

UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**REGISTRO DE IMAGENS TRIDIMENSIONAIS
DAS VIAS AÉREAS SUPERIORES PARA
GERAÇÃO DE MODELOS PARA PACIENTES
ESPECÍFICOS**

Belo Horizonte
01 de julho de 2009

UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**REGISTRO DE IMAGENS TRIDIMENSIONAIS
DAS VIAS AÉREAS SUPERIORES PARA
GERAÇÃO DE MODELOS PARA PACIENTES
ESPECÍFICOS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais como requisito parcial para a obtenção do grau de Mestre em Engenharia Elétrica.

BRUNO DO NASCIMENTO TEIXEIRA
ORIENTADOR: HANI CAMILLE YEHA

Belo Horizonte
01 de julho de 2009

Agradecimentos

Agradeço ao Professor Hani Yehia, meu orientador, pelos ensinamentos, pela paciência e, principalmente, pela confiança depositada em mim.

Agradeço também ao Prof. Sid Fels pela supervisão durante o período na UBC, pelo apoio e pelas idéias geniais que tanto me inspiraram e ao Prof. Eric Vatikiotis-Bateson pelo exemplo de dedicação.

Gostaria de agradecer aos meus colegas do CEFALA, Damares, Leonardo Almeida, Ana Claudia, Izabela, José Eduardo, João Pedro, principalmente ao Adriano, pela amizade e ajuda e aos colegas do OPAL, Tricia Pang e Professora Fernanda Almeida.

Gostaria também de agradecer à CAPES, que acreditou neste trabalho e o financiou.

Por último, gostaria de agradecer aos meus pais e à Juliana, pelo apoio, pela compreensão e pela paciência.

Resumo

Em aplicações médicas, o registro é necessário na fusão de imagens a fim de aumentar a resolução de estruturas volumétricas para facilitar a segmentação de regiões de interesse. Este trabalho aborda técnicas de registro tridimensionais usadas para o alinhamento de imagens médicas para modelagem paciente específica.

O projeto OPAL, do qual este trabalho faz parte, consiste na modelagem dinâmica do complexo oral, faringeal e laringeal para aplicações biomédicas. Parte da investigação do OPAL é o estudo da apnéia do sono obstrutiva através de simulação biomecânica 3D. A etapa de modelagem paciente específica pode ser dividida em quatro sub-etapas: aquisição, registro, segmentação e *morphing*.

O aumento da resolução volumétrica nas imagens de ressonância é resultante da combinação de imagens com direções de fatiamento e resoluções diferentes. Para combinar essas imagens, o registro monomodal é responsável por calcular a transformação que alinha as imagens. No registro multimodal foram alinhadas imagens de tomografia computadorizada com imagens de ressonância magnética para a combinação de informações diferentes. As imagens de ressonância magnética contêm informações de tecidos como músculos e as imagens de tomografia computadorizada informações do molde da arcada dentária. A informação contida nas imagens de tomografia computadorizada combinada com a informação da ressonância magnética facilita a segmentação de estruturas, principalmente a língua dos pacientes, adicionando nas imagens informações de contorno de regiões.

Um método baseado em intensidade é aplicado para calcular a transformação de corpo rígido para o alinhamento de imagens de ressonância magnética com diferentes direções de corte e resolução. Esse método basea-se na maximização da informação mútua entre as imagens. A melhoraria da segmentação da língua e do palato exige o registro da imagem do molde da arcada dentária com as imagens das vias aéreas superiores, por meio de técnicas de registro baseadas em ponto para imagens multimodais, como o método dos mínimos quadrados (LS - *Least Squares*), dos pontos mais próximos iterativos (ICP - *Iterative closest point*) e análise em componentes principais (PCA - *Principal Component Analysis*). A validação é feita por inspeção visual utilizando a imagem xadrez e pelo histograma de distâncias entre pontos correspondentes.

Abstract

In medical applications, image registration is needed each time two images are being fused in order to increase the resolution of volumetric structures and to facilitate boundaries finding. This work discusses techniques used to register medical images.

This work is part of OPAL project. OPAL is a project for dynamic modeling of the oral, pharyngeal, and laryngeal complex for biomedical applications. Part of the research plan for OPAL is to investigate obstructive sleep apnea, a medical condition that causes excessive daytime sleepiness, using Artisynt, a 3D biomechanical modeling toolkit. Patient specific modeling can be divided into four tasks: acquisition, registration, segmentation and morphing. The registration consists in finding the correspondence between two coordinates systems by computing the best rigid body transformation.

The volume resolution increasing in MRI images is resulting from the combination of images with directions and slicing different resolutions. To combine these images, monomodal registration techniques are applied to calculate the transformation that aligns the images from the same modality. On the other hand, multimodal registration techniques based on segmentation align images with different information to enhance the tongue contours. In multimodal image registration, CT scans were aligned with MRI scans to combine soft and hard tissues information. The MRI scans contain information about soft tissues such as muscles and CT scans contain about information of the dental cast or dense tissues.

A voxel intensity based method is used to determine the rigid-body transformation which aligns MRI scans with different slicing directions by maximization of mutual information. It increases the resolution of the volumetric structure by merging aligned scans. Improving tongue and palate segmentation requires dental cast scan alignment with upper airway merged scans by applying point based techniques for multimodality registration, such as least squares (LS - Least Squares), iterative closest points (ICP - Iterative closest point) and principal components analysis (PCA - Principal Component Analysis). The evaluation is carried out by visual inspection through checkerboard images and distance histograms.

Sumário

1	Introdução	1
1.1	Motivação	3
1.2	Definição do Problema	4
1.3	Objetivos	6
1.4	Trabalhos anteriores	6
1.5	Organização da Dissertação	8
2	Fundamentos Teóricos Gerais e Específicos	9
2.1	Introdução	9
2.2	Teoria da informação, Variáveis Aleatórias, Entropia e Informação Mútua	10
2.3	Transformação de Corpo Rígido	13
2.3.1	Notação Matricial	14
2.3.2	Quatérnio unitário	17
2.4	Análise em Componentes Principais	19
2.5	Mínimos Quadrados	21
2.6	Interpolação de imagens	21
2.6.1	Vizinho mais próximo	22
2.6.2	Linear	22
2.6.3	BSpline	22
2.7	Registro por Análise em Componentes Principais	25
2.8	Registro por Mínimos quadrados (forma fechada)	28
2.9	Ponto mais próximo iterativo - ICP	30
2.10	Métodos baseados na intensidade do voxel	35
2.11	Conclusão	37
3	Resultados	38
3.1	Introdução	38
3.2	Base de dados	39
3.3	Registro CT-MRI	40
3.3.1	Métodos baseados em superfícies	41

3.3.2	Método baseado em pontos	48
3.4	Registro MRI-MRI	54
4	Discussão dos Resultados	64
4.1	Registro CT-MRI	64
4.2	Registro MRI-MRI	66
5	Conclusão	67
	Referências Bibliográficas	69

Lista de Figuras

1.1	ArtiSynth: Modelo da língua para simulação biomecânica.	3
1.2	Realce das bordas da língua em uma determinada região através do alinhamento do molde da arcada dentária.	4
1.3	(a) Línguas segmentadas de imagens de ressonância magnética. (b) Línguas segmentadas de combinação de imagens de ressonância magnética após o registro de imagens.	5
2.1	Informação mútua calculada através de imagens bidimensionais transladas ao longo do eixos x e y	13
2.2	Translação ao longo dos eixos x , y e z	15
2.3	rotação de 1,57 rad em torno dos eixos x , y e z	15
2.4	Fatores de escala 0,5, 1,5 e 2,0.	16
2.5	Alinhamento de modelos tridimensionais com formas iguais.	20
2.6	Alinhamento de modelos tridimensionais com formas diferentes.	20
2.7	(a) Kernel de interpolação por vizinho mais próximo. (b) Magnitude da transformada de Fourier. (c) Magnitude em dB.	23
2.8	(a) Kernel de interpolação linear. (b) Magnitude da transformada de Fourier. (c) Magnitude em dB.	24
2.9	(a) Kernel de interpolação BSpline. (b) Magnitude da transformada de Fourier. (c) Magnitude em dB.	26
2.10	(a) Os pontos vermelhos representam os nós da malha dos marcadores MRI e os verdes os nós do marcadores CT.(b) \mathbf{M}_p e \mathbf{P}_p (MRI e CT respectivamente) após a transformação inicial.	31
2.11	(a) Os pontos vermelhos representam os nós da malha dos marcadores MRI e os verdes os nós do marcadores CT após a transformação inicial.(b) Os pontos amarelos são os nós dos marcadores CT mais próximos dos nós dos marcadores MRI. Esses pontos são calculados através do operador de proximidade \mathbf{C} . Os números indicam os pares de pontos mais próximos de \mathbf{M}_p e \mathbf{P}_p (MRI e CT respectivamente).	31
2.12	Busca dos vizinhos mais próximos.	33

3.1	Molde da arcada dentária com o aparelho oral para posicionamento da mandíbula (paciente normal). (a) Vista Sagittal, (b) Vista Coronal, (c) Vista Axial.	41
3.2	Molde da arcada dentária com o aparelho oral para posicionamento de relaxamento da mandíbula (paciente normal). (a) Vista Sagittal, (b) Vista Coronal, (c) Vista Axial.	42
3.3	Molde da arcada dentária com o aparelho oral para posicionamento de relaxamento da mandíbula (paciente normal). (a) Vista Sagittal, (b) Vista Coronal, (c) Vista Axial.	42
3.4	Registro CT-MRI:(a) Vista Sagittal;(b) Vista Coronal; (c) Vista Axial. . .	42
3.5	(a) Superfícies dos fiduciais extraídas da imagem CT (usando a segmentação do Amira). (b) Superfícies dos fiduciais extraídas de uma imagem MRI. (c) Modelo 3D dos fiduciais.	43
3.6	Região com distorção causada pela interação entre o campo magnético e artefatos de metais (obturações).	45
3.7	Alinhamento de fiduciais segmentados de 4 imagens MRI diferentes (paciente com sobrepeso) por registro baseado em PCA.	45
3.8	(a) Histogramas de distâncias para o alinhamento usando PCA para o alinhamento de imagens de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar). (b) Histograma de distâncias para o alinhamento usando PCA para o alinhamento de imagens de um paciente com peso normal com posição de relaxamento da mandíbula. (c) Histograma de distâncias para o alinhamento usando PCA para o alinhamento de imagens adquiridas de um paciente com sobrepeso com posição de relaxamento do mandíbula.	46
3.9	Alinhamento de fiduciais segmentados de 4 imagens MRI diferentes por registro baseado em ICP.	48
3.10	(a) Histograma de distâncias para o alinhamento usando ICP para o alinhamento de imagens de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar). (b) Histograma de distâncias para o alinhamento usando ICP para o alinhamento de imagens de um paciente com peso normal com posição de relaxamento da mandíbula. (c) Histograma de distâncias para o alinhamento usando ICP para o alinhamento de imagens adquiridas de um paciente com sobrepeso com posição de relaxamento do mandíbula.	49
3.11	Alinhamento de fiduciais segmentados de 4 imagens MRI diferentes por registro baseado em LS.	51

3.12	(a) Histograma de distâncias para o alinhamento por LS de imagens multimodais de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar). (b) Histograma de distâncias para o alinhamento de imagens de um paciente normal com posição de relaxamento da mandíbula por LS. (c) Histograma de distâncias para o alinhamento de um paciente com sobrepeso com posição de relaxamento da mandíbula por LS.	52
3.13	Imagem xadrez para a visualização do alinhamento CT-MRI. Essa imagem mostra o preenchimento de regiões da imagem de ressonância magnética com informação de tecidos densos da imagem de tomografia computadorizada do molde da arcada dentária. Nota-se também o preenchimento dos dentes na região. Como as imagens apresentam informações diferentes, técnicas automática de registro como maximização da informação mútua ou outras que operam diretamente na valor de intensidade do voxel, apresentam baixa performance, pois a região de sobreposição, no caso apenas os fiduciais, é limitada. Essas regiões comuns requerem a identificação para o cálculo de T	53
3.14	Registro de corpo rígido de 3 imagens MRI (paciente com peso normal):(a) Vista Sagital; (b) Vista Coronal; (c) Vista Axial.	54
3.15	Registro de corpo rígido de 3 imagens MRI (paciente com sobrepeso):(a) Vista Sagital; (b) Vista Coronal; (c) Vista Axial.	55
3.16	Registro MRI-MRI. (a) Histograma de distâncias para o alinhamento usando PCA para o alinhamento de imagens de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar) . (b) Registro MRI - MRI - Histograma de distâncias para o alinhamento usando PCA para o alinhamento de imagens de um paciente com peso normal com posição de relaxamento da mandíbula. (c) Registro MRI - MRI - Histograma de distâncias para o alinhamento usando PCA para o alinhamento de imagens de um paciente com sobrepeso com posição de relaxamento da mandíbula.	56
3.17	Alinhamento de fiduciais segmentados de 4 imagens MRI diferentes por registro baseado em PCA.	57

3.18	Registro MRI-MRI. (a) Histograma de distâncias para o alinhamento de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar) por ICP. (b) Histograma de distâncias para o alinhamento de um paciente com peso normal com posição de relaxamento da mandíbula por ICP. (c) Histograma de distâncias para o alinhamento de um paciente com sobrepeso com posição de relaxamento da mandíbula por ICP.	58
3.19	Registro MRI-MRI. (a) Histograma de distâncias para o alinhamento por LS de imagens multimodais de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar). (b) Histograma de distâncias para o alinhamento de imagens de um paciente normal com posição de relaxamento da mandíbula por LS. (c) Histograma de distâncias para o alinhamento de um paciente com sobrepeso com posição de relaxamento da mandíbula por LS.	59
3.20	(Alinhamento de fiduciais segmentados de 4 imagens MRI diferentes por registro baseado em LS.	60
3.21	Kernels de interpolação e convergência do registro por MI. A linha contínua corresponde ao kernel Bspline, a linha pontilhada vermelha ao kernel linear e a linha azul ao kernel do vizinho mais próximo. O eixo x corresponde ao número de iterações e o eixo y ao valor da MI.	61
3.22	Registro MRI-MRI. (a) Histograma de distâncias para o alinhamento de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar) por MI. (b) Histograma de distâncias para o alinhamento de um paciente com peso normal com posição de relaxamento da mandíbula por MI. (c) Histograma de distâncias para o alinhamento de um paciente com sobrepeso com posição de relaxamento da mandíbula por MI.	62
3.23	Imagem xadrez para a visualização do alinhamento MRI-MRI. As quatro primeiras imagens representam a vista sagital e as duas últimas a vista coronal. Diferente da Figura 3.13, essa imagem xadrez é composta por duas imagens de ressonância magnética, logo todos os quadrados estão preenchidos com informação. Nota-se que em regiões fixas as bordas são contínuas. Em regiões móveis, essas bordas apresentam uma descontinuidade. A fusão dessas imagens aumentam a resolução volumétrica, aumentando a qualidade da segmentação de modelos tridimensionais.	63
4.1	Registro CT-MRI: Histograma de todas as realizações de alinhamento de M e P usando os métodos baseado em pontos e superfícies.	65

4.2	Registro MRI-MRI: Histograma de todas as realizações de alinhamento de M e P usando os métodos baseado em pontos, superfícies e intensidade do voxel.	66
-----	---	----

Lista de Tabelas

2.1	Modelos de transformações	13
3.1	Imagens MRI - Paciente normal com a mandíbula alinhada com maxilar .	39
3.2	Imagens MRI - Paciente normal com aparelho oral (relaxamento)	40
3.3	Imagens MRI - Paciente com sobrepeso com aparelho oral (relaxamento) .	40
3.4	Imagens MRI - Referência para o alinhamento MRI-MRI.	55

Abreviações

LS	<i>Least Squares</i> - Mínimos quadrados.
ICP	<i>Iterative closest point</i> - Ponto mais próximo iterativo.
RICP	<i>Robust iterative closest point</i> - Ponto mais próximo iterativo robusto.
ITK	<i>Insight Software Toolkit</i> .
MRI	<i>Magnetic Resonance Imaging</i> - Ressonância magnética.
CT	<i>Computed Tomography</i> - Tomografia computadorizada.
PCA	<i>Principal Analysis Component</i> - Análise em componentes principais.
MI	<i>Mutual Information</i> - Informação mútua.
SVD	<i>Single Value Decomposition</i> - Decomposição em valores singulares.
V.A	Variável aleatória.

Lista de Símbolos

T	Transformação 3D.
t	Vetor de translação.
R	Matriz de rotação.
M	Imagem referência.
P	Imagem móvel.
V	Matriz unitária (SVD).
D	Matriz diagonal com os valores singulares (SVD).
U	Matriz unitária (SVD).
C	Matriz de covariância.
u	Intensidade do voxel.
μ	Parâmetros de transformação.
Q	Medida de similaridade.
E	Valor esperado.
C	Operador de proximidade.
\mathbf{M}_p	Conjunto referência.
\mathbf{P}_p	Conjunto móvel.
O	Matriz de permutação.
d	Distância euclidiana.
e	Erro médio quadrático.
s	Vetor de resíduos.
σ	Desvio padrão.
$I(\mathbf{M}; \mathbf{P})$	Informação mútua.
$H(\mathbf{M})$	Entropia.
$H(\mathbf{M}, \mathbf{P})$	Entropia conjunta.
f	Densidade de probabilidade.
η	A variância (tamanho da janela).
λ	Taxa de aprendizagem.
α_x	O ângulo de rotação em eixo x .
α_y	O ângulo de rotação em eixo y .
α_z	O ângulo de rotação em eixo z .
\mathbf{t}_x	Tranlação no eixo x .
\mathbf{t}_y	Tranlação no eixo y .
\mathbf{t}_z	Tranlação no eixo z .
\mathbf{R}_x	Matriz de rotação x .
\mathbf{R}_y	Matriz de rotação y .

\mathbf{R}_z	Matriz de rotação z .
$H(X Y)$	Entropia condicional.
U_s	Imagem discreta.
$U(x, y, z)$	Intensidade.
$K(x, y, z)$	Kernel de interpolação.
$K(x)$	Kernel de interpolação x .
$K(y)$	Kernel de interpolação y .
$K(z)$	Kernel de interpolação Z .
q	Quatérnio unitário.
Λ	Matriz ortonormal (PCA).

“Pure and complete sorrow is as impossible as pure and complete joy.”

Leo Nikolaevich Tolstoi

Capítulo 1

Introdução

Recentemente, os avanços de técnicas de processamento de imagens tais como segmentação e registro têm facilitado a extração de estruturas anatômicas complexas em imagens médicas. Essas estruturas segmentadas geram modelos tridimensionais, os quais são usados na simulação biomecânica para o estudo de tratamento e intervenção cirúrgica. A simulação biomecânica, utilizada antes de métodos cirúrgicos e tratamentos não-invasivos, reduz o stress físico aplicado ao paciente e o custo do tratamento.

A construção de modelos tridimensionais através de imagens volumétricas de pacientes específicos pode ser dividida em 4 sub-etapas: aquisição de imagens, registro, segmentação e *morphing*. Na etapa de aquisição deste trabalho, foram adquiridas imagens do trato vocal de dois pacientes diferentes: um com peso normal e outro com sobrepeso com posições de mandíbula diferentes (mantidas pelo uso de aparelho oral para tratamento da apnéia do sono). Após a etapa de aquisição, essas imagens foram registradas para realçar as bordas e aumentar a resolução volumétrica através da combinação de imagens. A etapa de fusão ou combinação de imagens está inserida na etapa de registro de imagens, que é o processo de sobreposição de imagens através de transformações. A etapa de segmentação extrai regiões e gera a malha tridimensional de estruturas anatômicas a partir das imagens registradas. A malha representa uma estrutura segmentada, a qual tem sua geometria modificada através de um atlas na etapa de *morphing*.

A apnéia do sono é um exemplo de estudo de planejamento de intervenção através de imagens adquiridas do paciente onde situações de tratamentos diferentes são simuladas através de modelos extraídos das vias aéreas superiores. A apnéia do sono pode ser causada pela obstrução da faringe provocada pela língua. Uma forma de tratamento é o uso de um aparelho oral, responsável por desobstruir a via aérea através do posicionamento da mandíbula.

Esta dissertação apresenta um trabalho dirigido ao estudo de técnicas de registro

de imagens utilizando imagens de modalidades diferentes, especificamente a tomografia computadorizada e ressonância magnética.

Para gerar os modelos usados na simulação de tratamento da apnéia do sono obstrutiva, utilizaram-se imagens de ressonância magnética (MRI - *Ressonance Magnetic Imaging*) para a extração de modelos 3D através de segmentação da língua, do trato vocal e do palato mole. A imagem de ressonância magnética apresenta informações de tecido mole, resultantes da interação do campo magnético com estruturas que contêm água (músculos). A tomografia computadorizada (CT - *Computed Tomography*) contém informação de tecidos densos, como ossos. Assim, a fusão de imagens com diferentes informações e resoluções diferentes é importante na etapa de segmentação, na qual informação de bordas deve estar visível para que o usuário seja capaz de extrair os contornos das estruturas. Para cada configuração de posicionamento de mandíbula tem-se imagens MRI com direção de fatiamento e resoluções diferentes e uma imagem CT para a representação da arcada dentária. A imagem CT foi adquirida utilizando um molde, evitando a exposição do paciente a raios X.

Para o registro de imagens monomodais, foram implementadas técnicas de registro baseadas na intensidade do voxel (elemento de volume representando um valor em um grid 3D), em pontos e superfícies. O registro baseado na intensidade do voxel baseia-se na maximização da informação mútua entre imagens para o alinhamento, as quais apresentam grandes regiões em comum. Métodos que operam diretamente no valor dos voxels são recomendados para casos de grande sobreposição de regiões. Por outro lado, para o registro de imagens de modalidades diferentes (registro CT-MRI) são necessárias técnicas baseadas em marcas externas, já que as imagens não apresentam regiões de sobreposição. Um problema muito comum em registro de imagens de modalidades diferentes é o fato de que as marcas devem estar visíveis nas duas modalidades, o que não é trivial. Para contornar esse problema, foram usados marcadores de óleo, os quais são visíveis tanto nas imagens obtidas através de MRI, quanto de CT.

Este trabalho é parte do projeto OPAL (*Oral, Pharyngeal and Laryngeal*). OPAL consiste na modelagem dinâmica do complexo oral, faringeal e laringeal para aplicações biomédicas. Parte da investigação do OPAL é o estudo da apnéia do sono obstrutiva através de simulação biomecânica 3D usando o *Artisynth toolkit*, o qual é um sistema de simulação biomecânica de estruturas anatômicas complexas como a língua e o modelo da vias areas superiores. A Figura 1.1 mostra, como exemplo, um modelo muscular de ativação da língua. Este modelo biomecânico foi construído com base na ativação de músculos e, juntamente com o OPAL, está sendo usado para o estudo de desordens como a apnéia do sono (Vogt et al., 2007; Fels et al., 2006; Stavness et al., 2006).

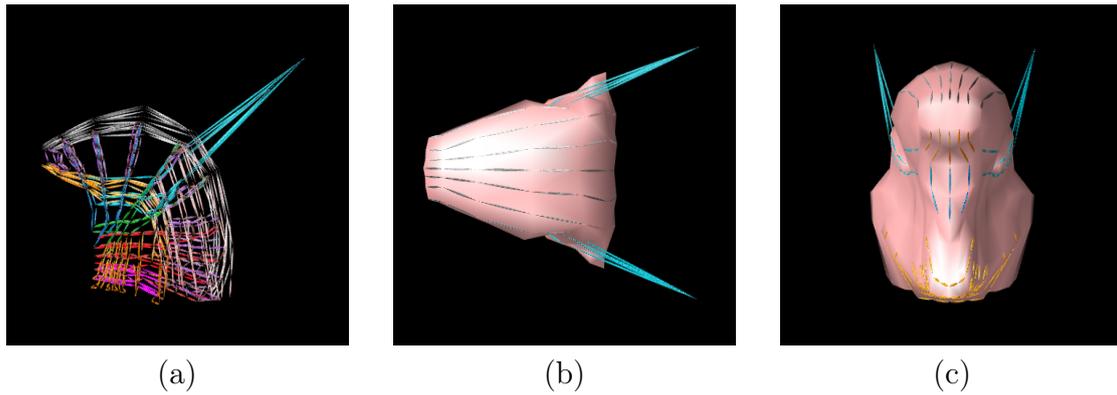


Figura 1.1: ArtiSynth: Modelo da língua para simulação biomecânica.

1.1 Motivação

As imagens de ressonância magnética são as imagens que provêm informação mais detalhada de tecidos moles entre as modalidades de imagens médicas. A ressonância magnética baseia-se na interação entre um campo magnético e spin de elétrons (Liang e Lauterbur, 2000). O hidrogênio isotrópico é usado nessa modalidade como prova por ser muito sensível ao campo magnético, realçando os tecidos constituídos por água e gordura, as quais contêm hidrogênio em suas estruturas.

Por outro lado, as imagens de tomografia computadorizada contêm informação de tecidos densos tais como ossos, nos quais a absorção de raios X é elevada.

Para a reconstrução de estruturas anatômicas para a simulação biomecânica 3D, a fusão de imagens, seja da mesma modalidade ou de modalidades diferentes, agrega informações que facilitam a segmentação de estruturas. Dois fatores muito importantes na segmentação de imagens são a resolução das imagens e a definição das bordas, que determinam os contornos das estruturas anatômicas. Como exemplo, a Figura 1.2 mostra o alinhamento entre modelos tridimensionais extraídos de imagens de tomografia computadorizada e de imagens de ressonância magnética. A língua é segmentada utilizando as imagens de MRI por ter informações de tecido mole (principalmente músculos). O registro da imagem CT no espaço de MRI realça os contornos da língua, o que facilita a segmentação guiada. A fusão de imagens requer o alinhamento das imagens. O registro de imagens calcula a transformação necessária para esse alinhamento com base em pontos ou regiões comuns entre as imagens. Na Figura 1.3, observa-se a estrutura anatômica da língua obtida com base apenas em imagens de MRI (a) e com base na combinação de imagens de MRI e de CT (b), onde é nítido o ganho de qualidade da segmentação.

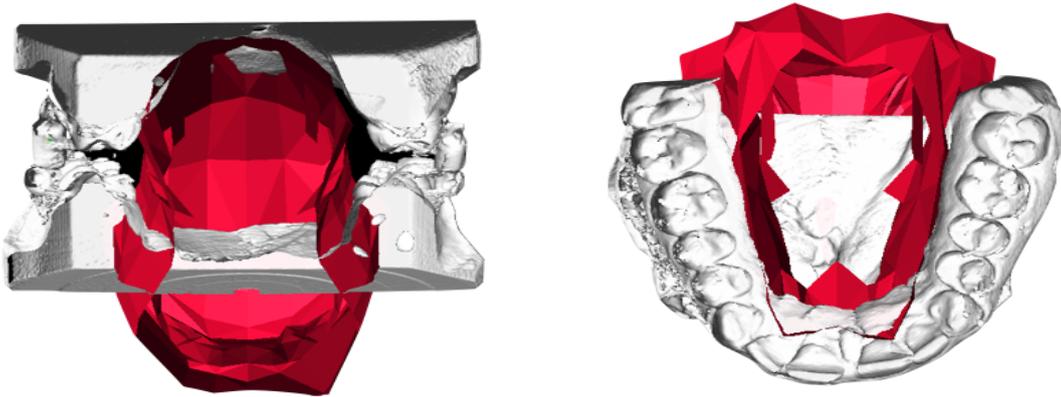


Figura 1.2: Realce das bordas da língua em uma determinada região através do alinhamento do molde da arcada dentária.

1.2 Definição do Problema

O registro de corpos rígidos determina a transformação rígida parametrizada pelo vetor ϖ , o qual contém três ângulos de rotação e três translações. Dessa forma, defini-se o vetor ϖ compreendendo seis parâmetros de transformação como $\varpi = [r_x, r_y, r_z, \mathbf{t}_x, \mathbf{t}_y, \mathbf{t}_z]$, onde r_x, r_y e r_z são os ângulos de rotação em torno dos eixos perpendiculares x, y e z e $\mathbf{t}_x, \mathbf{t}_y$, e \mathbf{t}_z são as translações ao longo desses eixos.

\mathbf{M} é definido como elemento de registro referência e \mathbf{P} como elemento móvel. O processo de registro calcula a transformação de corpo rígido \mathbf{T} , que mapeia os elementos de \mathbf{P} em \mathbf{M} . Seja \mathbf{M} uma imagem tridimensional, defini-se $u_{\mathbf{M}}$ a intensidade do voxel (elemento de volume), onde $u_{\mathbf{M}} \in \mathbb{R}$ e $L_{\mathbf{M}}$ onde $L_{\mathbf{M}} \in \mathbb{R}^3$ o grid tridimensional representando as coordenadas do voxel $u_{\mathbf{M}}$. A intensidade do voxel na posição do grid $L_{\mathbf{M}}$ é dado por $u_{\mathbf{M}}(X)$, onde $X \in \mathbb{R}^3$ e $X \subset L_{\mathbf{M}}$. Para imagens segmentadas, têm-se o grid segmentado $L_{\mathbf{M}_s}$, $L_{\mathbf{M}_s} \subset L_{\mathbf{M}}$ e o voxel $u_{\mathbf{M}}(X_s) = 1$, onde $X_s \in \mathbb{R}^3$ e $X_s \subset L_{\mathbf{M}_s}$. Extraindo a superfície através de $L_{\mathbf{M}_s}$, tem-se o conjunto de pontos \mathbf{M}_p , $\mathbf{M}_p \in \mathbb{R}^3$.

A métrica pode ser definida por $Q(\mathbf{M}(X), \mathbf{P}(X))$, onde $Q(\mathbf{M}(X), \mathbf{P}(X)) \in \mathbb{R}$, estando relacionada com a transformação $\mathbf{T}(\varpi, X)$. Assim, obtém-se a métrica de uma imagem referência e de uma imagem transformada $\mathbf{P}(\mathbf{T}(\varpi, X))$ dada por $Q(\mathbf{M}(X), \mathbf{P}(\mathbf{T}(\varpi, X)))$.

