



INSTITUTO SUPERIOR TÉCNICO
Universidade Técnica de Lisboa

Alinhamento de imagens médicas 2D e 3D

Miguel dos Santos Venâncio

Dissertação para obtenção do Grau de Mestre em
Engenharia Electrotécnica e de Computadores

Júri

Presidente: Prof. Carlos Jorge Ferreira Silvestre

Orientador: Prof^a Maria Margarida Campos da Silveira

Co-Orientador: Prof. Pedro Manuel Quintas Aguiar

Vogal: Prof. Jorge dos Santos Salvador Marques

Setembro, 2008

Agradecimentos:

O autor agradece à Professora Margarida Silveira e ao Professor Pedro Aguiar toda a colaboração prestada durante a execução deste trabalho, bem como toda a disponibilidade e apoio no esclarecimento de dúvidas e explicações diversas. Agradece-se também à Professora Isabel Ribeiro e a João Mota pela cedência da imagem das galerias romanas essenciais para o estudo desenvolvido.

Muito obrigado aos meus pais, irmão e a toda a minha família pela força que transmitiram, afecto e cooperação, bem como por proporcionarem todas as condições necessárias para que os objectivos pudessem ser atingidos.

A todos os meus amigos, um sincero obrigado, pelo companheirismo e tolerância demonstrada ao longo de todo o percurso universitário.

Resumo:

Nesta dissertação são avaliados e comparados dois métodos de alinhamento de imagens, de classes distintas. Da classe dos métodos baseados em emparelhamento de características foi escolhido o método ICP (*Iterative Closest Point*) [1], que é um dos mais utilizados quer em aplicações 2D quer 3D. Da classe dos métodos baseados em intensidade foi estudado um algoritmo que permite lidar com imagens com diferentes intensidades pois estima em simultâneo o alinhamento e a normalização dessas mesmas intensidades [2]. Nesta tese este método será denotado por SRIN (*Simultaneous Registration and Intensity Normalization*). Dado que são métodos de diferente natureza, o método de SRIN será aplicado a imagens de intensidade criadas a partir das mesmas características que as usadas pelo método ICP. Desta forma, no método SRIN é evitado o passo de emparelhamento de características.

Os resultados experimentais evidenciam que o algoritmo SRIN possui uma excelente capacidade de convergência e precisão de alinhamento utilizando diversos tipos de imagem e demonstram uma superioridade deste em relação ao ICP.

Palavras-chave:

Alinhamento de imagem, *iterative closest point*, normalização de intensidades, imagens médicas, dados de sensor laser

Abstract:

Two image registration methods of different classes are evaluated and compared in this dissertation. From the feature based methods, the chosen algorithm was the ICP (*Iterative Closest Point*) [1], which is one of the most commonly used image registration algorithms in 2D and 3D applications. From the area based methods, the studied algorithm permits the registration of images with different intensities since it simultaneously estimates the transformation parameters and the image normalization [2]. In this dissertation, this method will be referred to as SRIN (*Simultaneous Registration and Intensity Normalization*). Since these two methods are from different nature, the SRIN method will be applied in intensity images created from the same features used by the ICP method. In this way, the SRIN method avoids the step of feature correspondence.

Experimental results demonstrate that the SRIN algorithm has an excellent convergence capacity and registration precision using a variety of different images and reveal superiority of the SRIN method over the ICP.

Keywords:

Image registration, iterative closest point, intensity normalization, medical imaging, laser sensor data

Índice:

Agradecimentos:.....	3
Resumo:	5
Palavras-chave:.....	5
Abstract:.....	6
Keywords:.....	6
Índice:	7
Índice de figuras:	10
Índice de gráficos:	17
Lista de abreviaturas:	19
Capítulo 1.....	20
Introdução	20
Capítulo 2.....	23
Técnicas de alinhamento	23
2.1 Métodos baseados em emparelhamento de características	26
2.1.1 Tipos de características	26
2.1.2 Correspondência entre características	27
2.1.2.1 Métodos baseados em relações espaciais	27
2.1.2.2 Métodos baseados em descritores invariantes.....	27
2.1.2.3 Métodos de relaxação.....	28
2.2 Métodos baseados em intensidade	29
2.2.1 Métodos de Correlação.....	29

2.2.2 Métodos de <i>Fourier</i>	30
2.2.3 Métodos de informação mútua.....	30
2.2.4 Métodos de optimização	31
2.3 Tipos de modelo de transformação	32
2.3.1 Modelos globais	32
2.3.1.1 Transformação de corpo rígido.....	32
2.3.1.2 Transformação de semelhança Euclidiana	33
2.3.1.3 Transformação Afim.....	34
2.3.1.4 Transformação projectiva.....	35
2.3.2 Modelos locais.....	35
2.3.3 Modelos radiais	35
2.3.4 Alinhamento elástico	36
2.4 Transformação e interpolação da imagem	37
Capítulo 3.....	38
Descrição dos algoritmos estudados.....	38
3.1 <i>Iterative Closest Point</i> (ICP)	38
3.1.1 Algoritmo de detecção de contornos.....	43
3.2 Alinhamento e normalização de intensidade simultâneos (SRIN)	47
Capítulo 4.....	52
Resultados experimentais	52
4.1 Descrição dos dados	52
4.2 Métricas de desempenho	56
4.3 Resultados obtidos com ressonância magnética cerebral	57
4.3.1 <i>Iterative Closest Point</i> (ICP).....	57

4.3.2 Alinhamento e normalização de intensidade simultâneo (SRIN).....	61
4.3.3 Análise.....	65
4.4 Resultados obtidos com imagem de vasos sanguíneos de retina humana	68
4.4.1 <i>Iterative Closest Point</i> (ICP).....	68
4.4.2 Alinhamento e normalização de intensidade simultâneos (SRIN).....	74
4.4.3 Análise.....	81
4.5 Resultados obtidos com volume de galerias romanas adquirido por sensor laser	84
4.5.1 <i>Iterative Closest Point</i> (ICP).....	85
4.5.2 Alinhamento e normalização de intensidade simultâneos (SRIN).....	93
4.5.3 Análise.....	99
Capítulo 5.....	102
Conclusões e trabalho futuro	102
Bibliografia	103

Índice de figuras:

Figura 1 - Exemplo de alinhamento 2D de uma retina humana (na figura da esquerda a imagem original, no centro a imagem a alinhar e na da direita a sobreposição das imagens após alinhamento)	20
Figura 2 - Exemplo de alinhamento 3D de um volume cerebral humano (na esquerda a verde o volume original e a vermelho o volume a alinhar, na direita os volumes alinhados)	21
Figura 3 - Ilustração de um processo de alinhamento [3]	24
Figura 4 - Exemplo de alinhamento usando correlação cruzada normalizada [43]	30
Figura 5 - Exemplo de alinhamento utilizando informação mútua (a imagem original à esquerda, a imagem a alinhar ao centro e o alinhamento à direita)	31
Figura 6 - Exemplos de transformações em 2D (rotação, translação e escala)	33
Figura 7 - Sentidos de rotação do <i>Yaw</i> , <i>pitch</i> e <i>roll</i>	34
Figura 8 - Distância mínima entre pontos das rectas representadas a verde e amarelo	39
Figura 9 a) Triangulação de Delaunay do volume MRI cerebral b) Triangulação de Delaunay do volume galerias romanas	39
Figura 10 - Exemplo de alinhamento para mínimo local	42
Figura 11 - Orientação do vector gradiente	44
Figura 12 - Exemplo de detecção de contornos utilizando operador Sobel	46
Figura 13 - Exemplo de imagem de difícil extração de características (Cortes SPECT) [68]	47
Figura 14 - Exemplo da estratégia de pirâmide em 3 níveis em que o alinhamento se inicia na resolução mais baixa e vai gradualmente subindo até à resolução original	51
Figura 15 - Visualização tridimensional de um cérebro humano adquirido por MRI	53
Figura 16 - Cortes transversais de um cérebro humano adquirido por MRI	53
Figura 17 - Imagem dos vasos sanguíneos de uma retina humana	54
Figura 18 - Volume de galerias romanas obtido por sensor laser	55
Figura 19 - Cortes transversais de volume de galerias romanas obtido por sensor laser	55

Figura 20 - ICP - a) Volumes de MRI cerebral desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao volume original a verde. b) Volumes de MRI cerebral alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao volume original a verde 59

Figura 21 - ICP - a) Sobreposição dos cortes transversais de MRI cerebral desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde. b) Sobreposição dos cortes transversais de MRI cerebral alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde..... 59

Figura 22 - ICP - a) Volumes de MRI cerebral desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao volume original a verde. b) Volumes de MRI cerebral alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao volume original a verde 60

Figura 23 - ICP - a) Sobreposição dos cortes transversais de MRI cerebral desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao corte original a verde. b) Sobreposição dos cortes transversais de MRI cerebral alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original a verde..... 61

Figura 24 - SRIN - a) Volumes de MRI cerebral desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao volume original a verde. b) Volumes de MRI cerebral alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao volume original a verde 63

Figura 25 - SRIN - a) Sobreposição dos cortes transversais de MRI cerebral desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde. b) Sobreposição dos cortes transversais de MRI cerebral alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde..... 64

Figura 26 - SRIN - a) Volumes de MRI cerebral desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao volume original a verde. b) Volumes de MRI cerebral alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao volume original a verde 64

Figura 27 - SRIN - a) Sobreposição dos cortes transversais de MRI cerebral desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde. b) Sobreposição dos cortes transversais de MRI cerebral alinhados. O

corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde..... 65

Figura 28 - ICP - a) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi sintetizado por aplicação da transformação geométrica T1 ao corte original a vermelho b) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a vermelho 70

Figura 29 - ICP - a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. A imagem a vermelho foi sintetizada por aplicação da transformação geométrica T1 à imagem original verde b) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original verde..... 71

Figura 30 - ICP - a) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi sintetizado por aplicação da transformação geométrica T2 ao corte original a vermelho. b) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original a vermelho 72

Figura 31 - ICP - a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi sintetizado por aplicação da transformação geométrica T2 ao corte original verde. b) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original verde..... 72

Figura 32 - ICP - a) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas I_1 (a verde) e I_2 (a vermelho) b) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas I_1 (a verde) e I_2 (a vermelho) após alinhamento com o algoritmo ICP 73

Figura 33 - ICP - a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento I_1 (a verde) e I_2 (a vermelho) b) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento I_1 (a verde) e I_2 (a vermelho) após alinhamento 74

Figura 34 - ICP - a) Imagem de erro inicial. b) Imagem de erro final..... 74

Figura 35 - SRIN - a) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi sintetizado por aplicação da transformação geométrica T1 ao corte

original a vermelho b) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a vermelho 76

Figura 36 - SRIN - a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original verde b) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original verde 77

Figura 37 - SRIN - a) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi sintetizado por aplicação da transformação geométrica T2 ao corte original a vermelho b) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original a vermelho 77

Figura 38 - SRIN - a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi sintetizado por aplicação da transformação geométrica T2 ao corte original verde b) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original verde 78

Figura 39 - SRIN em imagem de características - a) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas I_1 (a verde) e I_2 (a vermelho) b) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas I_1 (a verde) e I_2 (a vermelho) após alinhamento com o algoritmo SRIN em imagem de características 79

Figura 40 - SRIN em imagem de características - a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento I_1 (a verde) e I_2 (a vermelho) b) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento I_1 (a verde) e I_2 (a vermelho) após alinhamento com o algoritmo SRIN em imagem de características ... 79

Figura 41 - SRIN em imagem de características - a) Imagem de erro final b) Imagem de erro final
80

Figura 42 - SRIN por intensidade original - a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento I_1 (a verde) e I_2 (a vermelho) b) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento I_1 (a verde) e I_2 (a vermelho) após alinhamento pelo algoritmo SRIN nas intensidades originais 80

Figura 43 - SRIN por intensidade original - a) Imagem de erro inicial	b) Imagem de erro final.....	81
Figura 44 - ICP - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao volume original a verde	b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao volume original a verde	87
Figura 45 - ICP - a) Sobreposição dos cortes transversais das galerias romanas desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde	b) Sobreposição dos cortes transversais das galerias romanas alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde.....	87
Figura 46 - ICP - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao volume original a verde	b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao volume original a verde	88
Figura 47 - ICP - a) Sobreposição dos cortes transversais das galerias romanas desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao corte original a verde-	b) Sobreposição dos cortes transversais das galerias romanas alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original a verde.....	89
Figura 48 - ICP - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde-	b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde	90
Figura 49 - ICP - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde-	b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde	91
Figura 50 - ICP - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde, e retirando-lhe CP	b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde e retirando-lhe CP.....	92

Figura 51 - ICP - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde, e retirando-lhe *CP* b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde e retirando-lhe *CP*..... 92

Figura 52 - SRIN - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao volume original a verde b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao volume original a verde 95

Figura 53 - SRIN - a) Sobreposição dos cortes transversais das galerias romanas desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde b) Sobreposição dos cortes transversais das galerias romanas alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde 95

Figura 54 - SRIN - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao volume original a verde b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao volume original a verde 96

Figura 55 - SRIN - a) Sobreposição dos cortes transversais das galerias romanas desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao corte original a verde b) Sobreposição dos cortes transversais das galerias romanas alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original a verde 96

Figura 56 - SRIN - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde- b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde 97

Figura 57 - SRIN - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde 98

Figura 58 - SRIN - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume

original a verde e retirando-lhe *CP* b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde e retirando-lhe *CP*..... 98

Figura 59 - SRIN - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde e retirando-lhe *CP* b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde e retirando-lhe *CP*..... 99

Índice de gráficos:

Gráfico 1 - ICP - Percentagem de não convergências por percentagem de <i>CP</i> no volume de MRI cerebral.....	57
Gráfico 2 - ICP - $Erro_{RMS\ médio}$ por percentagem de <i>CP</i> no volume de MRI cerebral	58
Gráfico 3 - SRIN - Percentagem de não convergências por percentagem de <i>CP</i> no volume de MRI cerebral.....	62
Gráfico 4 - SRIN - $Erro_{RMS\ médio}$ por percentagem de <i>CP</i> no volume de MRI cerebral.....	62
Gráfico 5 - Comparação das percentagens de não convergências por percentagens de <i>CP</i> no volume de MRI cerebral entre o ICP e o SRIN	66
Gráfico 6 - Comparação do $Erro_{RMS\ médio}$ por percentagens de <i>CP</i> no volume de MRI cerebral entre o ICP e o SRIN	66
Gráfico 7 - ICP - Percentagem de não convergências por percentagem de <i>CP</i> na imagem dos vasos sanguíneos da retina humana.....	69
Gráfico 8 - ICP - $Erro_{RMS\ médio}$ por percentagem de <i>CP</i> na imagem dos vasos sanguíneos da retina humana.....	69
Gráfico 9 - SRIN - Percentagem de não convergências por percentagem de <i>CP</i> na imagem dos vasos sanguíneos da retina humana.....	75
Gráfico 10 - SRIN - $Erro_{RMS\ médio}$ por percentagem de <i>CP</i> na imagem dos vasos sanguíneos da retina humana.....	75
Gráfico 11 - Sobreposição da percentagem de não convergências por percentagem de <i>CP</i> na imagem dos vasos sanguíneos da retina humana.....	82
Gráfico 12 - Sobreposição do $Erro_{RMS\ médio}$ por percentagem de <i>CP</i> na imagem dos vasos sanguíneos da retina humana.....	82
Gráfico 13 - ICP - Percentagem de não convergências por percentagem de <i>CP</i> nas galerias romanas	85
Gráfico 14 - ICP - $Erro_{RMS\ médio}$ por percentagem de <i>CP</i> nas galerias romanas	86

Gráfico 15 - SRIN - Percentagem de não convergências por percentagem de <i>CP</i> nas galerias romanas.....	93
Gráfico 16 - SRIN - $\bar{Erro}_{RMS\ médio}$ por percentagem de <i>CP</i> nas galerias romanas	94
Gráfico 17 - Comparação das percentagens de não convergências por percentagens de <i>CP</i> nas galerias romanas entre o ICP e o SRIN	100
Gráfico 18 - Comparação do $\bar{Erro}_{RMS\ médio}$ por percentagens de <i>CP</i> nas galerias romanas entre o ICP e o SRIN	100

Lista de abreviaturas:

CC - Correlação Cruzada normalizada

CP - *Control Points*

CR - *Correlation Ratio*

CT - *Computer Tomography*

ICP - *Iterative Closest Point*

MI - *Mutual Information*

MR - *Magnetic Resonance*

MRI - *Magnetic Resonance Imaging*

NMR - *Nuclear Magnetic Resonance*

PET - *Positron Emission Tomography*

RMS - *Root Mean Square*

SPECT - *Single Photon Emitting Computer Tomography*

SRIN - *Simultaneous Registration and Intensity Normalization*

SUSAN - *Smallest Univalve Segment Assimilating Nucleus*

SVD - *Singular Value Decomposition*

TPS - *Thin Plate Splines*

Capítulo 1

Introdução

Um problema comum em várias áreas de aplicação relacionadas com visão é lidar com imagens obtidas por sistemas de aquisição imperfeitos. Geometrias de imagem diferentes, erros de sensor, variação das condições do sensor ou climáticas podem introduzir vários tipos de distorção e degradação à imagem observada quando comparada com a imagem original. Estes podem resultar em imagens que sofrem de degradação por ruído, *blurring* ou mudanças de brilho/contraste. Constitui igualmente um obstáculo o facto de as imagens poderem ter orientações, escalas e posições diferentes ou/e sofrerem de distorções geométricas.

O alinhamento das imagens é de vital importância para aplicações cujas tarefas de análise de imagem, forneçam informação conseguida através da combinação de dados de várias fontes, como por exemplo, fusão de imagens, detecção de diferenças ou restauração multicanal. Dadas duas ou mais imagens da mesma cena, mas tiradas em momentos distintos, de ângulos diferentes ou por sensores de aquisição diversos, o sistema de alinhamento de imagens estima os parâmetros do modelo da transformação geométrica que melhor mapeia uma dada imagem alvo, para obter uma sobreposição perfeita entre as imagens.

