SUPERFÍCIES GERADAS A PARTIR DOS MODELOS

Para uma melhor visualização dos conjuntos de dados 3D, este apêndice traz a superfície gerada para cada um dos registros aplicados. Estas superfícies são obtidas a partir da técnica de reconstrução de superfície de Poisson. Para os registros do mesmo modelo, foram utilizados os mesmos parâmetros de reconstrução (para critério de comparação).

Ao lado da imagem de cada superfície gerada é apresentado um *QR Code*. Caso o leitor se interesse em visualizar a superfície 3D gerada por completo, é solicitado que faça o download do aplicativo Augment, onde, junto dos *QR Code* apresentados, é possível uma visualização 3D de cada um dos conjuntos apresentado.

Tendo em vista que para cada modelo a reconstrução das superfícies por Poisson foi feita fixando os parâmetros, alguns modelos gerados se apresentaram completamente pretos, onde, entendemos que o programa que gerou a reconstrução não foi capaz de visualizar de maneira adequada a superfície gerada. Solicitamos, então, a utilização do aplicativo de realidade aumentada (Augment) onde a visualização de tais modelos se faz possível.

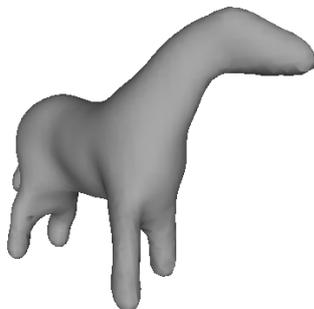
Figura 27 – Modelo *Horse*: ICP



Fonte: Autor.



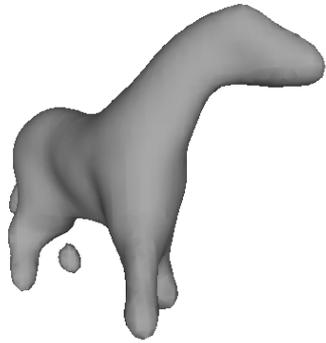
Figura 28 – Modelo *Horse*: CP-ICP



Fonte: Autor.

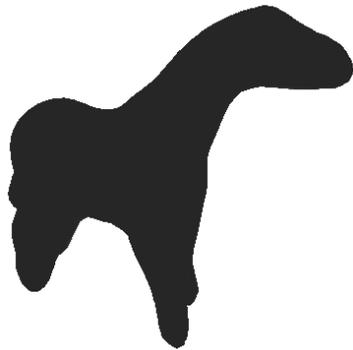


Figura 29 – Modelo *Horse*: Aleatória 50%



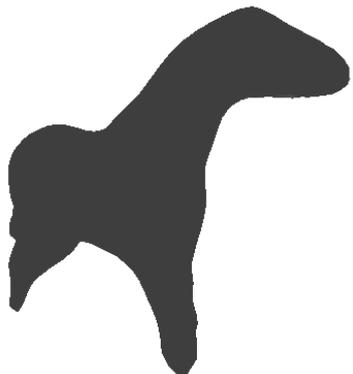
Fonte: Autor.

Figura 30 – Modelo *Horse*: Aleatória 70%



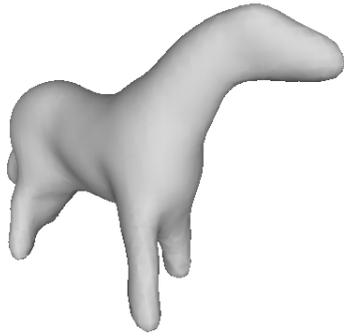
Fonte: Autor.

Figura 31 – Modelo *Horse*: SOM com 125 neurônios



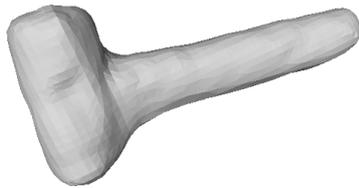
Fonte: Autor.

Figura 32 – Modelo *Horse*: SOM com 512 neurônios



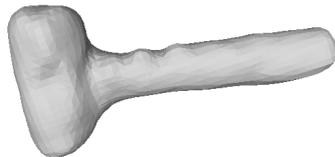
Fonte: Autor.

Figura 33 – Modelo *Hammer*: ICP



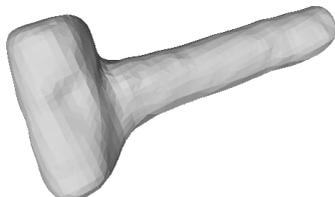
Fonte: Autor.