O problema de registro de imagens é minimizar $Q(\mathbf{M}(X), \mathbf{P}(\mathbf{T}(\varpi, X)))$, através de

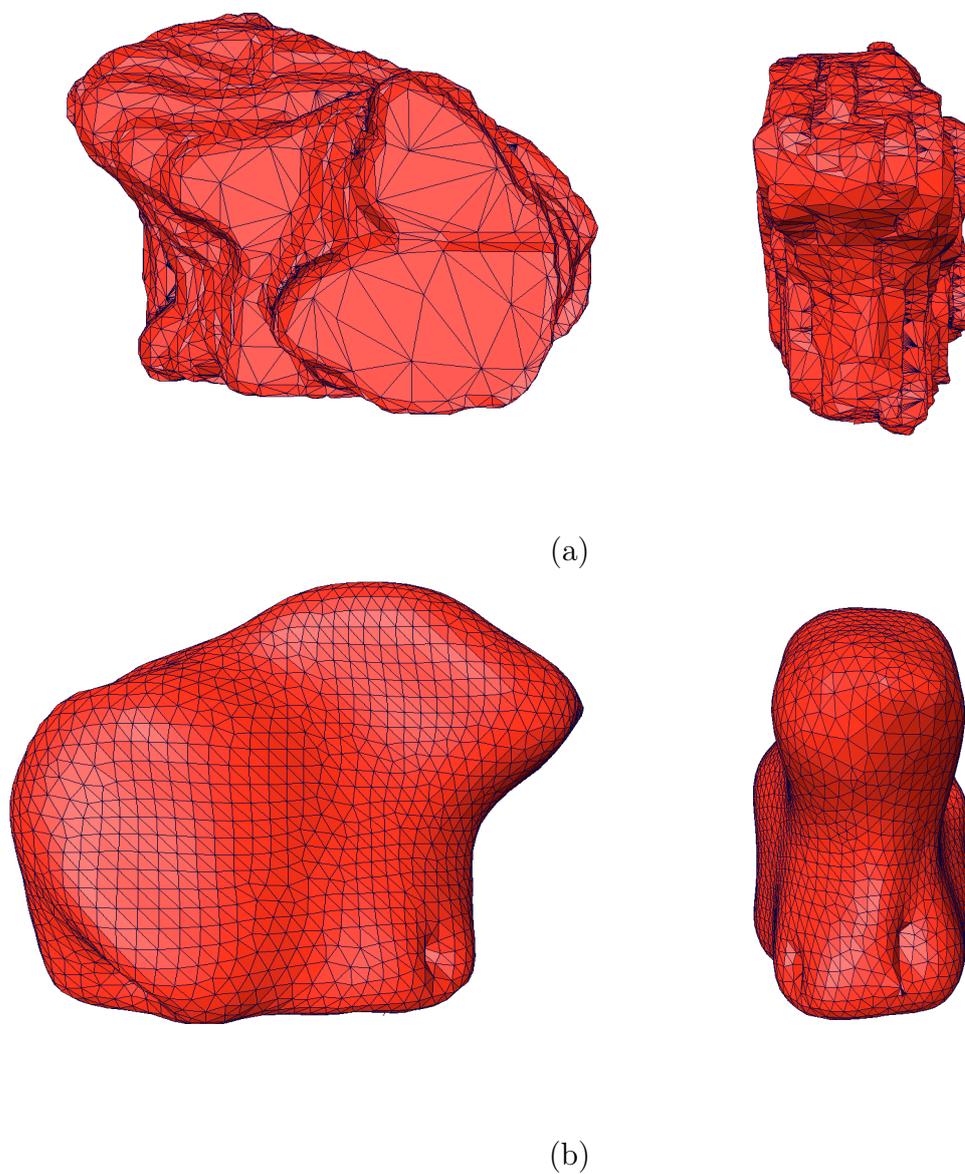


Figura 1.3: (a) Línguas segmentadas de imagens de ressonância magnética. (b) Línguas segmentadas de combinação de imagens de ressonância magnética após o registro de imagens.

ϖ :

$$\varpi = \operatorname{argmax}(Q(\mathbf{M}(X), \mathbf{P}(\mathbf{T}(\varpi, X)))). \quad (1.1)$$

A Equação (1.1) pode ser rescrita a seguir como:

$$\mathbf{T} = \operatorname{argmax}(Q(\mathbf{M}(X), \mathbf{P}(\mathbf{T}(X)))). \quad (1.2)$$

1.3 Objetivos

Essa dissertação tem por objetivo o estudo e a comparação de técnicas de registro de imagens tridimensionais através de transformações de corpo rígido. As técnicas de registro abrangem o problema de sobreposição e ausência de informação entre imagens monomodais e multimodais. Esse problema é solucionado através da escolha do elemento de registro, da métrica, do otimizador e do tipo de transformação. Este trabalho restringe-se a transformações de corpo rígido, mas testa diferentes elementos de registro (ponto e intensidade de voxel), métricas (distância euclidiana e informação mútua) e otimizadores (mínimos quadrados e gradiente descendente.)

1.4 Trabalhos anteriores

Nessa seção são introduzidos alguns métodos de registro baseados em segmentação e na intensidade do voxel. Entende-se como voxel a unidade volumétrica do volume de interesse. Os métodos baseados em segmentação são usados para o registro CT-MRI e MRI-MRI, enquanto que os métodos baseados em intensidade do voxel são usados apenas para o registro MRI-MRI.

Os métodos baseados em segmentação requerem a extração de estruturas de baixa complexidade, por exemplo, conjuntos de pontos ou estruturas como os vértices de uma superfície. Quando tais estruturas são marcadores externos de geometria simples, utiliza-se para elas o nome de *fiduciais*. Os métodos de registro de imagens multimodais podem ser classificados como métodos baseados em marcas externas (van den Elsen et al., 1993), já que as estruturas segmentadas das imagens são fiduciais colocados no paciente antes da etapa de aquisição das imagens.

Esses métodos reduzem o conteúdo da informação da imagem a pontos tridimensionais. Assim, a etapa de segmentação transforma as imagens em dois conjuntos de pontos: o conjunto referência \mathbf{M}_p e o conjunto móvel \mathbf{P}_p . A segmentação dessas estruturas pode interferir no resultado do alinhamento, sendo uma tarefa que consome

tempo. Neste trabalho, considerou-se a identificação de pontos como uma segmentação de baixa complexidade.

Horn et al. (1988) descrevem uma fórmula fechada para o problema de mínimos quadrados (LS) usando conjuntos com correspondência e alinhando esses conjuntos através de transformações. Entende-se correspondência entre conjuntos de pontos, a ordenação das linhas das matrizes que contêm as coordenadas de forma que o ponto de um conjunto corresponde ao mesmo ponto de outro conjunto, ou seja, eles são o mesmo ponto mas possuem as coordenadas transformadas por \mathbf{T} . Neste caso a segmentação corresponde a identificar pontos nas imagens.

Em conjuntos grandes de pontos, como vértices de superfícies extraídas de imagens, manter a correspondência entre os pontos é uma tarefa difícil, além de serem desbalanceados, pois apresentam formas e números de pontos diferentes. Essa condição é muitas vezes resultante da diferença de resolução das imagens. Neste caso é necessário calcular a correspondência entre os conjuntos através da busca do vizinho mais próximo. Besl e McKay (1992) propuseram o algoritmo de ponto mais próximo iterativo (ICP - *Robust iterative closest point*) para o registro tridimensional de conjuntos de pontos. Esse algoritmo também é descrito em Wang et al. (1996).

Zinßer et al. (2003) propôs uma extensão do ICP, o *Picky ICP*. Essa extensão usa seleção hierárquica de pontos e árvores K-d para a busca do vizinho mais próximo. Para taxas elevadas de *outliers*, pontos sem correspondência, Trucco et al. (1999) propuseram o ponto mais próximo iterativo robusto (RICP - *Robust iterative closest point*). Outra variação do ICP pode ser encontrada em Hufnagel et al. (2008), onde é proposto o EM-ICP (*Expectation Maximization - Iterative Closest Point*) com transformação *affine*. O EM-ICP foi introduzido por Granger e Pennec (2002).

Técnicas não-lineares de registro (Yanovsky et al., 2007b) (Yanovsky et al., 2007a) também podem ser aplicadas no alinhamento de imagens usando deformações. A vantagem desses métodos é o registro de imagens médicas onde ocorrem mudanças de tecidos. Neste caso não se aplica a transformação rígida.

Os métodos baseados em intensidade de voxel operam diretamente nos valores de tons de cinza da imagem para o cálculo da transformação rígida, sem uma etapa de processamento como a segmentação (Maintz e Viergever, 1997). Esses métodos usam todo o conteúdo das imagens e são usados para casos de elevada sobreposição de regiões.

Viola (1995), Thevenaz e Unser (1998) descreveram um método de registro baseado na teoria da informação onde a informação mútua entre as imagens é maximizada através de transformações de corpo rígido.

1.5 Organização da Dissertação

A dissertação é organizada da seguinte maneira: no Capítulo 2 são descritos os fundamentos teóricos gerais abrangendo descrição da análise em componentes principais (PCA), mínimos quadrados (LS), interpolação de imagens entre outros, que são usados na metodologia de registro de imagens médicas. Este capítulo descreve também os fundamentos teóricos gerais e específicos, tais como os métodos de registro usados para o alinhamento das imagens multimodais e monomodais. Os resultados dos métodos de registro são apresentados no Capítulo 3 através de histograma de distâncias entre pontos correspondentes. Também são usadas as imagens xadrez na validação por inspeção visual.

O Capítulo 4 analisa e compara os resultados descritos no Capítulo 3 com base no nível de interação e na distância entre pontos correspondentes. A dissertação finaliza com o Capítulo 5 o qual contém uma conclusão sobre o registro de imagens na modelagem tridimensional de estruturas específicas.

Capítulo 2

Fundamentos Teóricos Gerais e Específicos

2.1 Introdução

Este capítulo descreve os fundamentos teóricos gerais e específicos para o cálculo da transformação de corpo rígido \mathbf{T} para o alinhamento de uma imagem de referência \mathbf{M} com uma imagem móvel \mathbf{P} . A transformação \mathbf{T} pode ser representada pelo par (\mathbf{R}, \mathbf{t}) onde \mathbf{R} é a matriz de rotação e \mathbf{t} é o vetor de translação. São analisados os casos de imagens mono e multimodais.

O registro de imagens multimodais requer marcadores externos (fiduciais) que são segmentados nas imagens para gerar conjuntos de pontos \mathbf{M}_p e \mathbf{P}_p . Esses pontos ou nós da malha dos marcadores são necessários nos métodos de registro de imagens multimodais. Os métodos implementados para o cálculo de \mathbf{T} para esse registro são: (i) Análise em Componentes Principais (PCA); (ii) Mínimos quadrados ortonormal (LS); e (iii) Ponto mais próximo iterativo (ICP).

O registro de imagens monomodais MRI-MRI permite o uso de métodos baseados na intensidade de voxel. Esses métodos utilizam diretamente os valores de tons de cinza da imagem, sem uma etapa anterior de segmentação, utilizando todo o conteúdo das imagens (Maintz e Viergever, 1997). Os mesmos fiduciais utilizados para o registro multimodal então podem ser usados para validação do registro monomodal baseado em intensidade do voxel.

Com relação ao nível de interatividade, algoritmos de registro de imagens podem ser categorizados em três níveis: (i) métodos automáticos, onde as entradas do algoritmos são as imagens; (ii) métodos manuais, onde o usuário alinha as imagens aplicando as transformações e visualizando o alinhamento através de uma interface; e (iii) métodos semi-automáticos onde o usuário processa as imagens (por exemplo segmentando

regiões) ou avalia o registro, aceitando ou rejeitando o alinhamento sugerido. Os algoritmos baseados em segmentação (pontos e superfícies) são considerados como métodos semi-automáticos de registro. No caso de uso de fiduciais, o processo de segmentação consiste em identificar marcadores equivalentes em pares de imagens. Esse critério de categorização basea-se na interação com o usuário.

2.2 Teoria da informação, Variáveis Aleatórias, Entropia e Informação Mútua

Variáveis aleatórias, ou V.A's, são variáveis que possuem valores determinados pelo resultado de experiências. Sejam X e Y duas variáveis aleatórias e $\Omega_x = \{1, 2, 3, 4, 5, 6, 7\}$ e $\Omega_y = \{6, 7, 8, 9, 10, 11\}$ dois subconjuntos de \mathbb{R} contendo os valores possíveis de X e de Y respectivamente. Cada valor de X pode-se associar com um probabilidade P_x . A função:

$$P_x : \Omega_x \rightarrow [0, 1] \quad (2.1)$$

é chamada de distribuição de probabilidade. Um ensaio é um valor particular de X ou de Y . Uma coleção de ensaios é chamada de amostra e um evento é um subconjunto A do espaço amostral Ω_x , tal que $A \subset \Omega_x$ (Viola, 1995). A probabilidade de um evento, $P_x(X \in A)$ é proporcional ao número de vezes que é esperado o evento A . A soma de todo o espaço amostral de distribuição de probabilidade é igual a um:

$$\sum_{x_i \in \Omega_x} P(X \in \{x_i\}) = 1, \quad (2.2)$$

onde x é um elemento de Ω_x . As variáveis aleatórias neste trabalho apresentam valores expressos em uma escala contínua sendo consideradas como variáveis aleatórias contínuas. As imagens transformadas podem ser interpoladas através da convolução com kernels de interpolação, apresentando valores contínuos no espaço tridimensional. Para variáveis aleatórias contínuas, é usado a função de densidade de probabilidade:

$$f_x(x_0) = \lim_{\delta \rightarrow 0} \frac{P(x_0 < X < x_0 + \delta)}{\delta}. \quad (2.3)$$

A probabilidade de um evento pode ser calculada pela densidade de probabilidade através da integral:

$$P(x_1 < X < x_2) = \int_{x_1}^{x_2} f_x(x) dx, \quad (2.4)$$

onde $f_x(x)$ é a função densidade de probabilidade. A média ou o valor esperado de uma V.A é dada por:

$$m_x = E[X], \quad (2.5)$$

onde $E[.]$ é o operador valor esperado. O valor esperado da variável aleatória X , $E[X]$, é dado, no caso contínuo, por:

$$E[X] \equiv \int_{-\infty}^{\infty} x f_x(x) dx. \quad (2.6)$$

A variância de uma variável aleatória pode ser calculada como:

$$Var(X) \equiv E[(X - E[X])^2] = E[X^2] - E[X]^2, \quad (2.7)$$

e o desvio padrão $\sigma(X)$ é calculado através da raiz quadrada da variância. O desvio padrão é a medida de distância entre as amostras de X de $E[X]$.

A entropia é uma medida estatística relacionada com a aleatoriedade, a qual determina o quanto uma variável é aleatória e é dado por:

$$H(X) \equiv -E[\log(P(X))], \quad (2.8)$$

e

$$H(X) \equiv - \sum_{x_i \in \Omega_x} \log(P(X = x_i)) P(X = x_i). \quad (2.9)$$

A definição clássica de entropia aplica-se apenas em variáveis aleatórias discretas. A entropia aplicada para variáveis aleatórias contínuas é chamada de entropia contínua ou diferencial, é dada por (V.A's X e Y):

$$H(X) = - \int_{-\infty}^{\infty} f_x(X) \log f_x(X) dX, \quad (2.10)$$

e

$$H(Y) = - \int_{-\infty}^{\infty} f_y(Y) \log f_y(Y) dY, \quad (2.11)$$

onde $H(X)$ e $H(Y)$ são as entropias marginais. Entropia condicional pode ser definida

como medida de aleatoriedade de X dado Y dada pela seguinte equação:

$$H(X|Y) = E_X[E_Y[\log P(X|Y)]], \quad (2.12)$$

ou

$$H(Y|X) = H(X) - I(X; Y), \quad (2.13)$$

onde $P(X|Y)$ é a distribuição condicional, sendo a probabilidade de X dado Y definida por:

$$P(X|Y) = \frac{P(X, Y)}{P(X)}, \quad (2.14)$$

onde $P(X, Y)$ é a probabilidade conjunta. Duas variáveis são independentes se a distribuição conjunta é igual ao produto das distribuições marginais:

$$P(X, Y) = P(X)P(Y). \quad (2.15)$$

Para variáveis aleatórias contínuas, a entropia conjunta é dada por:

$$H(X, Y) = - \int f_{xy}(X, Y) \log f_{xy}(X, Y) dX dY. \quad (2.16)$$

Métodos baseados na intensidade de voxel buscam alinhar imagens através de uma métrica (ver Figura 2.1), como por exemplo, a informação mútua. Informação mútua é uma medida da dependência estatística entre duas variáveis aleatórias. A informação mútua $I(X, Y)$ é definida como:

$$I(X; Y) = H(X) + H(Y) - H(X, Y). \quad (2.17)$$

A equação 2.17 pode ser reescrita como:

$$I(X; Y) = H(X) - H(X|Y), \quad (2.18)$$

$H(X|Y)$ é a entropia condicional. Há três expressões equivalentes para informação mútua:

$$\begin{aligned} I(X; Y) &= H(X) + H(Y) - H(X, Y) \\ &= H(Y) - H(Y|X) \\ &= H(X) - H(X|Y). \end{aligned} \quad (2.19)$$

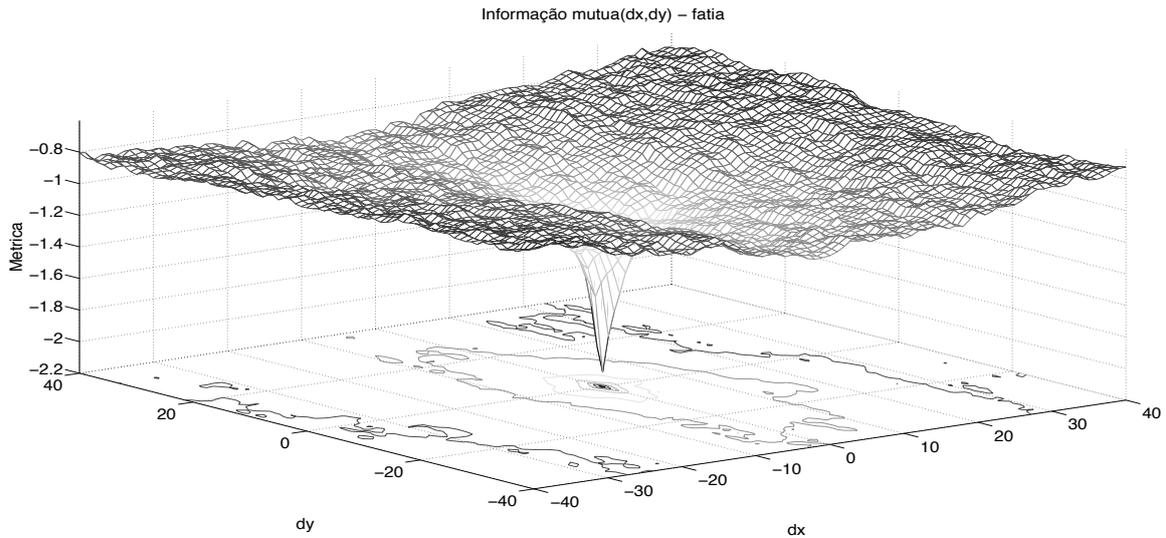


Figura 2.1: Informação mútua calculada através de imagens bidimensionais transladas ao longo do eixos x e y .

2.3 Transformação de Corpo Rígido

A transformação de corpo rígido permite apenas operações de translação e rotação (ver Tabela 2.1), e tem como objetivo o cálculo da matriz \mathbf{T} que alinha a imagens \mathbf{P} e \mathbf{M} :

$$\mathbf{P}(\mathbf{T}(\mu, \mathbf{x})) = \mathbf{M} = \mathbf{R}\mathbf{P} + \mathbf{t}, \quad (2.20)$$

onde $\mu = (\alpha_x, \alpha_y, \alpha_z, \mathbf{t}_x, \mathbf{t}_y, \mathbf{t}_z)$, α_x , α_y e α_z são os ângulos de rotação em tornos dos eixos x , y e z e $\mathbf{t}_x, \mathbf{t}_y$ e \mathbf{t}_z as translações ao longo desses mesmos eixos.

Tabela 2.1: Modelos de transformações

	Reflexão	Rotação	Translação	Escala (Figura 2.4)	Projeção	Curva
Corpo rígido	X	X	X	-	-	-
Afim	X	X	X	X	-	-
Projetiva	X	X	X	X	X	-
Curva	X	X	X	X	X	X

Este trabalho restringe-se realizar o registro de imagens através de transformações de corpo rígido. Esta restrição baseia-se na suposição de que o paciente encontra-se na mesma posição durante as medições, podendo, entretanto estar deslocando e com diferente orientação em relação ao equipamento.

Caso fosse levado em conta a possibilidade de as vias aéreas superiores se moverem entre uma medição e outra, seria mais interessante utilizar a transformação afin para a realização do registro.

2.3.1 Notação Matricial

Em termos matriciais a equação $\mathbf{P}(\mathbf{T}(\mu, \mathbf{x}) = \mathbf{M} = \mathbf{R}\mathbf{P} + \mathbf{t}$ pode ser reescrita como:

$$\begin{bmatrix} \mathbf{M}_x \\ \mathbf{M}_y \\ \mathbf{M}_z \\ 1 \end{bmatrix} = \mathbf{t}\mathbf{R} \begin{bmatrix} \mathbf{P}_x \\ \mathbf{P}_y \\ \mathbf{P}_z \\ 1 \end{bmatrix}, \quad (2.21)$$

onde,

$$\mathbf{t} = \begin{bmatrix} 1 & 0 & 0 & \mathbf{t}_x \\ 0 & 1 & 0 & \mathbf{t}_y \\ 0 & 0 & 1 & \mathbf{t}_z \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad (2.22)$$

e \mathbf{t}_x , \mathbf{t}_y e \mathbf{t}_z são translações (ver Figura 2.2) ao longo dos eixos X , Y e Z .

A matriz de rotação \mathbf{R} pode ser decomposta em:

$$\mathbf{R} = \mathbf{R}_x \mathbf{R}_y \mathbf{R}_z, \quad (2.23)$$

onde \mathbf{R}_x é a matriz de rotação (ver Figura 2.3) em torno do eixo x definida como *pitch* e dada por:

$$\mathbf{R}_x = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos(\alpha_x) & \sin(\alpha_x) & 0 \\ 0 & -\sin(\alpha_x) & \cos(\alpha_x) & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}. \quad (2.24)$$

\mathbf{R}_y é a matriz de rotação em torno do eixo y definida como *roll* e dada por:

$$\mathbf{R}_y = \begin{bmatrix} \cos(\alpha_y) & 0 & \sin(\alpha_y) & 0 \\ 0 & 1 & 0 & 0 \\ -\sin(\alpha_y) & 0 & \cos(\alpha_y) & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (2.25)$$

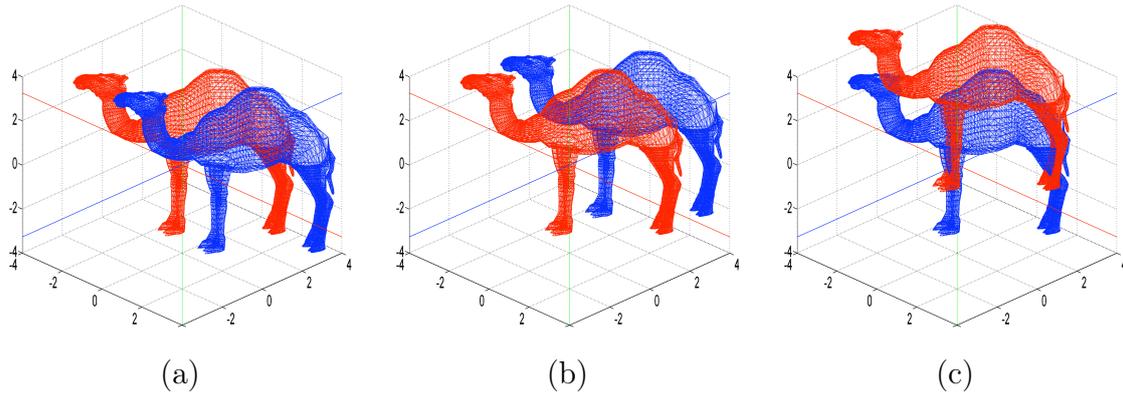


Figura 2.2: Translação ao longo dos eixos x , y e z .

e \mathbf{R}_z a matriz de rotação em torno do eixo y definida como *yaw* e dada por:

$$\mathbf{R}_z = \begin{bmatrix} \cos(\alpha_z) & 0 & \sin(\alpha_z) & 0 \\ -\sin(\alpha_z) & 0 & \cos(\alpha_z) & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}. \quad (2.26)$$

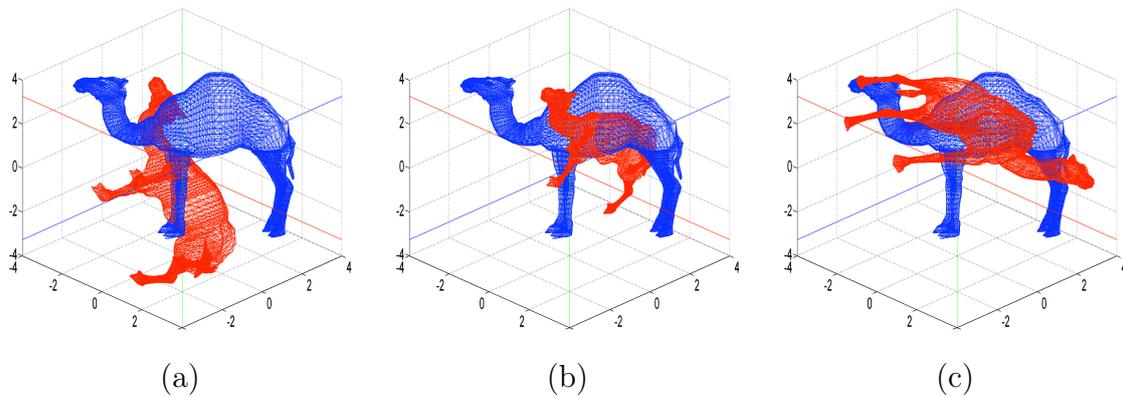


Figura 2.3: rotação de 1,57 rad em torno dos eixos x , y e z .

As matrizes de rotação são ortogonais e satisfazem as condições:

$$\det(\mathbf{R}) = 1 \quad (2.27)$$

e

$$\mathbf{R}^T = \mathbf{R}^{-1}. \quad (2.28)$$

A condição em que o determinante de uma matriz de rotação é igual a 1 pode ser

demonstrada reduzindo as dimensões as matrizes \mathbf{R}_x , \mathbf{R}_y e \mathbf{R}_z :

$$\mathbf{R}_x = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(\alpha_x) & \sin(\alpha_x) \\ 0 & -\sin(\alpha_x) & \cos(\alpha_x) \end{bmatrix}, \quad (2.29)$$

$$\mathbf{R}_y = \begin{bmatrix} \cos(\alpha_y) & 0 & \sin(\alpha_y) \\ 0 & 1 & 0 \\ -\sin(\alpha_y) & 0 & \cos(\alpha_y) \end{bmatrix}, \quad (2.30)$$

e

$$\mathbf{R}_z = \begin{bmatrix} \cos(\alpha_z) & 0 & \sin(\alpha_z) \\ -\sin(\alpha_z) & 0 & \cos(\alpha_z) \\ 0 & 1 & 0 \end{bmatrix}. \quad (2.31)$$

Calculando o determinante das matrizes \mathbf{R}_x , \mathbf{R}_y e \mathbf{R}_z , têm-se:

$$\det(\mathbf{R}_x) = \cos^2(\alpha_x) + \sin^2(\alpha_x) = 1, \quad (2.32)$$

$$\det(\mathbf{R}_y) = \cos^2(\alpha_y) + \sin^2(\alpha_y) = 1 \quad (2.33)$$

e

$$\det(\mathbf{R}_z) = \cos^2(\alpha_z) + \sin^2(\alpha_z) = 1. \quad (2.34)$$

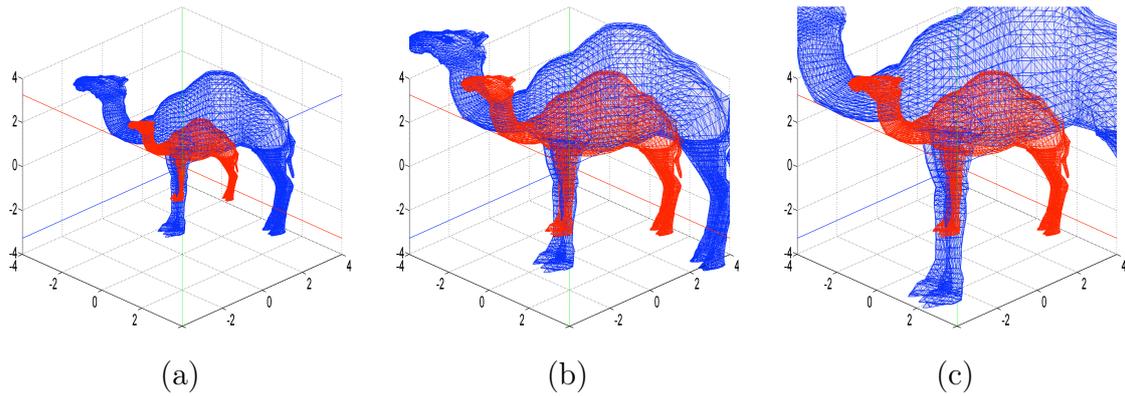


Figura 2.4: Fatores de escala 0,5, 1,5 e 2,0.

2.3.2 Quatérnio unitário

Quatérnios unitários representam orientações e rotações de objetos tridimensionais, sendo numericamente mais estáveis que as matrizes ortogonais, resolvendo o problema de *Gimbal Lock*, o qual consiste na perda de um grau de liberdade, quando dois eixos de três grimbals estão no mesmo lugar e não podem compensar rotação em torno de um eixo. Grimal é um suporte que permite rotações de um objeto.