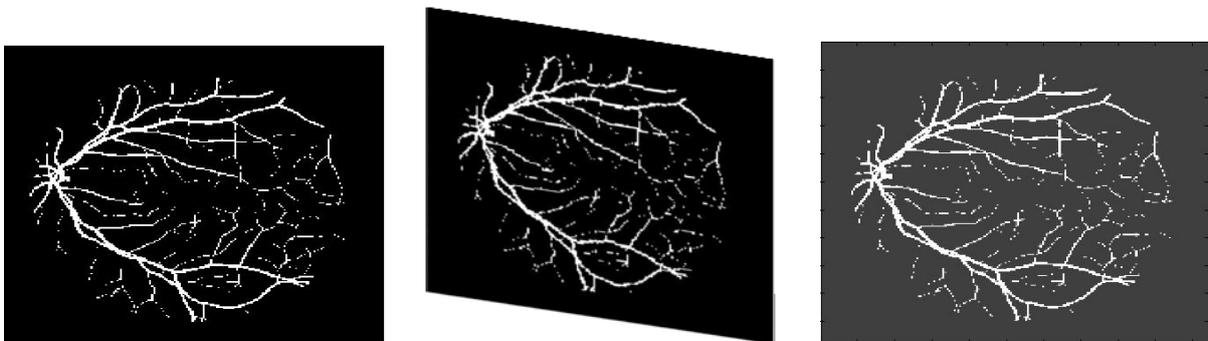


Figura 1 - Exemplo de alinhamento 2D de uma retina humana (na figura da esquerda a imagem original, no centro a imagem a alinhar e na da direita a sobreposição das imagens após alinhamento)

O alinhamento é então usado como primeiro passo em sistemas de processamento e análise de imagens como detecção remota (e.g. classificação multi-espectral, monitorização ambiental, detecção de discrepâncias, união de imagens, previsão meteorológica, criação de imagens de super-resolução), cartografia (actualização de mapas), visão computacional (localização de alvos, controlo de qualidade automática) ou medicina (e.g. combinação de imagens de CT e NMR para obter

informação mais detalhada sobre o paciente, monitorizar o crescimento de tumores, comparação entre os dados do paciente com atlas de anatomia (ver Figura 2)).

De uma perspectiva matemática simples, dadas duas imagens para serem alinhadas, o algoritmo de alinhamento estima os parâmetros do modelo da transformação geométrica τ_G que mapeia a imagem alvo para a de referência. Desta forma, o modelo de transformação mapeia um ponto $X' = (x'_1, x'_2)$ da imagem I' , para um ponto $X = (x_1, x_2)$ na imagem de referência I , sendo que $X = \tau_G(X')$. Se a um *pixel* p da imagem I corresponder um *pixel* p' da imagem I' então um alinhamento exacto deve resultar em $\tau_G(p')$ muito próximo de p . É fácil de ver que um erro de alinhamento pode ser definido por $\tau_G(I') - I$. O procedimento é igual para o caso de três dimensões, sendo que os pontos passam a ter três coordenadas, $X_{3D} = (x_1, x_2, x_3)$ e $X'_{3D} = (x'_1, x'_2, x'_3)$, o modelo de transformação geométrica $\tau_{G_{3D}}$ tem mais parâmetros e passamos a ter os *voxels* v e v' de tal forma que $X_{3D} = \tau_{G_{3D}}(X'_{3D})$ e $\tau_{G_{3D}}(v')$, muito próximo de v , e um erro de alinhamento associado que pode ser definido por $\tau_{G_{3D}}(I'_{3D}) - I_{3D}$.

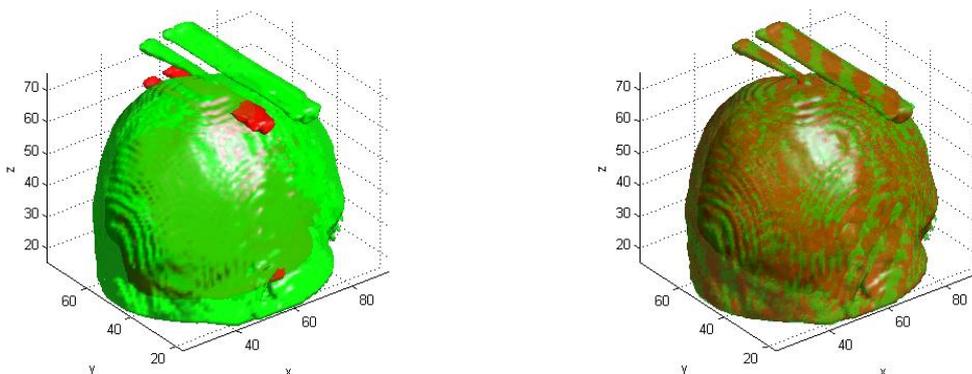


Figura 2 - Exemplo de alinhamento 3D de um volume cerebral humano (na esquerda a verde o volume original e a vermelho o volume a alinhar, na direita os volumes alinhados)

Com generalidade, os métodos de alinhamento de imagens podem ser divididos em dois grandes grupos: alinhamento baseado em emparelhamento de características e alinhamento global, ou seja, baseado na intensidade.

O alinhamento baseado em características inicia-se com a detecção destas dentro das imagens. As características são pontos distintivos na própria imagem, que podem tomar diversas formas. De seguida é executado um emparelhamento entre as características das imagens e posteriormente são estimados os parâmetros da função de mapeamento. O grande problema destes

métodos encontra-se na fase de detecção e emparelhamento das características. Na detecção de características, podemos encontrar-nos numa situação em que não é possível garantir a existência de pontos característicos em todas as zonas de interesse. Na correspondência entre características, problemas de ruído, oclusão de objectos de uma imagem para a outra devido a diversas razões (movimento, iluminação), podem levar a que características facilmente detectadas numa imagem não tenham correspondência na outra, ou que tenham um emparelhamento incorrecto.

O alinhamento global utiliza directamente os valores das intensidades dos *pixéis* ou *voxels* das imagens para estimar os parâmetros da função de transformação, recorrendo á minimização de uma função de custo entre as duas imagens. Estes processos utilizam normalmente o gradiente das imagens, o que leva a que, exista a possibilidade de os métodos de minimização convergirem para um mínimo local, o que é indesejável. Daqui resulta o facto de estes métodos necessitarem de uma boa estimativa inicial de forma a proporcionarem um alinhamento correcto.

Nesta dissertação são avaliados e comparados dois métodos de alinhamento de imagens, de classes distintas. Da classe dos métodos baseados em emparelhamento de características foi escolhido o método ICP (*Iterative Closest Point*), que é um dos mais utilizados quer em aplicações 2D quer 3D. Da classe dos métodos baseados em intensidade foi estudado um algoritmo que permite lidar com imagens com diferentes intensidades pois estima em simultâneo o alinhamento e a normalização dessas mesmas intensidades [2]. Nesta tese este método será denotado por SRIN (*Simultaneous Registration and Intensity Normalization*). Dado que são métodos de diferente natureza, o método de SRIN será aplicado a imagens de intensidade criadas a partir das mesmas características que as usadas pelo método ICP. Desta forma, no método SRIN é evitado o passo de emparelhamento de características.

Para efectuar a comparação entre os dois métodos de alinhamento, estes foram aplicados a imagens médicas de diferentes modalidades. Adicionalmente, e dado que são algoritmos de âmbito geral, foram testados num conjunto de dados de sensor laser.

Esta dissertação encontra-se organizada em 5 capítulos O primeiro capítulo descreve abreviadamente o problema abordado. São apontadas algumas motivações para estudar o problema e aplicações deste em diversas áreas. No segundo capítulo são apresentadas as principais técnicas de alinhamento existentes. São descritos os passos de cada método de alinhamento bem como as métricas utilizadas por cada um deles. No terceiro capítulo são descritos pormenorizadamente os dois algoritmos estudados nesta dissertação. No quarto capítulo são relatadas as experiências realizadas e os resultados obtidos. Finalmente, no quinto capítulo apresentam-se as conclusões e o trabalho futuro.

Capítulo 2

Técnicas de alinhamento

Devido à elevada multiplicidade de problemas a que o alinhamento de imagem tem de responder, em simultâneo com as inúmeras formas de degradação que estas podem sofrer, é impossível conceber um método universal de alinhamento que possa ser aplicado a todas as tarefas.

Todos os métodos devem ter em conta as características, a quantidade de ruído e a deformação geométrica das imagens, bem como a precisão do alinhamento requerido pelo problema a resolver. No entanto, a maioria dos algoritmos de alinhamento consiste nos seguintes quatro passos:

- **Detecção de características** - Extração, de preferência automática, de objectos salientes e distintivos na imagem (regiões fechadas, linhas de contorno, cantos, etc.). Para processamento posterior, as características são representadas por pontos, que são chamados de *control points* (CP).
- **Correspondência entre características** - Estabelecimento da relação entre as características detectadas na imagem de referência com as da imagem observada. São usadas várias métricas de similaridade e descritores de características para resolver este passo.
- **Estimação do modelo de transformação** – Estimação dos parâmetros da função de transformação de acordo com o seu tipo. São usadas as correspondências entre características para a estimativa dos parâmetros da função de mapeamento.
- **Transformação e interpolação da imagem** – Transformação da imagem de acordo com os parâmetros estimados no passo anterior. Os valores da imagem em coordenadas não inteiras são calculados usando técnicas de interpolação adequadas.

Estes passos são ilustrados na Figura 3, em que na primeira linha se pode ver a detecção de características (neste caso, cantos), na segunda linha mostra-se a correspondência entre elas (os pares correspondentes estão marcados com números) e na última linha, do lado esquerdo temos a estimação dos parâmetros da transformação e à direita a transformação e a interpolação da imagem.

A implementação de cada um destes passos tem os seus problemas típicos. Inicialmente é necessário decidir qual o tipo de característica necessária para resolver o problema. Estes têm de ser objectos distintos e espalhados pela imagem. Tem de haver um número mínimo de características comuns entre a imagem observada e a de referência, mesmo que estas não cubram exactamente a

mesma cena, ou que exista alguma mudança numa das imagens. Os métodos de detecção devem ser também imunes a ruído ou a outras formas de degradação da imagem.

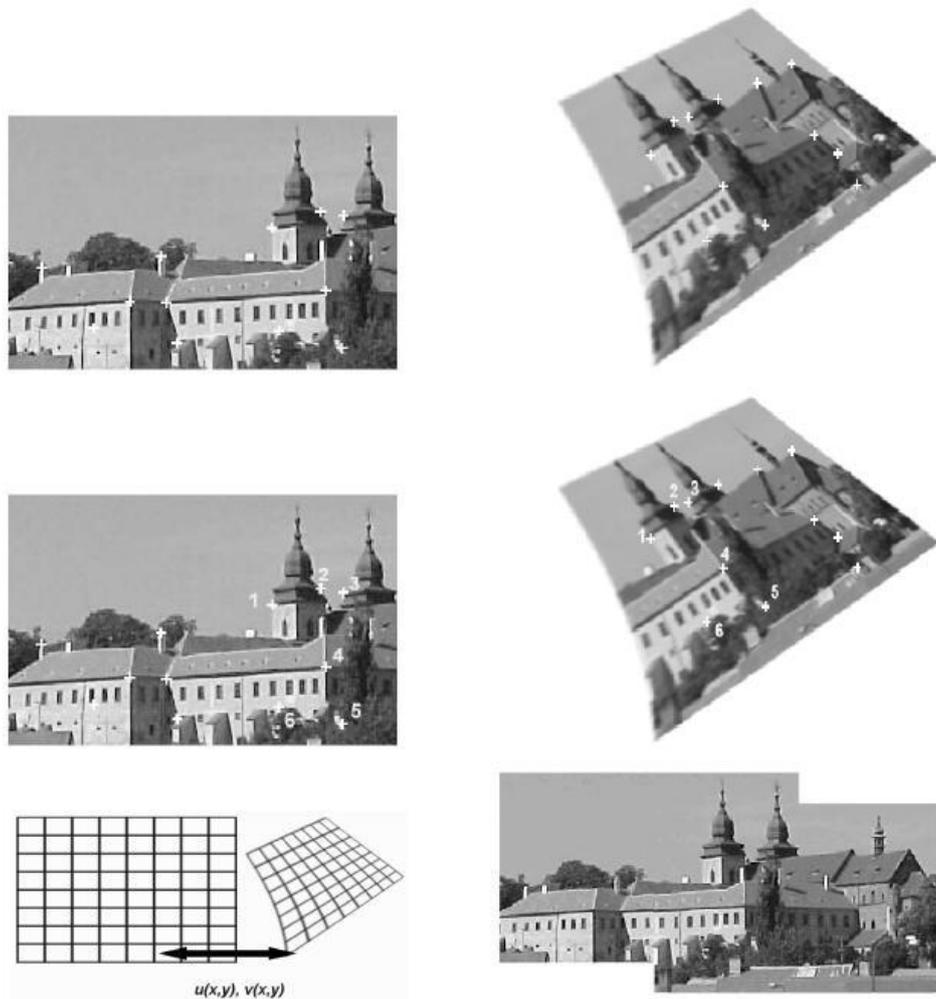


Figura 3 - Ilustração de um processo de alinhamento [3]

Problemas provocados por uma detecção incorrecta de características ou por degradação da imagem podem surgir no processamento das relações entre características. Diferentes condições de aquisição de imagem ou uma diferente sensibilidade espectral dos sensores podem provocar que características correspondentes fisicamente não sejam marcadas como tal. A escolha dos descritores e das métricas de similaridade têm de ter em conta estes factores, sendo que o ideal seria os primeiros serem invariantes às últimas. Este processo tem de ser capaz de fazer a distinção entre características diferentes, não ser influenciado pela presença de ruído, e mesmo que existam características sem correspondência estas não podem afectar o seu desempenho.

Normalmente, a escolha da função de transformação é feita tendo em conta informação sobre os métodos de aquisição das imagens e a degradação esperada. Se não existir nenhuma desta

informação, o modelo escolhido deve ser o mais geral possível, de forma a lidar com todas as alterações que possam existir. Nesta escolha pesam igualmente os erros provenientes dos passos anteriores e ainda o erro mínimo de aproximação aceitável.

A selecção da técnica de interpolação adequada depende da precisão da transformação exigida, ou do tempo computacional necessário para a fazer. Sendo que quanto maior for a precisão da interpolação, maior é também o tempo necessário para a realizar.

De seguida são apresentadas várias técnicas para solucionar cada um dos passos anteriormente apresentados.

2.1 Métodos baseados em emparelhamento de características

Nestes métodos, e tal como descrito anteriormente, é necessária a extracção de características da imagem. Estas *características* podem ser regiões, linhas ou pontos e representam informação num nível superior. Esta propriedade torna estes métodos ideais para situações em que são expectáveis mudanças de iluminação ou em análise multi-sensor.

2.1.1 Tipos de características

As regiões são secções fechadas de alto contraste e de um tamanho apropriado dentro da imagem [4]. Podem ser lagos ou reservatórios, florestas, sombras [3], edifícios [5] ou áreas urbanas [6]. Estas regiões são geralmente representadas por descritores invariantes a rotações, escalas e estáveis perante ruído e variações de nível de cinzento. Estas regiões são detectadas por algoritmos de segmentação [3], sendo que a sua precisão pode influenciar significativamente o resultado do alinhamento. Recentemente, a ideia de descritores invariantes a mudanças de escala fez surgir um novo algoritmo usando círculos virtuais em conjunto com transformações de distância [7]. Outro método utilizando vizinhanças invariantes [8], é baseado no algoritmo de Harris para detecção de cantos [9]. Um modo de abordagem diferente foi proposto por Matas *et al* [10], usando regiões extremas maximamente estáveis.

As *características* de tipo linha podem ser representações de segmentos de linha gerais [5], contornos de objectos [11], linhas costeiras [12], estradas [13] ou estruturas anatómicas alongadas em imagens médicas [14]. Para a extracção destas características são usados algoritmos de detecção de contornos como o de Canny [15] ou as matrizes de Sobel [16]. Li *et al* propuseram usar o conhecimento prévio de linhas detectadas na imagem de referência para extrair as linhas na imagem observada usando contornos elásticos [17].

Os pontos podem corresponder a intersecções entre linhas [18], cantos [19], cruzamentos de estradas [20], centroides de regiões [21], pontos de alta variância [22] ou de inflexão de curvas [23]. A maior parte dos algoritmos usa os cantos como característica a detectar. Dois dos mais usados são o detector de Harris [9] e o método SUSAN [24]. Outros modos propostos para a detecção de cantos usam as derivadas parciais de segunda ordem [25] ou procuram o extremo local da curvatura de Gauss [26] para descobrirem os cantos, apesar de estes serem sensíveis a ruído na imagem. Para resolver este problema foi proposto um algoritmo que não usa quaisquer derivadas, sendo um método paramétrico [27].

2.1.2 Correspondência entre características

Assumindo que as *características* das imagens de referência e observada já foram detectadas, o objectivo deste passo é fazer as correspondências entre os pares de *características* usando as suas relações espaciais ou os seus descritores. Estes métodos são geralmente aplicados quando a estrutura local da informação é mais significativa que a transportada pela intensidade das imagens.

Permitem assim o alinhamento de imagens de naturezas diferentes (fotografias aéreas e mapas) e de distorções complexas entre imagens. A restrição típica destes métodos é a instabilidade temporal e da detecção das *características*. É ponto crucial estes processos possuírem descritores discriminativos, robustos e invariantes às diferenças entre as imagens.

Deste modo, estes métodos são divididos em dois grupos, através da distribuição espacial ou pelos descritores das características.

2.1.2.1 Métodos baseados em relações espaciais

Estes métodos são habitualmente empregues se as características detectadas forem ambíguas ou se a sua vizinhança estiver localmente distorcida. É usada a informação sobre a distância e a distribuição espacial entre os *CP* nas imagens observada e de referência. Um método, baseado no *graph matching algorithm*, avalia o número de características da imagem observada que depois de uma transformação particular, ficam dentro de uma distância mínima das características da imagem de referência. Os parâmetros da transformação que minimizam as distâncias eram considerados como a estimação válida [28]. Outra técnica, calcula, para cada par de *CP* das imagens de referência e observada, os parâmetros da transformação que mapeia um ponto no outro. Estes são depois representados como um ponto no espaço dos parâmetros de transformação. Os parâmetros de transformação que mapeiam um maior número de características tendem a formar uma aglomeração que é seguidamente detectada e o seu centroide é considerado como o vector de parâmetros mais provável [18]. Outro critério é o de minimização da distância generalizada entre pontos, usada pelo ICP [1].