Figura 34 – Modelo *Hammer*: CP-ICP



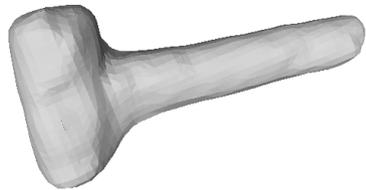
Fonte: Autor.

Figura 35 – Modelo *Hammer*: Aleatória 50%



Fonte: Autor.

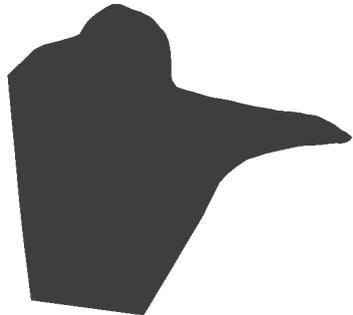
Figura 36 – Modelo *Hammer*: Aleatória 70%



Fonte: Autor.



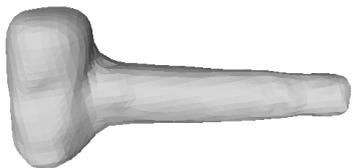
Figura 37 – Modelo *Hammer*: SOM com 125 neurônios



Fonte: Autor.



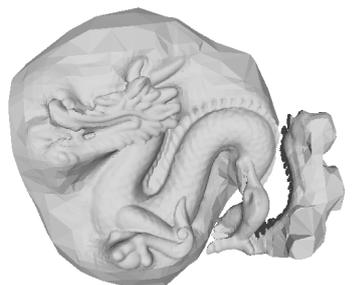
Figura 38 – Modelo *Hammer*: SOM com 512 neurônios



Fonte: Autor.



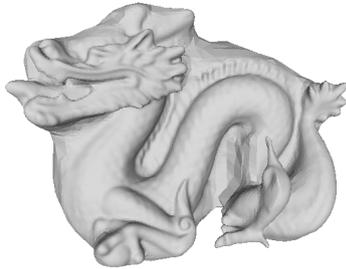
Figura 39 – Modelo *Dragon*: ICP



Fonte: Autor.



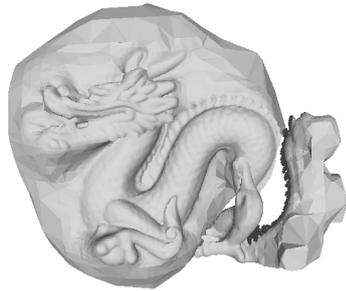
Figura 40 – Modelo *Dragon*: CP-ICP



Fonte: Autor.



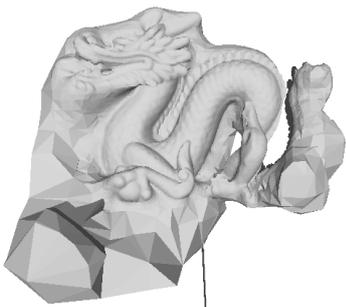
Figura 41 – Modelo *Dragon*: Aleatória 50%



Fonte: Autor.



Figura 42 – Modelo *Dragon*: Aleatória 70%



Fonte: Autor.



Figura 43 – Modelo *Buddha*: ICP



Fonte: Autor.



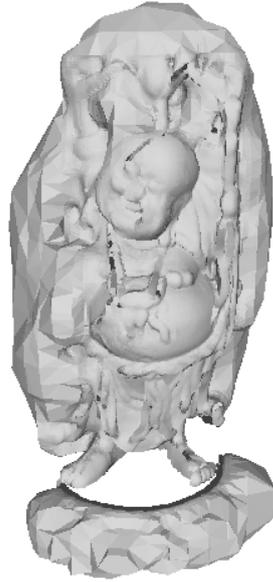
Figura 44 – Modelo *Buddha*: CP-ICP



Fonte: Autor.

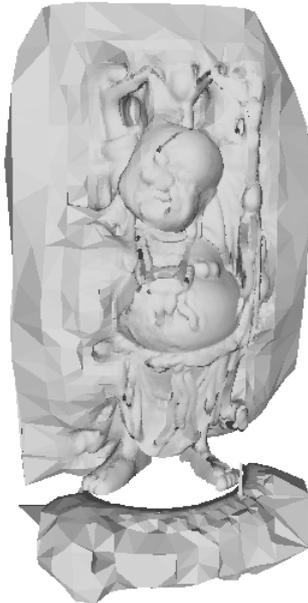


Figura 45 – Modelo *Buddha*: Aleatória 50%



Fonte: Autor.

Figura 46 – Modelo *Buddha*: Aleatória 70%



Fonte: Autor.