O espaço de rotações tridimensionais pode ser parametrizado por ângulos de Euler. Alguns pontos dessa representação satisfazem o problema de Gimbal. Uma maneira de evitar o *Gimbal Lock* é usar quatro coordenadas euclidianas w, x, y, z onde:

$$w^2 + x^2 + y^2 + z^2 = 1. \quad (2.35)$$

A rotação é representada pelo ponto (w, x, y, z) em torno do eixo direcionado pelo vetor (x, y, z) e pode ser calculada por:

$$\begin{aligned} \alpha &= 2 \sin^{-1} w \\ &= 2 \cos^{-1} \sqrt{x^2 + y^2 + z^2}. \end{aligned} \quad (2.36)$$

O quatérnio unitário pode ser escrito em termos de (w, x, y, z) como:

$$\begin{aligned} q &= w + x\mathbf{i} + y\mathbf{j} + z\mathbf{k} \\ &= w + (x, y, z) \\ &= \cos\left(\frac{\alpha}{2}\right) + \mathbf{u} \sin\left(\frac{\alpha}{2}\right). \end{aligned} \quad (2.37)$$

De maneira semelhante aos números complexos o quatérnio unitário pode ser escrito em termos de símbolos abstratos como \mathbf{i} , \mathbf{j} e \mathbf{k} , os quais satisfazem o seguinte produto:

$$\begin{aligned} \mathbf{i}^2 &= -1 \\ \mathbf{j}^2 &= -1 \\ \mathbf{k}^2 &= -1 \\ \mathbf{ijk} &= -1. \end{aligned} \quad (2.38)$$

Logo, têm-se que a parte imaginária do quatérnio $b\mathbf{i} + c\mathbf{j} + d\mathbf{k}$, que pode ser reescrito

adicionando um escalar a , onde $a \in \mathbb{R}$:

$$q = a + b\mathbf{i} + c\mathbf{j} + d\mathbf{k}. \quad (2.39)$$

A matriz unitária \mathbf{R} correspondente ao quaternião q é dada por:

$$\mathbf{R} = \begin{bmatrix} w^2 + x^2 - y^2 - z^2 & 2xy + 2wz & 2xz - 2wy \\ 2xy - 2wz & w^2 - x^2 - y^2 - z^2 & 2yz + 2wx \\ 2xz + 2wy & 2yz - 2wx & \cos(\alpha_x) \end{bmatrix}. \quad (2.40)$$

Para converter uma matriz ortogonal \mathbf{R} para quaternião, é necessário que o determinante de \mathbf{R} seja igual a 1:

$$\det(\mathbf{R}) = 1 \quad (2.41)$$

e que o traço da matriz \mathbf{R} seja maior que zero,

$$r_{11} + r_{22} + r_{33} > 0, \quad (2.42)$$

onde

$$\mathbf{R} = \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix}. \quad (2.43)$$

Logo, w, x, y, z podem ser calculados por:

$$w = \sqrt{\frac{r_{11} + r_{22} + r_{33} + 1}{2}}, \quad (2.44)$$

$$x = \frac{r_{32} - r_{23}}{4w}, \quad (2.45)$$

$$y = \frac{r_{13} - r_{31}}{4w}, \quad (2.46)$$

e

$$z = \frac{r_{21} - r_{12}}{4w}. \quad (2.47)$$

2.4 Análise em Componentes Principais

Para o registro de conjunto de pontos tridimensionais é necessário o alinhamento dos eixos do novo sistema de coordenadas obtido pela PCA (ver figuras 2.5 e 2.6). A PCA foi introduzida por Pearson (1901) na área biológica. Uma solução para PCA pode ser derivada da decomposição em autovetores. O princípio é calcular a matriz ortonormal Λ que $\mathbf{M}_{pca} = \Lambda \mathbf{M}_p$, onde \mathbf{M}_p é uma matriz $m \times n$ a qual contém os dados (no caso de registro baseado em pontos ou superfícies \mathbf{M}_p é a matriz que contém os pontos no espaço tridimensional) e \mathbf{M}_{pca} uma matriz cujas linhas contém as componentes principais de \mathbf{M} . A matriz de covariância $\mathbf{C}_{\mathbf{M}_{pca}}$ dada por (Shlens, 2005):

$$\mathbf{C}_{\mathbf{M}_{pca}} \equiv \frac{1}{n} \mathbf{M}_{pca} \mathbf{M}_{pca}^T \quad (2.48)$$

deve ser diagonal uma vez que as componentes principais são ortogonais. A Equação 2.48 pode ser reescrita da seguinte maneira:

$$\begin{aligned} \mathbf{C}_{\mathbf{M}_{pca}} &= \frac{1}{n} \mathbf{M}_{pca} \mathbf{M}_{pca}^T \\ &= \frac{1}{n} \Lambda \mathbf{M}_p (\Lambda \mathbf{M}_p)^T \\ &= \frac{1}{n} \Lambda \mathbf{M}_p \mathbf{M}_p^T \Lambda^T \\ &= \Lambda \frac{1}{n} \mathbf{M}_p \mathbf{M}_p^T \Lambda^T \\ &= \Lambda \mathbf{C}_{\mathbf{M}_p} \Lambda^T. \end{aligned} \quad (2.49)$$

A matriz $\mathbf{C}_{\mathbf{M}_p}$ pode ser decomposta em:

$$\mathbf{C}_{\mathbf{M}_p} = \mathbf{E} \mathbf{D} \mathbf{E}^T, \quad (2.50)$$

onde \mathbf{D} é uma matriz diagonal e \mathbf{E} uma matriz com os autovetores de $\mathbf{C}_{\mathbf{M}_p}$ normalizados. Assim, têm-se:

$$\begin{aligned} \mathbf{C}_{\mathbf{M}_{pca}} &= \Lambda \mathbf{C}_{\mathbf{M}_p} \Lambda^T \\ &= \Lambda \mathbf{E} \mathbf{D} \mathbf{E}^T \Lambda^T \\ &= \Lambda \Lambda^T \mathbf{D} \Lambda \Lambda^T \\ &= \mathbf{I} \mathbf{D} \mathbf{I} \\ &= \mathbf{D}. \end{aligned} \quad (2.51)$$

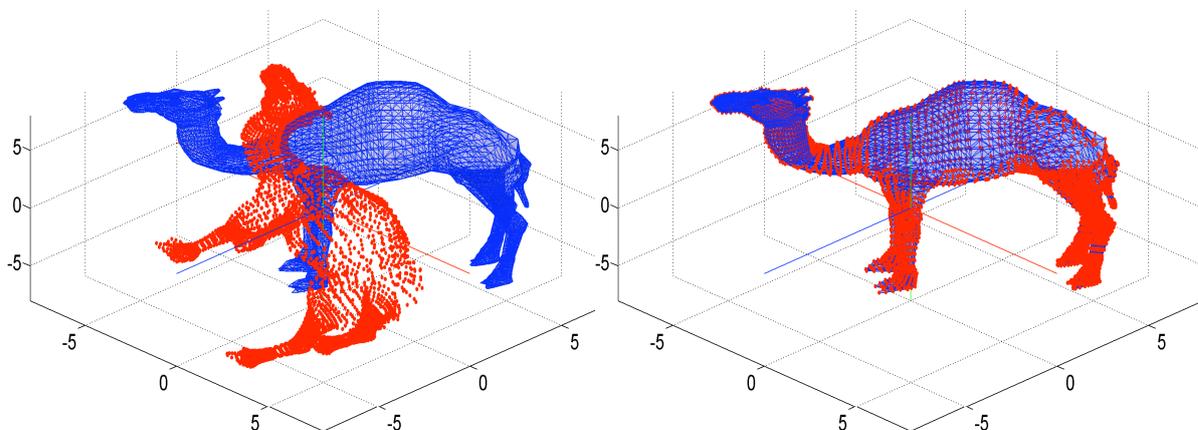


Figura 2.5: Alinhamento de modelos tridimensionais com formas iguais.

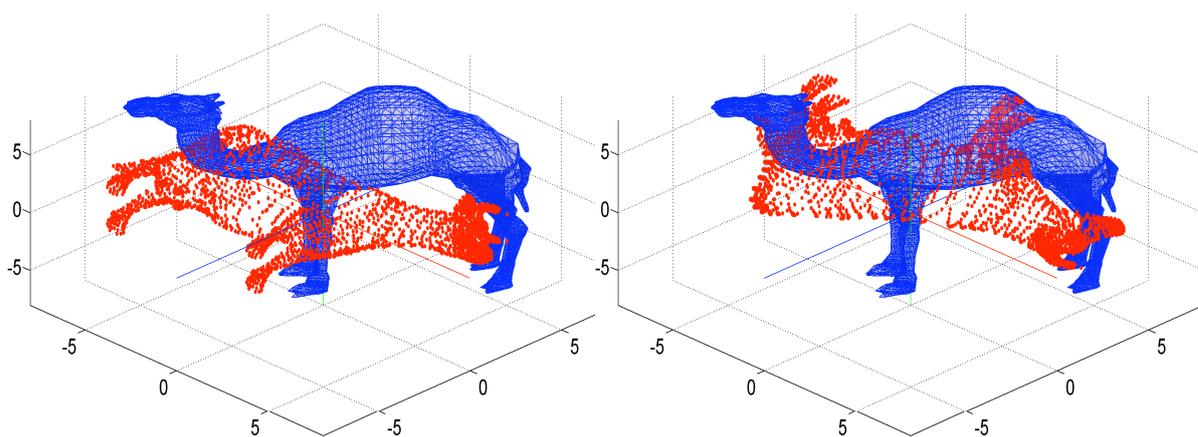


Figura 2.6: Alinhamento de modelos tridimensionais com formas diferentes.

2.5 Mínimos Quadrados

Considerando o sistema linear de m equações:

$$\mathbf{A}\theta = \mathbf{b}, \quad (2.52)$$

onde θ é um vetor n -dimensional, \mathbf{A} uma matriz $m \times n$ que contém os coeficientes das equações e \mathbf{b} o vetor m -dimensional de dados. Se \mathbf{A} for quadrada, a solução é dada por:

$$\begin{aligned} \mathbf{A}\theta &= \mathbf{b} \\ \theta &= \mathbf{A}^{-1}\mathbf{b} \end{aligned} \quad (2.53)$$

Se $m > n$ ($\mathbf{A}_{m \times n}$) a solução pode ser encontrada através do cálculo da pseudoinversa de \mathbf{A} :

$$\begin{aligned} \mathbf{A}\theta &= \mathbf{b} \\ \mathbf{A}^T\mathbf{A}\theta &= \mathbf{A}^T\mathbf{b} \end{aligned} \quad (2.54)$$

Calculando θ têm-se:

$$\theta = (\mathbf{A}^T\mathbf{A})^{-1}\mathbf{A}^T\mathbf{b}. \quad (2.55)$$

Essa solução é ótima em termos de mínimos quadrados (Trucco e Verri, 1998).

2.6 Interpolação de imagens

A amostragem de imagens consiste em reconstruir a imagem tridimensional U , onde $U(x, y, z)$ é o valor da intensidade do voxel a partir da imagem discreta U_s (cuja intensidade é dada por $U_s(k, l, m)$) onde $x, y, z \in \mathbb{R}$ e $k, l, m \in \mathbb{N}$. A intensidade $U(x, y, z)$ deve ser calculada a partir de seus vizinhos discretos em U_s . A reconstrução pode ser definida como a convolução entre um filtro reconstrutor K e uma imagem discreta:

$$U(x, y, z) = \sum_k \sum_l \sum_m U_s(k, l, m)K(x - k, y - l, z - m). \quad (2.56)$$

O varredura de uma imagem contínua dada por U gera infinitas repetições de seu espectro contínuo dado por S_u no domínio de Fourier. Não ocorre sobreposição se a

critério de Nyquist (frequência de amostragem deve ser maior que duas vezes a maior frequência do espectro desse sinal.) é satisfeito (Lehmann et al., 1999). Assim a imagem U pode ser reconstruída perfeitamente a partir de sua amostra U_s .

O kernel de interpolação $K(x, y, z)$ pode ser separado em três Kernels:

$$K(x, y, z) = K(x)K(y)K(z). \quad (2.57)$$

A seguir, três possibilidades de kernel são descritas: Vizinho mais próximo, Linear e BSpline.

2.6.1 Vizinho mais próximo

Usando a propriedade de separabilidade do kernel (ver equação 2.57), tem-se que o valor de $U(x)$ é igual ao valor de seu vizinho mais próximo em $U_s(k)$. Esse kernel de interpolação apresenta a forma retangular (ver Figura 2.7):

$$K_0(x) = \begin{cases} 1, & 0 \leq |x| \leq 0.5 \\ 0, & c.c. \end{cases} \quad (2.58)$$

2.6.2 Linear

O valor de $U(x)$ dado pela interpolação linear (ver Figura 2.8) é dado pelo ponderação dos valores de seus vizinhos pela distância. O kernel linear apresenta forma triangular e é dado pela equação:

$$K_1(x) = \begin{cases} 1 - |x|, & 0 \leq |x| \leq 1 \\ 0, & c.c. \end{cases} \quad (2.59)$$

2.6.3 BSpline

O kernel de interpolação BSpline podem ser criado através de um aproximador aplicado a diferentes amostras de $U_s(k)$. Devido à sua simetria e separabilidade, a reconstrução pode ser escrita da seguinte forma (Lehmann et al., 1999):

$$U(x) = \sum_k U_s(k)K_3(x - k), \quad (2.60)$$

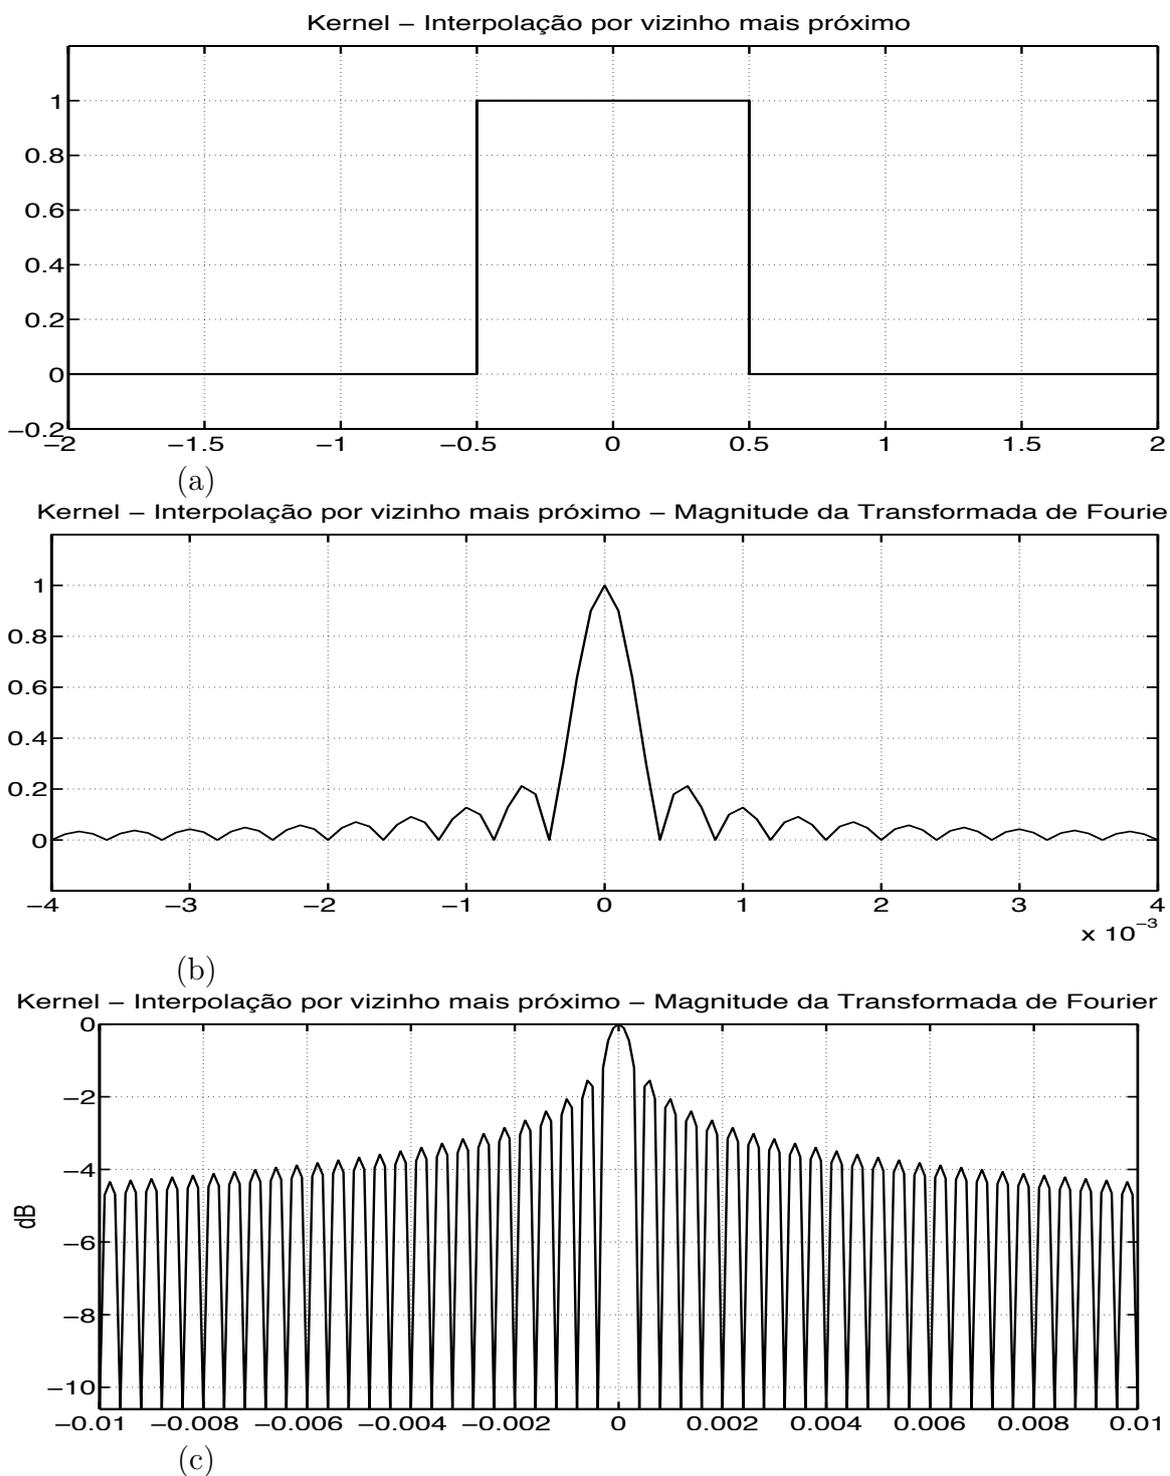


Figura 2.7: (a) Kernel de interpolação por vizinho mais próximo. (b) Magnitude da transformada de Fourier. (c) Magnitude em dB.

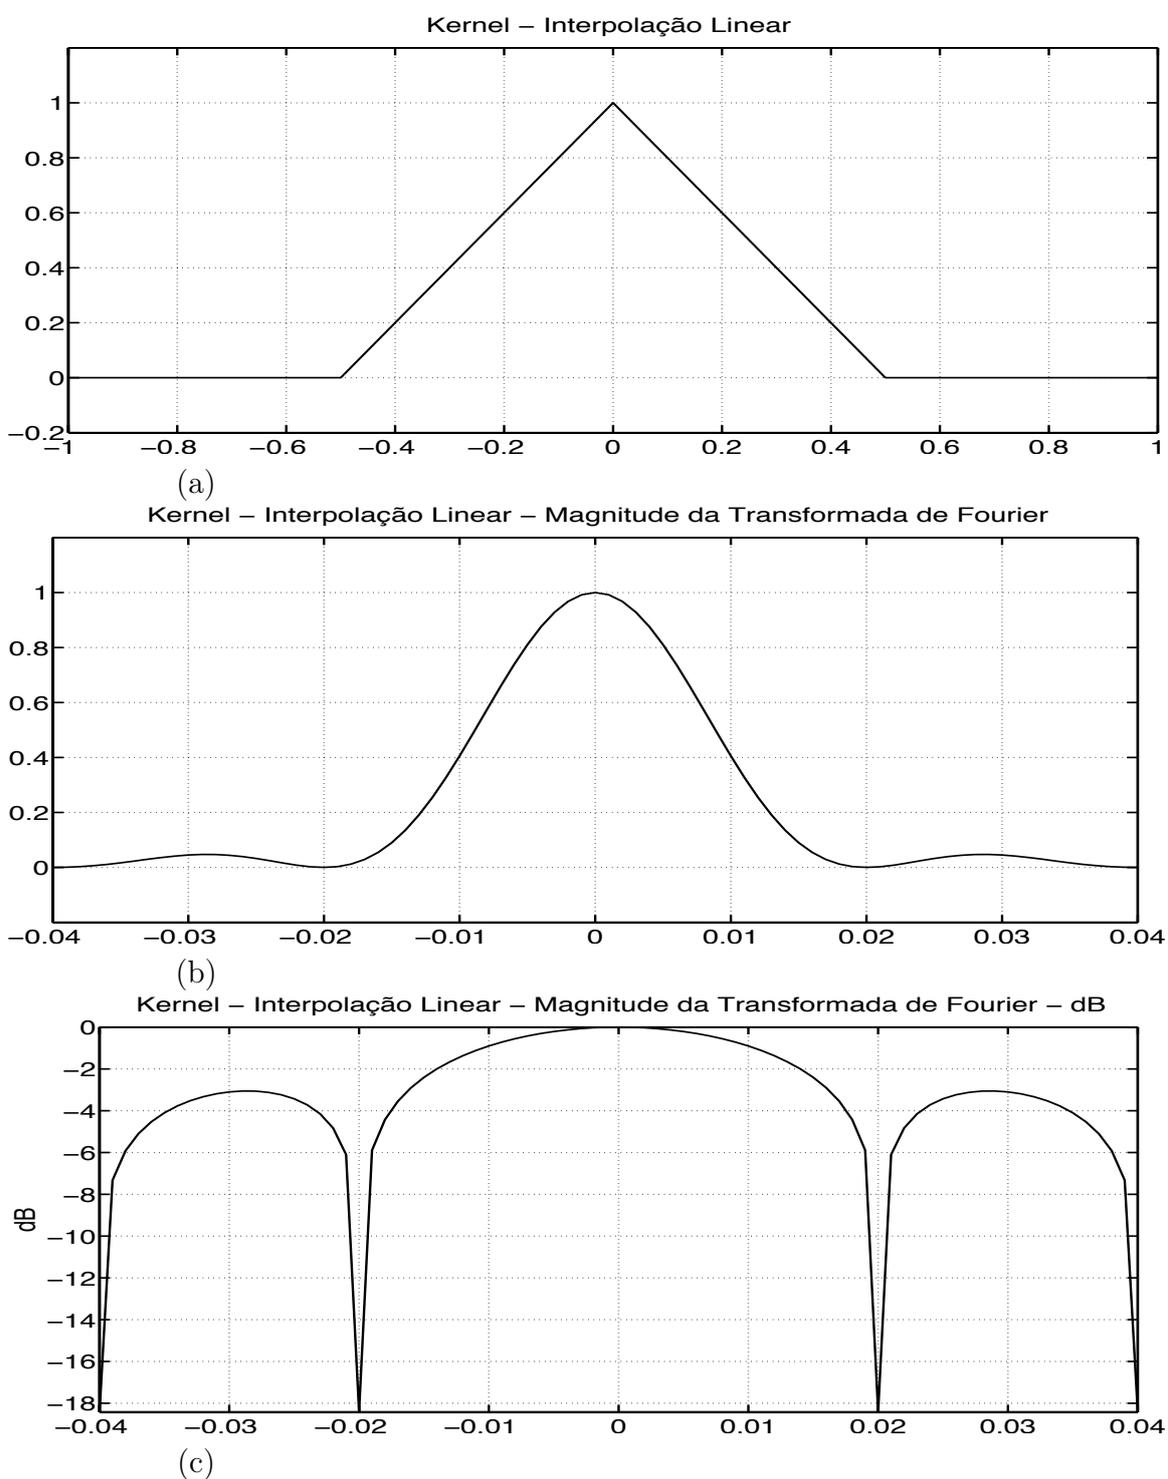


Figura 2.8: (a) Kernel de interpolação linear. (b) Magnitude da transformada de Fourier. (c) Magnitude em dB.

onde

$$K(x) = K_3(x) = \begin{cases} (1/2)|x|^3 - |x|^2 + 2/3, & 0 \leq |x| \leq 1 \\ -(1/6)|x|^3 + |x|^2 - 2|x| + 4/3, & 1 \leq |x| \leq 2 \\ 0, & c.c. \end{cases} \quad (2.61)$$

O kernel de interpolação BSpline é mostrado na Figura 2.9. Cada um desses kernels possui características diferentes e seu desempenho é ilustrado na seção 3.4.

2.7 Registro por Análise em Componentes Principais

A metodologia proposta para o registro de imagens multimodais consiste em um alinhamento inicial, o qual pode ser realizado através de análise em componentes principais (PCA) (Chung et al., 1998). Neste processo, a geometria dos fiduciais é extraída através da segmentação semi-automática das imagens de tomografia computadorizada e ressonância magnética.

Os conjuntos de pontos de referência \mathbf{M}_p e \mathbf{P}_p móvel podem apresentar tamanhos diferentes, não sendo necessário calcular a correspondência entres os conjuntos. \mathbf{M}_p e \mathbf{P}_p são extraídos através de segmentação ou de posicionamento de *templates* de marcadores de óleo nas imagens de MRI e CT, respectivamente.

O primeiro passo no método baseado em PCA é o cálculo das matrizes de covariância $\mathbf{C}_{\mathbf{M}_p}$ e $\mathbf{C}_{\mathbf{P}_p}$:

$$\mathbf{C}_{\mathbf{M}_p} = E[(\mathbf{M}_p - E[\mathbf{M}_p])(\mathbf{M}_p - E[\mathbf{M}_p])^T], \quad (2.62)$$

$$\mathbf{C}_{\mathbf{P}_p} = E[(\mathbf{P}_p - E[\mathbf{P}_p])(\mathbf{P}_p - E[\mathbf{P}_p])^T]. \quad (2.63)$$

A seguir, $\mathbf{C}_{\mathbf{M}_p}$ e $\mathbf{C}_{\mathbf{P}_p}$ são decompostas, através da decomposição em valores singulares (SVD):

$$\mathbf{C}_{\mathbf{M}_p} = \mathbf{V}_{\mathbf{M}_p}^T \mathbf{D}_{\mathbf{M}_p} \mathbf{U}_{\mathbf{M}_p}, \quad (2.64)$$

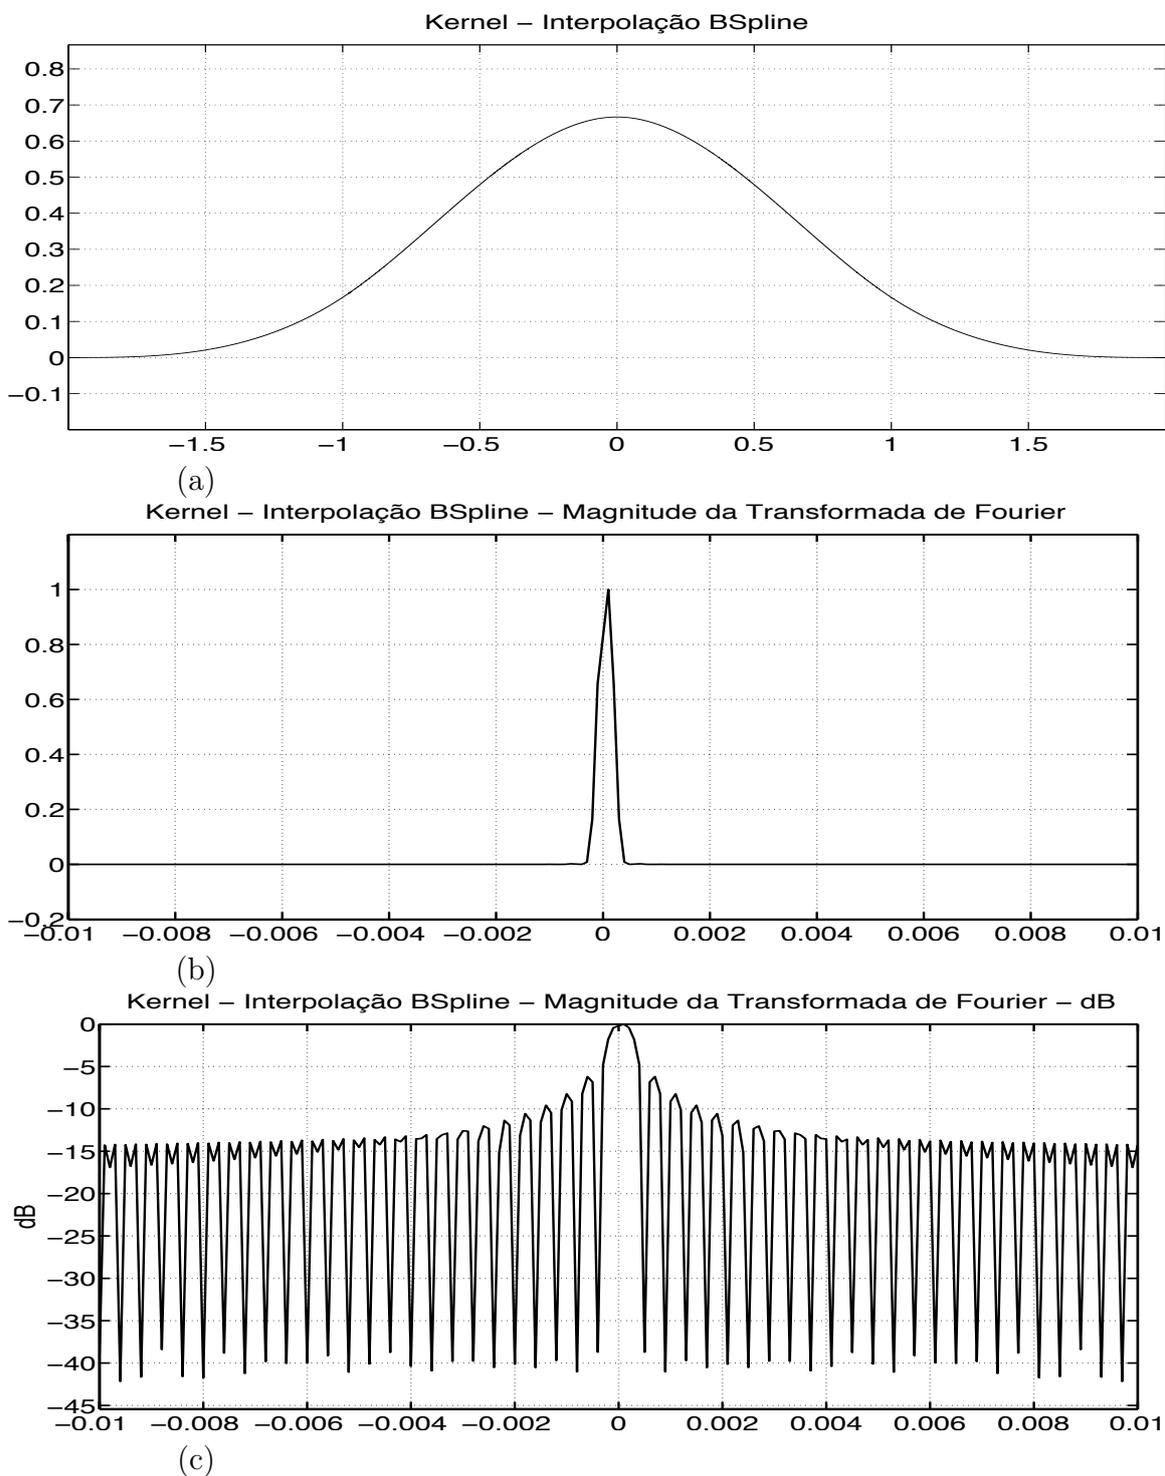


Figura 2.9: (a) Kernel de interpolação BSpline. (b) Magnitude da transformada de Fourier. (c) Magnitude em dB.

$$\mathbf{C}_{\mathbf{P}_p} = \mathbf{V}_{\mathbf{P}_p}^T \mathbf{D}_{\mathbf{P}_p} \mathbf{U}_{\mathbf{P}_p}, \quad (2.65)$$

onde $\mathbf{D}_{\mathbf{M}_p}$ e $\mathbf{D}_{\mathbf{P}_p}$ são matrizes diagonais contendo os autovalores de $\mathbf{C}_{\mathbf{M}_p}$ e $\mathbf{C}_{\mathbf{P}_p}$, respectivamente; e $\mathbf{U}_{\mathbf{P}_p}$ e $\mathbf{U}_{\mathbf{M}_p}$ são matrizes unitárias contendo os autovetores normalizados correspondentes.

Nos sistemas de coordenadas definidas pelas componentes principais, tem-se:

$$\mathbf{M}_{pca} = \mathbf{U}_{\mathbf{M}_p}^T \mathbf{M}_p, \quad (2.66)$$

e

$$\mathbf{P}_{pca} = \mathbf{U}_{\mathbf{P}_p}^T \mathbf{P}_p. \quad (2.67)$$

Idealmente $\mathbf{U}_{\mathbf{M}_p}^T \mathbf{M}_p = \mathbf{U}_{\mathbf{P}_p}^T \mathbf{P}_p$ e $\mathbf{M}_p = \mathbf{U}_{\mathbf{M}_p} \mathbf{U}_{\mathbf{P}_p}^T \mathbf{P}_p$. Logo \mathbf{R} pode ser reescrito como:

$$\mathbf{R} = \mathbf{U}_{\mathbf{M}_p} \mathbf{U}_{\mathbf{P}_p}^T. \quad (2.68)$$

A seguir, a translação \mathbf{t} é dada por:

$$\mathbf{t} = E[\mathbf{M}_p] - \mathbf{R}E[\mathbf{P}_p]. \quad (2.69)$$

O alinhamento por PCA consiste de quatro passos e pode ser sumarizado conforme o Algoritmo 1: (i) Cálculo das matrizes de covariâncias $\mathbf{C}_{\mathbf{M}_p}$ e $\mathbf{C}_{\mathbf{P}_p}$; (ii) Decomposição SVD; (iii) Cálculo de \mathbf{R} ; e (iv) Cálculo de \mathbf{t} .