2.1.2.2 Métodos baseados em descritores invariantes

Este método baseia-se no uso de descritores para calcular as correspondências entre características. Os descritores devem satisfazer diversos requisitos. Serem invariantes (os descritores

de uma característica correspondente na imagem de referência e observada têm de ser iguais), únicos (duas características diferentes devem ter descritores diferentes), estáveis (o descritor de uma característica ligeiramente deformada deve ser aproximado ao descritor da característica original) e independentes (se o descritor de uma característica for um vector, os seus elementos devem ser independentes). Consequentemente, as características das imagens de referência e observada com os descritores mais similares são etiquetados como correspondentes. A escolha do tipo de descritor depende das características da característica e na deformação geométrica das imagens. O descritor mais simples é a intensidade da imagem, usada numa vizinhança próxima da característica [29]. A sua correspondência é seguidamente calculada usando a correlação, os coeficientes da correlação [30] ou mesmo a informação mútua [3]. Descritores mais complexos são por exemplo, momentos invariantes, usados para descrever regiões fechadas [31-33]. Descritores orientados geometricamente, gerados a partir de combinações invariantes de propriedades geométricas básicas das características[34, 35].

2.1.2.3 Métodos de relaxação

Os métodos de relaxação são uma das soluções do *consistent labeling problem*: etiquetar cada característica da imagem observada com a etiqueta de uma característica da imagem de referência, para que seja consistente com a etiquetagem feita aos outros pares de características [36]. O processo de recalculer os pares das figuras de mérito, considerando a qualidade de emparelhamento dos pares de características é iterativamente repetido até ser atingida uma situação estável [37]. A inclusão no algoritmo de descritores de características de canto e de linha, permite ao processo lidar com transformações corpo rígido (rotações e translações) mas é computacionalmente pesado [38, 39].

2.2 Métodos baseados em intensidade

Estes métodos fazem a união entre o passo de detecção e correspondência de características. Neste caso, as características, sendo os valores da intensidade das imagens, não são extraídas delas. Estes métodos usam janelas de tamanho pré definido (que podem ser da dimensão total da imagem) para executar a correspondência entre as imagens [40]. As limitações inerentes a estes métodos são intrínsecas ao modo de procedimento. Imagens com pouca variância na sua intensidade podem provocar alinhamentos incorrectos dentro das janelas. Ruído, variação das condições de iluminação ou o uso de diferentes sensores, todos eles modificam os valores de intensidade utilizados para a correspondência e, por consequência, deterioram a sua precisão. São também pesados computacionalmente, visto que são usadas imagens inteiras para fazer a estimativa da correspondência. Deste modo, estes algoritmos são utilizados em situações em que não existem muitos pontos de referência e em que a informação é dada pela variação de níveis de cinzento da imagem ou pela sua cor.

2.2.1 Métodos de Correlação

A correlação cruzada normalizada (CC) é a representação clássica dos métodos baseados em intensidade [41], sendo W a janela utilizada, $E(W)$ a média da região no interior da janela W , I a imagem e $E(I)$ a média da imagem, então

$$CC(i, j) = \frac{\sum_w (W - E(W))(I_{(i,j)} - E(I_{(i,j)}))}{\sqrt{\sum_w (W - E(W))^2} \sqrt{\sum_{I_{(i,j)}} (I_{(i,j)} - E(I_{(i,j)}))^2}} \quad (1)$$

Esta medida de similaridade é calculada entre pares de janelas da imagem observada e da de referência e o seu máximo é calculado. Quando este máximo é atingido, o par de janelas para o qual foi calculado é considerado como correspondente (ver Figura 4). Este método consegue lidar eficazmente com translações e ligeiras rotações e variações de escala. Existem versões da CC mais gerais, que lidam com maiores deformações [3], mas a carga computacional cresce muito rápido com o aumento de complexidade das transformações. É também usado o rácio de correlação, visto que consegue suportar diferenças entre intensidades das imagens, tornando-se ideal se estas forem adquiridas com diferentes sensores [42]. Estes métodos têm duas grandes desvantagens: devido às imagens observada e de referência serem muito semelhantes, todos os valores saídos da correlação vão ser muito idênticos, o que torna difícil a extracção do máximo; além disso têm um grande peso computacional. No entanto a sua implementação em *hardware* é extremamente simples, o que os torna úteis em aplicações em tempo real.



Figura 4 - Exemplo de alinhamento usando correlação cruzada normalizada [43]

2.2.2 Métodos de *Fourier*

Estas técnicas exploram a representação de *Fourier* das imagens no domínio da frequência. Estes métodos calculam o espectro de potência cruzada das imagens observada e de referência e procuram pelo seu máximo na inversa.

$$\frac{f(a)f(b)^*}{|f(a)f(b)^*|} = e^{2\pi i(ux_0 + vy_0)} \quad (2)$$

Conseguem assim apresentar robustez contra ruído correlacionado, dependente de frequência e sobre perturbações de iluminação não uniformes e variantes no tempo [3]. Quando usado em conjunto com mapeamento log-polar da magnitude espectral, o método consegue alinhar distorções afim [44]. O seu uso pode ser estendido a imagens binárias de contornos para alinhamentos multimodais [3]. As técnicas baseadas na análise de *Fourier* são computacionalmente mais rápidas e suportam melhor ruído que os métodos correlacionais.

2.2.3 Métodos de informação mútua

Original da teoria da informação, a informação mútua é uma medida de dependência estatística entre dois conjuntos de dados e é particularmente adequada para alinhamento multimodal. A informação mútua entre duas variáveis aleatórias X e Y é dada por

$$IM(X, Y) = H(Y) - H(Y | X) = H(X) + H(Y) - H(X, Y) \quad (3)$$

onde $H(X) = -E_X(\log(P(X)))$ representa a entropia da variável aleatória e $P(X)$ é a distribuição de probabilidade de X . O método é baseado na maximização da informação mútua. Esta técnica é usada em imagiologia médica (MR, CT e PET) [45] onde permite diagnósticos que de outra forma não eram possíveis de obter. De notar na Figura 5 que a imagem de referência e observada (primeira e

segunda imagem respectivamente) são o inverso uma da outra. Mostra-se assim, que o algoritmo de informação mútua não necessita de imagens com valores de intensidades similares para conseguir bons resultados de alinhamento.



Figura 5 - Exemplo de alinhamento utilizando informação mútua (a imagem original à esquerda, a imagem a alinhar ao centro e o alinhamento à direita)

Devido ao seu tempo computacional, usa-se uma estratégia em pirâmide para acelerar o algoritmo. Esta estratégia utiliza o mesmo processo de alinhamento, mas inicia o algoritmo com as imagens de referência e observada em resoluções inferiores (reduzindo assim as distâncias entre os pontos de cada uma das imagens) e indo gradualmente melhorando as estimativas de alinhamento à medida que sobe para resoluções maiores. Isto permite que as primeiras aproximações sejam executadas velozmente, e obtendo esta informação, torna-se mais rápido resolver quando se aumentam as dimensões das imagens [46].

2.2.4 Métodos de otimização

Todos os métodos anteriores necessitam de maximizar ou minimizar a sua função de custo de forma eficiente, e este é um problema de otimização multidimensional, onde o número de dimensões corresponde aos graus de liberdade da transformação geométrica [3]. Existem diversos modos sofisticados para o cálculo dos mínimos ou máximos [47], entre eles destacam-se os métodos de Gauss-Newton, Levenberg-Marquardt que proporcionam uma boa velocidade e taxa de convergência. Note-se que estes algoritmos tendem para mínimos ou máximos locais, pelo que se torna necessário uma boa estimativa inicial para o processo de otimização [48]

2.3 Tipos de modelo de transformação

Após a correspondência entre as características ser estabelecida, é calculada a função de mapeamento, que deve transformar a imagem observada de forma a sobrepor a imagem de referência. A tarefa a ser resolvida consiste na escolha da função de mapeamento e a estimação dos seus parâmetros. O tipo de função escolhido deve corresponder às deformações geométricas existentes na imagem observada, ao método de aquisição de imagens e à precisão de alinhamento requerida. Em algumas situações, a deformação geométrica é conhecida e pode ser usada uma correção baseada na inversa desta deformação [49]. Estes métodos podem ser divididos em dois grandes grupos, modelos globais e modelos locais.

2.3.1 Modelos globais

Estes modelos usam todos os *CP* para estimar os parâmetros de uma transformação válida para toda a imagem. Os parâmetros dos modelos são geralmente calculados por mínimos quadrados, de forma a minimizar a soma dos erros ao quadrado. Um modelo global de mapeamento não consegue lidar com imagens deformadas localmente. A técnica dos mínimos quadrados distribui a distorção geométrica igualmente por toda a imagem, o que não permite o mapeamento de deformações locais [3].

2.3.1.1 Transformação de corpo rígido

A mais comum das transformações geométricas é a de corpo rígido. Estas transformações preservam todas as distâncias, ângulos e paralelismo de rectas e podem ser determinadas sem ambiguidade por dois pontos nas imagens. Como consequência, as formas dos objectos nas imagens não se modificam. Este tipo de transformação realiza uma rotação seguida de uma translação. As matrizes de rotação R são matrizes unitárias ($R^T R = I$), que além disso não invertem a direcção dos eixos ($\det(R) = 1$) e podem ser definidas por um parâmetro [50]. As translações são vectores multidimensionais (T) que possuem tantos parâmetros como as dimensões. Cada um destes parâmetros corresponde a uma direcção. Desta forma, uma transformação 2D de corpo rígido pode ser descrita por três parâmetros (t_{x1} , t_{x2} e θ), estes mapeiam um ponto (x'_1, x'_2) da imagem I' para um ponto (x_1, x_2) da imagem I da seguinte maneira:

$$I = \tau_G(I') = T(t_{x1}, t_{x2}) + R(\theta)I' \quad (4)$$

Em detalhe, a representação toma a forma

$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{bmatrix} \begin{bmatrix} x'_1 \\ x'_2 \end{bmatrix} + \begin{bmatrix} t_{x1} \\ t_{x2} \end{bmatrix} \quad (5)$$

2.3.1.2 Transformação de semelhança Euclidiana

As transformações de corpo rígido, quando acompanhadas por um parâmetro uniforme de escala (s) (ver Figura 6) tornam-se em transformações de semelhança Euclidiana. Estas são transformações que em 2D são definidas por quatro parâmetros (t_{x1} , t_{x2} , θ e s). Como as transformações de corpo rígido, preservam todas as distâncias, ângulos e paralelismo de rectas [50] e são definidas como

$$I = \tau_G(I') = T(t_{x1}, t_{x2}) + sR(\theta)I' \quad (6)$$

Em maior detalhe, para transformações 2D, são descritas da seguinte forma

$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = s \begin{bmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{bmatrix} \begin{bmatrix} x'_1 \\ x'_2 \end{bmatrix} + \begin{bmatrix} t_{x1} \\ t_{x2} \end{bmatrix} \quad (7)$$

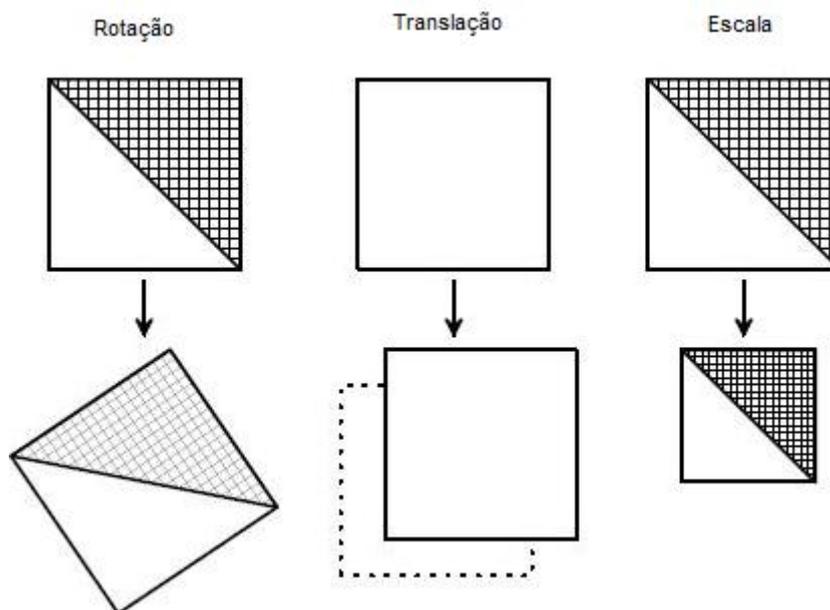


Figura 6 - Exemplos de transformações em 2D (rotação, translação e escala)

Para 3D, o número de parâmetros aumenta para sete, três rotações sobre os eixos (*yaw*, *pitch* e *roll*, (ver Figura 7), três translações e o factor de escala. Em detalhe, é descrita da seguinte forma

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = s \begin{bmatrix} \cos \alpha \cos \beta & \cos \alpha \sin \beta \sin \gamma - \sin \alpha \cos \gamma & \cos \alpha \sin \beta \cos \gamma + \sin \alpha \sin \gamma \\ \sin \alpha \cos \beta & \sin \alpha \sin \beta \sin \gamma + \cos \alpha \cos \gamma & \sin \alpha \sin \beta \cos \gamma - \cos \alpha \sin \gamma \\ -\sin \beta & \cos \beta \sin \gamma & \cos \beta \cos \gamma \end{bmatrix} \begin{bmatrix} x_1' \\ x_2' \\ x_3' \end{bmatrix} + \begin{bmatrix} t_{x1} \\ t_{x2} \\ t_{x3} \end{bmatrix} \quad (8)$$

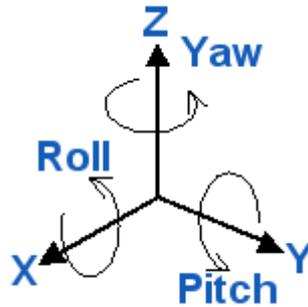


Figura 7 - Sentidos de rotação do *Yaw*, *pitch* e *roll*

2.3.1.3 Transformação Afim

É um tipo de transformação mais geral que as anteriores. Realiza rotação, translação e escalamento horizontal, vertical e oblíquo. Este modelo preserva paralelismos mas não ângulos e distâncias e é definido por três pontos não colineares [50]. A forma geral de uma transformação afim para 2D é dada por

$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} x_1' \\ x_2' \end{bmatrix} + \begin{bmatrix} t_{x1} \\ t_{x2} \end{bmatrix} \quad (9)$$

sendo que a_{11} , a_{12} , a_{21} , a_{22} , t_{x1} e t_{x2} são os parâmetros da transformação. No caso de 3D, o número de parâmetros sobe para doze e são descritos da seguinte forma.

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} \begin{bmatrix} x_1' \\ x_2' \\ x_3' \end{bmatrix} + \begin{bmatrix} t_{x1} \\ t_{x2} \\ t_{x3} \end{bmatrix} \quad (10)$$

2.3.1.4 Transformação projectiva

É a mais geral das transformações, transforma rectas em rectas, mas não preserva ângulos, distâncias nem paralelismos. Pode ser determinada univocamente por quatro pontos independentes [3, 50]. Em 2D, esta transformação é descrita por.

$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = x'_1 x'_2 \begin{bmatrix} p_{11} \\ p_{21} \end{bmatrix} + \begin{bmatrix} p_{12} & p_{13} \\ p_{22} & p_{23} \end{bmatrix} \begin{bmatrix} x'_1 \\ x'_2 \end{bmatrix} + \begin{bmatrix} t_{x1} \\ t_{x2} \end{bmatrix} \quad (11)$$

Em 3D, o número de parâmetros sobe para quinze, sendo estes descritos da seguinte forma.

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = x'_1 x'_2 x'_3 \begin{bmatrix} p_{11} \\ p_{21} \\ p_{31} \end{bmatrix} + \begin{bmatrix} p_{12} & p_{13} & p_{14} \\ p_{22} & p_{23} & p_{24} \\ p_{32} & p_{33} & p_{34} \end{bmatrix} \begin{bmatrix} x'_1 \\ x'_2 \\ x'_3 \end{bmatrix} + \begin{bmatrix} t_{x1} \\ t_{x2} \\ t_{x3} \end{bmatrix} \quad (12)$$

2.3.2 Modelos locais

Perturbações locais de uma imagem devem ser alinhadas usando a informação sobre a distorção geométrica local. Mínimos quadrados pesados e métodos de média ponderada têm a habilidade de alinhar imagens localmente ao introduzir ligeiras variações às soluções originais. Métodos locais (mapeamento linear ou cúbico)[51, 52] produzem uma triangulação entre os CP da imagem e usam uma função de mapeamento válida para cada triângulo.

2.3.3 Modelos radiais

Estes modelos são representativos do grupo de mapeamento global, mas conseguem lidar com variações geométricas locais. Estas funções têm a forma de uma combinação linear entre uma função radialmente simétrica transladada com um polinómio de baixo grau.

$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} a_{11} \\ a_{21} \end{bmatrix} + \begin{bmatrix} a_{12} & a_{13} \\ a_{22} & a_{23} \end{bmatrix} \begin{bmatrix} x'_1 \\ x'_2 \end{bmatrix} + \sum_{i=1}^N c_i g(X, X_i) \quad (13)$$

Uma importante propriedade do valor da função em cada ponto é que depende apenas da distância do ponto aos CP, não na sua posição. Alguns exemplos de funções radiais usadas em alinhamento são as multiquadráticas, multiquadráticas recíprocas [53], Gaussianas, funções de Wendland [54] e *thin plate splines* (TPS). As funções multiquadráticas e de Wendland possuem uma influência global muito baixa e mesmo deformações locais significativas podem ser bem alinhadas

utilizando esta abordagem. Esta propriedade é vantajosa para alinhar imagens onde as mudanças ocorram, na sua maioria, localmente (e.g imagens médicas)[53, 54]. As maiores representantes das funções radiais são as TPS, onde o termo radial tem a forma de.

$$g(X, X_i) = \|X - X_i\|^2 \ln(\|X - X_i\|) \quad (14)$$

A TPS pode ser vista como uma lâmina muito fina, fixa nas posições determinadas pelos CP na imagem de referência e na altura dada pelas coordenadas dos CP correspondentes na imagem observada [55]. A TPS minimiza o funcional de variação quadrática de energia potencial que reflecte a quantidade de variação da função, e que deve ser pequeno para uma boa função de mapeamento [56]. O alinhamento por TPS apresenta resultados bons, mas os cálculos podem ser extensos e demorados caso exista um grande número de CP.