Algoritmo 1 Alinhamento utilizando PCA

Input: CT, MRI vertices da malha dos marcadores

Output: Matriz \mathbf{R} e vetor \mathbf{t}

1. Calcule as matrizes $\mathbf{C}_{\mathbf{M}_p}$ e $\mathbf{C}_{\mathbf{P}_p}$.

2. Decomposição SVD.

3. $\mathbf{R} = \mathbf{V}_{\mathbf{M}_p} \mathbf{U}_{\mathbf{P}_p}$.

4. $\mathbf{t} = \text{media}(\mathbf{M}_p) - \mathbf{R} * \text{media}(\mathbf{P}_p)$ e $\mathbf{T} = [\mathbf{R} \ \mathbf{t}; 0 \ 0 \ 0 \ 1]$.

Nos casos em que a sobreposição dos conjuntos \mathbf{M}_p e \mathbf{P}_p é inferior a 50%, a precisão do registro por PCA torna-se bastante ruim.

2.8 Registro por Mínimos quadrados (forma fechada)

Uma alternativa para o alinhamento através de PCA é o alinhamento através de mínimos quadrados (LS - *Least Squares*) (Horn et al., 1988). Neste método, utiliza-se os centros dos fiduciais correspondentes nas imagens móvel \mathbf{P} e de referência \mathbf{M} como base para o processo de alinhamento. Este processo se inicia com o cálculo da matriz de covariância cruzada entre as coordenadas dos centros dos fiduciais nas imagens móvel e de referência:

$$\mathbf{C}_{\mathbf{M}_p\mathbf{P}_p} = E[(\mathbf{M}_p - \mu_{\mathbf{M}_p})(\mathbf{P}_p - \mu_{\mathbf{P}_p})^T], \quad (2.70)$$

onde

$$\mathbf{M}_p = \begin{bmatrix} m_{11} & m_{12} & m_{13} \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ m_{k1} & m_{k2} & m_{k3} \end{bmatrix} \quad (2.71)$$

e

$$\mathbf{P}_p = \begin{bmatrix} p_{11} & p_{12} & p_{13} \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ p_{k1} & p_{k2} & p_{k3} \end{bmatrix} \quad (2.72)$$

contêm as coordenadas em três dimensões dos centros dos k fiduciais utilizados nas imagens móvel e de referência, respectivamente. $\mu_{\mathbf{M}_p}$ e $\mu_{\mathbf{P}_p}$ são as médias das posições dos centros dos fiduciais nos sistemas de coordenadas das imagens móvel e de referência, respectivamente.

A seguir, através de decomposição em valores singulares, expressa-se:

$$\mathbf{C}_{\mathbf{M}_p\mathbf{P}_p} = \mathbf{U}\mathbf{D}\mathbf{V}^T, \quad (2.73)$$

onde \mathbf{D} é a matriz diagonal contendo os valores singulares de $\mathbf{C}_{\mathbf{M}_p\mathbf{P}_p}$, \mathbf{U} e \mathbf{V} são matrizes unitárias, contendo os autovetores normalizados de $\mathbf{C}_{\mathbf{M}_p\mathbf{P}_p}\mathbf{C}_{\mathbf{M}_p\mathbf{P}_p}^T$ e de $\mathbf{C}_{\mathbf{M}_p\mathbf{P}_p}^T\mathbf{C}_{\mathbf{M}_p\mathbf{P}_p}$ respectivamente.

Pode-se então rotacionar \mathbf{M}_p e \mathbf{P}_p :

$$\mathbf{M}_r = \mathbf{U}^T(\mathbf{M}_p - \mu_{\mathbf{M}_p}), \quad (2.74)$$

$$\mathbf{P}_r = \mathbf{V}^T(\mathbf{P}_p - \mu_{\mathbf{P}_p}), \quad (2.75)$$

de forma que a matriz de covariância nos novos sistemas de coordenadas torna-se:

$$\mathbf{C}_{\mathbf{M}_p\mathbf{P}_p} = E[(\mathbf{M}_r)(\mathbf{P}_r)^T] \quad (2.76)$$

$$= E[(\mathbf{U}^T(\mathbf{M}_p - \mu_{\mathbf{M}_p}))(\mathbf{V}^T(\mathbf{P}_p - \mu_{\mathbf{P}_p}))^T] \quad (2.77)$$

$$= \mathbf{U}^T E[(\mathbf{M}_p - \mu_{\mathbf{M}_p})(\mathbf{P}_p - \mu_{\mathbf{P}_p})^T] \mathbf{V} \quad (2.78)$$

$$= \mathbf{U}^T \mathbf{C}_{\mathbf{M}_p\mathbf{P}_p} \mathbf{V} \quad (2.79)$$

$$= \mathbf{U}^T \mathbf{U} \mathbf{D} \mathbf{V}^T \mathbf{V} \quad (2.80)$$

$$= \mathbf{D}. \quad (2.81)$$

Assim cada componente de \mathbf{M}_r é correlacionada com apenas uma componente de \mathbf{P}_r . Se os centros das imagens móvel e de referência são os mesmos, então:

$$\mathbf{M}_r = \mathbf{P}_r \quad (2.82)$$

ou

$$\mathbf{U}^T \mathbf{M}_p = \mathbf{V}^T \mathbf{P}_p. \quad (2.83)$$

Pode-se reescrever a Equação 2.83 como $\mathbf{M}_p = \mathbf{R}\mathbf{P}_p$, onde \mathbf{R} :

$$\mathbf{R} = \mathbf{U}\mathbf{V}^T. \quad (2.84)$$

Por último, a translação \mathbf{t} é calculada por:

$$\mathbf{t} = E[\mathbf{M}_p] - \mathbf{R}E[\mathbf{P}_p]. \quad (2.85)$$

O Algoritmo 2 mostra o cálculo de (\mathbf{R}, \mathbf{t}) que minimiza a distância entre os pontos

correspondentes dos conjuntos \mathbf{M}_p e \mathbf{P}_p .

Algoritmo 2 Mínimos quadrados

Input: Conjunto de pontos (correspondência)

Output: Matriz \mathbf{R} e vetor \mathbf{t}

$$\mathbf{R} \text{ e } \mathbf{t} \implies (\mathbf{R}, \mathbf{t}) = \underset{i=1}{\operatorname{argmin}} \sum_{i=1}^{N_P} \|m_i - \mathbf{R}p_i - \mathbf{t}\|^2$$

2.9 Ponto mais próximo iterativo - ICP

O algoritmo de registro por ponto mais próximo iterativo proposto por Besl e McKay (1992), semelhante ao registro por PCA, utiliza conjuntos de pontos esparsos, os quais representam os fiduciais. O alinhamento por PCA, entretanto, não fornece um resultado preciso, servindo basicamente para um alinhamento inicial, que é refinado através do método ICP. Neste método de registro é necessário recuperar a correspondência entre os pontos, utilizando o conceito de vizinho mais próximo. Calculando a correspondência através da permutação das linhas da matriz de vértices dos marcadores, o problema se reduz ao registro por mínimos quadrados (LS). O algoritmo de registro por LS descrito na seção 2.8 não recupera a correspondência entre os pares de pontos, sendo necessário que o usuário identifique os fiduciais mantendo a ordem dos centros nas matrizes. O ICP pode ser considerado como uma extensão do método LS, no qual a correspondência entre os pontos é feita automaticamente.

Para calcular a correspondência entre os pontos, define-se o operador de proximidade \mathbf{C} :

$$\mathbf{P}_{pc} = \mathbf{C}(\mathbf{M}_p, \mathbf{P}_p), \quad (2.86)$$

onde \mathbf{P}_{pc} é uma matriz com as linhas ordenadas, cujas linhas são um subconjunto das linhas de \mathbf{P}_p , cada uma delas correspondendo a uma linha de \mathbf{M}_p . Dessa maneira, árvore K-d *trees*, algoritmo de busca por afinidade (Wang et al., 1996) e busca exaustiva são métodos de implementação do operador \mathbf{C} . A Figura 2.10 mostra a etapa de alinhamento inicial (por PCA), necessária para a recuperação da correspondência entre os conjuntos. Cabe observar que o número de pontos obtidos através de MRI para os fiduciais é uma ordem de magnitude menor que no caso de CT, pois a resolução de CT é bem maior que a resolução de MRI. Esta correspondência entre os conjuntos é calculada pelo algoritmo de vizinho mais próximo, podendo ser visualizada na Figura 2.11.

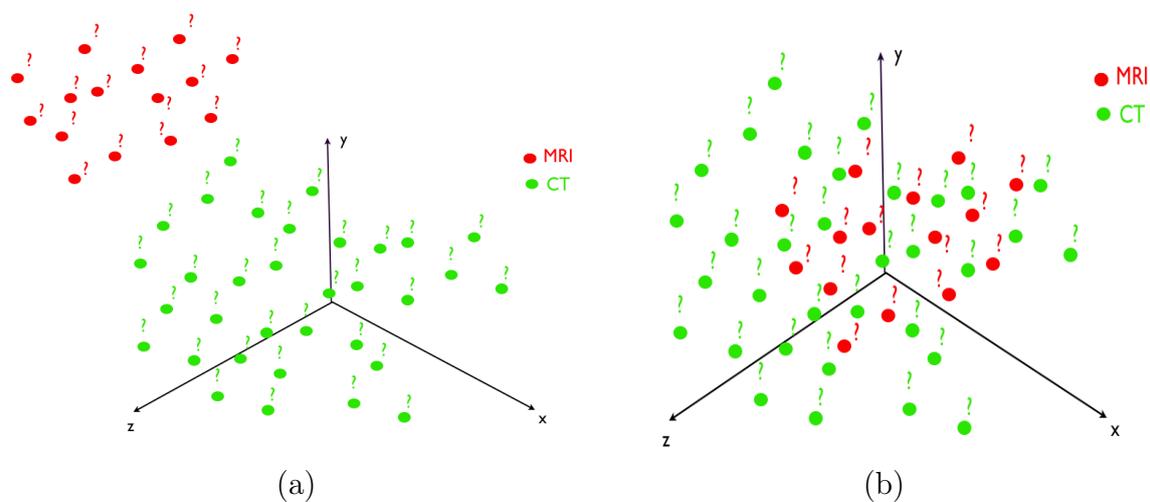


Figura 2.10: (a) Os pontos vermelhos representam os nós da malha dos marcadores MRI e os verdes os nós do marcadores CT. (b) \mathbf{M}_p e \mathbf{P}_p (MRI e CT respectivamente) após a transformação inicial.

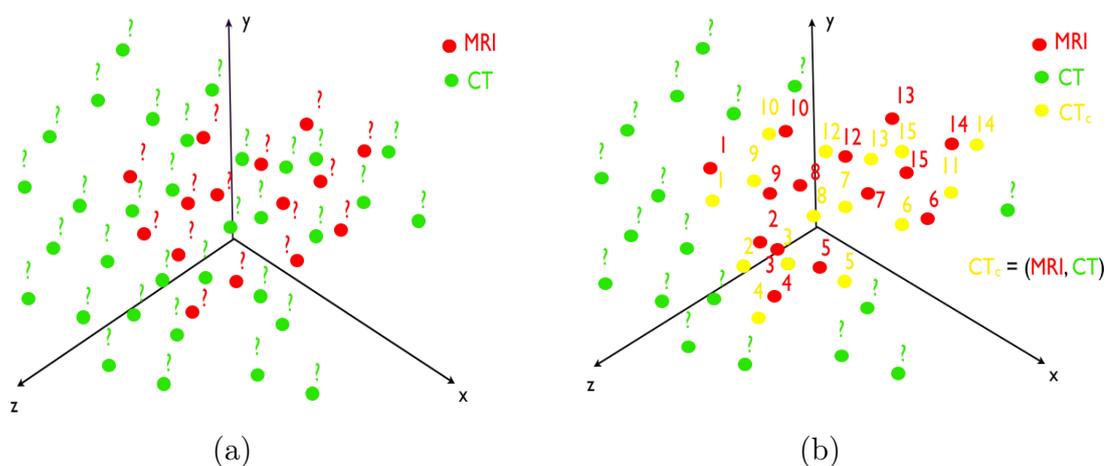


Figura 2.11: (a) Os pontos vermelhos representam os nós da malha dos marcadores MRI e os verdes os nós do marcadores CT após a transformação inicial. (b) Os pontos amarelos são os nós dos marcadores CT mais próximos dos nós dos marcadores MRI. Esses pontos são calculados através do operador de proximidade \mathbf{C} . Os números indicam os pares de pontos mais próximos de \mathbf{M}_p e \mathbf{P}_p (MRI e CT respectivamente).

A Equação de registro $\mathbf{M}_p = \mathbf{R}\mathbf{P}_p$ pode ser reescrita conforme a Equação abaixo:

$$\mathbf{M}_p = \mathbf{R}\mathbf{P}_p\mathbf{O}, \quad (2.87)$$

onde \mathbf{O} é uma matriz de permutação, a qual é usada para colocar pontos correspondentes na mesma ordem (Wang et al., 1996).

Algoritmo 3 Algoritmo de recuperação da correspondência entre os pontos (Wang et al., 1996)

1. Cálculo das matrizes de correlação $\mathbf{P}_{cp}^T\mathbf{P}_{cp}$ e $\mathbf{M}_{cp}^T\mathbf{M}_{cp}$ onde \mathbf{P}_{cp} e \mathbf{M}_{cp} centraliza \mathbf{P}_p e \mathbf{M}_p .
 2. Cálculo dos autovetores e autovalores Q_P e Q_M aplicando $\mathbf{P}_{cp}^T\mathbf{P}_{cp}$ e $\mathbf{M}_{cp}^T\mathbf{M}_{cp}$.
 3. Cálculo da afinidade h_{ij} .
 4. *Matching* através do algoritmo de Karp.
-

Outra alternativa de calcular a correspondência é utilizar uma árvore K-d, a qual acelera a busca dos vizinhos mais próximos. Neste algoritmo, cada nó representa uma partição do conjunto de pontos em dois nós sucessores. A raiz representa toda a nuvem de pontos e cada folha um ponto. Árvores K-d podem ser usadas para obter a matriz de permutação O no rearranjo da matriz \mathbf{P} . Tanto o algoritmo baseado na afinidade (Wang et al., 1996) (ver algoritmo 3), quanto árvores K-d aumentam a velocidade de busca em relação à busca exaustiva do subconjunto de linhas de \mathbf{P}_p que minimiza a soma das distâncias às linhas correspondentes de \mathbf{M}_p .

O Algoritmo 4 sumariza o método de registro por ICP em quatro passos: (i) Os conjuntos de pontos \mathbf{M}_p e \mathbf{P}_p são gerados através do processo de segmentação; (ii) através do operador \mathbf{C} , calcula-se o subconjunto \mathbf{P}_{pc} ; (iii) cálculo de \mathbf{T} por LS e transformação de corpo rígido do conjunto de pontos \mathbf{P}_{pc} ; e (iv) verificação do critério de parada.

Algoritmo 4 Algoritmo de registro ICP

Input: CT e MRI nós da malha dos marcadores

Output: Matriz de rotação \mathbf{R} e translação \mathbf{t}

1. Segmentação de \mathbf{M} e \mathbf{P} ; **while** $((d = 1/N_p \sum_{i=1}^{N_p} \|m_{pi} - p_{pci}^*\|^2 \leq \epsilon)$ **do**
 2. $y = \{m_{pi} \in \mathbf{M}_p | p_{pci} \in \mathbf{P}_{pc} : \mathbf{P}_{pc} = \mathbf{C}(\mathbf{M}_p, \mathbf{P}_p)\}$ onde $\mathbf{M}_p = \mathbf{R}\mathbf{P}_{pc}$, $\mathbf{M}_p = \{m_{pi}\}_1^{N_M}$, $\mathbf{P}_{pc} = \{p_{pci}\}_1^{N_P}$ e $\mathbf{C}(\mathbf{M}_p, \mathbf{P}_p) = \operatorname{argmin} \|m_{pi} - p_{pi}\|$.
 3. Estimacão por mínimos quadrados de \mathbf{T} .
 4. $\mathbf{P}_{pc}^* = \mathbf{R}\mathbf{P}_{pc}$ (*Transformação*)

end

O passo 2 do Algoritmo 4, estimacão de \mathbf{T} pelo método de registro por mínimos

quadrados (ver seção 2.8), reduz a distância média entre os pontos correspondentes durante cada iteração do ICP, onde a determinação do ponto mais próximo reduz a distância para cada ponto individualmente. Segundo Besl e McKay (1992), o algoritmo de pontos mais próximos iterativo sempre converge monotonicamente para um o mínimo local, onde a função objetiva é a distância quadrática média. Para cada iteração, o erro quadrático médio é dado por:

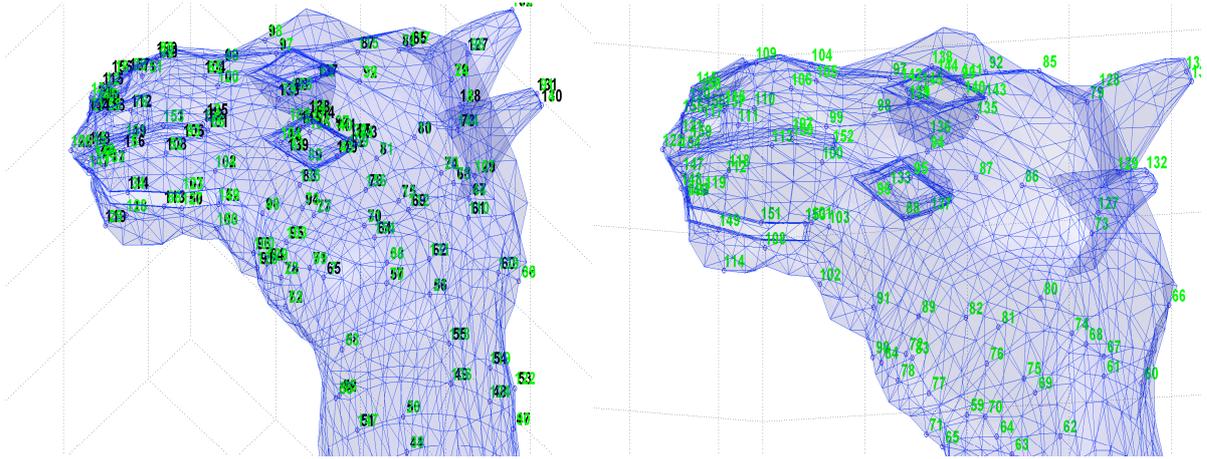


Figura 2.12: Busca dos vizinhos mais próximos.

$$e_k = \|\mathbf{M}_p - \mathbf{P}_{pck}\|, \quad (2.88)$$

onde e_k é a norma do erro de cada iteração.

A distância quadrática média d_k após a transformação é:

$$d_k = \|\mathbf{M}_{ppcik} - \mathbf{R}_k \mathbf{P}_k \mathbf{O}_k\|. \quad (2.89)$$

onde \mathbf{R}_k é determinado de forma que $d_k \leq e_k$. Na próxima iteração aplica-se a transformação \mathbf{T} no conjunto de pontos \mathbf{P}_{pck} gerando \mathbf{P}_{pck+1} . Se a correspondência for mantida entre as iterações k e $k + 1$ o erro quadrático médio e_{k+1} é dado por (Besl e McKay, 1992):

$$e_{k+1} = d_k. \quad (2.90)$$

Outras implementações de registro por ICP são descritas em Trucco et al. (1999) e Zinβer et al. (2003). Em Zinβer et al. (2003) há variações no ICP como seleção hierárquica de pontos, implementação da árvores K-d para busca do vizinho mais próximo e monitorização dos parâmetros de movimento no critério de parada.

de s :

$$w_i = \begin{cases} 1, & |s_i| \leq 2.5\sigma \\ 0, & \text{outro caso} \end{cases} \quad (2.93)$$

\mathbf{R} final é calculado através de um problema de mínimos quadrados ponderados.

2.10 Métodos baseados na intensidade do voxel

Os métodos de registro baseados na intensidade do voxel usam o conceito de medida de similaridade, a qual tem um valor máximo quando as imagens estão perfeitamente alinhadas. Essa medida de similaridade é calculada usando diretamente o valor da intensidade do voxel. Esses métodos são constituídos por quatro elementos: (i) medida de similaridade; (ii) método de otimização; (iii) interpolação; e (iv) transformação.

Para o alinhamento das imagens escolheu-se a informação mútua (MI) como medida de similaridade entre as imagens. A informação mútua $I(\mathbf{M}; \mathbf{P})$ entre duas imagens \mathbf{M} e \mathbf{P} é calculada por (ver seção 2.2):

$$I(\mathbf{M}; \mathbf{P}) = H(\mathbf{M}) + H(\mathbf{P}) - H(\mathbf{M}, \mathbf{P}), \quad (2.94)$$

onde $H(\cdot)$ é a entropia de uma variável aleatória definida por $H(x) \equiv - \sum_{x \in X} p(x) \ln p(x)$ ou $H(X) = -E[\ln(p(X))]$. Assim, têm-se $H(\mathbf{M})$ a entropia de \mathbf{M} , $H(\mathbf{P})$ a entropia de \mathbf{P} e $H(\mathbf{M}, \mathbf{P})$ a entropia conjunta de \mathbf{M} e \mathbf{P} . Se \mathbf{M} e \mathbf{P} forem independentes, têm-se:

$$H(\mathbf{M}, \mathbf{P}) = H(\mathbf{M}) + H(\mathbf{P}) \quad (2.95)$$

e

$$H(\mathbf{M}|\mathbf{P}) = H(\mathbf{M}), \quad (2.96)$$

$H(\mathbf{M}|\mathbf{P})$ é a entropia condicional.

O registro de imagens tridimensionais busca maximizar a informação mútua entre a imagem de referência \mathbf{M} e a imagem móvel \mathbf{P} , sem uma etapa de segmentação, através da transformada de corpo rígido \mathbf{T} . Essa transformada é parametrizada por μ (ver Seção 1.2):

$$\mathbf{T}(\mu, \mathbf{x}), \quad (2.97)$$

onde $\mathbf{x} \in \mathbb{R}^3$ é o conjunto de dados usados para encontrar o conjunto de parâmetros μ

que otimiza a transformação de corpo rígida \mathbf{T} .

Nas implementações de Thevenaz e Unser (1998) e Viola (1995) de registo por informação mútua usa-se a transformação de corpo rígido. A Equação 2.94 pode ser reescrita (Viola, 1995):

$$I(\mathbf{M}(\mathbf{x}); \mathbf{P}(\mathbf{T}(\mu, \mathbf{x}))) = H(\mathbf{M}(\mathbf{x})) + H(\mathbf{P}(\mathbf{T}(\mu, \mathbf{x}))) - H(\mathbf{M}(\mathbf{x}), \mathbf{P}(\mathbf{T}(\mu, \mathbf{x}))). \quad (2.98)$$

O lado direito da Equação 2.98 possui três termos. O primeiro termo não depende de \mathbf{T} e corresponde à entropia da imagem de referência \mathbf{M} . O segundo termo, a entropia da imagem móvel, não depende de \mathbf{T} , pois a entropia de um conjunto de pontos não se altera através de transformações de corpo rígido. O terceiro termo, o negativo da entropia conjunta $H(\mathbf{M}(\mathbf{x}), \mathbf{P}(\mathbf{T}(\mu, \mathbf{x})))$ mapeia a relação entre $\mathbf{M}(\mathbf{x})$ e $\mathbf{P}(\mathbf{T}(\mu, \mathbf{x}))$. Têm-se o máximo da informação mútua quando $H(\mathbf{M}(\mathbf{x}), \mathbf{P}(\mathbf{T}(\mu, \mathbf{x})))$ é mínima.

Viola (1995) estima a densidade de probabilidade através do Método da Janela de Parzen. A entropia pode ser expressa como o valor esperado E do logaritmo negativo da densidade de probabilidade f :

$$H(a) = E[-\ln(f(a))]. \quad (2.99)$$

A função densidade de probabilidade $f(a)$ é desconhecida. Assim, é utilizada uma aproximação de $f(a)$ por uma sobreposição de densidades gaussianas centradas em a_i :

$$f(a) \approx \frac{1}{N_A} \sum_{i=1}^{N_A} G_\eta(a - a_i), \quad (2.100)$$

onde $G_\eta(a)$:

$$G_\eta(a) \equiv \sum_{i=1}^{N_A} \frac{1}{(\eta\sqrt{2\pi})^d} \exp\left(-\frac{1}{2}\left(\frac{a - a_i}{\eta}\right)^2\right), \quad (2.101)$$

onde η é a variância (tamanho da janela), d a dimensão e N_A o número de gaussianas usado na aproximação.

Substituindo a Equação 2.101 em 2.100, têm-se:

$$f(a) \approx \frac{1}{N_A} \sum_{i=1}^{N_A} \frac{1}{(\eta\sqrt{2\pi})^d} \exp\left(-\frac{1}{2}\left(\frac{a - a_i}{\eta}\right)^2\right). \quad (2.102)$$

Assim, a Equação 2.99 pode ser reescrita da seguinte maneira:

$$H(a) \equiv E\left[-\ln\left(\frac{1}{N_A} \sum_{i=1}^{N_A} \frac{1}{(\eta\sqrt{2\pi})^d} \exp\left(-\frac{1}{2}\left(\frac{a - a_i}{\eta}\right)^2\right)\right)\right]. \quad (2.103)$$

Para encontrar a transformação que alinha as imagens (Viola, 1995), calcula-se a derivada de $I(\mathbf{M}(\mathbf{x}), \mathbf{P}(\mathbf{T}(\mu, \mathbf{x})))$ em relação a μ :

$$\frac{d}{d\mu} I(\mathbf{M}(\mathbf{x}), \mathbf{P}(\mathbf{T}(\mu, \mathbf{x}))) = 0, \quad (2.104)$$

e, como

$$\begin{aligned} \frac{d}{d\mu} I(\mathbf{M}(\mathbf{x}); \mathbf{P}(\mathbf{T}(\mu, \mathbf{x}))) &= \frac{d}{d\mu} [H(\mathbf{M}(\mathbf{x})) + H(\mathbf{P}(\mathbf{T}(\mu, \mathbf{x}))) - H(\mathbf{M}(\mathbf{x}), \mathbf{P}(\mathbf{T}(\mu, \mathbf{x})))] \\ &= \frac{d}{d\mu} H(\mathbf{M}(\mathbf{x})) + \frac{d}{d\mu} H(\mathbf{P}(\mathbf{T}(\mu, \mathbf{x}))) - \frac{d}{d\mu} H(\mathbf{M}(\mathbf{x}), \mathbf{P}(\mathbf{T}(\mu, \mathbf{x}))) \\ &= -\frac{d}{d\mu} H(\mathbf{M}(\mathbf{x}), \mathbf{P}(\mathbf{T}(\mu, \mathbf{x}))), \end{aligned} \quad (2.105)$$

pois $H(\mathbf{M}(\mathbf{x}))$ não depende de μ e $H(\mathbf{P}(\mathbf{T}(\mu, \mathbf{x})))$ não se altera devido a transformação de corpo rígido.

2.11 Conclusão

Neste capítulo foram descritos métodos de registro para o alinhamento de imagens médicas. Nos métodos de registro baseados em marcadores externos, a identificação de pontos reduz o conteúdo de informação da imagem a um conjunto esparço de pontos, o que permite a implementação de métodos de otimização mais rápidos (Maintz e Viergever, 1997). O método de registro por LS reduz o conjunto de pontos em apenas alguns pares que representam os centróides dos marcadores, diferente do método de registro por PCA e ICP que utilizam todos os pontos dos marcadores sem recuperar a correspondência entre os conjuntos. Os métodos baseados na intensidade do voxel usam todo o conteúdo da imagem e requerem grandes regiões de sobreposição. No próximo capítulo, os resultados das técnicas de registro descritas são apresentados: registro CT-MRI e registro MRI-MRI.

Capítulo 3

Resultados

3.1 Introdução

Este capítulo apresenta os experimentos de registro de corpo rígido para o alinhamento de imagens monomodais e multimodais usando métodos baseados em pontos, superfícies e voxels.

Inicia-se pela descrição da base de dados, detalhada na Seção 3.2. A seguir, nas seções 3.3 e 3.4, apresenta-se os resultados obtidos, respectivamente, para registros multimodais e monomodais usando as técnicas baseadas em PCA, PCA-ICP e LS descritas no Capítulo 2. Essas técnicas requerem uma interação para segmentação/identificação de estruturas comuns entre as imagens de referência \mathbf{M} e móvel \mathbf{P} . No registro multimodal (especificamente CT-MRI) são usados pontos, que representam os centros ou vértices das malhas dos fiduciais. Os conjuntos móveis que contêm os centros ou vértices dos fiduciais, \mathbf{P}_p , são extraídos pela segmentação de regiões de imagens de tomografia computadorizada, enquanto que os conjuntos fixos \mathbf{M}_p das mesmas regiões são extraídos de imagens de ressonância magnética. As regiões em comum das imagens \mathbf{M} e \mathbf{P} são os fiduciais.

A comparação dos métodos baseados em superfícies e pontos (segmentação dos fiduciais) é feita através do alinhamento de 3 imagens de tomografia computadorizada (CT) de moldes da arcada dentária com imagens de ressonância magnética adquiridas de pacientes. As imagens de ressonância magnética apresentam direções de fatiamento e resoluções diferentes. Essas imagens são consideradas como as imagens de referência (\mathbf{M}) para o alinhamento. As imagens de tomografia foram adquiridas de moldes dentários com aparelhos orais para o tratamento da apnea do sono, gerando dois posicionamentos de mandíbula: posição de relaxamento e posição onde a mandíbula é alinhada com o maxilar (ver figuras 3.1 3.2 e 3.3). As imagens de tomografia são consideradas como imagens móveis (\mathbf{P}) para o registro. Os moldes CT e imagens MRI

são adquiridos de dois tipos de pacientes: peso normal e sobrepeso. Pacientes com sobrepeso são importantes porque seus registros das vias aéreas superiores fornecem informações importantes para a compreensão do processo da apnea do sono.

No registro monomodal são alinhadas apenas imagens de ressonância magnética. Os resultados são apresentados na Seção 3.4. A base de imagens de ressonância magnética é descrita a seguir.

3.2 Base de dados

A base de imagens de ressonância magnética é composta por imagens adquiridas de pacientes com pesos diferentes para o estudo da apnea do sono. Uma forma de tratamento para a apnea do sono é o uso de um aparelho oral que mantém a mandíbula alinhada com o maxilar. Em todas as imagens adquiridas, o paciente usa o aparelho oral que modifica a posição da mandíbula. São dois tipos de aparelho oral: um que mantém a mandíbula do paciente alinhada com o maxilar e outro que coloca a mandíbula na posição de relaxamento. O aparelho oral é constituído por um tipo de resina acrílica transparente que se encaixa nos dentes do paciente, o qual não aparece nas imagens de ressonância magnética. A seguir, são descritos os processos de aquisição de ressonância magnética de pacientes de peso normal e com sobrepeso.