2.3.4 Alinhamento elástico

Outra forma de alinhar imagens com distorções complexas e/ou locais é não usar qualquer função de mapeamento paramétrica. Assim, a estimação da deformação geométrica é reduzida à procura pelos melhores parâmetros. Esta ideia foi introduzida em 1989 [57] e é normalmente chamada de alinhamento elástico. As imagens são vistas como pedaços de folhas plásticas, nas quais forças externas esticam a imagem e forças internas definidas por rigidez ou suavidade, são aplicadas para alinhar a imagem com o mínimo de força aplicada. O alinhamento é conseguido por localização do estado de energia mínima de forma iterativa [3]. Neste método, os passos de correspondência entre características e de estimação do modelo de transformação são executados simultaneamente. Esta é uma das vantagens do alinhamento elástico, pois não são conhecidos descritores de características invariantes a deformações complicadas e a correspondência entre características é difícil de conseguir de forma tradicional. Uma das desvantagens do alinhamento elástico surge quando as distorções são muito localizadas. Este problema pode ser resolvido usando alinhamento fluido [58]. Este método usa modelos fluidos de viscosidade para controlar a transformação da imagem. A imagem de referência é modelada como um líquido espesso que flui até se sobrepor à imagem observada sobre o controlo da derivada de um modelo sensorial Gaussiano. A fraqueza deste método é o *blurring* introduzido no processo de alinhamento.

2.4 Transformação e interpolação da imagem

As funções de mapeamento obtidas durante o passo anterior são usadas para transformar a imagem observada e assim alinhar as imagens. A transformação pode ser executada usando dois métodos: *Forward* e *backward*.

No método *forward*, cada pixel da imagem observada é directamente transformado utilizando a função de mapeamento estimada. Este método é de difícil implementação, pois pode produzir buracos ou sobreposições na imagem resultante (devido a discretização e arredondamentos). Devido a este problema o método *backward* é normalmente escolhido. Neste, os pixels da imagem resultante são determinados utilizando as coordenadas do pixel correspondente (no mesmo sistema de coordenadas da imagem de referência) e a inversa da função de mapeamento estimada. Desta forma a interpolação ocorre na imagem observada, evitando-se assim buracos e sobreposições na imagem resultante.

A interpolação em si é habitualmente realizada pela convolução da imagem com um *kernel* interpolante. Interpolantes óptimos (função *sinc*) são difíceis de implementar devido à sua extensão infinita. Assim, são usados vários interpolantes de suporte limitado. Para reduzir o peso computacional, são considerados interpolantes separáveis. Esta característica permite substituir uma convolução 2D $m \times n$ por $(m + 1)$ convoluções 1D, que são mais rápidas [3].

As funções bilinear e bicúbica, splines quadráticas [59, 60], B-splines cúbicas e de ordens mais altas [61] e Gaussianas [62] são os interpolantes utilizados mais regularmente. Em 2000, foi apresentado um método diferente de interpolação, em que a função interpoladora não utiliza directamente os níveis de cinzento, mas sim valores de funções de níveis de cinzento. Este método apresentou resultados superiores aos métodos tradicionais [63]. As funções de maior ordem fornecem resultados de interpolação das imagens transformadas superiores, mas possuem um maior peso computacional. As funções bilineares são as que oferecem a melhor relação entre precisão e tempo computacional, facto que as leva a ser muito utilizadas. A interpolação cúbica é recomendada se a transformação geométrica envolver um aumento da imagem observada [3].

Capítulo 3

Descrição dos algoritmos estudados

Neste capítulo são descritos os dois algoritmos de alinhamento estudados. Estes são o conhecido *iterative closest point* (ICP) [1], em que as distâncias entre pontos vão sendo iterativamente minimizadas e o algoritmo SRIN [2] que utiliza o método de Lucas-Kanade [47] para estimar os parâmetros da transformação.

3.1 *Iterative Closest Point* (ICP)

O ICP é o mais popular dos algoritmos de alinhamento 3D e foi apresentado por Besl e McKay em 1992 [1]. O algoritmo apresentado é uma variação do original, com capacidade para calcular variações de escala.

Os dados de entrada ICP são dois conjuntos de pontos de controlo, um de dados A e outro de modelo B . Estes conjuntos de pontos podem ser conseguidos através do algoritmo de detecção de contornos descrito posteriormente, aplicado às imagens observada e de referência.

A estrutura básica do ICP é de realizar iterativamente os seguintes dois passos até convergir. Primeiro, é determinada a correspondência entre pares de pontos dos conjuntos de dados e modelo. No segundo, é estimada a função de mapeamento que melhor alinha os pares de pontos correspondentes, sendo depois aplicada no conjunto de dados. Como o erro de alinhamento é reduzido em cada passo, o ICP converge sempre em tempo finito [1].

O primeiro passo do algoritmo pode ser dividido em pequenas partes. Inicialmente, os pontos de controlo a ser utilizados têm de ser escolhidos. Nesta parte foi empregue a solução original do ICP, todos os pontos existentes nos conjuntos de dados e modelo são utilizados pelo algoritmo. (existem outros métodos [64], que visam melhorar a velocidade computacional do algoritmo mas que lhe retiram alguma precisão). De seguida, para cada ponto do conjunto de dados, é descoberto o ponto correspondente no conjunto modelo. Esta correspondência é executada calculando as distâncias entre o ponto do conjunto de dados e os pontos na sua vizinhança do conjunto modelo, sendo que o ponto do conjunto modelo seleccionado como correspondente é o que produz uma distância menor (ver Figura 8). Sendo a , um ponto no conjunto de dados e b um ponto no conjunto modelo, a distância é calculada da seguinte forma

$$d(a,b) = \sqrt{(b_x - a_x)^2 + (b_y - a_y)^2 + (b_z - a_z)^2} = \|b - a\| \quad (15)$$

Sendo que para os pontos serem correspondentes, a distância entre eles tem ser mínima. Então pontos correspondentes respeitam a relação.

$$d(a,b) = \min \|b - a\| \quad (16)$$

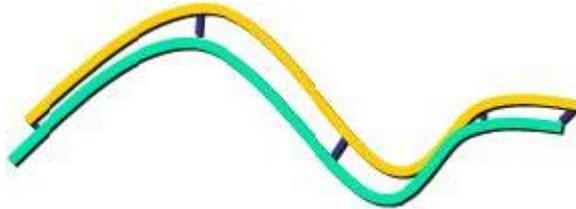


Figura 8 - Distância mínima entre pontos das rectas representadas a verde e amarelo

A operação de correspondência entre pontos é a mais demorada do ICP. Para acelerar este passo, foi utilizada uma triangulação de *Delaunay* (ver Figura 9 a) e b)) do conjunto modelo,



Figura 9 a) Triangulação de Delaunay do volume MRI cerebral
b) Triangulação de Delaunay do volume galerias romanas

sendo depois, para cada ponto do conjunto de dados, procurado o índice correspondente ao ponto com a distância mínima. Estas funções estão incluídas no *Matlab*, o que torna este passo mais rápido. Ficamos então, com o conjunto de pontos correspondentes.

$$C = \{(i, j) | a_i \in A \wedge b_j \in B \text{ são pontos correspondentes}\} \quad (17)$$

Depois de as correspondências serem calculadas, podem-se rejeitar pares de pontos que se considerem incorrectos, ou utilizar pesos. Ambos os métodos visam melhorar a robustez do algoritmo

a ruído e *outliers* [64], mas diminuem a velocidade de convergência do ICP [65]. Não foi utilizado nenhum destes métodos no algoritmo apresentado, visto que as imagens possuem pouco ruído e não existia vantagem em usá-los.

O segundo passo do ICP corresponde ao cálculo da função de mapeamento que melhor aproxima o conjunto de dados ao conjunto modelo. Como medida de erro é utilizado o critério dos mínimos quadrados das distâncias dos pares de pontos correspondentes. Sendo R a matriz de rotação, s o factor de escala e t o vector de translação, o problema de minimização pode ser descrito da seguinte forma.

$$(R^*, t^*, s^*) = \arg \min_{R, t, s} \sum_{(i, j) \in C} \|b_j - sRa_i - t\|^2 \quad (18)$$

Em forma matricial e sendo θr os parâmetros da rotação, θs os parâmetros de escala e θt os parâmetros da translação.

$$(R^*, t^*, s^*) = \arg \min_{R, t, s} \sum_{(i, j) \in C} \left\| \begin{bmatrix} b_{j_1} \\ b_{j_2} \\ b_{j_3} \end{bmatrix} - \begin{bmatrix} \theta s_1 & 1 & 1 \\ 1 & \theta s_2 & 1 \\ 1 & 1 & \theta s_3 \end{bmatrix} \begin{bmatrix} \theta r_1 & \theta r_2 & \theta r_3 \\ \theta r_4 & \theta r_5 & \theta r_6 \\ \theta r_7 & \theta r_8 & \theta r_9 \end{bmatrix} \begin{bmatrix} a_{i_1} \\ a_{i_2} \\ a_{i_3} \end{bmatrix} - \begin{bmatrix} \theta t_1 \\ \theta t_2 \\ \theta t_3 \end{bmatrix} \right\|^2 \quad (19)$$

Existem vários algoritmos para resolver este problema [66]. Foi seleccionado o algoritmo baseado na SVD, pois fornece consistentemente bons níveis de precisão, estabilidade e velocidade [66]. Inicialmente são calculados os centros de massa dos conjuntos de dados e modelo

$$\bar{a} = \frac{1}{|C|} \sum_{(i, j) \in C} a_i \quad , \quad \bar{b} = \frac{1}{|C|} \sum_{(i, j) \in C} b_j \quad (20)$$

Estes centros de massa são utilizados para centrar os conjuntos de pontos, que corresponde ao problema de minimização.

$$R^* = \arg \min_R \sum_{(i, j) \in C} \|(b_j - \bar{b}) - R(a_i - \bar{a})\|^2 \quad (21)$$

E sendo resolvido calculando o SVD da matriz

$$K = \sum_{(i, j) \in C} (b_j - \bar{b})(a_i - \bar{a})^T = UDV^T \quad (22)$$

$$\text{E fazendo } R^* = \begin{bmatrix} \theta r_1^* & \theta r_2^* & \theta r_3^* \\ \theta r_4^* & \theta r_5^* & \theta r_6^* \\ \theta r_7^* & \theta r_8^* & \theta r_9^* \end{bmatrix} = UV^T .$$

Seguidamente, e utilizando o método proposto em [65], é calculado o factor de escala. Este depende da matriz de rotação previamente estimada e o seu problema de minimização é descrito por

$$s^* = \arg \min_s \sum_{(i,j) \in C} \|(b_j - \bar{b}) - sR^*(a_i - \bar{a})\|^2 \quad (23)$$

Desta forma s é estimado da seguinte forma.

$$s^* = \begin{bmatrix} \theta s_1^* \\ \theta s_2^* \\ \theta s_3^* \end{bmatrix} = \frac{\sum_{(i,j) \in C} \tilde{b}_j^T \tilde{a}_i}{\sum_{(i,j) \in C} \tilde{a}_i^T \tilde{a}_i} \quad (24)$$

E depois colocado em forma de matriz 3×3 .

$$s^* = \begin{bmatrix} \theta s_1^* & 1 & 1 \\ 1 & \theta s_2^* & 1 \\ 1 & 1 & \theta s_3^* \end{bmatrix} \quad (25)$$

Sendo que \tilde{b}_j e \tilde{a}_i são vectores definidos da seguinte forma.

$$\tilde{b}_j = (b_j - \bar{b}) \quad , \quad \tilde{a}_i = R^*(a_i - \bar{a}) \quad (26)$$

O último passo é o cálculo da estimativa da translação, pois necessita das estimativas da matriz de rotação e do factor de escala e é efectuado da seguinte forma.

$$t^* = \begin{bmatrix} \theta t_1^* \\ \theta t_2^* \\ \theta t_3^* \end{bmatrix} = \bar{b} - \begin{bmatrix} \theta s_1^* & 1 & 1 \\ 1 & \theta s_2^* & 1 \\ 1 & 1 & \theta s_3^* \end{bmatrix} \begin{bmatrix} \theta r_1^* & \theta r_2^* & \theta r_3^* \\ \theta r_4^* & \theta r_5^* & \theta r_6^* \\ \theta r_7^* & \theta r_8^* & \theta r_9^* \end{bmatrix} \bar{a} \quad (27)$$

Como referenciado anteriormente, o ICP converge sempre em tempo finito. Mas esta convergência pode ser em direcção a um mínimo local se o seu ponto inicial for muito afastado do seu alinhamento correcto, o que não é desejável (ver Figura 10).

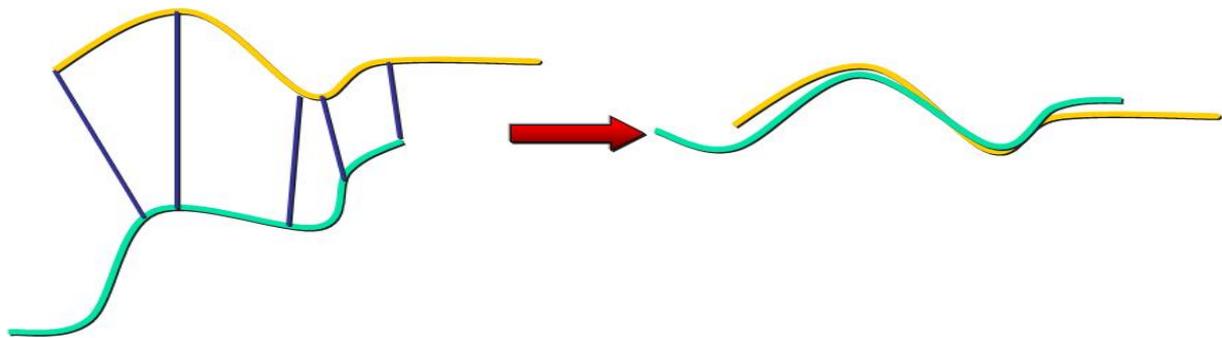


Figura 10 - Exemplo de alinhamento para mínimo local

Para tentar resolver este problema é estimada uma função de pré-alinhamento que visa aproximar os dois conjuntos de pontos antes do ICP começar a funcionar. Nesta implementação foram utilizados os centros de massa da equação (20) para calcular uma translação inicial para que os valores médios dos conjuntos de dados e modelo sejam iguais.

$$t_{inicial}^* = \bar{b} - \bar{a} \quad (28)$$

3.1.1 Algoritmo de detecção de contornos

Previamente ao uso do ICP, é necessária a utilização de um detector de características. Os detectores de características têm sido objecto de vários estudos por investigadores de processamento de imagem. Diferentes características podem ser utilizadas em diferentes aplicações, ou algoritmos distintos usar características diferentes para resolver o mesmo problema. O algoritmo apresentado é o método de *Sobel* para detecção de contornos, mas utilizado em 3D.

O método de *Sobel* [16] utiliza o cálculo do gradiente da equação (29) e é capaz de detectar contornos e a sua orientação, tendo como grandes vantagens a sua simplicidade de implementação e de ser computacionalmente leve. Em sentido oposto, a aproximação ao gradiente é bastante crua e o algoritmo é bastante sensível a ruído. A escolha recaiu neste algoritmo pois, para além da sua simplicidade de implementação, as imagens testadas apresentam muito pouco ruído e assim o desempenho do método é comparável a algoritmos mais complexos [67]

$$\nabla f(x, y, z) = \left(\frac{df}{dx}, \frac{df}{dy}, \frac{df}{dz} \right) \quad (29)$$

Para aumentar a relação sinal-ruído na imagem é realizada uma suavização desta com um filtro gaussiano passa-baixo (equação (30)). Este realiza uma média ponderada de cada *pixel* em relação à sua vizinhança, retirando ruído e algum detalhe à imagem, mas permitindo uma melhor detecção de contornos.

$$F(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{x^2}{2\sigma^2}} \quad (30)$$

Esta operação é realizada pela convolução (*) da imagem original (*I*) com o kernel gaussiano (*F*) (equação (31)). Para evitar a utilização de um kernel 3D, a convolução pode ser realizada sequencialmente com o kernel de 1D. Primeiro suaviza-se a na direcção *x*, seguidamente utiliza-se a imagem suavizada em *x* e suaviza-se na direcção *y* e finalmente usa-se a imagem suavizada nas duas direcções para suavizar a direcção *z*.

$$I' = I * F \quad (31)$$

Seguidamente, o algoritmo calcula o gradiente da imagem em cada ponto, dando a direcção do maior aumento possível de intensidade luminosa e a taxa de variação nessa direcção. O resultado do método mostra então se a mudança nesse ponto da imagem foi “suave” ou “abrupta”, evidenciando desse modo a probabilidade dessa parte da imagem ser considerado um contorno e como este último está orientado (ver Figura 11). Na prática, o cálculo da amplitude do gradiente é mais fidedigno e fácil de interpretar que o cálculo da sua direcção.

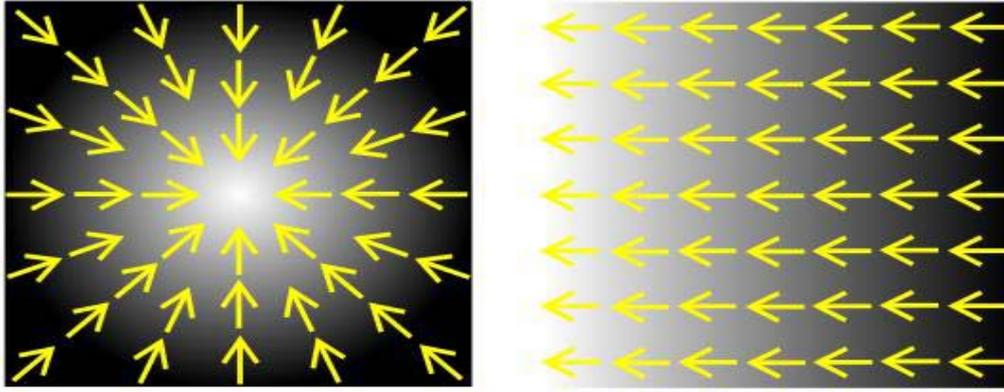


Figura 11 - Orientação do vector gradiente

O gradiente de uma função de três variáveis (neste caso a função de intensidade da imagem) é em cada ponto da imagem um vector 3D com os seus componentes dados pelas derivadas em cada uma das direcções (vertical, horizontal e profundidade). Em cada ponto da imagem, o vector gradiente aponta na direcção do maior aumento possível de intensidade e o seu comprimento corresponde à taxa de variação nessa direcção. Isto implica, que o resultado da operação num ponto que pertença a uma região de intensidade constante é um vector nulo e que num ponto de contorno é um vector perpendicular ao contorno com o sentido das intensidades das menores para as maiores.

Matematicamente, o algoritmo usa 3 *kernels* de dimensão $3 \times 3 \times 3$ que são convolidos com a imagem suavizada, de forma a calcular as aproximações das derivadas, uma para cada direcção (horizontal, vertical e profundidade). Sendo a imagem suavizada definida por I' , e as imagens cujos pontos contêm as aproximações das derivadas segundo as três direcções definidas por G_x , G_y e G_z , então as matrizes de *Sobel* para cada direcção são:

Segundo a direcção x

$$S_x(1, :, :) = \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 4 & 1 \end{bmatrix} \quad S_x(2, :, :) = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad S_x(3, :, :) = \begin{bmatrix} -1 & -2 & -1 \\ -2 & -4 & -2 \\ -1 & -4 & -1 \end{bmatrix} \quad (32)$$

$$G_x = S_x * I' \quad (33)$$

Segundo a direcção y

$$S_y(:,1,:) = \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 4 & 1 \end{bmatrix} \quad S_y(:,2,:) = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad S_y(:,3,:) = \begin{bmatrix} -1 & -2 & -1 \\ -2 & -4 & -2 \\ -1 & -4 & -1 \end{bmatrix} \quad (34)$$

$$G_y = S_y * I' \quad (35)$$

Segundo a direcção z

$$S_z(:,:,1) = \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 4 & 1 \end{bmatrix} \quad S_z(:,:,2) = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad S_z(:,:,3) = \begin{bmatrix} -1 & -2 & -1 \\ -2 & -4 & -2 \\ -1 & -4 & -1 \end{bmatrix} \quad (36)$$

$$G_z = S_z * I' \quad (37)$$

De notar que as matrizes S_x , S_y e S_z estão rodadas entre si em 90° , para corresponderem a cada direcção do gradiente.

Em cada ponto da imagem, as aproximações ao gradiente resultantes, podem ser utilizadas para calcular a sua amplitude (38)

$$G = \sqrt{G_x^2 + G_y^2 + G_z^2} \quad (38)$$

A amplitude do gradiente é um operador isotrópico. Isto significa que ele é capaz de detectar contornos em todas as direcções. Neste ponto é executado um limiar da amplitude do gradiente, seleccionando como contornos os valores que sejam superiores a este.

$$\text{se } G(x, y, z) > T \quad \text{então } G(x, y, z) \text{ é ponto de contorno} \quad (39)$$

O resultado final é uma imagem binária, em que o valor um indica os pontos de controlo (ver Figura 12)

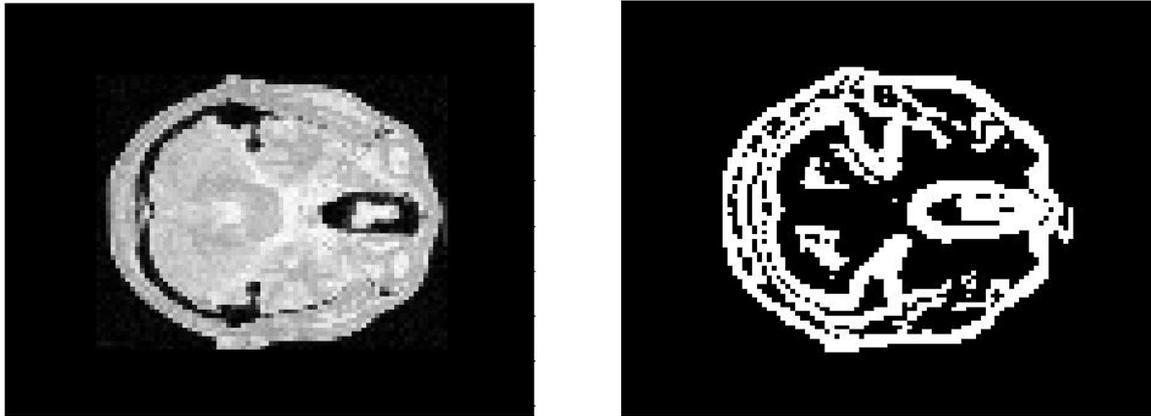


Figura 12 - Exemplo de detecção de contornos utilizando operador Sobel

a) Imagem original

b) Correspondente mapa de contornos

A partir deste ponto é possível realizar o alinhamento das imagens utilizando o ICP.

3.2 Alinhamento e normalização de intensidade simultâneos (SRIN)

O algoritmo SRIN foi desenvolvido para alinhar imagens médicas geradas por SPECT (ver Figura 13). Nestas imagens, o algoritmo funciona directamente com as intensidades dos *voxels* da imagem original.

Nesta dissertação, o algoritmo SRIN é testado utilizando imagens de características fornecidas por um algoritmo detector de características (neste caso, o algoritmo descrito em 3.1.1). O objectivo deste modo de utilização é evitar uma das razões que levam os algoritmos baseados em características a não convergir, a fase de correspondência entre características.

Assim, são criadas imagens com base nas características das imagens a alinhar, sendo posteriormente utilizado o SRIN para obter o alinhamento destas.

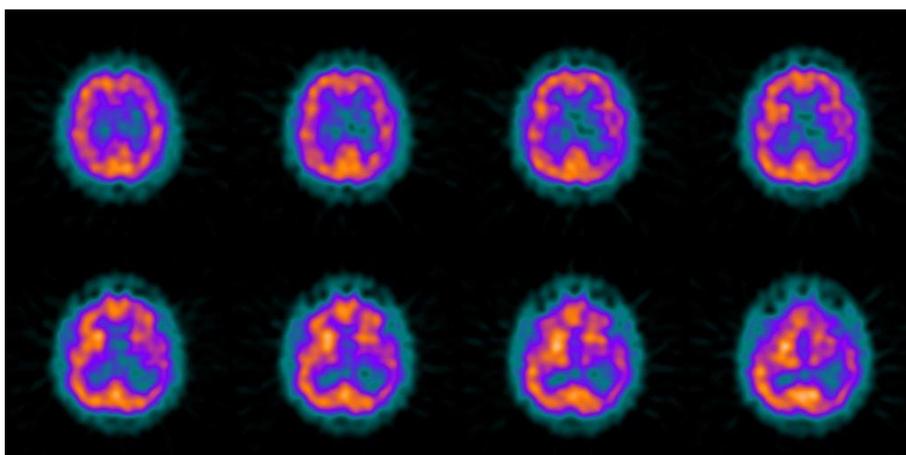


Figura 13 - Exemplo de imagem de difícil extracção de características (Cortes SPECT) [68]

O algoritmo descrito em [2] une o alinhamento das imagens e a normalização de intensidades dentro do mesmo algoritmo. Assim, são estimados em passos alternados o alinhamento (utilizando um algoritmo de minimização de mínimos quadrados) e a normalização de intensidades (utilizando um modelo linear). Isto resulta num algoritmo computacionalmente simples onde são calculados a função de mapeamento e os parâmetros lineares que modelam a intensidade sucessivamente até à sua convergência.

O algoritmo necessita de dois volumes 3D, um de referência $I_1(x)$ e outro observado $I_2(x)$. Conforme expressado anteriormente, assume-se que os níveis de intensidade dos volumes estão relacionados linearmente, ou seja

$$I_1(x) = \alpha I_2(W(\theta; x)) + \beta \quad (40)$$

Onde θ representa o conjunto de parâmetros da função de mapeamento W , α e β são respectivamente o parâmetro de escala e deslocamento do modelo linear utilizado para a normalização das intensidades. Para obter um alinhamento correcto, é necessário estimar, em conjunto, os parâmetros θ , α e β que minimizam a função de custo adoptada E

$$\{\theta^*, \alpha^*, \beta^*\} = \arg \min_{\theta, \alpha, \beta} E(\theta, \alpha, \beta) \quad (41)$$

Onde a função de custo adoptada $E(\theta, \alpha, \beta)$ é a soma dos erros quadrados

$$E(\theta, \alpha, \beta) = \sum_x e^2(\theta, \alpha, \beta) \quad (42)$$

$$e(\theta, \alpha, \beta) = I_1(x) - \alpha I_2(W(\theta; x)) - \beta \quad (43)$$

Nesta parte podia ser tentador desenvolver directamente o método de Gauss-Newton para estimar todos os parâmetros (θ, α, β) [69]. Em vez disso, utiliza-se o método descrito por Aguiar P.[70] para imagens a 2D onde se tira vantagem de a função de erro (43) ser linear nas variáveis de normalização (α, β) , o que leva a um algoritmo simples.

A função (41) é então minimizada utilizando um método iterativo de dois passos. No primeiro passo, a variável θ é mantida fixa e a função (41) é minimizada em ordem a α e β , o que leva a uma solução fechada do problema. No segundo passo, α e β são mantidos fixos e a função (41) é minimizada em ordem a θ .

A estimação dos parâmetros α e β para θ fixo, da definição da função de custo E (42)(43), as suas derivadas em ordem a α e β são

$$\frac{dE}{d\alpha} = -2 \sum_x I_2(W(\theta; x)) e(\theta, \alpha, \beta; x) \quad (44)$$

$$\frac{dE}{d\beta} = -2 \sum_x e(\theta, \alpha, \beta; x) \quad (45)$$

As estimativas α^* e β^* , são calculadas minimizando as suas derivadas, *i.e* igualando as suas derivadas a zero:

$$\frac{dE}{d\alpha} = 0 \Leftrightarrow \sum_x I_1 I_2 - \alpha \sum_x I_2^2 - \beta \sum_x I_2 = 0 \quad (46)$$

$$\frac{dE}{d\beta} = 0 \Leftrightarrow \sum_x I_1 - \alpha \sum_x I_2 - \beta N = 0 \quad (47)$$

Onde N é o número de *voxels* na região somada da função de custo E .

Dado que as equações (46) e (47) são lineares para α e β , conseguem-se soluções de forma fechada para as estimativas $\tilde{\alpha}$ e $\tilde{\beta}$

$$\alpha^* = \frac{N \sum_x I_1 I_2 - \sum_x I_1 \sum_x I_2}{N \sum_x I_2^2 - (\sum_x I_2)^2} \quad (48)$$

$$\beta^* = \frac{\sum_x I_1 \sum_x I_2^2 - \sum_x I_1 \sum_x I_1 I_2}{N \sum_x I_2^2 - (\sum_x I_2)^2} \quad (49)$$

Para estimar o parâmetro θ mantendo α e β fixos, é utilizado o algoritmo de Lucas-Kanade [47]. O objectivo deste algoritmo é minimizar a soma dos erros quadrados entre duas imagens (eq.(50)), que é o problema que possuímos agora que os parâmetros α e β estão fixos.

$$\sum_x (I_2(W(\theta; x)) - I_1)^2 \quad (50)$$

A minimização da função (50) é realizada em relação a θ e a soma é executada em todos os *voxels* x na imagem I_1 . Para otimizar a função (50), o algoritmo de Lucas-Kanade, assume que uma estimativa actual de θ é conhecida e iterativamente calcula incrementos aos parâmetros $\Delta\theta$; *i.e.* a expressão (51) é minimizada

$$\sum_x (I_2(W(\theta + \Delta\theta; x)) - I_1)^2 \quad (51)$$

em ordem a $\Delta\theta$, sendo então, os parâmetros actualizados

$$\theta \leftarrow \theta + \Delta\theta \quad (52)$$

Estes dois passos são iterados até que a estimativa dos parâmetros θ convirja. Para averiguar a convergência, verifica-se se a norma dos parâmetros θ é inferior a um limiar ε ; i.e. $\|\Delta\theta\| \leq \varepsilon$.

No método de Lucas-Kanade, a função (51) é linearizada realizando uma expansão em série de Taylor de primeira ordem sobre o termo $I_2(W(\theta + \Delta\theta; x))$, resultando

$$\sum_x (I_2(W(\theta; x)) + \nabla I_2 \frac{dW}{d\theta} \Delta\theta - I_1)^2 \quad (53)$$

Onde ∇I_2 é o gradiente da imagem I_2 , como definido na função (29), avaliado em $W(\theta; x)$; i.e. ∇I_2 é calculado nas coordenadas de I_2 e depois transformado para as coordenadas de I_1 utilizando a estimativa actual da transformação $W(\theta; x)$. O termo $\frac{dW}{d\theta}$ é o *Jacobiano* da transformação, ou seja, se $W(\theta, x) = (W_x(\theta, x), W_y(\theta, x))^T$, então

$$\frac{dW}{d\theta} = \begin{bmatrix} \frac{dW_x}{d\theta_1} & \frac{dW_x}{d\theta_2} & \dots & \frac{dW_x}{d\theta_n} \\ \frac{dW_y}{d\theta_1} & \frac{dW_y}{d\theta_2} & \dots & \frac{dW_y}{d\theta_n} \end{bmatrix} \quad (54)$$

Para descobrir a solução da função (53), é executada a sua derivada parcial em relação a Δp , que tem a seguinte forma

$$\sum_x \left[\nabla I_2 \frac{dW}{d\theta} \right]^T \left[I_2(W(\theta, x)) + \nabla I_2 \frac{dW}{d\theta} \Delta\theta - I_1(x) \right] \quad (55)$$

O mínimo é calculado igualando a expressão (55) a zero. Este cálculo fornece a solução de forma fechada do problema da equação (53)

$$\Delta\theta = H^{-1} \sum_x \left[\nabla I_2 \frac{dW}{d\theta} \right]^T [I_1(x) - I_2(W(\theta; x))] \quad (56)$$

Onde H é a aproximação de Gauss-Newton à matriz *Hessiana*

$$H = \sum_x \left[\nabla I_2 \frac{dW}{d\theta} \right]^T \left[\nabla I_2 \frac{dW}{d\theta} \right] \quad (57)$$

Assim, o algoritmo de Lucas-Kanade consiste em iterativamente resolver as equações (52) e (56) até se atingir a convergência. Um dos problemas deste algoritmo, é que a aproximação por série de Taylor de primeira ordem utilizada na estimação de $\Delta\theta$ apenas é boa se o valor inicial do parâmetro θ_0 for suficientemente próximo de θ .

Para lidar com maiores variações entre as imagens, é usada uma aproximação em pirâmide de 3 níveis (ver Figura 14). Esta estratégia utiliza os mesmos processos de alinhamento, mas inicia os algoritmos com as imagens de referência e observada em resoluções inferiores (reduzindo assim as distâncias entre os pontos de cada uma das imagens) e indo gradualmente melhorando as estimativas de alinhamento à medida que sobe para resoluções maiores. Em cada nível, esta estratégia diminui consideravelmente o espaço de procura, reduzindo assim o tempo de processamento. Outra vantagem desta estratégia é que as maiores discrepâncias entre as imagens são resolvidas nas resoluções mais baixas, servindo as altas resoluções para executar pequenos ajustes. Assim, a utilização de pirâmides é essencial para uma boa convergência do algoritmo e também para a redução do seu tempo computacional.

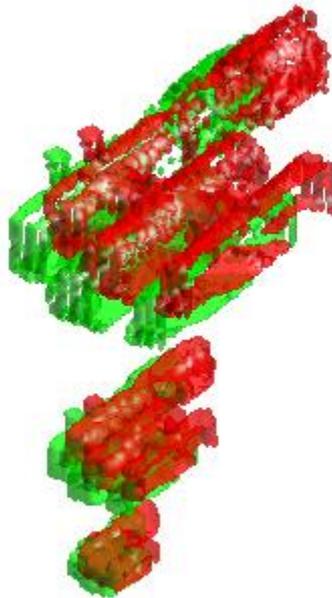


Figura 14 - Exemplo da estratégia de pirâmide em 3 níveis em que o alinhamento se inicia na resolução mais baixa e vai gradualmente subindo até à resolução original

Capítulo 4

Resultados experimentais

Neste capítulo, descrevem-se as experiências realizadas no sentido de avaliar e comparar o desempenho dos dois algoritmos de alinhamento descritos no capítulo anterior. Os dados utilizados nestas experiências encontram-se descritos na secção 4.1, tendo sido criados também dados sintéticos a partir destes, o que nos permite saber os parâmetros das transformações envolvidas,

O algoritmo ICP utiliza características extraídas das imagens mas para o caso do SRIN, dado que se trata de um método global, este será aplicado a imagens que são criadas a partir das mesmas características que as usadas pelo ICP.

As métricas utilizadas para efectuar a avaliação do desempenho são descritas na secção 4.2. e os resultados das mesmas apresentam-se na secções 4.3 a 4.5.

4.1 Descrição dos dados

O primeiro dado de teste é uma imagem tridimensional de ressonância magnética de um cérebro humano obtida (ver Figura 15 e Figura 16). O volume original foi extraído da base de dados BrainWeb [71] e é produzido por um simulador de MRI. Trata-se de volume em escala de cinzento com dimensões $274 \times 328 \times 270$. Devido ao elevado peso computacional dos algoritmos, a imagem processada foi uma versão reduzida da original por um factor de três em todos os eixos. As características escolhidas foram os pontos de contorno obtidos por aplicação do operador de *Sobel* descrito no capítulo 3.1.1. Depois de detectados os contornos, o volume fornece 89528 *CP*.