Paciente de peso normal - Mandíbula alinhada com maxilar

Para o registro, usaram-se 16 imagens de ressonância magnética de um paciente de peso normal usando aparelho oral, sendo 7 imagens com a posição de mandíbula indicada na Figura 3.1 e 9 imagens com a posição de relaxamento da mandíbula indicada na Figura 3.2. A Tabela 3.1 lista as imagens, a dimensão e a orientação da varredura do paciente normal com a posição da mandíbula alinhada com o maxilar 3.1.

Tabela 3.1: Imagens MRI - Paciente normal com a mandíbula alinhada com maxilar

MRI		
Imagem	Dimensão (voxels)	Corte
256732529_301_T2W_TSE_Sag_CLEAR_20080220.hdr	512 x 512 x 36	Sagital
256732529_401_T2_Sag_sFOV_CLEAR_20080220.hdr	288 x 288 x 40	Sagital
256732529_501_T2W_50TE_Sag_CLEAR_20080220.hdr	512 x 512 x 36	Sagital
256732529_701_PD_35TE_sFOVSag_CLEAR_20080220.hdr	288 x 288 x 42	Sagital
256732529_801_T2_3D_VISTA_Sag_SENSE_20080220.hdr	512 x 512 x 128	Sagital
256732529_1001_COR_PD_20080220.hdr	512 x 512 x 84	Coronal
256732529_1101_SAG_PD_20080220.hdr	512 x 512 x 84	Sagital

Paciente de peso normal - Posição de relaxamento da mandíbula

A Tabela 3.2 lista as imagens do paciente normal na posição de relaxamento da mandíbula. Nessa posição a língua ocupa quase toda a cavidade bucal, diferente da posição indicada na Figura 3.1, onde o maxilar está alinhado com a mandíbula. A Figura 3.2 mostra o posicionamento de relaxamento da mandíbula para esse tipo de aparelho oral.

Tabela 3.2: Imagens MRI - Paciente normal com aparelho oral (relaxamento)

MRI		
Imagem	Dimensão	Orientação
257340011_501_T2W_Sag_loc_20080227.hdr	512 x 512 x 25	Sagital
257340011_701_T2_3D_VISTA_Sag_SENSE_20080227.hdr	512 x 512 x 128	Sagital
257340011_801_PD_SAG_20080227.hdr	512 x 512 x 42	Sagital
257340011_901_PD_COR_20080227.hdr	512 x 512 x 68	Coronal
257340011_1001_PD_AXIAL_20080227.hdr	512 x 512 x 84	Axial
257340011_1101_IR_SE_IR1500_20080227.hdr	176 x 176 x 30	-
257340011_1201_IR_SE_IR1000_20080227.hdr	176 x 176 x 30	-
257340011_1301_IR_SE_IR600_20080227.hdr	176 x 176 x 30	-
257340011_1501_IR_SE_IR100_20080227.hdr	176 x 176 x 30	-

Paciente com sobrepeso - Posição de relaxamento da mandíbula

As imagens adquiradas do paciente com sobrepeso são listadas na Tabela 4.3. Para esse paciente, têm-se apenas imagens com o aparelho oral na posição de relaxamento indicada na Figura 3.3.

Tabela 3.3: Imagens MRI - Paciente com sobrepeso com aparelho oral (relaxamento)

MRI		
Imagem	Dimensão	Orientação
269860707_701_PD_COR_SENSE_20080721.hdr	512 x 512 x 68	Coronal
269860707_801_PD_AXIAL_SENSE_20080721.hdr	512 x 512 x 84	Axial
269860707_1301_PD_SAG_CLEAR_20080721.hdr	512 x 512 x 42	Sagital
269860707_1401_PD_COR_SENSE_20080721.hdr	512 x 512 x 68	Coronal
269860707_1501_PD_AXIAL_SENSE_20080721.hdr	512 x 512 x 84	Axial

3.3 Registro CT-MRI

A Figura 3.4 mostra um exemplo de alinhamento CT-MRI através de superfícies. A superfície vermelha representa a superfície do molde da arcada dentária, enquanto que superfície cinza representa a superfície extraída da imagem MRI. As imagens de ressonância magnética não apresentam informações sobre tecidos densos e sem água como ossos e dentes. Os espaços vazios das imagens MRI podem ser preenchidos pelas

imagens de tomografia computadorizada, facilitando a segmentação da língua através da determinação das bordas dos dentes. Entretanto, não há uma região considerável de sobreposição entre as duas imagens de modalidades diferentes.

As figuras 3.1, 3.2 e 3.3 mostram as posições da mandíbula mantidas pelo aparelho oral. Neste aparelho estão inseridos os fiduciais de óleo, os quais são considerados como o objeto de registro. Os fiduciais, ou marcadores de óleo, são estruturas cilíndricas inclusas no aparelho oral. O número total de marcadores é 8, 4 em cada lado da boca. As figuras 3.1, 3.2 e 3.3 mostram que é possível a reconstrução da geometria dos fiduciais a partir das imagens de tomografia computadorizada.

Usou-se tomografia computadorizada apenas para adquirir imagens do molde da arcada dentária dos pacientes, uma vez que os efeitos da tomografia computadorizada podem ser nocivos ao corpo humano quando realizada várias vezes na mesma região. Nessas imagens estão presentes apenas informação da arcada dentária. O molde é constituído por gesso, condição favorável para a aquisição de imagens usando tomografia computadorizada.

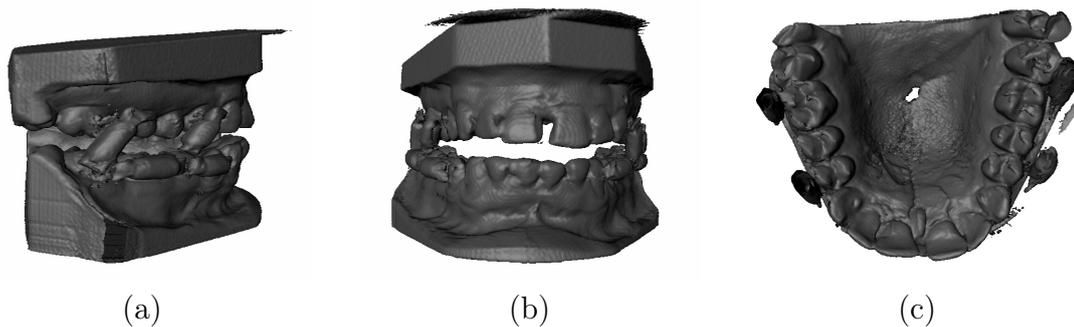


Figura 3.1: Molde da arcada dentária com o aparelho oral para posicionamento da mandíbula (paciente normal). (a) Vista Sagittal, (b) Vista Coronal, (c) Vista Axial.

A seguir são apresentados os resultados obtidos utilizando o registro baseado em superfícies (Seção 3.3.1) e os resultados dos métodos baseados em pontos (a seção 3.3.2).

3.3.1 Métodos baseados em superfícies

O registro CT-MRI usa regiões segmentadas de imagens de ressonância magnética e de tomografia computadorizada. Essas regiões representam os fiduciais, comuns nas duas modalidades. As superfícies tridimensionais dos moldes, reconstruídas pelas imagens CT, podem ser visualizadas nas figuras 3.1 3.2 e 3.3, onde as duas primeiras foram adquiridas do molde de gesso do paciente normal e a terceira do paciente com sobrepeso. A dimensão das imagens CT é 512 x 512 x 512. Para o paciente normal, tem-se duas

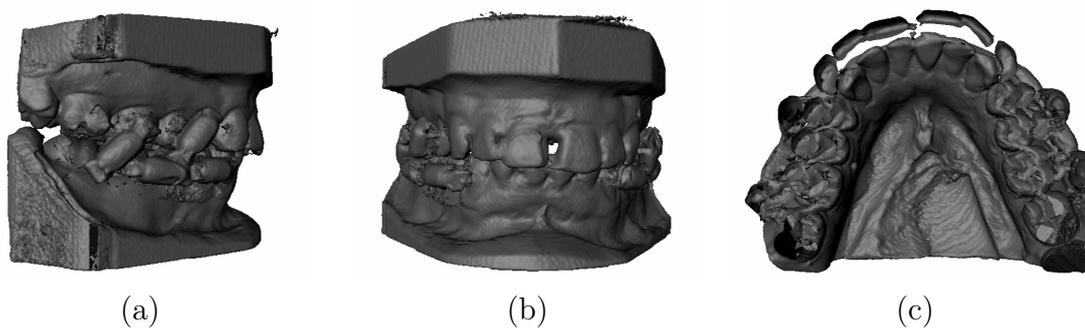


Figura 3.2: Molde da arcada dentária com o aparelho oral para posicionamento de relaxamento da mandíbula (paciente normal). (a) Vista Sagittal, (b) Vista Coronal, (c) Vista Axial.

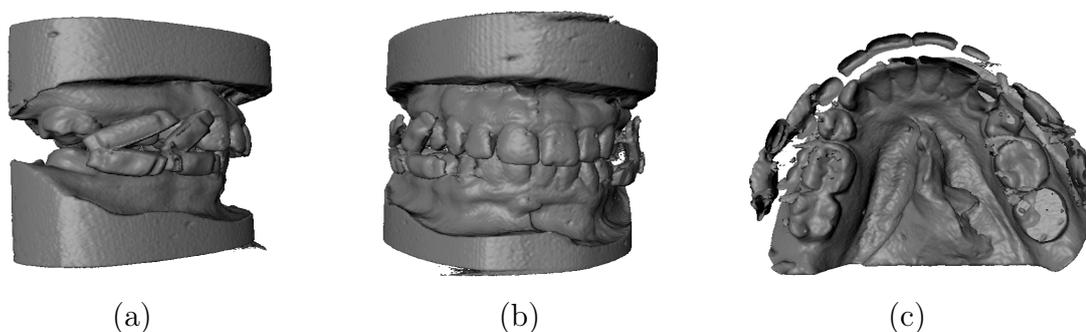


Figura 3.3: Molde da arcada dentária com o aparelho oral para posicionamento de relaxamento da mandíbula (paciente normal). (a) Vista Sagittal, (b) Vista Coronal, (c) Vista Axial.

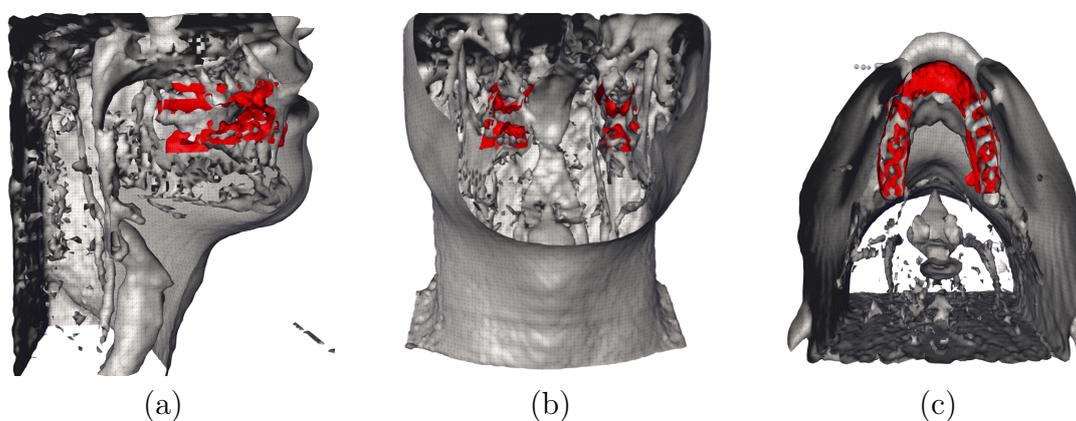


Figura 3.4: Registro CT-MRI:(a) Vista Sagittal;(b) Vista Coronal; (c) Vista Axial.

posições de mandíbula mantidas pelo aparelho oral para o tratamento da apnea do sono. Nesse aparelho oral estão inseridos os fiduciais de óleo, visíveis nas duas modalidades e usados como referência para esse alinhamento. As Figuras 3.5 (a) (b) mostram as superfícies dos fiduciais geradas pela segmentação de regiões das imagens de ressonância e tomografia computadorizada. Os conjuntos \mathbf{M}_p e \mathbf{P}_p são os vértices dessas superfícies.

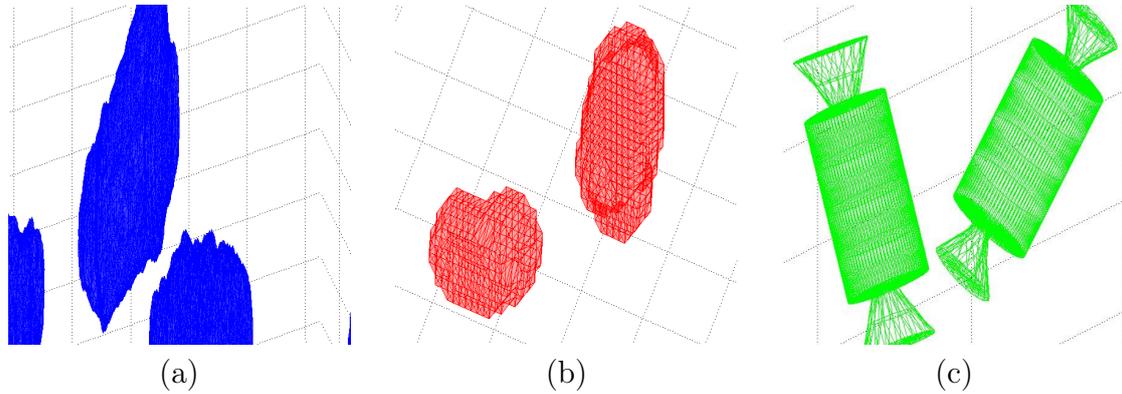


Figura 3.5: (a) Superfícies dos fiduciais extraídas da imagem CT (usando a segmentação do Amira). (b) Superfícies dos fiduciais extraídas de uma imagem MRI. (c) Modelo 3D dos fiduciais.

Análise em Componentes Principais

No método de alinhamento por PCA, usaram-se três combinações diferentes de imagens para o registro CT-MRI:

- Paciente normal (imagem MRI) - Aparelho oral (imagem CT);
- Paciente normal (imagem MRI) - Relax (imagem CT);
- Paciente com sobrepeso (imagem MRI) - Aparelho Oral (imagem CT).

O registro de corpo rígido pela PCA requer a segmentação dos fiduciais para o alinhamento dos eixos das componentes principais das superfícies de vértices \mathbf{M}_p e \mathbf{P}_p . Uma característica do registro por PCA é a ausência de correspondência nos conjuntos de pontos para o alinhamento. Após a etapa de segmentação das regiões que representam os fiduciais, as superfícies cujos vértices são os conjuntos fixo \mathbf{M}_p e móvel \mathbf{P}_p são geradas. As faces das superfícies são desprezadas no registro. Calcula-se as matrizes de covariância $\mathbf{C}_{\mathbf{M}_p}$ e $\mathbf{C}_{\mathbf{P}_p}$ usando os vértices. A rotação \mathbf{R} é calculada através do produto de matrizes geradas pela decomposição SVD de $\mathbf{C}_{\mathbf{M}_p}$ e $\mathbf{C}_{\mathbf{P}_p}$. A translação é calculada pelo produto da rotação pela média. Têm-se o par (\mathbf{R}, \mathbf{t}) , que é a transformada de corpo rígido que alinha \mathbf{M}_p e \mathbf{P}_p (ver Seção 2.7).

A Figura 3.8 (a) mostra o histograma de distância do alinhamento CT-MRI para o registro de imagens adquiridas do paciente normal. O histograma corresponde às realizações dos alinhamentos de 7 imagens de ressonância magnética (ver Tabela 3.1) com 1 imagem de tomografia computadorizada na posição de alinhamento entre a mandíbula e o maxilar (ver Figura 3.1). A distância entre os pares de pontos é calculada utilizando os vizinhos mais próximos. O histograma de distâncias é mostrado na Figura 3.8.

Para o outro alinhamento CT-MRI, foram usadas 9 imagens de MRI na posição de relaxamento da mandíbula (ver Tabela 3.2) e a imagem CT da Figura 3.2. O resultado do alinhamento é o histograma de distâncias da Figura 3.8 (b). Esse registro corresponde ao posicionamento das imagens adquiridas do paciente com o posicionamento de relaxamento da mandíbula. As referências para o alinhamento são as imagens de MRI, semelhante ao caso do alinhamento das imagens do paciente com a posição de maxilar e mandíbula alinhados.

A Figura 3.8 (c) mostra o histograma para o alinhamento de 5 imagens de MRI de um paciente com sobrepeso e 1 imagem de CT, correspondente à terceira configuração de imagens. Assim como os histogramas das figuras 3.8 (a) e (b), o histograma da Figura 3.8 (c) apresenta grande dispersão.

O número de fiduciais segmentados das imagens do paciente com sobrepeso é menor que o número de fiduciais segmentados das imagens do paciente normal. Alguns fiduciais não são visíveis devido a obturações do paciente, as quais interagem com o campo magnético distorcendo as imagens nessas regiões. Na Figura 3.6, a malha (vermelha) à direita em 3.6 (a) corresponde à extração da superfície da região distorcida da imagem. Essa região pode ser visualizada nas Figuras 3.6 (b) e (c). Essa distorção causa a perda de alguns fiduciais na imagens. A Figura 3.7 mostra exemplos de alinhamento dos conjuntos \mathbf{M}_p e \mathbf{P}_p após o registro por PCA.

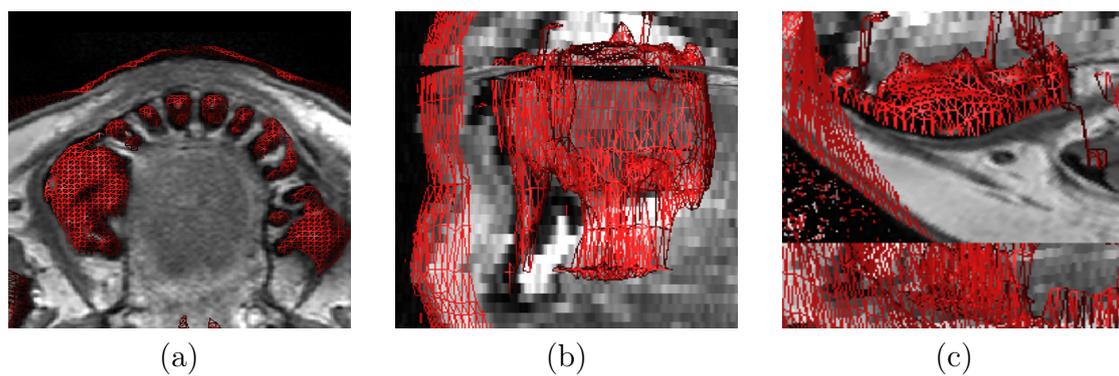


Figura 3.6: Região com distorção causada pela interação entre o campo magnético e artefatos de metais (obturações).

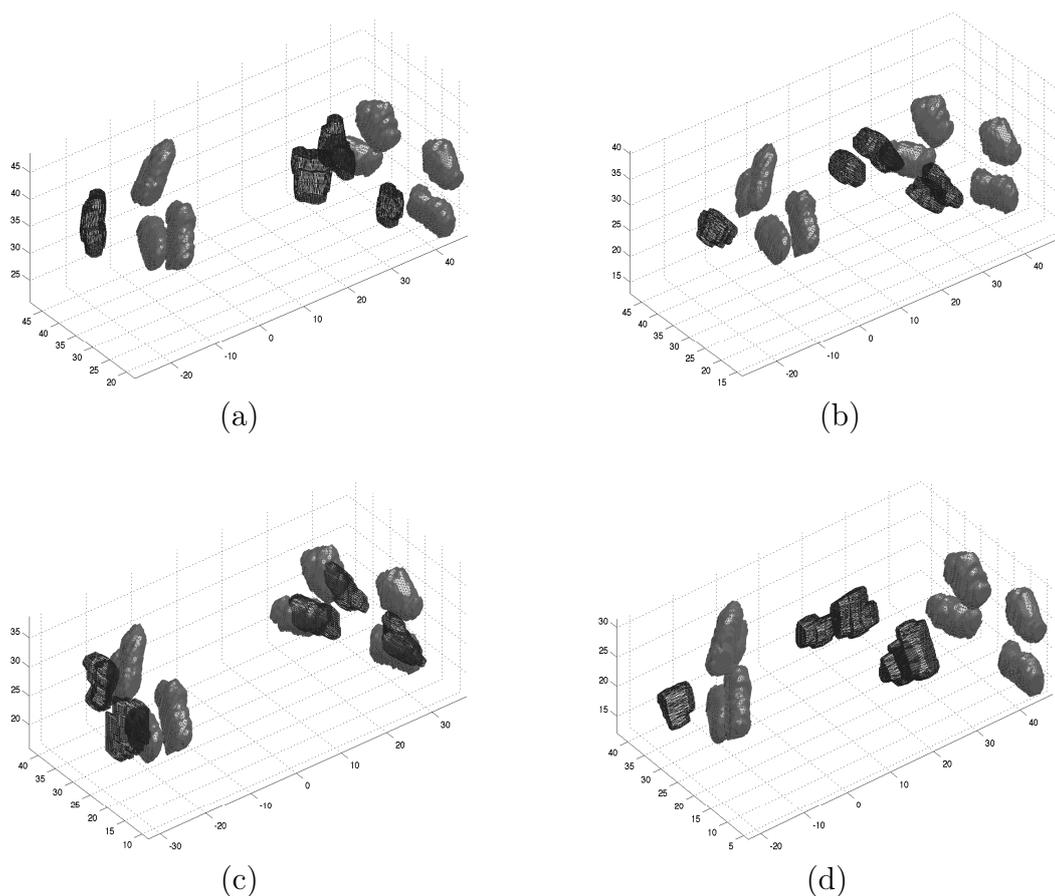


Figura 3.7: Alinhamento de fiduciais segmentados de 4 imagens MRI diferentes (paciente com sobrepeso) por registro baseado em PCA.

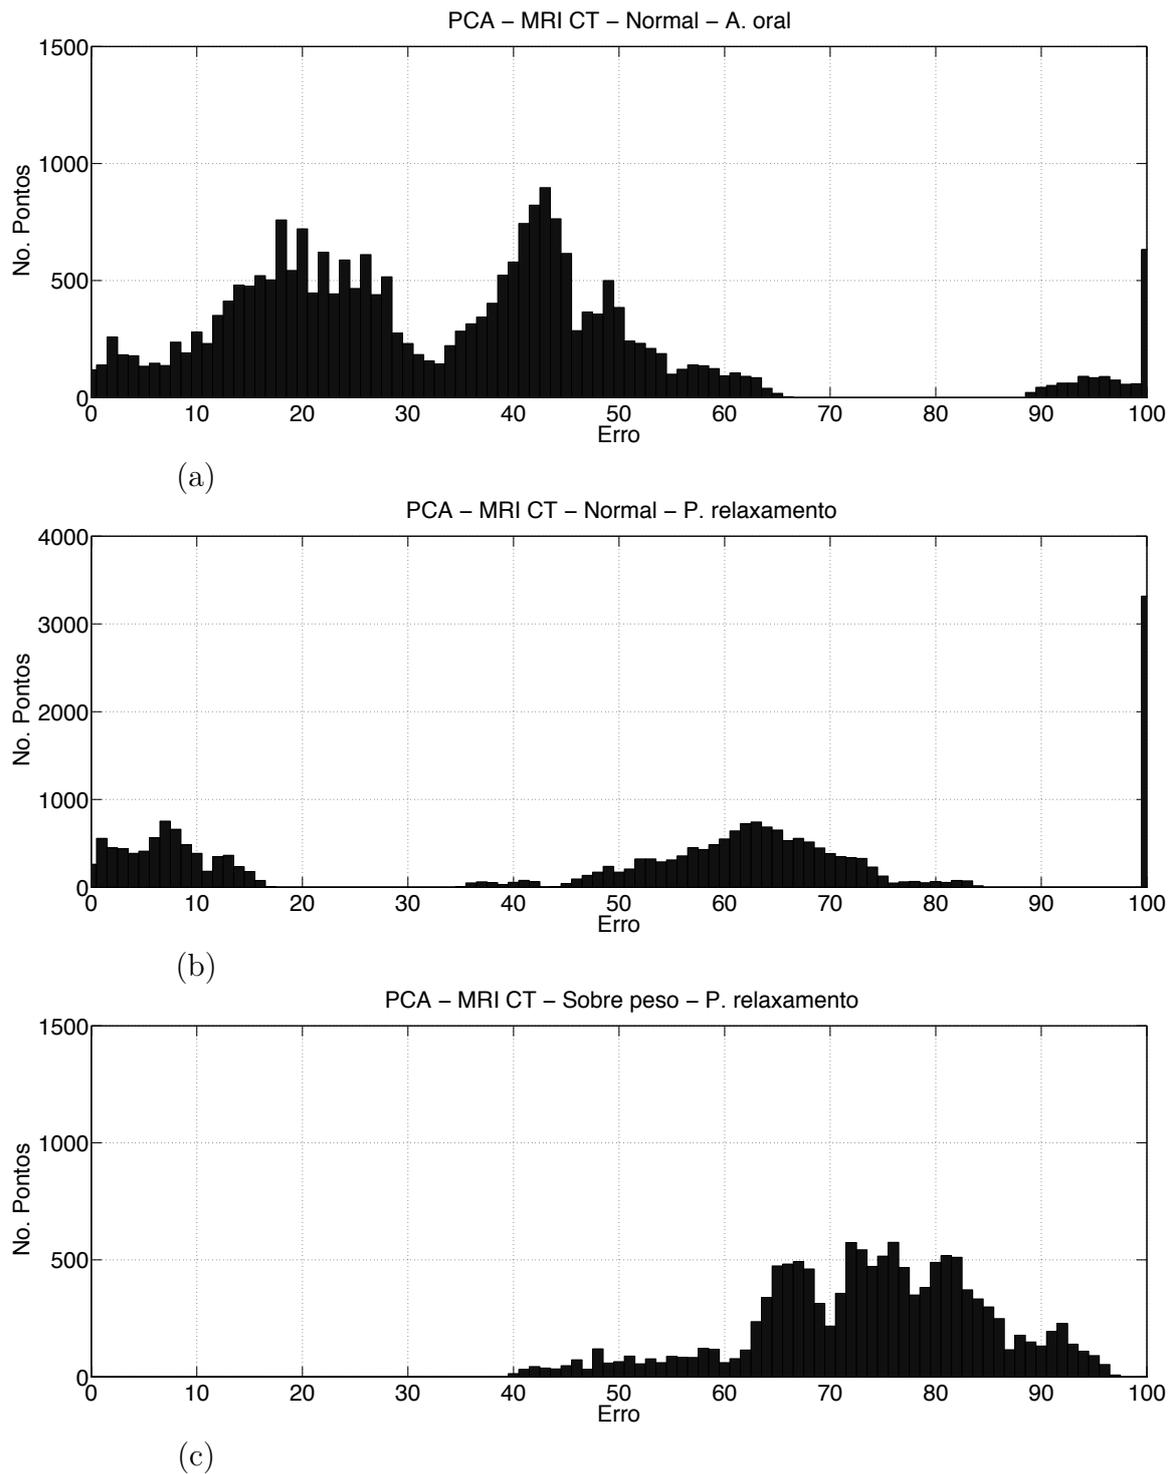


Figura 3.8: (a) Histogramas de distâncias para o alinhamento usando PCA para o alinhamento de imagens de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar). (b) Histograma de distâncias para o alinhamento usando PCA para o alinhamento de imagens de um paciente com peso normal com posição de relaxamento da mandíbula. (c) Histograma de distâncias para o alinhamento usando PCA para o alinhamento de imagens adquiridas de um paciente com sobrepeso com posição de relaxamento do mandíbula.

Ponto mais próximo iterativo - ICP

Para a validação do método de registro por ICP, foram usadas as estruturas segmentadas do registro por PCA das imagens das Tabelas 3.1, 3.2 e 3.3. A transformação inicial é calculada por PCA, gerando uma sobreposição maior entre os conjuntos de pontos \mathbf{M}_p e \mathbf{P}_p (ver Figura 3.7). Essa sobreposição dos conjuntos de pontos no espaço é importante para o cálculo de correspondência. O ICP é uma alternativa eficiente para o ajuste fino do alinhamento por PCA.

Por ser um método iterativo de registro (ver Algoritmo 4 no Capítulo 2), o algoritmo ICP requer um tempo maior para calcular a matriz de rotação e translação \mathbf{T} . A etapa principal do ICP é a busca dos pontos mais próximos, correspondendo à parte iterativa do método. No registro por PCA, o cálculo de \mathbf{T} é direto, sem considerar a correspondência dos pontos. Para conjuntos de pontos desbalanceados, por exemplo, com muitos *outliers*, o cálculo dos vizinhos mais próximos pode ser impreciso, levando a solução a um mínimo local. As diferenças nas resoluções das imagens (resolução maior nas imagens de tomografia que apresenta mais fatias por milímetro e uma resolução menor nas imagens de ressonância magnética) gera essa diferença no número de pontos. Ao segmentar as imagens, os conjuntos de pontos (vértices das malhas) gerados pelas regiões segmentadas nas imagens de tomografia computadorizada apresentam densidade maior que o conjunto de pontos extraídos das imagens de ressonância magnética.

Nos experimentos 1 e 2 (registro de imagens do paciente com peso normal), é possível segmentar quase todos os fiduciais nas imagens de ressonância magnética, gerando uma distorção nas formas dos fiduciais devido à resolução baixa. Por outro lado em imagens com resolução alta (número de fatias por milímetro), a segmentação torna-se uma tarefa que consome muito tempo. Esses dois casos (experimentos 1 e 2) correspondem ao caso do mesmo número de estruturas segmentadas, onde tem-se grande parte dos fiduciais segmentados.

No experimento 3, registro de imagens de um paciente com sobrepeso, tem-se dois tipos de desbalanceamento dos conjuntos \mathbf{M}_p e \mathbf{P}_p : um gerado pelas resoluções diferentes das imagens; outro pelo número de marcadores segmentados nas imagens de ressonância magnética. Analisando a Figura 3.6, a segmentação dos fiduciais do lado esquerdo é dificultada pela distorção causada pela interação entre o campo magnético e artefatos de metal na boca do paciente. Para o cálculo de \mathbf{T} são necessárias pelo menos três estruturas segmentadas não-colineares, assim a distorção não impede o alinhamento dos conjuntos.

A Figura 3.10 mostra os histogramas de distâncias entre pontos correspondentes referentes aos experimentos 1, 2 e 3. Comparando com o histograma da Figura 3.8, observa-se que o ICP alinha os conjuntos de pontos reduzindo a distância entre os pares

de pontos. Em um histograma de registro ideal, espera-se que a média dos pontos em torno de zero. No alinhamento fino por ICP, há redução da distância entre pontos, mas a média das distâncias não é zero. Os valores em torno de zero no histograma indicam sobreposição significativa dos conjuntos de pontos \mathbf{M}_p e \mathbf{P}_p .

O método de registro baseado em pontos (resultados descritos na seção 3.3.2) busca balancear os conjuntos \mathbf{M}_P e \mathbf{P}_p através da identificação de alguns pontos comuns nas imagens. Como a identificação dos pontos requer que o usuário mantenha a correspondência, apenas poucos pontos são usados para o registro. Essa identificação resolve o problema de desbalaceamento causado pela resolução e pela ausência dos fiduciais.