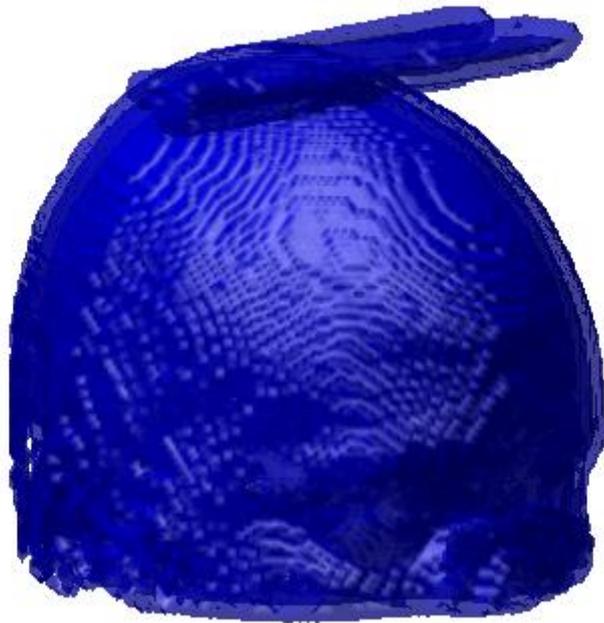


Figura 15 - Visualização tridimensional de um cérebro humano adquirido por MRI

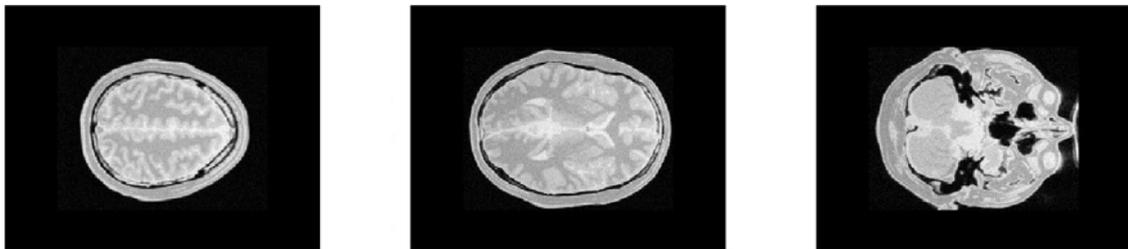


Figura 16 - Cortes transversais de um cérebro humano adquirido por MRI

O segundo dado de teste é uma imagem bidimensional dos vasos sanguíneos de uma retina humana extraída da base de dados Drive [73] (ver Figura 17). Esta imagem foi obtida utilizando uma câmara retinal Canon CR5 de 3 CCD e possui uma resolução de 215×208 . Sendo uma imagem com componentes RGB, necessita de extracção de características. Porém, não é necessária a intervenção do algoritmo de detecção de contornos, pois a imagem de características já se encontra disponível na base de dados [73]. Esta obtenção de características das imagens originais foi executada manualmente por observadores humanos, a quem foi pedido que assinalassem todos os

pixéis em que tivessem 70% de certeza de ser um vaso sanguíneo. A imagem de características utilizada possui 2700 *CP*.

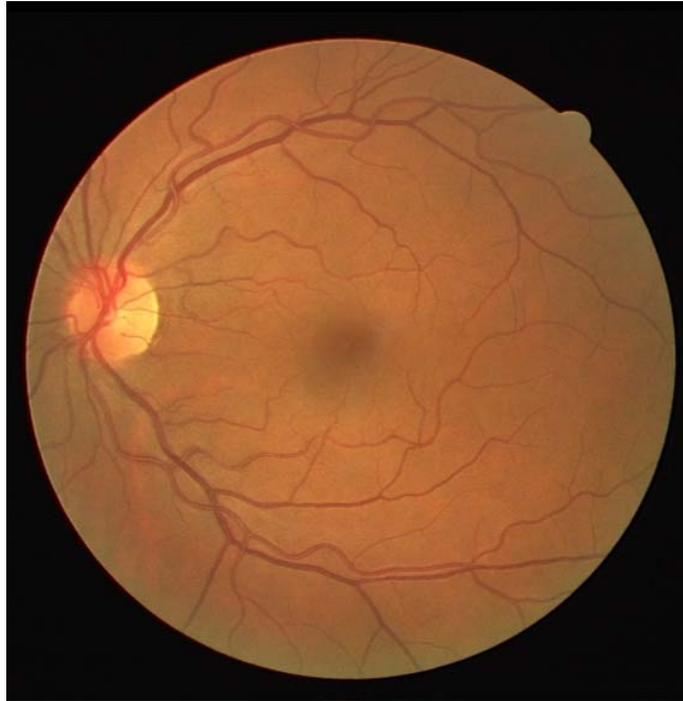


Figura 17 - Imagem dos vasos sanguíneos de uma retina humana

O terceiro dado de teste é um conjunto de leituras de um sensor laser que calcula as distâncias das superfícies envolventes e que foi obtido nas galerias romanas do subsolo Lisboaeta [72]. O volume tridimensional das galerias romanas possui as dimensões $127 \times 116 \times 68$ e está representado na Figura 18. Este volume é fornecido num formato de pontos individuais que descrevem os contornos das galerias romanas e que podem ser utilizados como características, não sendo por isso necessário o passo adicional para a sua extracção. Apesar da sua dimensão, o volume contém apenas 3756 *CP*, o que torna a matriz descritora da imagem tridimensional bastante esparsa. Na Figura 19 são apresentados os cortes transversais das galerias romanas.

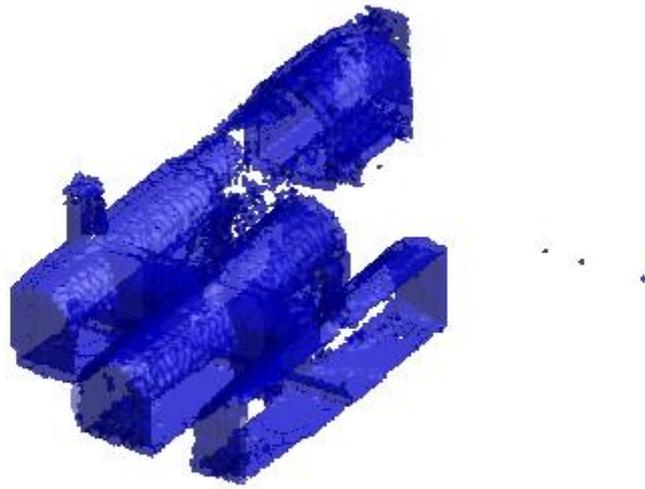


Figura 18 - Volume de galerias romanas obtido por sensor laser



Figura 19 - Cortes transversais de volume de galerias romanas obtido por sensor laser

4.2 Métricas de desempenho

O desempenho das técnicas de alinhamento aplicadas é medida utilizando a percentagem de alinhamentos não convergentes em n tentativas de alinhamento e medindo o $Erro_{RMS}$ (*Root Mean Square*) entre os parâmetros θ das transformações aplicada às imagens e os parâmetros θ' das transformações que os algoritmos apresentam como solução para o alinhamento entre as imagens.

Sendo que as transformações utilizadas são afins e contendo estas doze parâmetros (como descrito na eq.(10)), temos então mais detalhadamente o $Erro_{RMS}$ com a seguinte forma

$$Erro_{RMS} = \sqrt{\sum_{n=1}^{12} (\theta_n - \theta'_n)^2} \quad (58)$$

Nos testes em que as transformações são aleatórias é utilizada como métrica de erro a média do $Erro_{RMS}$. São geradas v transformações por percentagem de CP , mas apenas são consideradas para o $Erro_{RMS\ médio}$ aquelas em que se concluiu que os algoritmos convergiram. A não convergência em ambos os algoritmos é determinada se o número de iterações máximo permitido for atingido e se o limiar mínimo de precisão exigido ao algoritmo não for atingido. Assim, o $Erro_{RMS\ médio}$ é calculado da seguinte forma.

$$Erro_{RMS\ médio} = \frac{\sqrt{\sum_{n=1}^{12} (\theta_n - \theta'_n)^2}}{n^{\circ} \text{ de convergências em } v \text{ transformações}} \quad (59)$$

Nos casos em que as imagens não estão relacionadas por nenhuma transformação (imagem I_1 e imagem I_2), é impossível fazer uma medida quantitativa do erro entre elas. Neste cenário é criada uma imagem de erro, que permite uma comparação visual do alinhamento produzido. A imagem de erro é gerada da seguinte maneira.

$$I_{erro} = I_2 - I_1 \quad (60)$$

4.3 Resultados obtidos com ressonância magnética cerebral

Para ambos os algoritmos de alinhamento, foi efectuado o seguinte teste: Os *CP* foram reduzidos controladamente até ao máximo do multiplicador 0,7 do original, sendo incrementados em 0,1 após serem testadas com imagens com transformações afim aleatórias. As transformações afim possuem os seguintes limites: As translações podem ir de -10 a 10 em todos os eixos, os factores de escala podem ir de 0.85 a 1.15 em todos os eixos e as rotações podem ser de -10° a 10° em todos os eixos, podendo o seu centro de rotação deslocar-se do centro da imagem em qualquer eixo 5 *voxels*. São utilizados 4 factores de escala para o número de *CP* utilizados no alinhamento (0.7, 0.8, 0.9 e 1), em cada um deles são testadas com imagens com transformações aleatórias.

Posteriormente são apresentados dois alinhamentos efectuados por cada algoritmo com transformações afim geradas manualmente, com o objectivo de ilustrar o processo de alinhamento.

4.3.1 Iterative Closest Point (ICP)

No teste desenvolvido, são medidas as percentagens de não convergências do algoritmo por percentagem de *CP* (ver Gráfico 1) e é registado o $Erro_{RMS\ médio}$ do algoritmo por percentagem de *CP* (ver Gráfico 2).

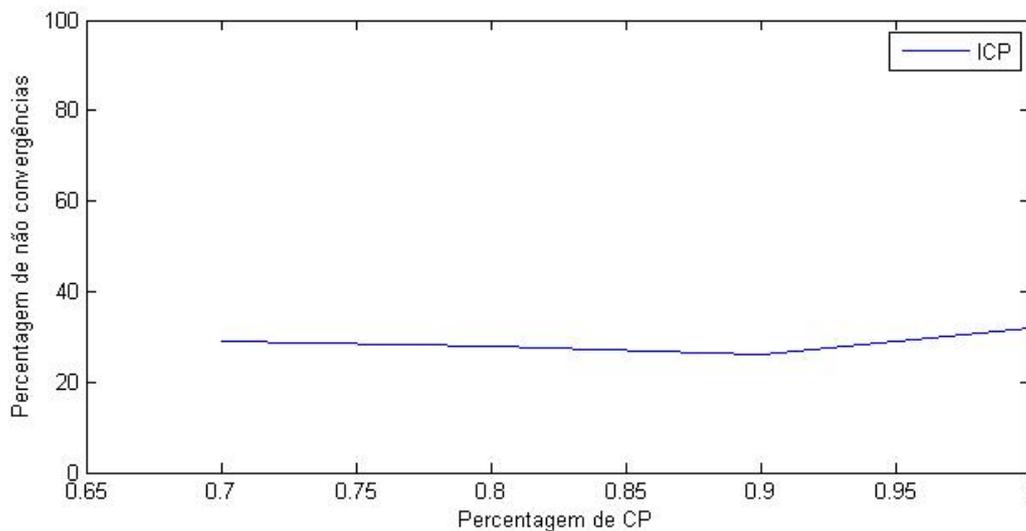


Gráfico 1 - ICP - Percentagem de não convergências por percentagem de *CP* no volume de MRI cerebral

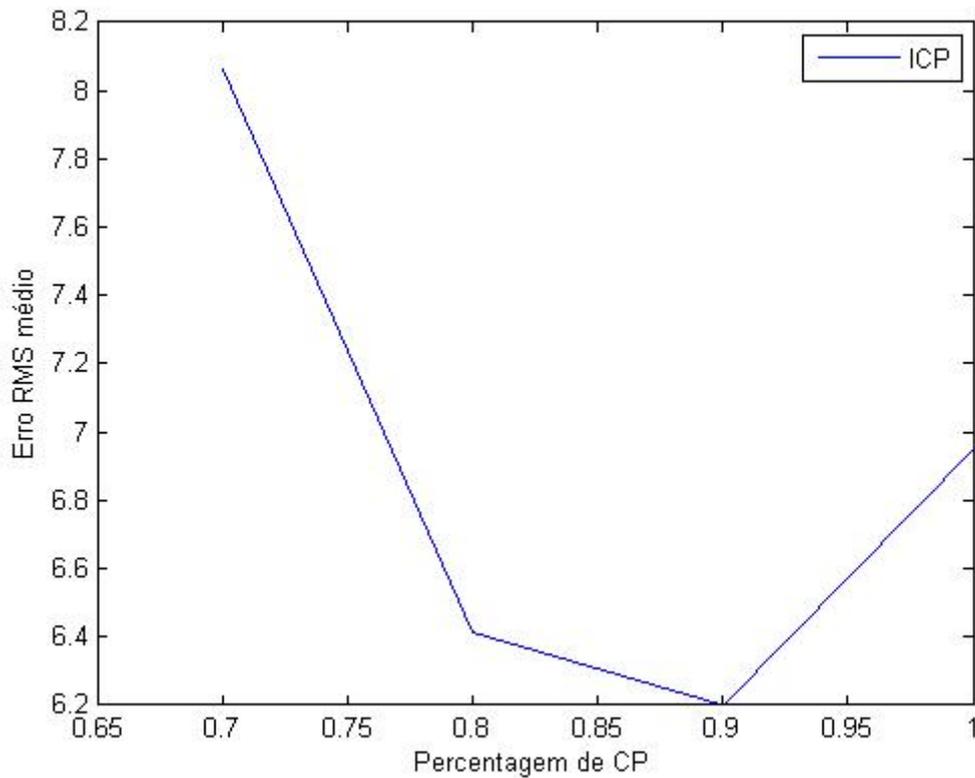


Gráfico 2 - ICP - $Erro_{RMS\ médio}$ por percentagem de CP no volume de MRI cerebral

Seguidamente são mostrados dois exemplos de alinhamentos efectuados pelo algoritmo com transformações afim geradas manualmente.

No primeiro exemplo é utilizada a matriz de transformação afim T1 com os seguintes parâmetros

$$T1 = \begin{bmatrix} 0.8863 & 0.1563 & 0 & 0 \\ -0.191 & 1.0833 & 0 & 0 \\ 0 & 0 & 1.05 & 0 \\ 16.1558 & -9.3608 & 3 & 1 \end{bmatrix} \quad (61)$$

correspondentes a uma transformação com translações de 10, -5 e 3 nos eixos x , y e z respectivamente, factores de escala de 0.9, 1.1 e 1.05 nos eixos x , y e z , e a uma rotação de 10° sobre o eixo dos z . Na Figura 20 a) visualizam-se os volumes de MRI cerebral desalinhados, O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao volume original a verde e na Figura 20 b) apresentam-se os volumes de MRI cerebral alinhados, O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao volume original a verde.



Figura 20 - ICP - a) Volumes de MRI cerebral desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao volume original a verde.
 b) Volumes de MRI cerebral alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao volume original a verde

Na Figura 21 a) mostra a sobreposição dos cortes transversais de MRI cerebral desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde e na Figura 21 b) a sobreposição dos cortes transversais de MRI cerebral alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde.

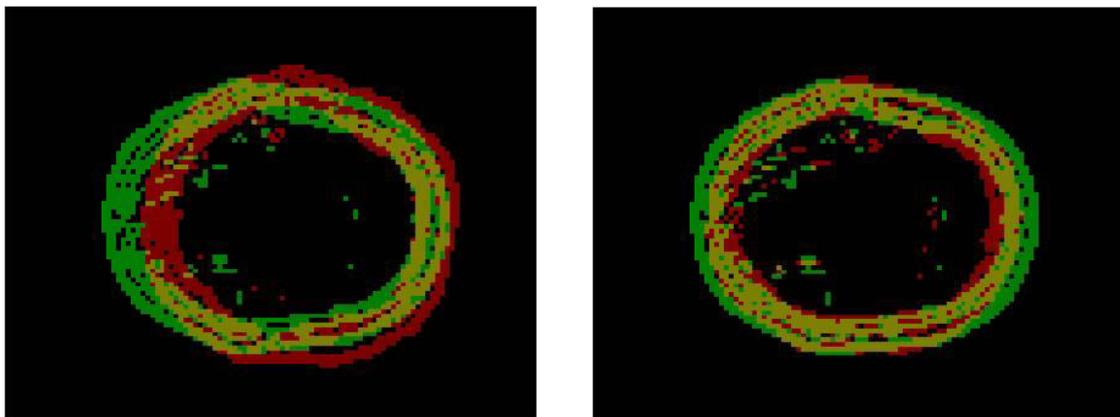


Figura 21 - ICP - a) Sobreposição dos cortes transversais de MRI cerebral desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde.
 b) Sobreposição dos cortes transversais de MRI cerebral alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde.

O $Erro_{RMS}$ do processo de alinhamento foi igual a 17.79.

Realizou-se uma nova transformação afim T2 com os seguintes parâmetros

$$T2 = \begin{bmatrix} 1.0889 & 0.0655 & -0.0618 & 0 \\ -0.0478 & 0.8414 & 0.0506 & 0 \\ 0.0625 & -0.0590 & 1.0394 & 0 \\ -6.6595 & 9.9607 & 4.6988 & 1 \end{bmatrix} \quad (62)$$

correspondentes a uma transformação com translações de -7, 10 e 5 nos eixos x , y e z respectivamente, factores de escala de 1.1, 0.85 e 1.05 nos eixos x , y e z , e a uma rotação de 10° sobre o eixos x , y e z . Na Figura 22 a) visualizam-se os volumes de MRI cerebral desalinhados, O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao volume original a verde e na Figura 22 b) visualizam-se os volumes de MRI cerebral alinhados, O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao volume original a verde.



Figura 22 - ICP -
a) Volumes de MRI cerebral desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao volume original a verde.
b) Volumes de MRI cerebral alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao volume original a verde

Na Figura 23 a) apresenta-se a sobreposição dos cortes transversais de MRI cerebral desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde e na Figura 23 b) a sobreposição dos cortes transversais de MRI cerebral alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde.

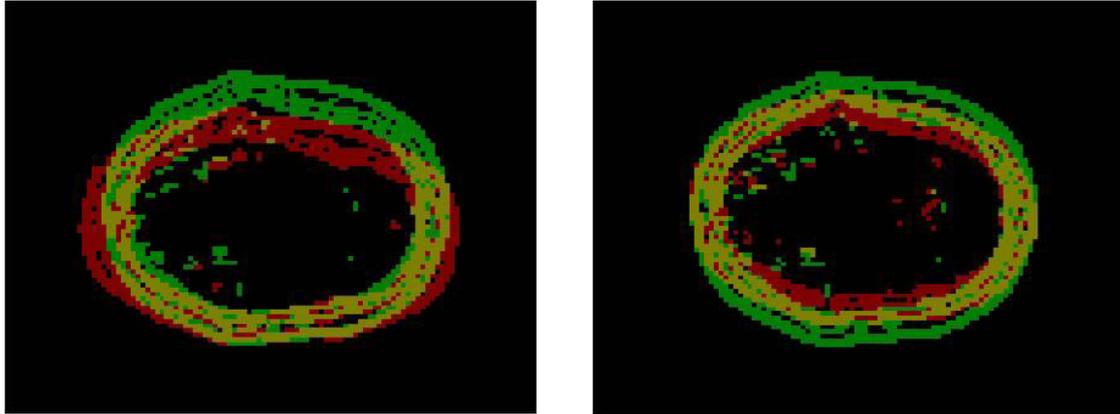


Figura 23 - ICP - a) Sobreposição dos cortes transversais de MRI cerebral desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao corte original a verde.

b) Sobreposição dos cortes transversais de MRI cerebral alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original a verde.

O $Erro_{RMS}$ do processo de alinhamento é igual a 8.029.

4.3.2 Alinhamento e normalização de intensidade simultâneo (SRIN)

O teste foi efectuado para as mesmas transformações utilizadas no teste descrito no capítulo 4.3. No teste desenvolvido são medidas as percentagens de não convergências do algoritmo por percentagem de CP (ver Gráfico 3) e é registado o $Erro_{RMS\ médio}$ do algoritmo por percentagem de CP (ver Gráfico 4).

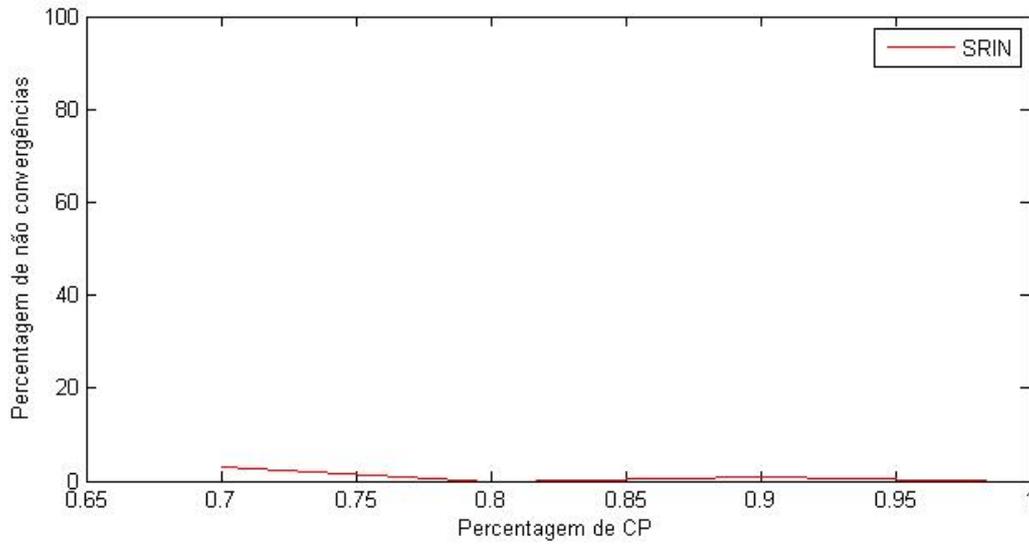


Gráfico 3 - SRIN - Percentagem de não convergências por percentagem de CP no volume de MRI cerebral

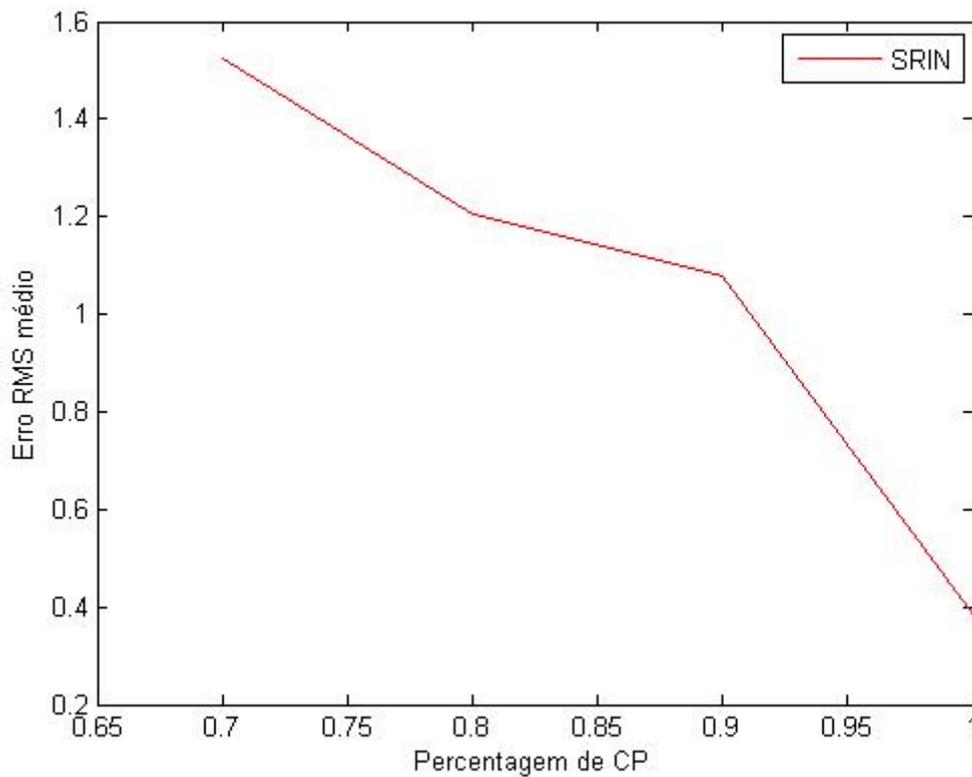


Gráfico 4 - SRIN - $Erro_{RMS\ médio}$ por percentagem de CP no volume de MRI cerebral

Seguidamente são mostrados dois exemplos de alinhamentos efectuados pelo algoritmo com transformações afim geradas manualmente.

Nos exemplos seguintes são utilizadas matrizes de transformação T1 (61) e T2 (62) previamente usadas nos exemplos para o ICP.

Para o exemplo com a transformação T1 (61), o $Erro_{RMS}$ foi igual a 0.3511 e na Figura 24 a) visualizam-se os volumes de MRI cerebral desalinhados, O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao volume original a verde e na Figura 24 b) apresentam-se os volumes de MRI cerebral alinhados, O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao volume original a verde.

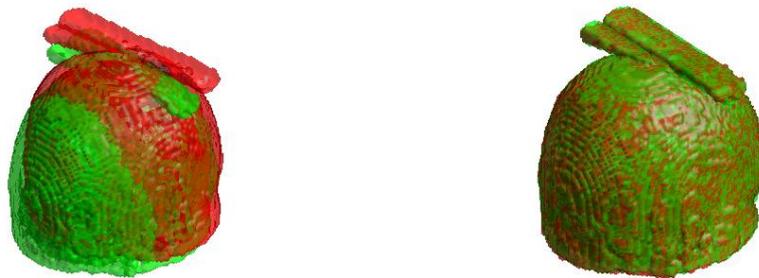


Figura 24 - SRIN - a) Volumes de MRI cerebral desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao volume original a verde.
b) Volumes de MRI cerebral alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao volume original a verde

Na Figura 25 a) apresenta-se a sobreposição dos cortes transversais de MRI cerebral desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde e na Figura 25 b) a sobreposição dos cortes transversais de MRI cerebral alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde.

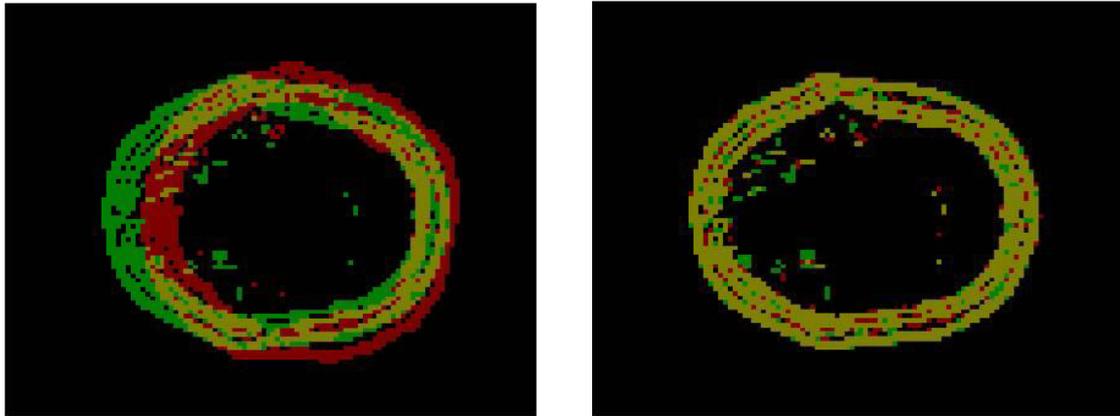


Figura 25 - SRIN - a) Sobreposição dos cortes transversais de MRI cerebral desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde.
 b) Sobreposição dos cortes transversais de MRI cerebral alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde.

O $Erro_{RMS}$ do processo de alinhamento é igual a 0.2705.

No exemplo com a função de mapeamento T2 (62), o $Erro_{RMS}$ foi igual a 0.3518 e na Figura 26 a) visualizam-se os volumes de MRI cerebral desalinhados, O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao volume original a verde e na Figura 26 b) apresentam-se os volumes de MRI cerebral alinhados, O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao volume original a verde.



Figura 26 - SRIN - a) Volumes de MRI cerebral desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao volume original a verde.
 b) Volumes de MRI cerebral alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao volume original a verde

Na Figura 27 a) visualiza-se a sobreposição dos cortes transversais de MRI cerebral desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde e na Figura 27 b) a sobreposição dos cortes transversais de MRI cerebral alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde.

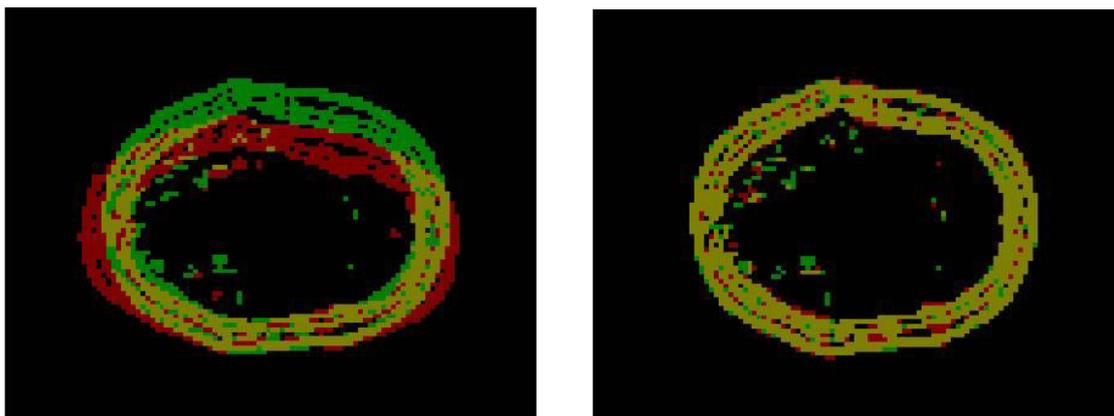


Figura 27 - SRIN - a) Sobreposição dos cortes transversais de MRI cerebral desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde.

b) Sobreposição dos cortes transversais de MRI cerebral alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde.

O $Erro_{RMS}$ do processo de alinhamento é igual a 0.3533.

4.3.3 Análise

Para se poder comparar os resultados de ambos os algoritmos estudados, foram sobrepostos o Gráfico 1 e Gráfico 3 (ver Gráfico 5) e o Gráfico 2 e Gráfico 4 (ver Gráfico 6).

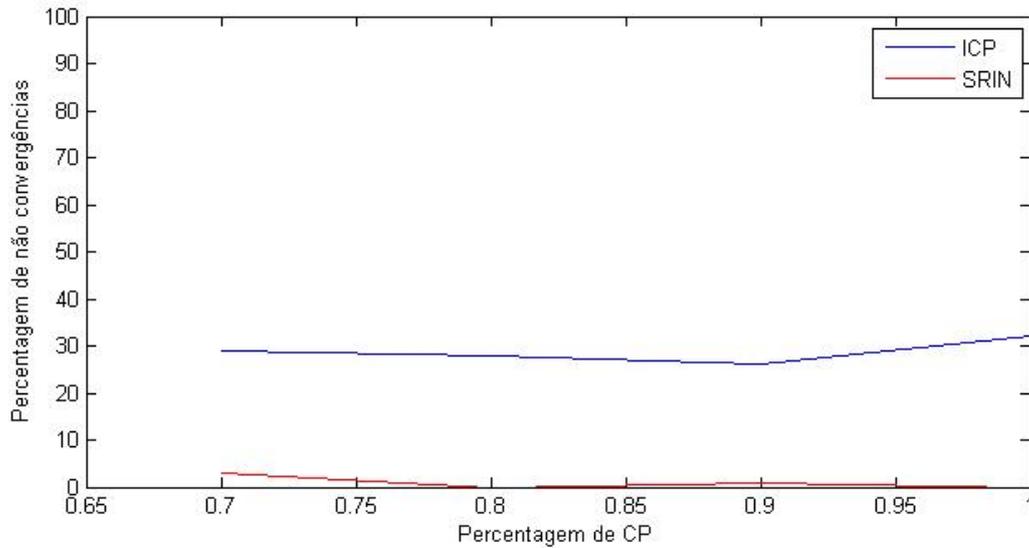


Gráfico 5 - Comparação das percentagens de não convergências por percentagens de CP no volume de MRI cerebral entre o ICP e o SRIN

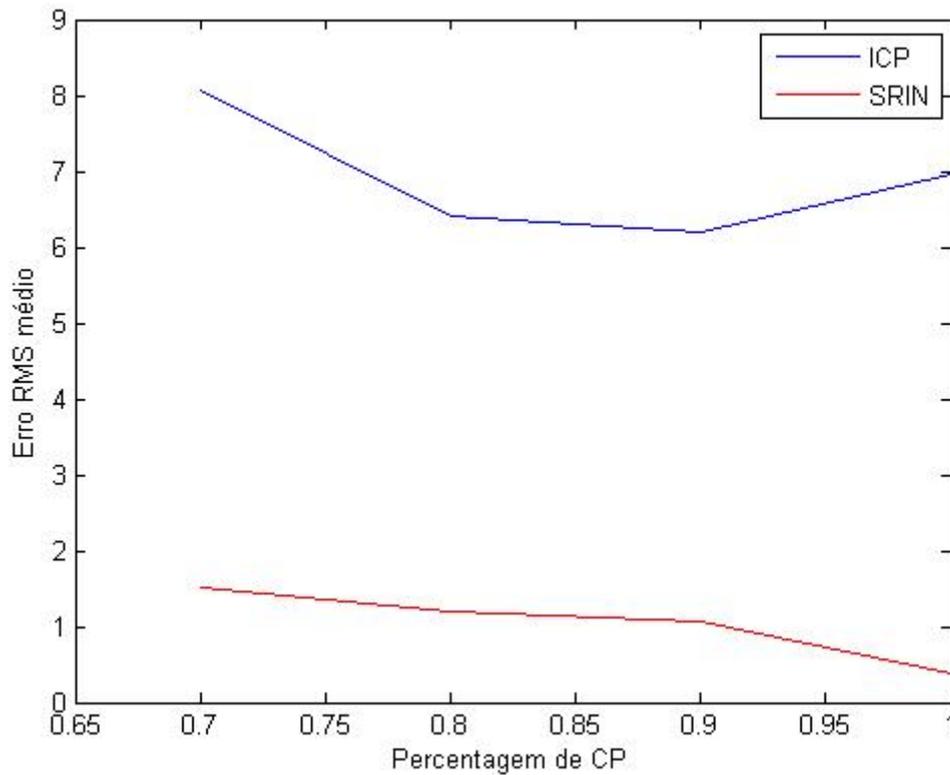


Gráfico 6 - Comparação do $Erro_{RMS\ médio}$ por percentagens de CP no volume de MRI cerebral entre o ICP e o SRIN

Analisados os dados obtidos do teste (ver Gráfico 5 e Gráfico 6) realizados para o volume cérebro, denota-se um equilíbrio entre o SRIN e o ICP.

Percebe-se uma clara superioridade do algoritmo SRIN sobre o ICP quer em termos de convergência, quer em termos de $Erro_{RMS\ médio}$. Nota-se o facto de o ICP ter a tendência para convergir para mínimos locais, o que justifica o $Erro_{RMS\ médio}$ elevado. Existe também um elevar tanto da percentagem de não convergências como do $Erro_{RMS\ médio}$ no ICP quando são utilizados a totalidade dos CP, o que pode ser justificado pelo aumento do número de correspondências entre características executadas de maneira errónea. O SRIN tem o comportamento esperado, á medida que o número de CP é aumentado, quer a percentagem de CP como de $Erro_{RMS\ médio}$ vão diminuindo.