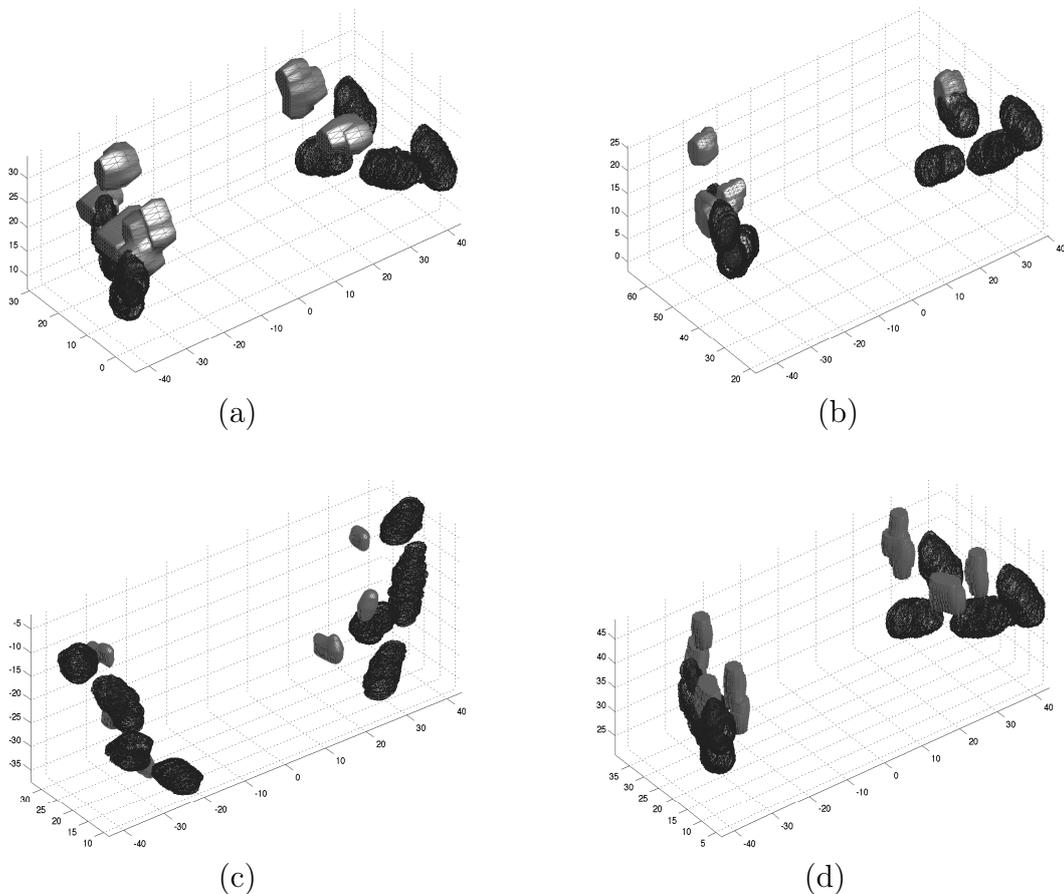
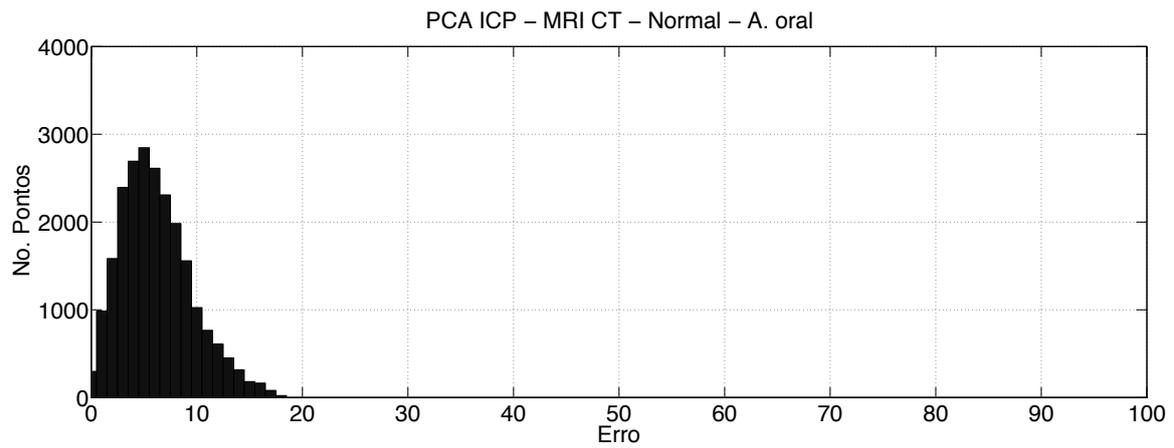


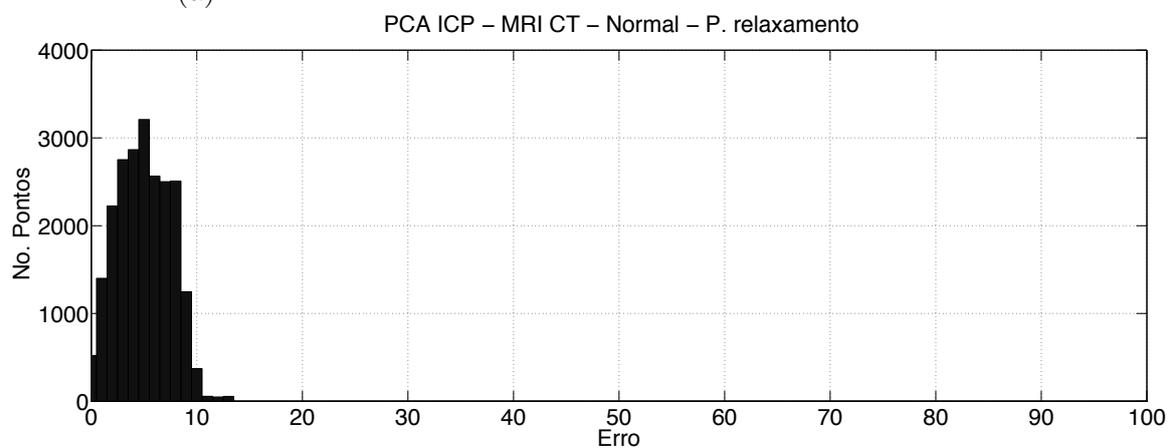
Figura 3.9: Alinhamento de fiduciais segmentados de 4 imagens MRI diferentes por registro baseado em ICP.

3.3.2 Método baseado em pontos

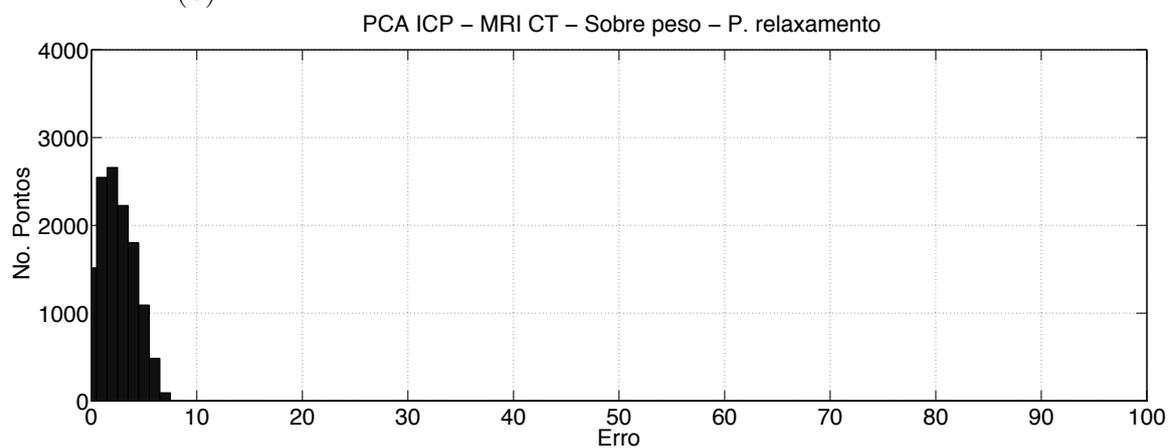
O registro por LS requer a identificação de pontos comuns nas imagens \mathbf{M} e \mathbf{P} . Esses pontos são identificados manualmente de maneira a representar os centros dos fiduciais. A posição dos centros dos fiduciais é imprecisa nas imagens de ressonância magnética por



(a)



(b)



(c)

Figura 3.10: (a) Histograma de distâncias para o alinhamento usando ICP para o alinhamento de imagens de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar). (b) Histograma de distâncias para o alinhamento usando ICP para o alinhamento de imagens de um paciente com peso normal com posição de relaxamento da mandíbula. (c) Histograma de distâncias para o alinhamento usando ICP para o alinhamento de imagens adquiridas de um paciente com sobrepeso com posição de relaxamento do mandíbula.

sua resolução baixa. Em várias imagens, a posição do centro do fiducial está localizada entre fatias, dificultando a identificação dos centros pelo usuário. A validação do método é feita utilizando a mesma base de imagens e as mesmas estruturas segmentadas dos métodos de registro por PCA e ICP.

O histograma de distâncias de alinhamento é calculado transformando os vértices da malha dos fiduciais após o cálculo da transformação através do registro dos centros (ver Figura 3.11). A correspondência é calculada através da busca do vizinho mais próximo de forma semelhante ao dos métodos baseado em superfícies (ver seção 3.3.1). Essa correspondência é usada somente no cálculo da distância entre os pontos da malha.

Para o registro por mínimos quadrados, são necessários pelo menos três pontos não-colineares. A identificação de pontos consome um tempo menor que a segmentação de regiões dos fiduciais ao longo das fatias das imagens tridimensionais, etapa necessária para o registro baseadas em superfícies, gerando conjuntos com o mesmo número de pontos, eliminando assim os *outliers*. Porém, este processo exige uma atenção maior do usuário para manter a ordem de seleção. O registro de \mathbf{P}_p em \mathbf{M}_p de 4 imagens de tomografia e de 4 imagens de ressonância magnética repectivamente é mostrado na Figura 3.11.

A Figura 3.12 mostra os histogramas de distâncias entre pontos correspondentes após o alinhamento de \mathbf{M}_p e \mathbf{P}_p . Para a validação do método de registro por mínimos quadrados, usaram-se os fiduciais segmentados para o cálculo do histograma de distâncias entre pontos mais próximos. Analisando os histogramas, nota-se um aumento no número de pontos com distância a seu correspondente igual a zero, indicando uma sobreposição maior entre as nuvens de pontos. O problema de registro por mínimos quadrados pode ser considerado como caso ideal para registro de pontos, onde há ausência de *outliers* e a correspondência é conhecida.

A imagem xadrez de um registro CT-MRI é mostrada na Figura 3.13. Nela, mostra-se o preenchimento de regiões da imagem de ressonância magnética com informação de tecidos densos da imagem de tomografia computadorizada do molde da arcada dentária.

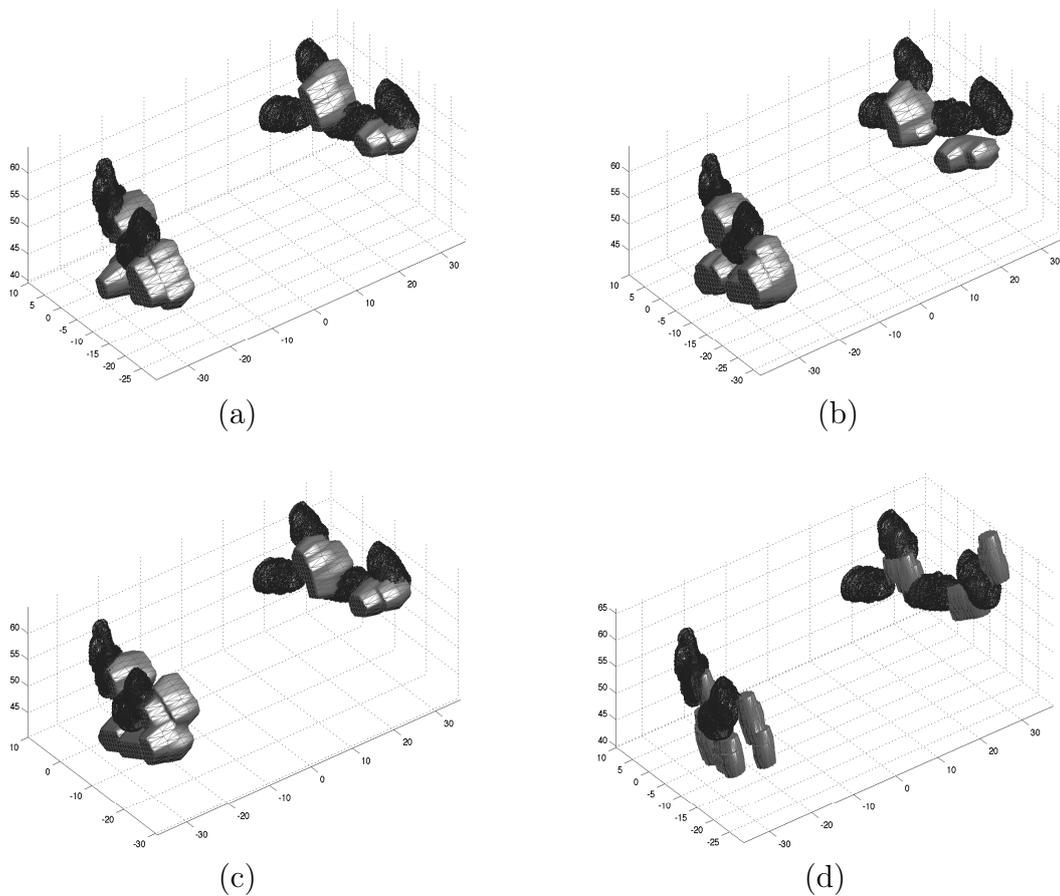


Figura 3.11: Alinhamento de fiduciais segmentados de 4 imagens MRI diferentes por registro baseado em LS.

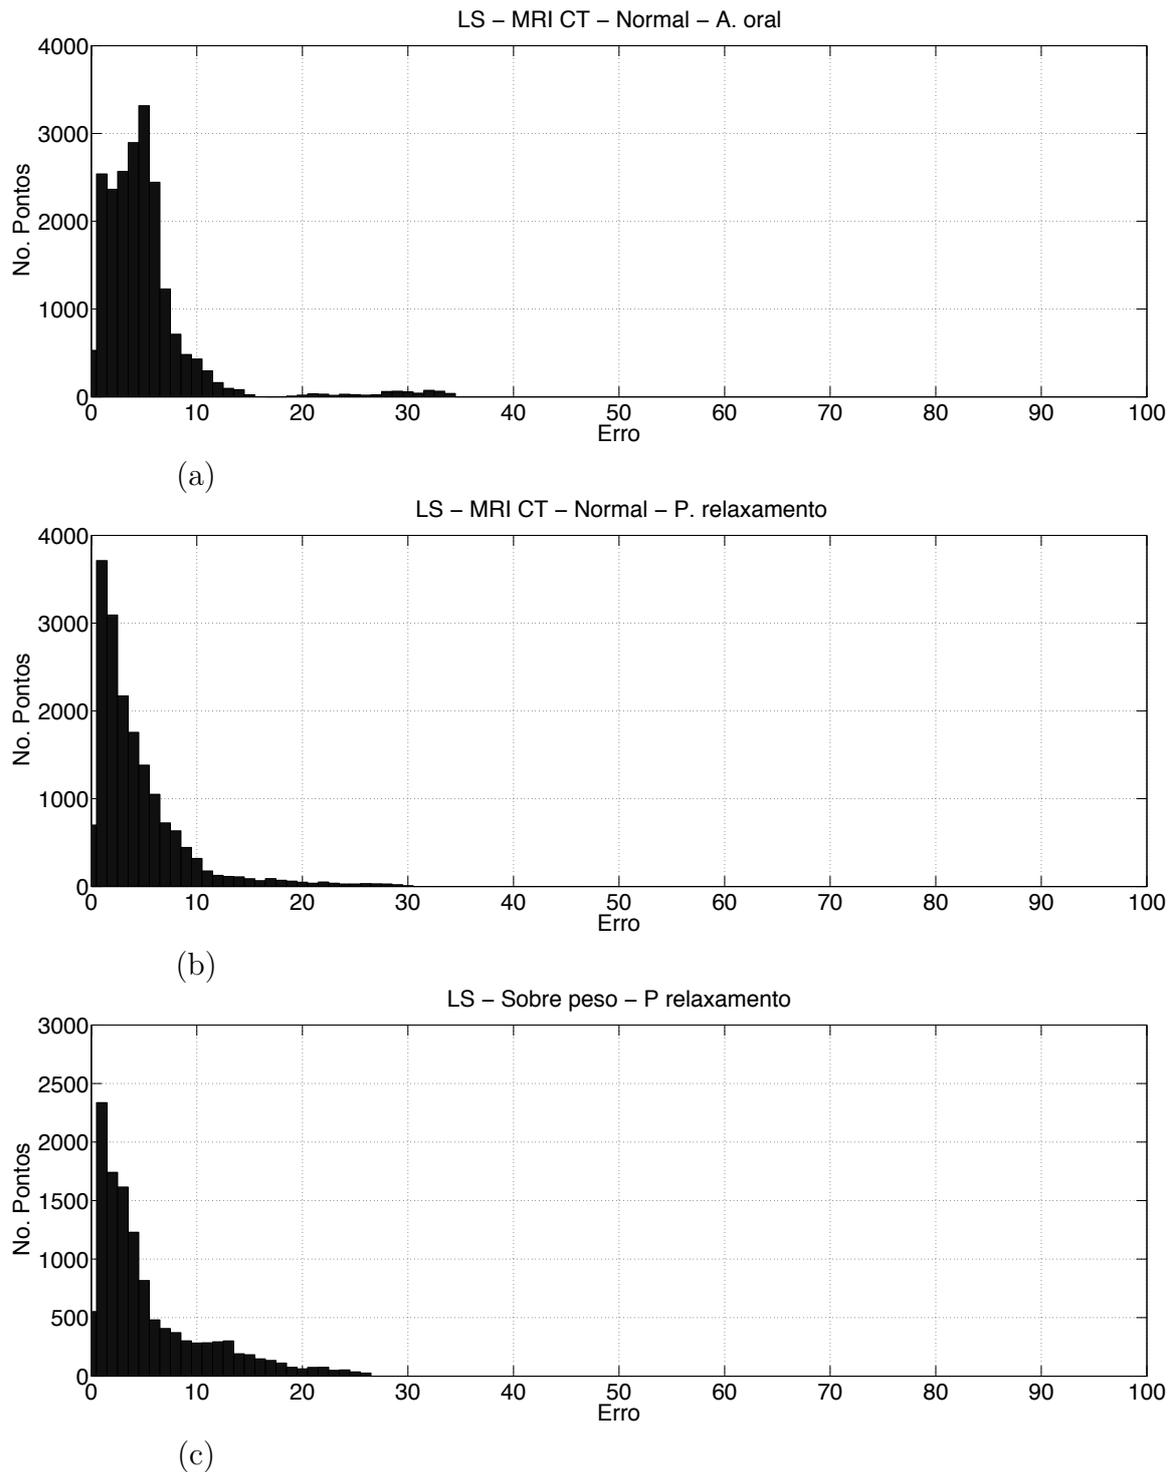


Figura 3.12: (a) Histograma de distâncias para o alinhamento por LS de imagens multimodais de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar). (b) Histograma de distâncias para o alinhamento de imagens de um paciente normal com posição de relaxamento da mandíbula por LS. (c) Histograma de distâncias para o alinhamento de um paciente com sobrepeso com posição de relaxamento da mandíbula por LS.

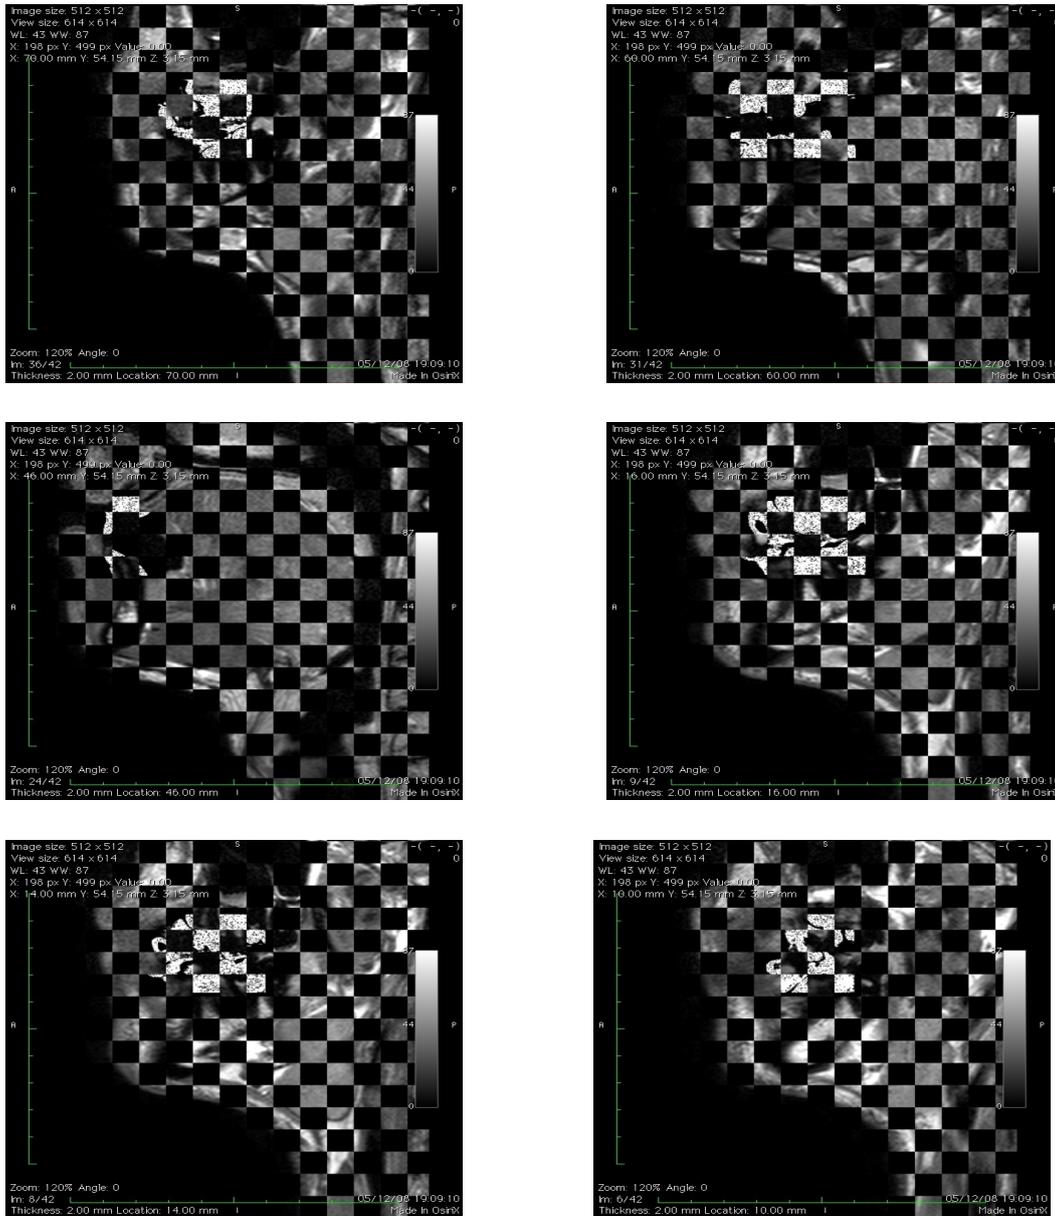


Figura 3.13: Imagem xadrez para a visualização do alinhamento CT-MRI. Essa imagem mostra o preenchimento de regiões da imagem de ressonância magnética com informação de tecidos densos da imagem de tomografia computadorizada do molde da arcada dentária. Nota-se também o preenchimento dos dentes na região. Como as imagens apresentam informações diferentes, técnicas automática de registro como maximização da informação mútua ou outras que operam diretamente na valor de intensidade do voxel, apresentam baixa performance, pois a região de sobreposição, no caso apenas os fiduciais, é limitada. Essas regiões comuns requerem a identificação para o cálculo de T .

3.4 Registro MRI-MRI

O registro MRI-MRI alinha imagens \mathbf{M} e \mathbf{P} com grandes regiões de sobreposição, sem uma etapa de segmentação. As Figuras 3.14 e 3.15 mostram um exemplo de alinhamento usando informação mútua como medida de similaridade. A visualização do alinhamento MRI - MRI, ou $\mathbf{M} \leftarrow \mathbf{P}$ é feita através de superfícies de nível extraídas das imagens nas Figuras 3.14 e 3.15. A validação desse processo pode ser feita por inspeção visual através da imagem xadrez (Figura 3.23). Porém para monitorar o registro, a visualização por superfícies de nível é omputacionalmente mais leve. Nessa visualização, as imagens são transformadas em conjuntos de pontos $\mathbf{M} \rightarrow \mathbf{M}_p$ e $\mathbf{P} \rightarrow \mathbf{P}_p$. O registro baseado na intensidade dos voxels utiliza todo o conteúdo da imagem, operando diretamente nos valores de tons de cinza. Assim, imprecisões no processo de identificação de pontos ou segmentação são evitadas.

O alinhamento das imagens por maximização da informação mútua (MI) requer uma etapa de pré-alinhamento. Essa etapa de pré-alinhamento pode ser implementada pelo o registro por PCA (ver Seção 2.7) para o alinhamento dos eixos. Neste caso, a PCA pode ser aplicada diretamente nos valores de tons de cinza da imagem sem segmentar a imagens em pontos.

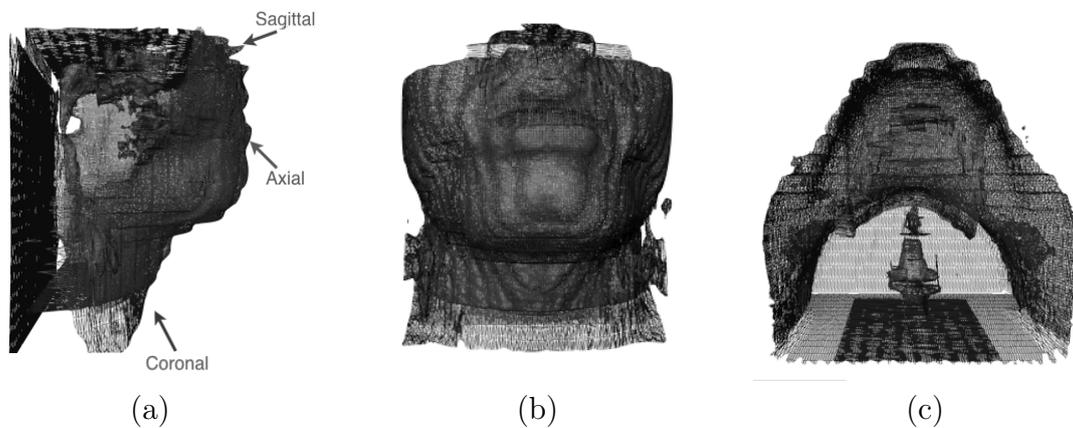


Figura 3.14: Registro de corpo rígido de 3 imagens MRI (paciente com peso normal):(a) Vista Sagital; (b) Vista Coronal; (c) Vista Axial.

Para validação do método de registro baseado na informação mútua foram realizados experimentos de alinhamento utilizando métodos baseados em pontos e em superfícies. A geometria dos fiduciais é segmentada das imagens de ressonância magnética, gerando os conjuntos \mathbf{M}_p e \mathbf{P}_p de forma balanceada, já que as resoluções das imagens de MRI são próximas (ver tabelas 3.1, 3.2 e 3.4). O número de estruturas segmentadas é igual na maioria dos experimentos, condição favorável para o cálculo dos vizinhos próximos,

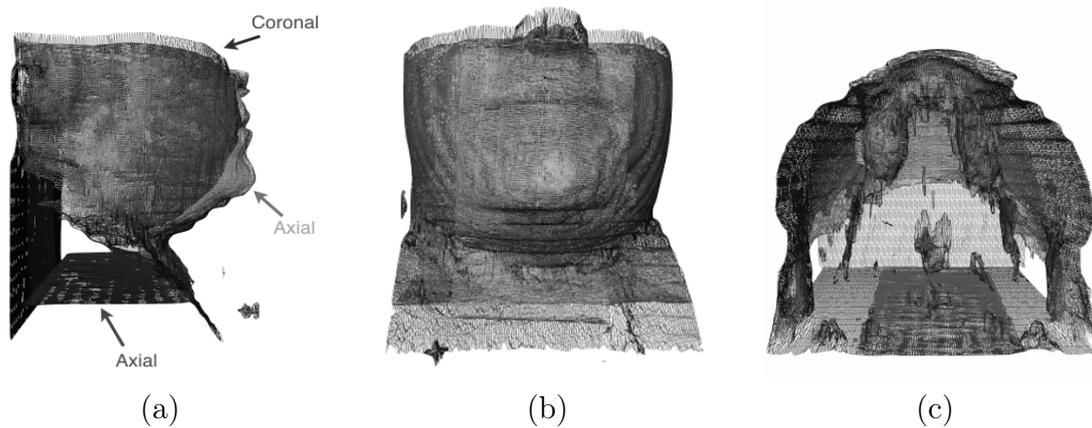


Figura 3.15: Registro de corpo rígido de 3 imagens MRI (paciente com sobrepeso):(a) Vista Sagital; (b) Vista Coronal; (c) Vista Axial.

pois resulta em uma baixa taxa de *outliers* é baixa. De maneira semelhante à validação feita no registro por LS em que a transformada \mathbf{T} é aplicada às malhas dos fiduciais para calcular o histograma de distâncias, o registro por MI alinha as imagens \mathbf{M} e \mathbf{P} . Posteriormente, as imagens são segmentadas para o cálculo do histograma de distâncias entre pontos de \mathbf{M}_p e de \mathbf{P}_p . As imagens usadas como referência para o alinhamento são listadas na Tabela 3.4.

Tabela 3.4: Imagens MRI - Referência para o alinhamento MRI-MRI.

MRI			
Imagem	Dimensão	Corte	
269860707_801_PD_AXIAL_SENSE_20080721.hdr	512 x 512 x 84	Axial	
256732529_1001_COR_PD_20080220.hdr	512 x 512 x 84	Coronal	
257340011_1001_PD_AXIAL_20080227.hdr	512 x 512 x 84	Axial	

Na Figura 3.16, tem-se os histogramas de distâncias entre pontos dos conjuntos \mathbf{M}_p e \mathbf{P}_p gerados pelo registro por PCA. A Figura 3.16 (a) mostra o histograma de distâncias para o registro $\mathbf{M}_p \leftarrow \mathbf{P}_p$ de imagens de um paciente com peso normal usando aparelho oral. O número de pontos de \mathbf{M}_p , cuja distância a seu correspondente em \mathbf{P}_p é zero, é elevado (5500 pontos) em comparação com o histograma da Figura 3.8 (a), onde o número desses pontos é bem baixa (< 800 pontos). Nos histogramas da Figura 3.8 (b) e (c), tem-se o mesmo comportamento no alinhamento de imagens do paciente com peso normal na posição de relaxamento da mandíbula e de imagens do paciente com sobrepeso. Nesses histogramas a dispersão ainda é grande. Um exemplo de alinhamento por PCA de conjuntos de pontos extraídos de imagens da mesma modalidade pode ser visto na Figura 3.17. Os conjuntos de pontos \mathbf{M}_p e \mathbf{P}_p são balanceados, já que são gerados a partir de imagens de ressonância magnética.

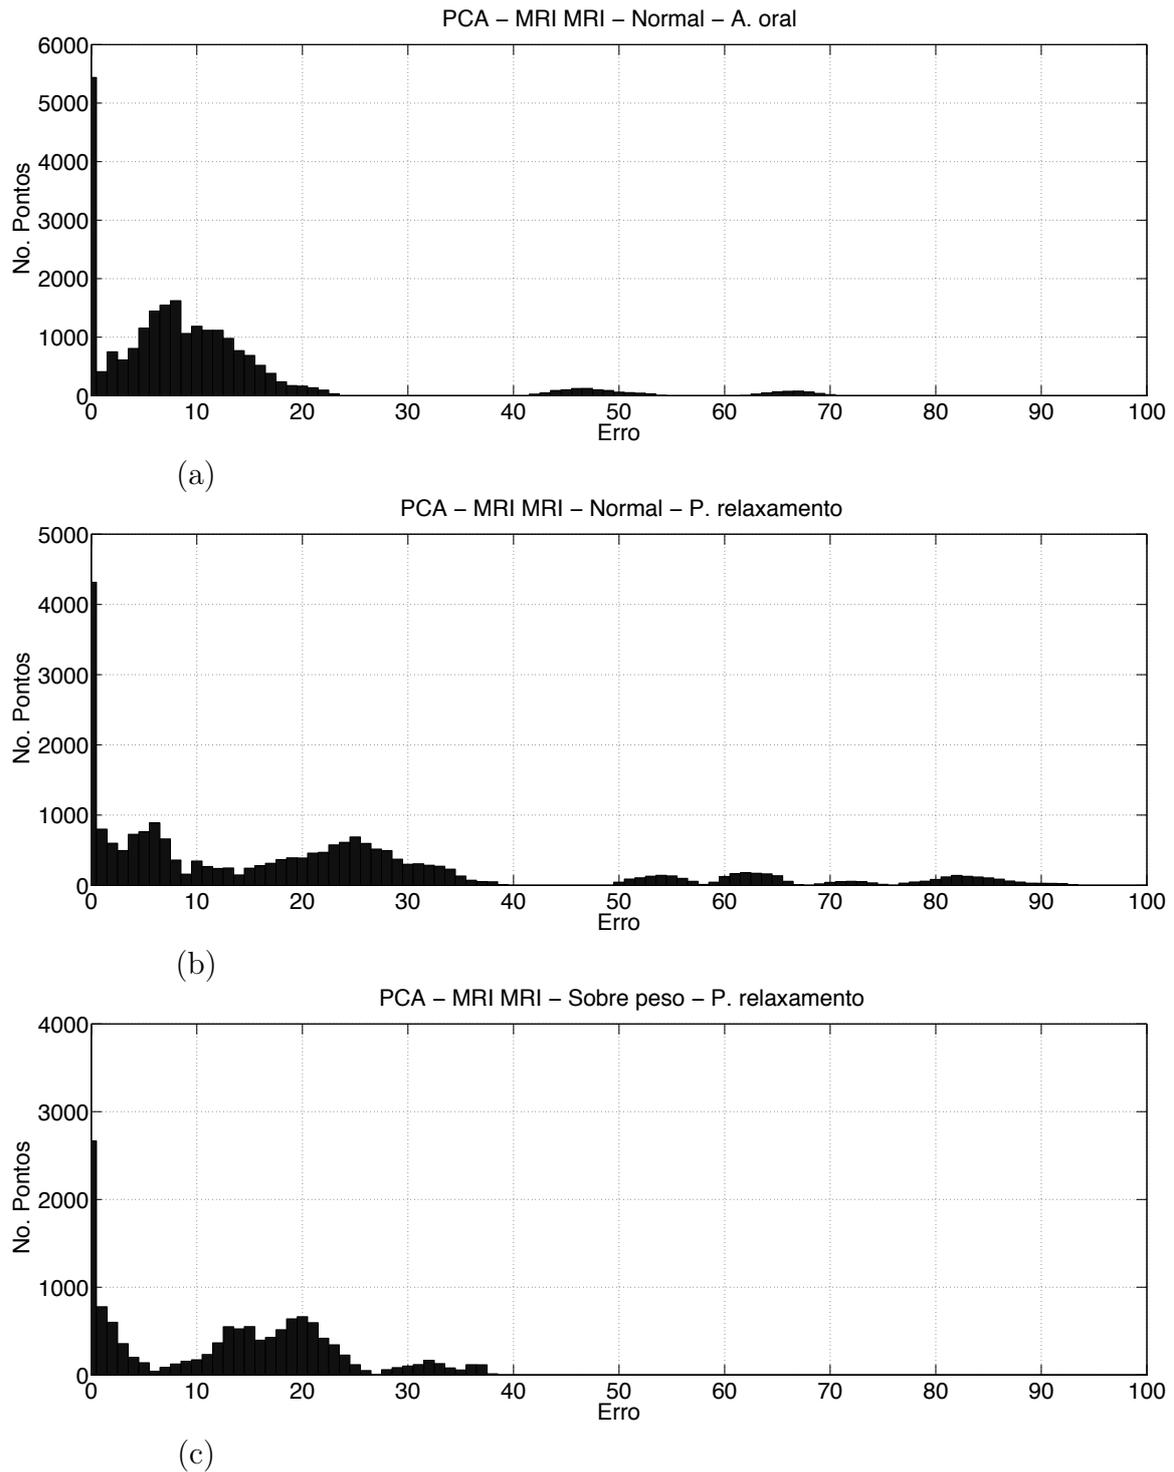


Figura 3.16: Registro MRI-MRI. (a) Histograma de distâncias para o alinhamento usando PCA para o alinhamento de imagens de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar). (b) Registro MRI - MRI - Histograma de distâncias para o alinhamento usando PCA para o alinhamento de imagens de um paciente com peso normal com posição de relaxamento da mandíbula. (c) Registro MRI - MRI - Histograma de distâncias para o alinhamento usando PCA para o alinhamento de imagens de um paciente com sobrepeso com posição de relaxamento da mandíbula.

Na Figura 3.18, verifica-se o mesmo comportamento de aumento no número de pontos de \mathbf{M}_p cuja distância a seu correspondente em \mathbf{P}_p é zero no registro $\mathbf{M}_p \leftarrow \mathbf{P}_p$. Esses histogramas são gerados pelo registro fino por ICP. Como o alinhamento inicial, \mathbf{T}_i , é calculado por PCA, o registro fino por ICP é fortemente dependente da transformação inicial \mathbf{T}_i . No registro por ICP observa-se uma forte redução da dispersão no histograma de distâncias, o que pode ser visto comparando as figuras 3.8 e 3.16.

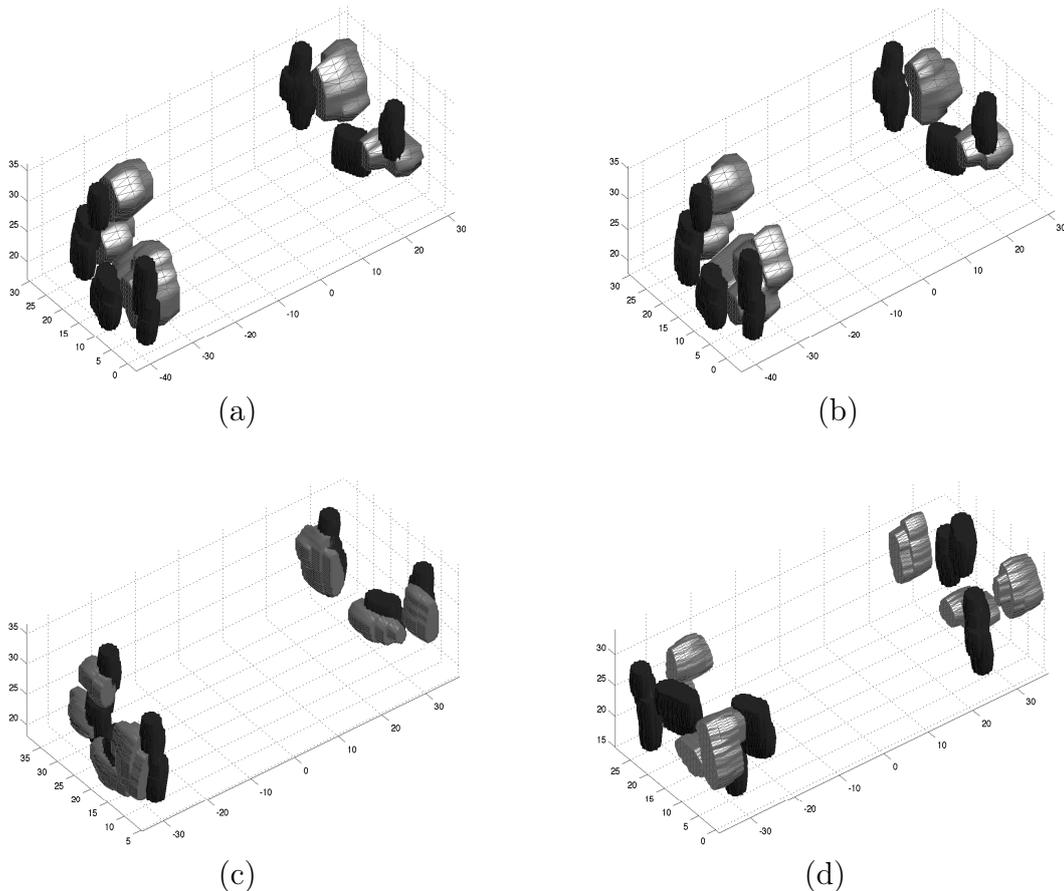


Figura 3.17: Alinhamento de fiduciais segmentados de 4 imagens MRI diferentes por registro baseado em PCA.

Os histogramas gerados pelo registro por mínimos quadrados para o alinhamento de imagens monomodais podem ser vistos na Figura 3.19. Analisando esses histogramas, verifica-se um aumento no número de pontos com distância igual zero em relação ao histograma da Figura 3.12, comportamento presente nos métodos de registro por PCA e ICP. Porém para o método de registro por mínimos quadrados, os conjuntos \mathbf{M}_p e \mathbf{P}_p são sempre balanceados, apresentando o mesmo número de elementos. Assim, esse aumento no pontos com distância zero pode estar relacionado com o formato dos fiduciais segmentados. No registro CT-MRI, os fiduciais segmentados das imagens de

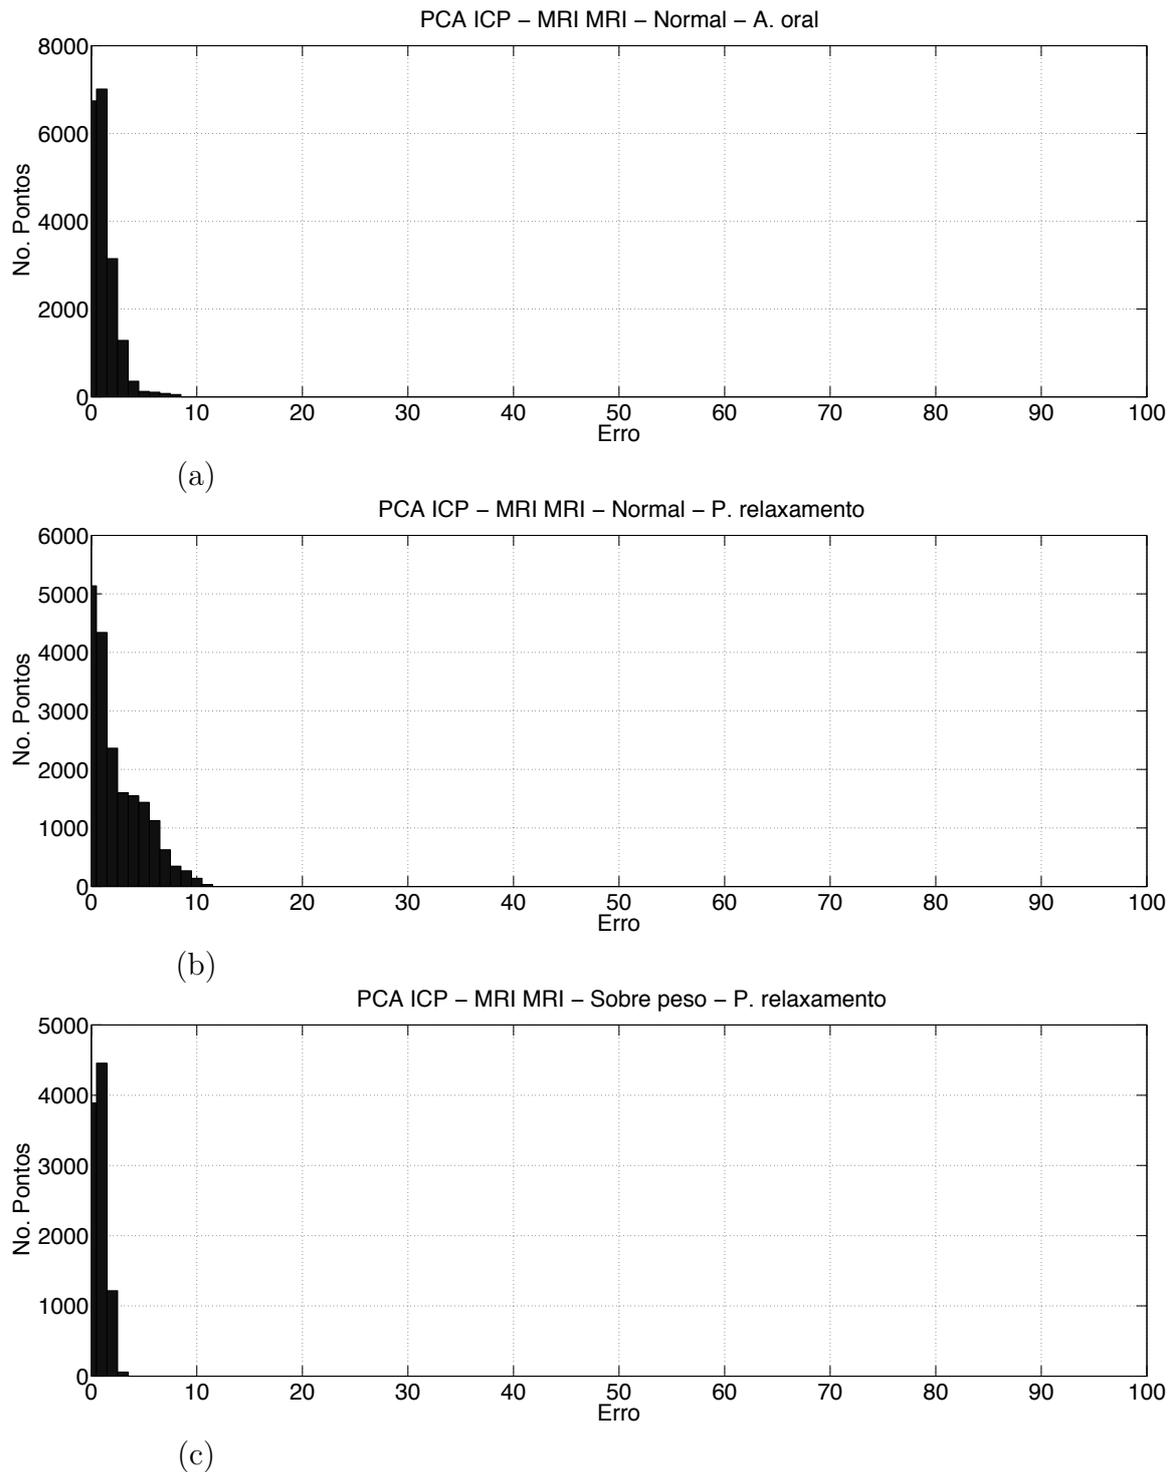


Figura 3.18: Registro MRI-MRI. (a) Histograma de distâncias para o alinhamento de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar) por ICP. (b) Histograma de distâncias para o alinhamento de um paciente com peso normal com posição de relaxamento da mandíbula por ICP. (c) Histograma de distâncias para o alinhamento de um paciente com sobrepeso com posição de relaxamento da mandíbula por ICP.

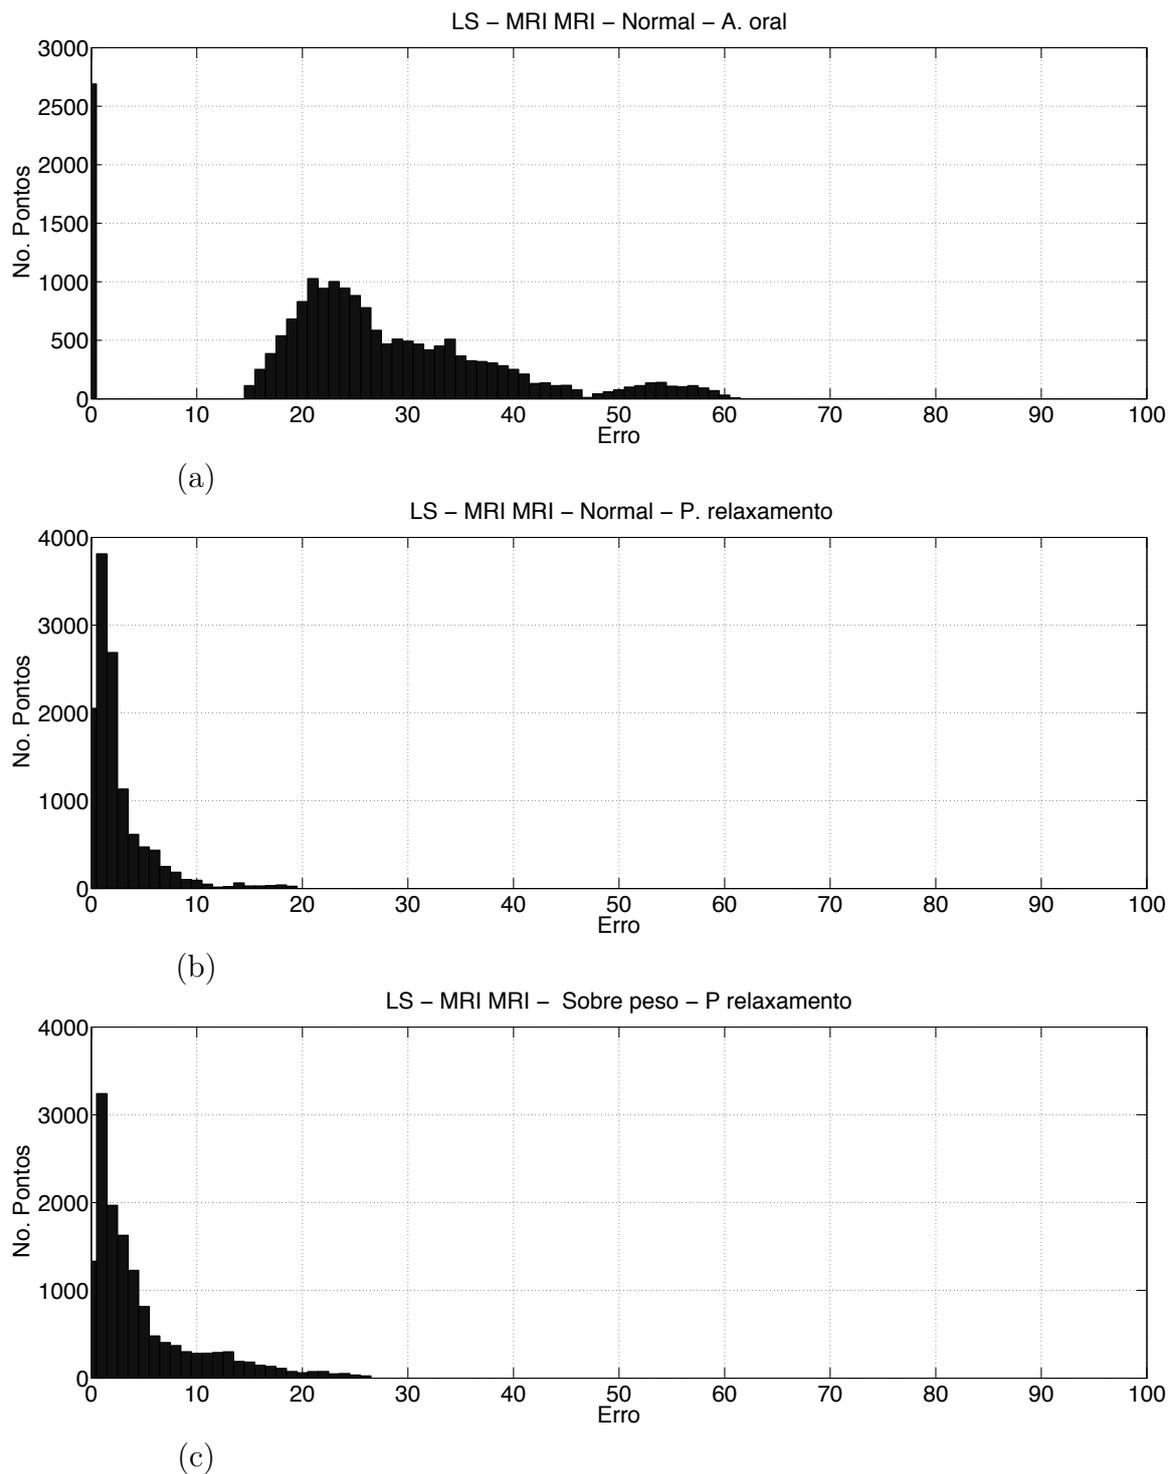


Figura 3.19: Registro MRI-MRI. (a) Histograma de distâncias para o alinhamento por LS de imagens multimodais de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar). (b) Histograma de distâncias para o alinhamento de imagens de um paciente normal com posição de relaxamento da mandíbula por LS. (c) Histograma de distâncias para o alinhamento de um paciente com sobrepeso com posição de relaxamento da mandíbula por LS.

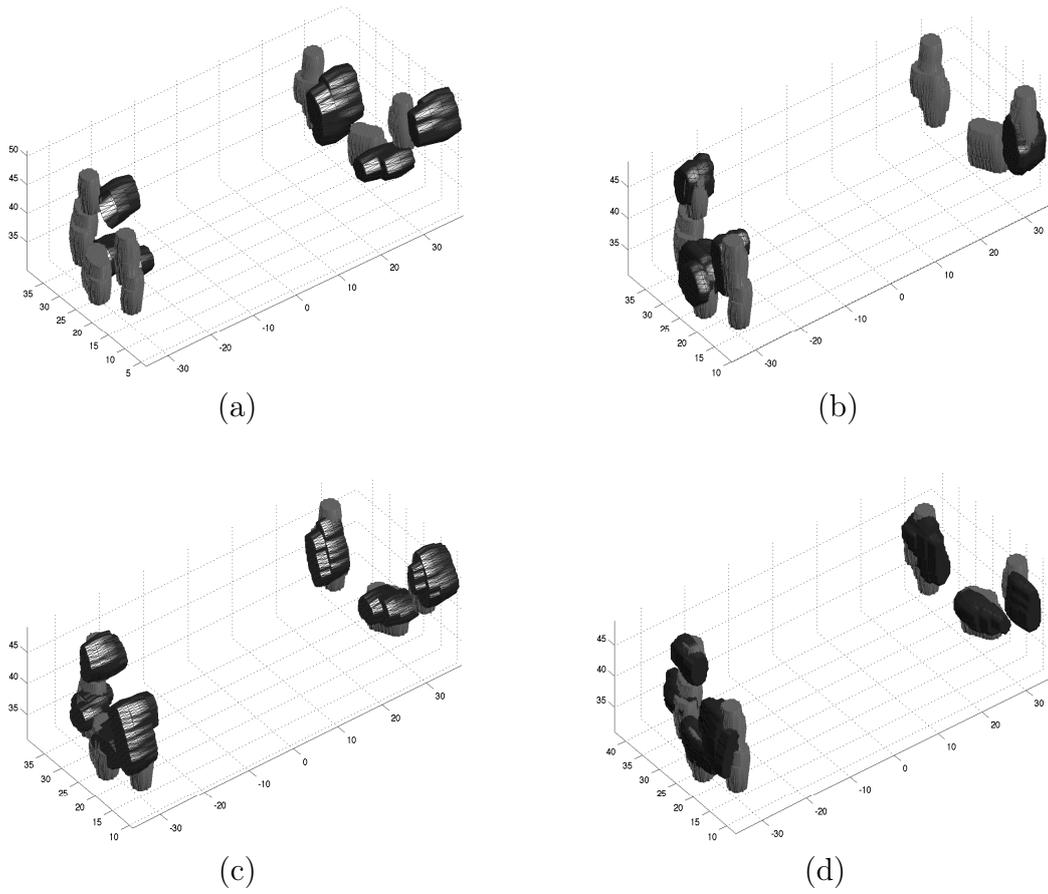


Figura 3.20: (Alinhamento de fiduciais segmentados de 4 imagens MRI diferentes por registro baseado em LS.

tomografia computadorizada, devido uma resolução bem maior, apresentam formatos diferentes dos fiduciais das imagens de ressonância magnética. No registro MRI-MRI, os fiduciais apresentam formatos semelhantes devido a características das imagens MRI.

Os histogramas da Figura 3.22 mostram o resultado do registro através da maximização da informação mútua. Esses histogramas apresentam uma concentração de pontos em torno da distância zero. O custo computacional do registro baseado na informação mútua entre intensidades dos voxel é grande, sendo que em toda iteração é necessária a re-amostragem da imagem móvel \mathbf{P} para o cálculo da medida de similaridade. Nos experimentos, usou-se a interpolação linear por ser mais simples e convergir rapidamente (ver Figura 3.21). Em imagens com resolução alta, a interpolação linear apresenta um resultado semelhante à interpolação através do kernel do vizinho mais próximo. A interpolação é necessária quando o voxel de \mathbf{P} está localizado em uma região entre fatias de \mathbf{M} , fora do *grid*. A imagem xadrez de um registro MRI-MRI é mostrada na Figura 3.23.

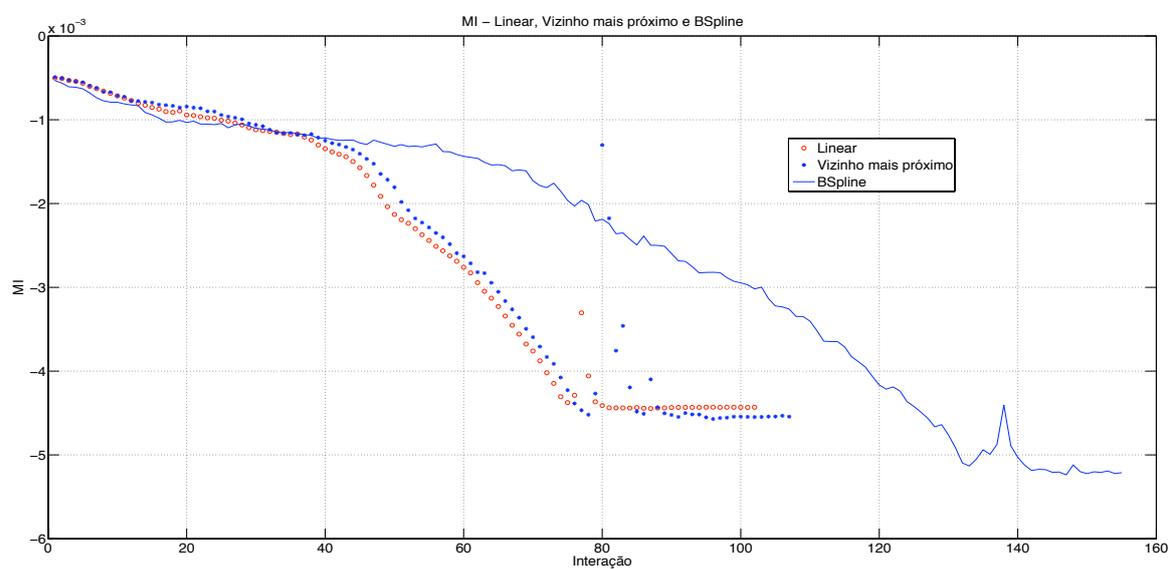


Figura 3.21: Kernels de interpolação e convergência do registro por MI. A linha contínua corresponde ao kernel Bspline, a linha pontilhada vermelha ao kernel linear e a linha azul ao kernel do vizinho mais próximo. O eixo x corresponde ao número de iterações e o eixo y ao valor da MI.

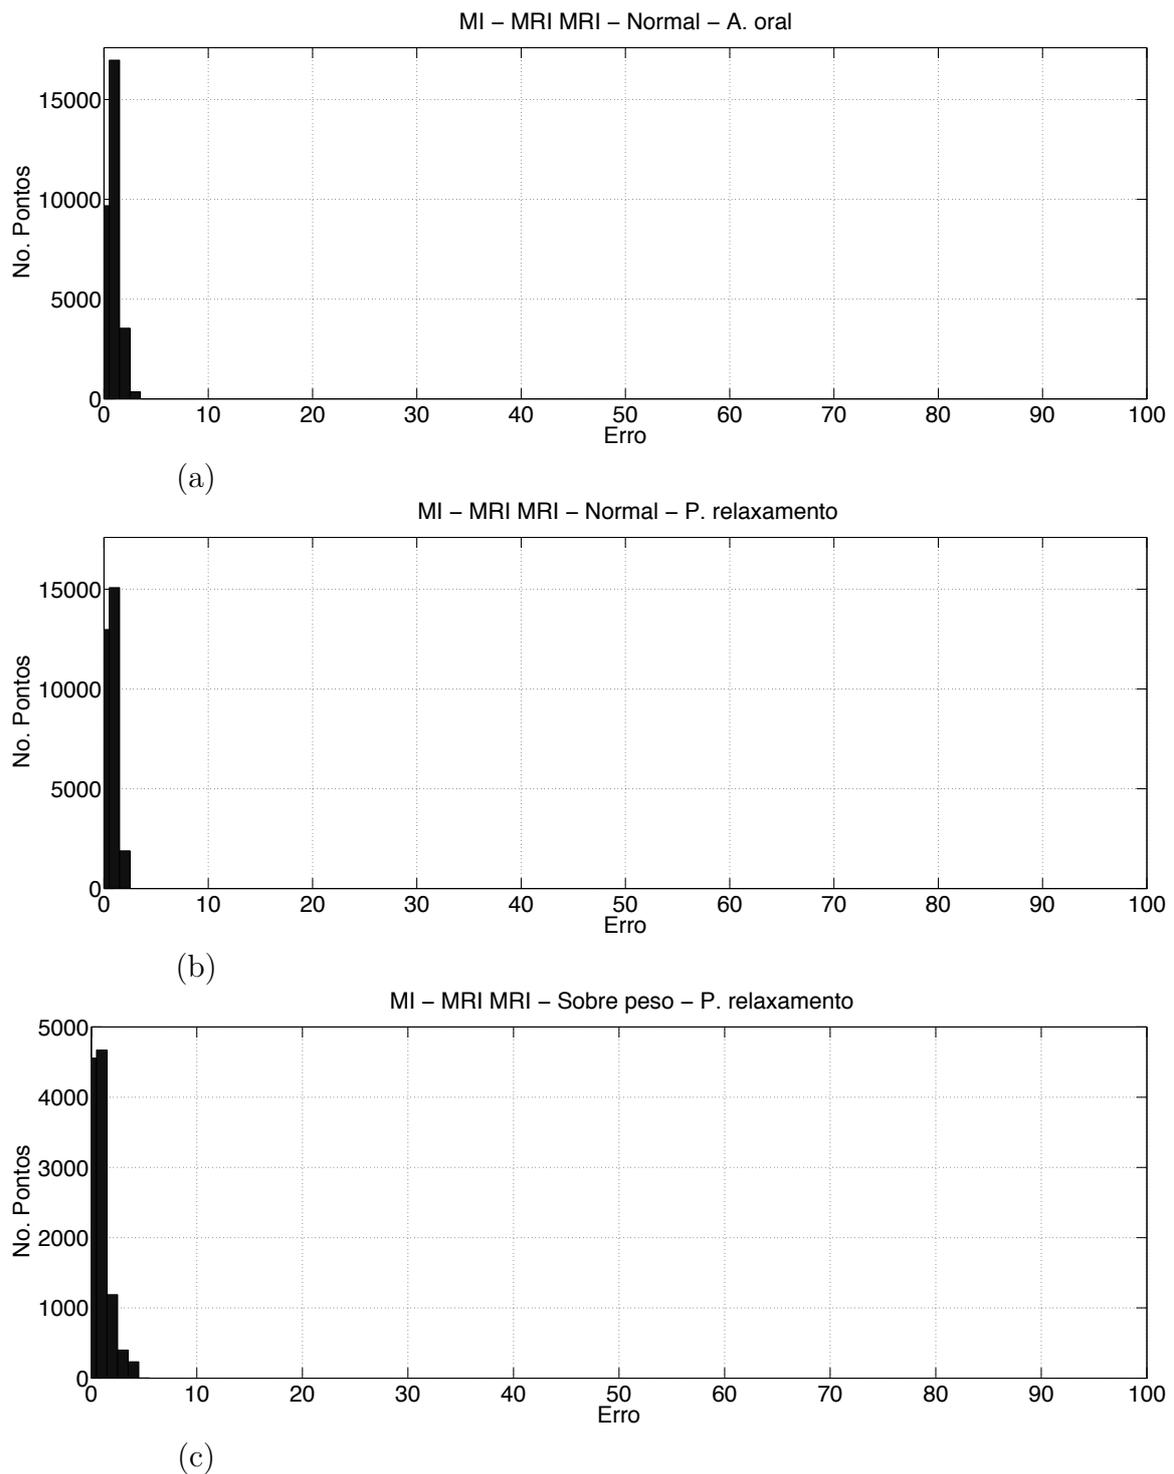


Figura 3.22: Registro MRI-MRI. (a) Histograma de distâncias para o alinhamento de um paciente com peso normal usando aparelho oral (posição de alinhamento entre mandíbula e maxilar) por MI. (b) Histograma de distâncias para o alinhamento de um paciente com peso normal com posição de relaxamento da mandíbula por MI. (c) Histograma de distâncias para o alinhamento de um paciente com sobrepeso com posição de relaxamento da mandíbula por MI.

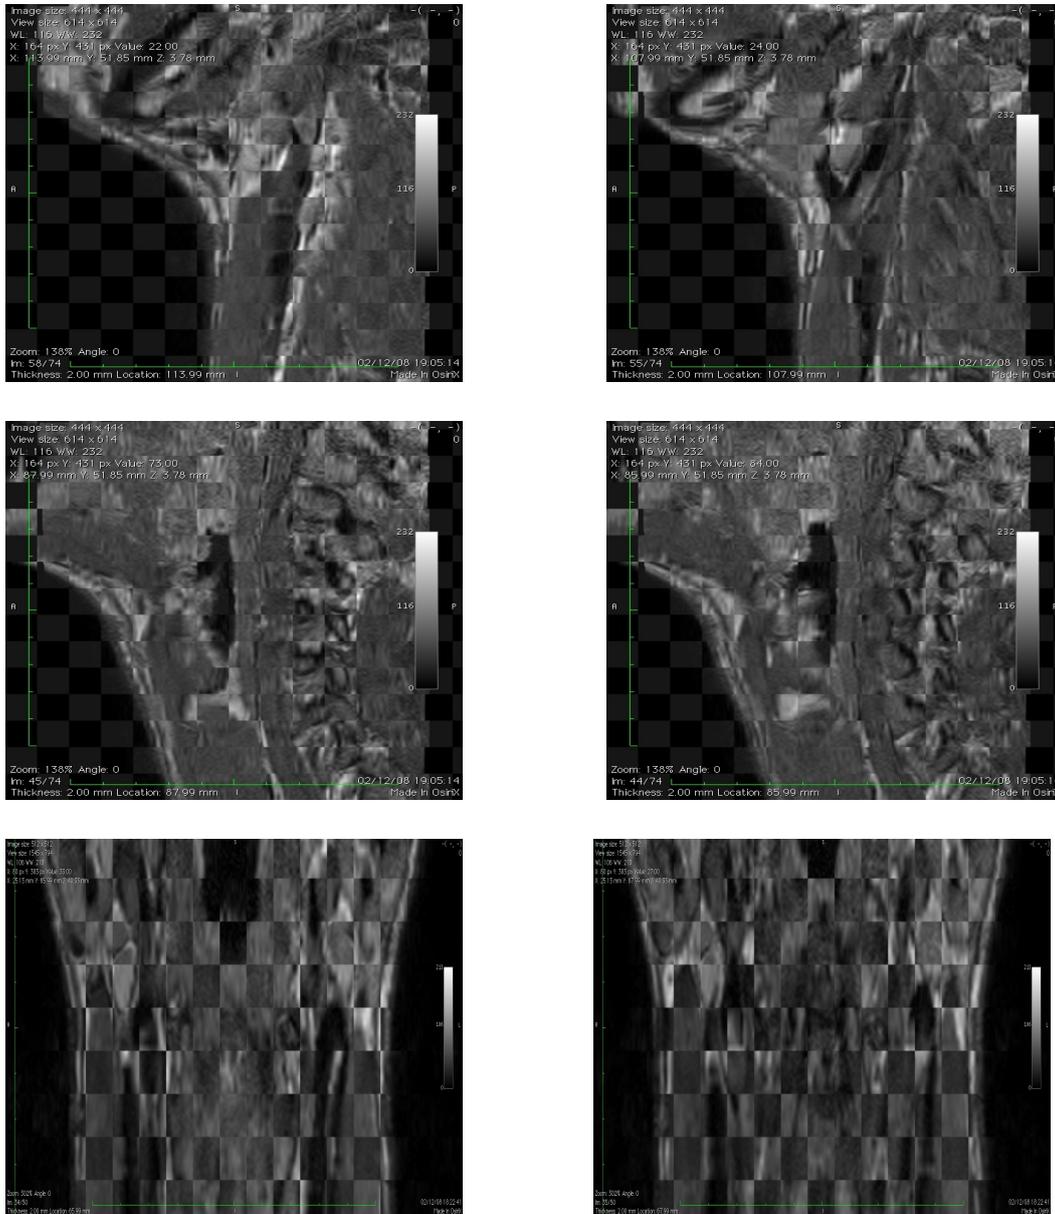


Figura 3.23: Imagem xadrez para a visualização do alinhamento MRI-MRI. As quatro primeiras imagens representam a vista sagital e as duas últimas a vista coronal. Diferente da Figura 3.13, essa imagem xadrez é composta por duas imagens de ressonância magnética, logo todos os quadrados estão preenchidos com informação. Nota-se que em regiões fixas as bordas são contínuas. Em regiões móveis, essas bordas apresentam uma descontinuidade. A fusão dessas imagens aumentam a resolução volumétrica, aumentando a qualidade da segmentação de modelos tridimensionais.

Capítulo 4

Discussão dos Resultados

Neste capítulo, uma análise dos resultados apresentados no Capítulo 3 é feita através da comparação dos métodos de registro de corpo rígido. Os resultados do capítulo anterior são agrupados em duas seções considerando o tipo de registro: registro MRI-MRI e registro CT-MRI. Os fiduciais são as referências para o registro de imagens multimodais e são usados na validação do método baseado na maximização da informação mútua. Para o registro multimodal é necessária a identificação ou segmentação dos fiduciais para gerar o objeto de registro. Esse registro pode ser classificado como registro baseado em marcadores externos. No registro monomodal, as imagens possuem grandes regiões em comum. Assim, a segmentação de estruturas não é necessária para geração dos objetos de registro, já que a imagem inteira pode ser usada como objeto de registro. Há uma questão crítica no caso do registro MRI-MRI: segmentar regiões ou usar o conteúdo inteiro da imagem? Segundo o Capítulo 2, apenas três pontos não-colineares são necessários para calcular a transformação de corpo rígido que alinhe as imagens \mathbf{M} e \mathbf{P} (registro por mínimo quadrados). O custo computacional para o registro de 3 pares de pontos no espaço tridimensional é baixo em relação ao registro por maximização da informação mútua. Porém, o uso de mais pontos pode aumentar a precisão do alinhamento? Esta pergunta é outra que este capítulo busca responder através da validação usando os fiduciais. A seleção de regiões comuns nas imagens \mathbf{M} e \mathbf{P} é feita de forma manual e está sujeita a imprecisão do usuário ao identificar essas regiões ou pontos. Essa etapa de segmentação pode ser automatizada, mas esse não é o foco deste trabalho.

4.1 Registro CT-MRI

No registro CT-MRI tem-se o alinhamento de duas imagens com informações diferentes, onde os fiduciais são comuns entre elas. Para o cálculo de \mathbf{T} que mapeia a relação

entre \mathbf{M} e \mathbf{P} é necessário identificar esses pontos em comum através da segmentação de regiões nas imagens. A segmentação dessas regiões pode gerar dois objetos de registro: pontos ou conjuntos grandes de pontos que representam a geometria da região. Os algoritmos de registro por PCA e ICP usam grandes conjuntos de pontos (vértices das malhas dos marcadores geradas pela região segmentada da imagem). O algoritmo de registro por mínimos quadrados utiliza apenas poucos pares de pontos. Há a tentativa de verificar se o aumento do número de pontos aumenta a precisão do registro. O aumento do número de pontos faz com que a correspondência entre os pares dos conjuntos \mathbf{M}_p e \mathbf{P}_p seja perdida. O alinhamento por PCA é um alinhamento inicial, o qual, não requer correspondência entre pontos no cálculo de \mathbf{T} . Para o registro por ICP, é necessário recuperar essa correspondência através do critério de distância, em que os vizinhos mais próximos são os pares de objeto de registro. A recuperação da correspondência limita o registro por ICP para casos de conjuntos de pontos com grande sobreposição. Por outro lado, como o registro por mínimos quadrados utiliza poucos pontos, é fácil manter essa correspondência. LS é um caso especial de ICP, onde a correspondência é conhecida. A Figura 4.1 mostra os histogramas de distâncias entre pontos de todas as realizações do registro CT-MRI.

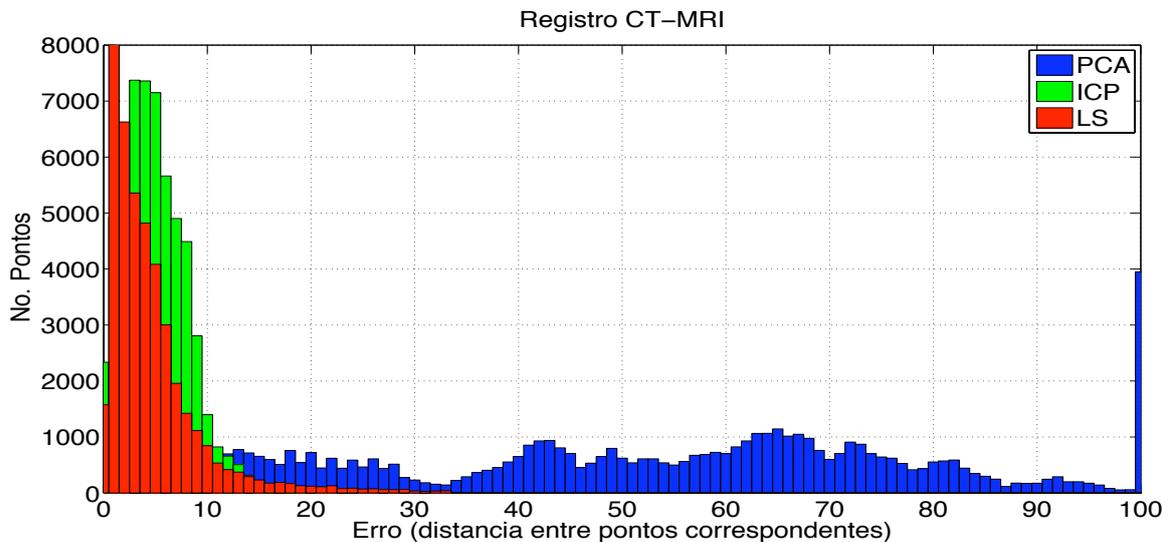


Figura 4.1: Registro CT-MRI: Histograma de todas as realizações de alinhamento de \mathbf{M} e \mathbf{P} usando os métodos baseado em pontos e superfícies.

O histograma do método de registro baseado em pontos (LS) apresenta grandes quantidades de pontos em torno da distância zero, seguido pelos métodos baseados em superfícies (PCA-ICP e PCA). Em termos de alinhamento, isto significa que a sobreposição da geometria dos fiduciais após aplicar a transformação de corpo rígido \mathbf{T} é grande, ou seja, a distância entre pontos correspondentes é pequena. O alinhamento fino por ICP reduz a distância entre pontos correspondentes do alinhamento por PCA.

4.2 Registro MRI-MRI

O registro MRI-MRI, como já dito anteriormente, alinha imagens que contêm a mesma informação (imagens de ressonância magnética contêm informação sobre tecidos moles como músculos) porém com resoluções diferentes e adquiridas em tempos diferentes. Assim, regiões como língua e outros tecidos moles podem apresentar algum movimento, causando uma diferença em algumas regiões, não afetando significativamente o cálculo da transformada pelo registro baseado na intensidade do voxel, já que grande parte da imagem permanece estática. Na Figura 4.2, tem-se os histogramas de distâncias de todas as realizações de alinhamento $\mathbf{M} \leftarrow \mathbf{P}$ pelos métodos de registro baseados em pontos, superfícies e intensidades de voxel.

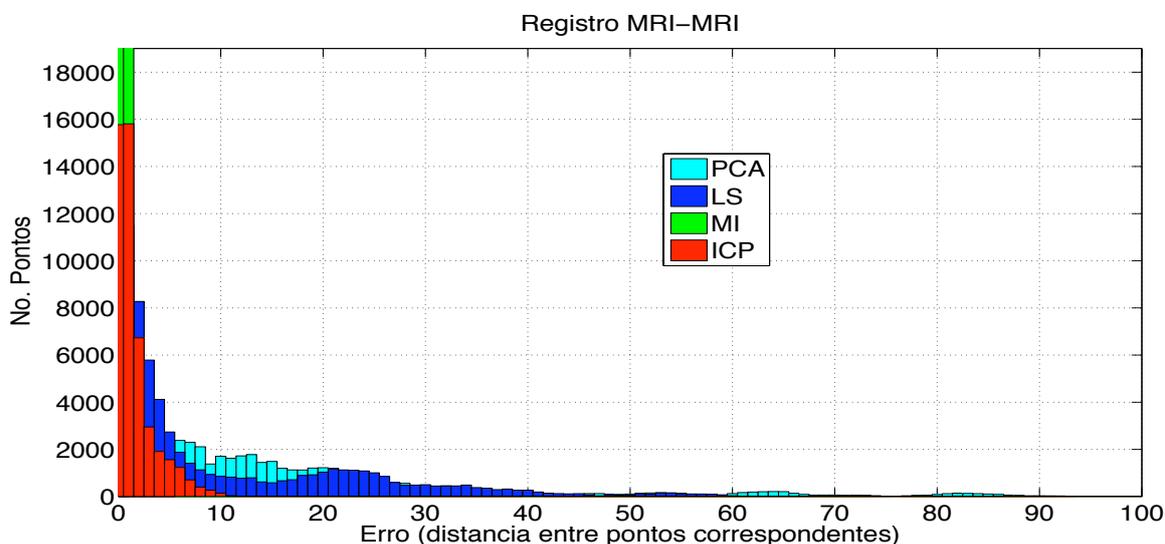


Figura 4.2: Registro MRI-MRI: Histograma de todas as realizações de alinhamento de \mathbf{M} e \mathbf{P} usando os métodos baseado em pontos, superfícies e intensidade do voxel.

O histograma do método de registro por maximização da informação mútua (ou registro baseado na intensidade do voxel) apresenta grande quantidade de pontos com distância próxima de zero, tendo uma maior precisão no alinhamento em termos de distância entre pontos correspondentes. O alinhamento por LS apresenta também grandes concentrações de pontos em torno do zero e pode ser usado na validação do método de registro por maximização da informação mútua.

Capítulo 5

Conclusão

A simulação biomecânica de estruturas tridimensionais auxilia no planejamento de intervenções cirúrgicas e no tratamento de doenças. O projeto OPAL tem como o objetivo a modelagem de estruturas tridimensionais anatômicas complexas. A etapa de modelagem pode ser dividida em quatro sub-etapas: aquisição, registro, segmentação e *morphing*. A etapa de registro consiste em um pré-processamento da imagem, aumentando a resolução volumétrica através do registro monomodal e realçando os contornos de regiões através do registro multimodal.

O aumento da resolução volumétrica nas imagens de ressonância é resultante da combinação de imagens com direções de corte diferentes. Para combinar essas imagens, o registro monomodal é responsável por calcular a transformação que alinha as imagens. Em aplicações médicas, é muito importante a precisão desse alinhamento para a combinação das imagens, gerando uma imagem com alta resolução em todas as direções. Por outro lado, têm-se o registro multimodal de imagens, que alinha imagens com informações diferentes para realçar os contornos. No registro multimodal foram alinhadas imagens de tomografia computadorizada com imagens de ressonância magnética para a combinação de informações diferentes. As imagens de ressonância magnética contêm informações de tecidos moles como músculos e as imagens de tomografia computadorizada informações do molde da arcada dentária. A informação contida nas imagens de tomografia computadorizada combinadas com a informação da ressonância magnética facilita a segmentação de estruturas, principalmente a língua dos pacientes, adicionando nas imagens informações sobre o contorno da língua.

Técnicas diferentes de registro foram estudadas e implementadas buscando uma comparação entre os métodos. Nos métodos baseados em superfícies, PCA e PCA-ICP, a segmentação de regiões consome um tempo maior que a identificação de pontos no método baseado em pontos. Nos métodos de PCA e PCA-ICP, a quantidade de pontos é maior que no método de registro por LS, porém a correspondência não é conhecida, o

que dificulta o registro e diminui a precisão. Nem sempre o uso de grandes quantidades de pontos resulta no aumento da precisão de alinhamento.

Por outro lado no registro monomodal observou-se que o uso de todo o conteúdo da imagem, por exemplo o registro por MI, aumenta a precisão do alinhamento, mas aumenta também a complexidade e o custo computacional. A realização de registro através de mínimos quadrados é interessante pelo baixo custo computacional e interação humana, onde o usuário apenas marca alguns pontos na imagem. Porém a imprecisão como a localização de alguns pontos em regiões fora do *grid* pode ocorrer neste caso. O uso de toda a informação da imagem, torna o método de registro monomodal automático mas apresenta um custo computacional grande.

Referências Bibliográficas

- BANDari, E.; Xiang, Q. S. e Little, J. (1994). Visual echo registration of magnetic resonance images. *In Applications of computer vision in medical image processing, AAAI spring symposium series*, pp. 38–41.
- Ben Sassi, O.; Delleji, T.; Taleb-Ahmed, A.; Feki, I. e Ben Hamida, A. (2008). Mr image monomodal registration using structure similarity index. *First Workshops on Image Processing Theory, Tools Applications.*, pp. 1–5.
- Besl, P. J. e McKay, N. D. (1992). A method for registration of 3-d shapes. *IEEE Transactions on pattern analysis and machine intelligence*, 14:239–256.
- Chung, D.; Yun, I. e Lee, S. (1998). Registration of multiple range views using the reverse calibration technique. *Pattern Recognition*, pp. 457–464.
- Collignon, A.; VANDermeulen, D.; Suetens, P.; Marchal, G.; Baert, A. e Oosterlinck, A. (1994). Automatic registration of 3d images of the brain based on fuzzy objects. *Medical imaging: image processing SPIE Press*, pp. 162–175.
- Collins, D. L.; Evans, A. C.; Holmes, C. e Peters, T. M. (1995). Automatic 3d segmentation of neuro-anatomical structures from mri. *In Bizais, Y., Barillot, C. and di Paola, R. (eds), Information processing in medical imaging, Kluwer*, pp. 139–152.
- Ettinger, G. J.; Grimson, W. E. L. e Lozano-P´erez, T. (1994). Automatic 3d image registration for medical change detection applications. *In Applications of computer vision in medical image processing, AAAI spring symposium series*, pp. 182–185.
- Feldmar, J.; MalANDain, G.; Declerck, J. e Ayache, N. (1996). Extension of the icp algorithm to non-rigid intensity-based registration of 3d volumes. *In Mathematical methods in biomedical image analysis, IEEE computer society press*, pp. 84–93.
- Fels, S.; Lloyd, J.; van den Doel, K.; Vogt, F.; Stavness, I. e Vatikiotis-Bateson, E. (2006). Developing physically-based, dynamic vocal tract models using artisynth. *Proceedings of ISSP 06*, pp. 419–426.

- Ge, Y.; Fitzpatrick, J. M.; Votaw, J. R.; Gadamsetty, S.; Maciunas, R. J.; Kessler, R. M. e Margolin, R. A. (1994). Retrospective registration of pet and mr brain images: an algorithm and its stereotactic validation. *Journal of computer assisted tomography*, 18:800–810.
- Granger, S. e Pennec, X. (2002). Multi-scale em-icp: A fast and robust approach for surface registration. *Proceedings of the ECCV02*, 2525:418432.
- Gueziec, A. (1993). Large deformable splines, crest lines and matching. *In International conference on computer vision, IEEE computer society press*, pp. 650–657.
- Hajnal, J. V.; Saeed, N.; Oatridge, A.; Williams, E. J.; Young, I. R. e Bydder, G. M. (1995). Detection of subtle brain changes using subvoxel registration and subtraction of serial mr images. *Journal of computer assisted tomography*, pp. 677–691.
- Hemler, P. F.; Sumanaweera, T.; Pichumani, R.; van den Elsen, P. A.; Napel, S.; Drace, J. e Adler, J. (1994). A system for multimodality image fusion of the spine. *In Applications of computer vision in medical image processing, AAAI spring symposium series*, pp. 42–45.
- Hemler, P. F.; Sumanaweera, T.; van den Elsen, P. A.; Napel, S. e Adler, J. R. (1996). Quantified registration error versus the accuracy of registered surfaces for a multimodality surfacebased registration system. *In Loew, M. H. and Hanson, K. M. (eds), Medical Imaging: Image processing*, 2710:348–357.
- Hill, D. L. G.; Studholme, C. e Hawkes, D. J. (1994). Voxel similarity measures for automated image registration. *Visualization in biomedical computing*, pp. 205–216.
- Horn, B. K. P.; Hilden, H. M. e Negahdaripour, S. (1988). Closed-form solution of absolute orientation using orthonormal matrices. *Journal of the Optical Society of America*, pp. 1127–1137.
- Hufnagel, H.; Pennec, X.; Ehrhardt, J.; Ayache, N. e Handels, H. (2008). Generation of a statistical shape model with probabilistic point correspondences and em-ic. *International Journal for Computer Assisted Radiology and Surgery - IJCARS*, 2:265273.
- Jiang, H.; Holton, K. e Robb, R. (1992). Image registration of multimodality 3-d medical images by chamfer matching. *Technical report, Dept of Physiology and Biophysics, Biomedical Imaging Resource, Mayo Foundation, Rochester, MN 55905*.
- Lehmann, T.; Gonner, C. e Spitzer, K. (1999). Survey: Interpolation methods in medical image processing. *IEEE Transactions on Medical Imaging*.

- Levin, D. N.; Pelizzari, C. A.; Chen, G. T.; Chen, C. e Cooper, M. D. (1998). Retrospective geometric correlation of mr, ct, and pet images. *Radiology*, 169:817–823.
- Levin, D. N.; Pelizzari, C. A.; Chen, G. T. Y.; Chen, C. e Cooper, M. D. (1988). Retrospective geometric correlation of mr, ct, and pet images. *Radiology*, 169:817–823.
- Li, S.; Peng, J.; Kwok, J. e Zhang, J. (2006). Multimodal registration using the discrete wavelet frame transform. *18th International Conference on Pattern Recognition*, pp. 877 – 880.
- Liang, Z. e Lauterbur, P. C. (2000). *Principles of Magnetic Resonance Imaging*.
- Liu, X. e Imielinska, C. Laine, A. D. A. (2007). Symmetry based multi-modality registration of the brain imagery. *IEEE International Symposium on Signal Processing Information Technology*, pp. 807 – 812.
- Maguire, G. Q.; Noz, M.; Rusinek, H.; Jaeger, J.; Kramer, E. L.; Sanger, J. e Smith, G. (1991). Graphics applied to medical image registration. *IEEE Computer graphics and applications*, 11:20–28.
- Maintz, J. B. A.; Beekman, F. J.; de Bruin, W.; van den Elsen, P. A.; van Rijk, P. P. e Viergever, M. A. (1996). Automatic registration and intensity scaling of spect brain images. *Journal of nuclear medicine*, p. 213.
- Maintz, J. B. A. e Viergever, M. A. (1997). A survey of medical image registration. *Oxford University Press*.
- Maurer, C. R.; Fitzpatrick, J. M.; Galloway, R. L.; Wang, M. Y.; Maciunas, R. J. e Allen, G. S. (1995). The accuracy of image-guided neurosurgery using implantable fiducial markers. In *Lemke, H. U., Inamura, K., Jaffe, C. C. AND Vannier, M. W. (eds), Computer assisted radiology, Berlin, Springer-Verlag*, pp. 1197–1202.
- Pearson, K. (1901). *On lines and planes of closest fit to systems of points in space*. Philosophical Magazine.
- Pennec, X. e Thirion, J. (1995). Validation of 3-d registration methods based on points and frames. In *International conference on computer vision, Los Alamitos*, pp. 557–562.
- Petti, P. L.; Kessler, M. L.; Fleming, T. e Pitluck, S. (1994). An automated image-registration technique based on multiple structure matching. *Medical physics*, 21:1419–1426.

- Pietrzyk, U.; Herholz, K.; Schuster, A.; von Stockhausen, H.; Lucht, H. e Heiss, W. (1996). Clinical applications of registration and fusion of multimodality brain images from pet, spect, ct, and mri. *European journal of radiology*, 21:174–182.
- Posada-Gomez, R.; Alor-Hernez, G.; Garcia-Martinez, M. e Martinez-Sibaja, A. (2007). Non-invasive tumor localization by 3d registration of range sensor computer tomography images. *Eighth Mexican International Conference on Current Trends in Computer Science*, pp. 65–72.
- Rusinek, H.; Tsui, W.; Levy, A. V.; Noz, M. E. e de Leon, M. J. (1993). Principal axes and surface fitting methods for threedimensional image registration. *Journal of nuclear medicine*, 34:2019–2024.
- Shlens, J. (2005). A tutorial on principal component analysis. *Systems Neurobiology Laboratory, Salk Insitute for Biological Studies*.
- Stavness, I.; Hannam, A.; Lloyd, J. e Fels, S. (2006). An integrated, dynamic jaw laryngeal model constructed from ct data. *Proceedings of ISBMS 06 in Springer LNCS 407*, pp. 169–177.
- Strother, S. C.; ANDerson, J. R.; Xu, X.; Liow, J.; Bonar, D. C. e Rottenberg, D. A. (1994). Quantitative comparisons of image registration techniques based on high-resolution mri of the brain. *Journal of computer assisted tomography*, 18:954–962.
- Taneja, U.; Holton, K. S.; Camp, J. C. e Robb, R. A. (1994). Evaluating the accuracy of three-dimensional image registration algorithms used in multimodal image fusion in visualization in biomedical computing. *Radiology*, 2359:238–250.
- Thevenaz, P. e Unser, M. (1998). An efficient mutual information optimizer for multi-resolution image registration.
- Thirion, J. (1994). Extremal points: definition and application to 3d image registration. *In Computer vision AND pattern recognition, Los Alamitos, CA. IEEE Computer Society press*, pp. 587–592.
- Trucco, E.; Fusiello, A. e Roberto, V. (1999). Robust motion correspondence of noisy 3-d point sets with missing data. *Pattern Recognition Letters*, 20:889–898.
- Trucco, E. e Verri, A. (1998). *Introductory Techniques for 3-D computer Vision*. Prentice Hall.
- van den Elsen, P. A.; Pol, E. J. D. e Viergever, M. A. (1993). Medical image matching - a review with classification. *IEEE Engineering in medicine and biology*, pp. 26–39.

- van den Elsen, P. A. e Viergever, M. A. (1993). Automated ct and mr brain image registration using geometrical feature correlation. *In Nuclear science symposium and medical imaging conference IEEE*, pp. 1827–1830.
- Vandermeulen, D.; Collignon, A.; Michiels, J.; Bosmans, H.; Suetens, P.; Marchal, G.; Timmens, G.; van den Elsen, P.; Viergever, M.; Ehrlicke, H.; Hentschel, D. e Graumann, R. (1995). Multi-modality image registration within covira. *In Beolchi, L. and Kuhn, M. H. (eds), Medical imaging: analysis of multimodality 2D/3D images*, 19:29–42.
- Viola, P. A. (1995). Alignment by maximization of mutual information. *Ph.D. Thesis Massachusetts institute of technology*.
- Vogt, F.; Lloyd, J.; Buchaillard, S.; Perrier, P.; Chabanas, M.; Payan, Y. e Fels, S. (2007). Investigation of efficient 3d finite element modeling of a muscle-activated tongue. *Proceedings of ISBMS 06 in Springer LNCS 407*, pp. 19–28.
- Wang, X.; Cheng, Y.-Q.; Collins, R. T. e Hanson, A. R. (1996). Determining correspondences and rigid motion of 3-d point sets with missing data.
- Wong, A. (2008). Simultaneous multi-modal registration of multiple images based on multi-dimensional joint phase moment distributions. *IEEE*, pp. 65–72.
- Yanovsky, I.; Osher, S.; Thompson, P. e A., L. (2007a). Log-unbiased large-deformation image registration. *Computer Vision Theory and Applications*, 1:272–279.
- Yanovsky, I.; Thompson, P.; Osher, S. e Leow, A. (2007b). Topology preserving log-unbiased nonlinear image registration: Theory and implementation. *IEEE Conference on Computer Vision and Pattern Recognition*, 31.
- Zinßer, T.; Schmidt, J. e Numann, H. (2003). A refined icp algorithm for robust 3-d correspondence estimation. *IEEE Trans*.
- Zuk, T.; Atkins, S. e Booth, K. (1994). Approaches to registration using 3d surfaces. *Medical imaging: image processing Bellingham, WA SPIE Press*, 2167:176–187.