4.4 Resultados obtidos com imagem de vasos sanguíneos de retina humana

Para ambos os algoritmos de alinhamento, foi efectuado o seguinte teste: Os *CP* foram reduzidos controladamente até ao máximo do multiplicador 0,7 do original, sendo incrementados em 0,1 após serem testadas com imagens com transformações afim aleatórias. As transformações afim possuem os seguintes limites: As translações podem ir de -10 a 10 em ambos os eixos, os factores de escala podem ir de 0.85 a 1.15 em ambos os eixos e as rotações podem ser de -10° a 10° no eixo dos z , podendo o seu centro de rotação deslocar-se do centro da imagem em qualquer eixo 5 *pixels*. São utilizados 4 factores de escala para o número de *CP* utilizados no alinhamento (0.7, 0.8, 0.9 e 1), em cada um deles são testadas com imagens com transformações aleatórias.

Posteriormente são mostrados dois alinhamentos efectuados por cada algoritmo com transformações afim geradas manualmente, com o objectivo de ilustrar o processo de alinhamento. Por fim compara-se o alinhamento entre duas imagens diferentes. Neste exemplo demonstra-se que o alinhamento pelas características produz resultados diferentes de um alinhamento global. Deste modo é utilizado igualmente o algoritmo SRIN no seu modo normal, ou seja utilizando a intensidade da imagem total.

4.4.1 Iterative Closest Point (ICP)

No teste desenvolvido são medidas as percentagens de não convergências do algoritmo por percentagem de *CP* (ver Gráfico 7) e é registado o $Erro_{RMS\ médio}$ do algoritmo por percentagem de *CP* (ver Gráfico 8).

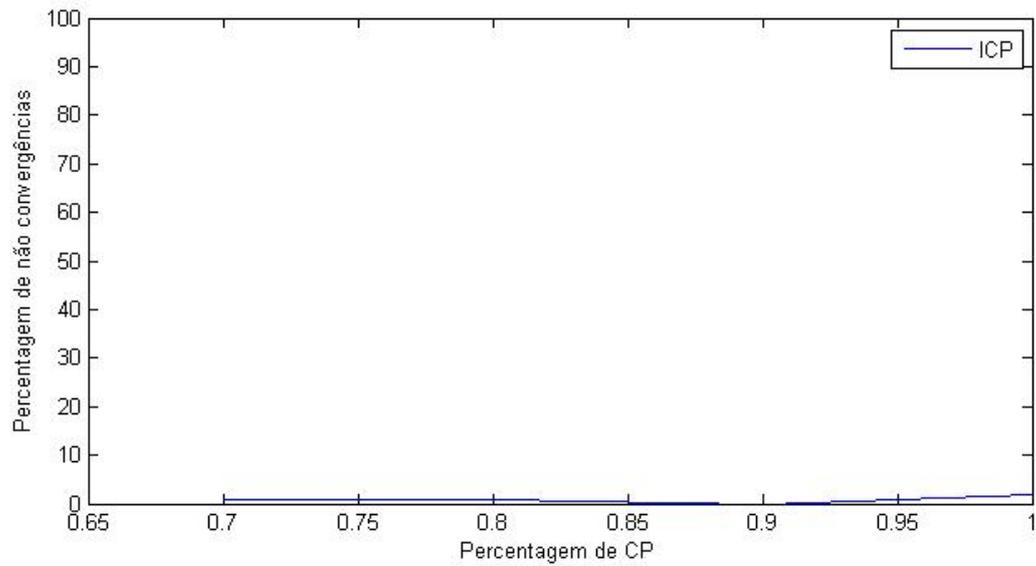


Gráfico 7 - ICP - Percentagem de não convergências por percentagem de CP na imagem dos vasos sanguíneos da retina humana

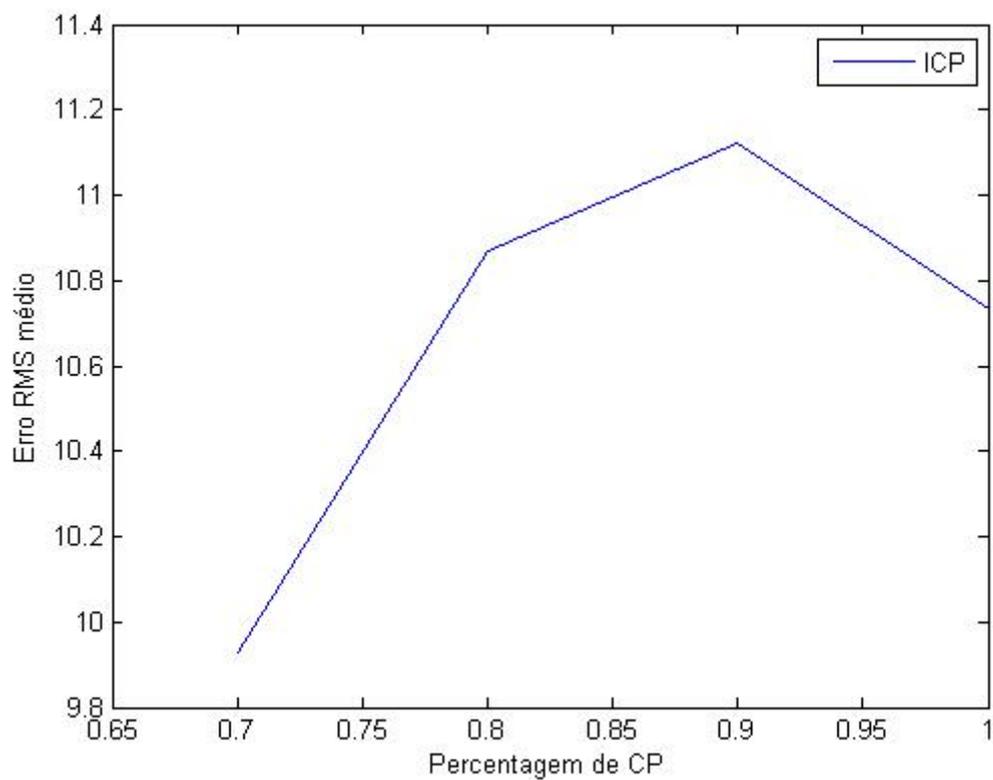


Gráfico 8 - ICP - $Erro_{RMS\ médio}$ por percentagem de CP na imagem dos vasos sanguíneos da retina humana

Seguidamente são mostrados dois alinhamentos efectuados pelo algoritmo com transformações afim geradas manualmente, para ilustrar o processo de alinhamento.

No primeiro exemplo é utilizada a matriz de transformação afim T1 com os seguintes parâmetros

$$T1 = \begin{bmatrix} 0.9464 & 0.0828 & 0 \\ -0.0872 & 0.9962 & 0 \\ 15.4733 & -12.9735 & 1 \end{bmatrix} \quad (63)$$

correspondentes a uma transformação com translações de 6, -4 nos eixos x, y respectivamente, factores de escala de 0.95 e 1 nos eixos x, y , e a uma rotação de 5° sobre o eixo dos z .

Na Figura 28 a) visualizam-se as imagens binarizadas dos vasos sanguíneos da retina humana desalinhadas, a imagem representada a verde foi sintetizada por aplicação da transformação geométrica T1 à imagem original a vermelho e na Figura 28 b) apresenta-se a sobreposição das imagens binarizadas dos vasos sanguíneos da retina humana alinhadas. A imagem verde foi alinhada após ser sintetizada por aplicação da transformação geométrica T1 à imagem original verde.

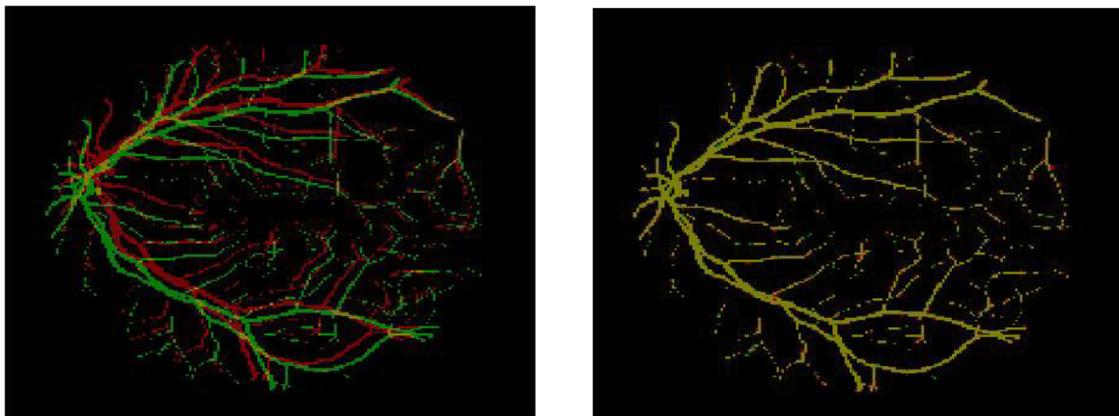


Figura 28 - ICP -
a) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi sintetizado por aplicação da transformação geométrica T1 ao corte original a vermelho
b) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a vermelho

Na Figura 29 a) visualizam-se as imagens em escala de cinzento dos vasos sanguíneos da retina humana desalinhadas, a imagem a vermelho foi sintetizada por aplicação da transformação geométrica T1 à imagem original a verde e na Figura 29 b) apresenta-se a sobreposição das imagens em escala de cinzento dos vasos sanguíneos da retina humana alinhadas. A imagem a vermelho foi alinhada após ser sintetizada por aplicação da transformação geométrica T1 à imagem original verde.

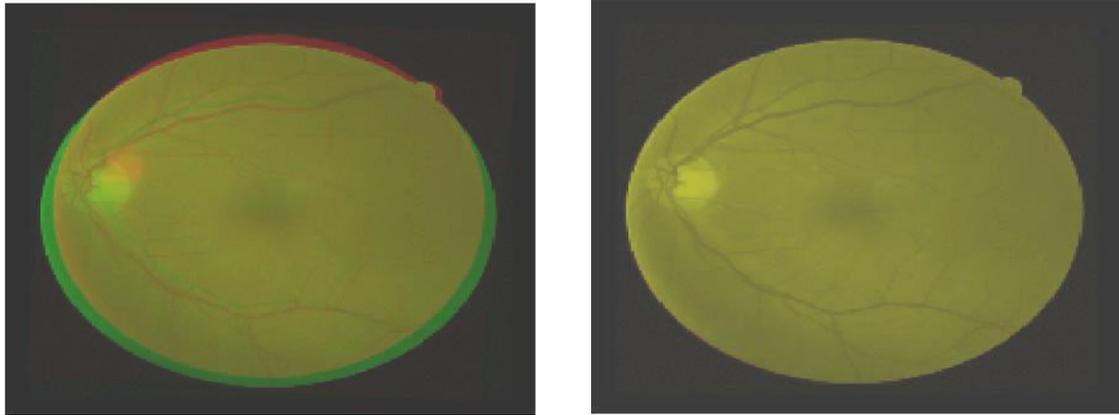


Figura 29 - ICP -
a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. A imagem a vermelho foi sintetizada por aplicação da transformação geométrica T1 à imagem original verde
b) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original verde

O $Erro_{RMS}$ do processo de alinhamento é igual a 0.0891 .

Realizou-se uma nova transformação afim T2 com os seguintes parâmetros

$$T2 = \begin{bmatrix} 0.9356 & 0.165 & 0 \\ -0.1910 & 1.0833 & 0 \\ 29.6926 & -24.0872 & 1 \end{bmatrix} \quad (64)$$

correspondentes a uma transformação com translações de 10, -7 nos eixos x, y respectivamente, factores de escala de 0.95 e 1.1 nos eixos x, y , e a uma rotação de 10° sobre o eixo dos z .

Na Figura 30 a) visualizam-se as imagens binarizadas dos vasos sanguíneos da retina humana desalinhadas, a imagem representada a verde foi sintetizada por aplicação da transformação geométrica T2 à imagem original a vermelho e na Figura 30 b) apresenta-se a sobreposição das imagens binarizadas dos vasos sanguíneos da retina humana alinhadas. A imagem verde foi alinhada após ser sintetizada por aplicação da transformação geométrica T2 à imagem original verde.

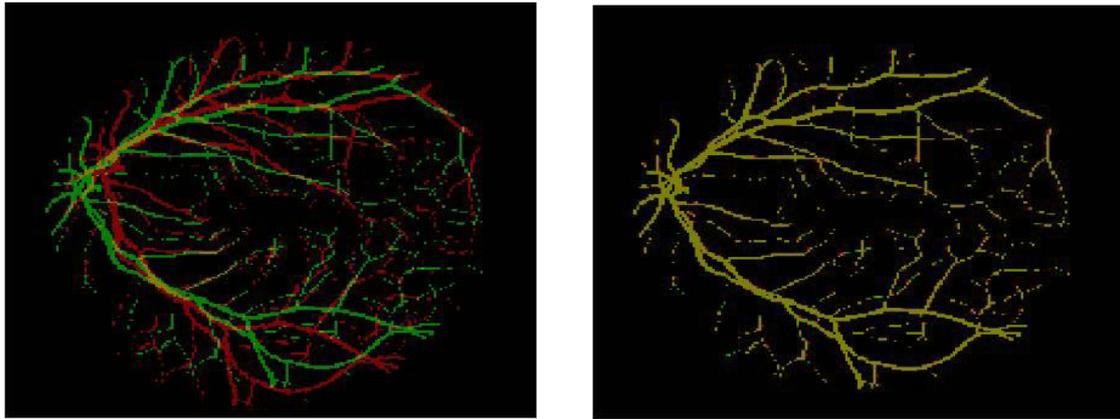


Figura 30 - ICP - a) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi sintetizado por aplicação da transformação geométrica T2 ao corte original a vermelho.

b) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original a vermelho

Na Figura 31 a) visualizam-se as imagens em escala de cinzento dos vasos sanguíneos da retina humana desalinhadas, a imagem a vermelho foi sintetizada por aplicação da transformação geométrica T2 à imagem original a verde e na Figura 31 b) apresenta-se a sobreposição das imagens em escala de cinzento dos vasos sanguíneos da retina humana alinhadas. A imagem a vermelho foi alinhada após ser sintetizada por aplicação da transformação geométrica T2 à imagem original verde.

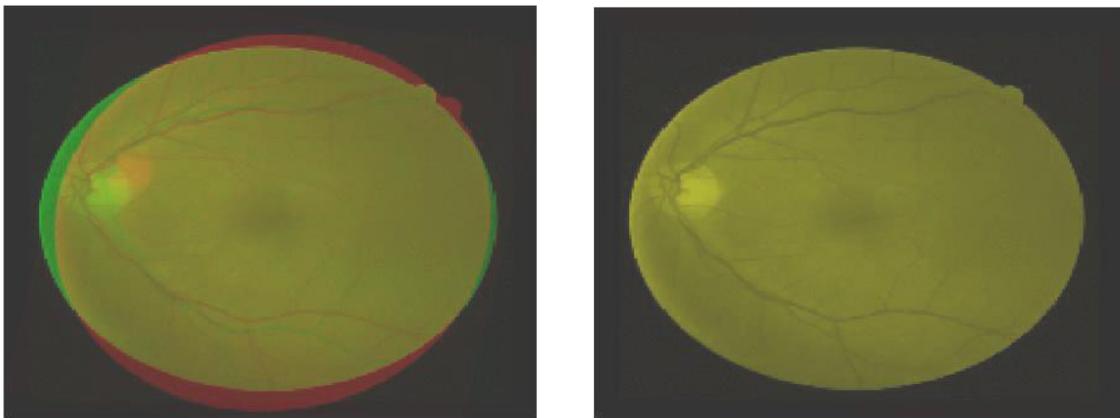


Figura 31 - ICP - a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi sintetizado por aplicação da transformação geométrica T2 ao corte original verde.

b) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original verde

Após o processo de alinhamento, o $Erro_{RMS}$ é igual a 0.087 .

No último exemplo é mostrado o alinhamento entre duas imagens independentes I_1 e I_2 . O objectivo deste é a verificação de que o alinhamento de imagens executado com imagens de características é diferente ao realizado com o algoritmo SRIN utilizando as intensidades originais da imagem.

Na Figura 32 a) visualizam-se sobrepostas as imagens dos vasos sanguíneos da retina humana independentes binarizadas de I_1 (a verde) e I_2 (a vermelho), e na Figura 32 b) a sobreposição das imagens da retina humana independentes binarizadas de I_1 (a verde) e I_2 (a vermelho) alinhadas.

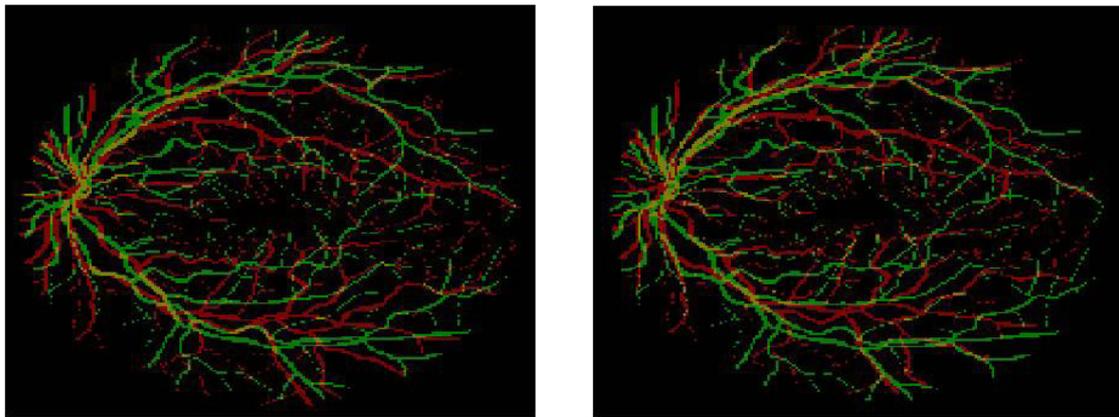


Figura 32 - ICP - a) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas I_1 (a verde) e I_2 (a vermelho)

b) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas I_1 (a verde) e I_2 (a vermelho) após alinhamento com o algoritmo ICP

Na Figura 33 a) apresentam-se sobrepostas as imagens dos vasos sanguíneos da retina humana independentes em escala de cinzento de I_1 (a verde) e I_2 (a vermelho), e na Figura 33 b) a sobreposição das imagens da retina humana independentes em escala de cinzento de I_1 (a verde) e I_2 (a vermelho) alinhadas.

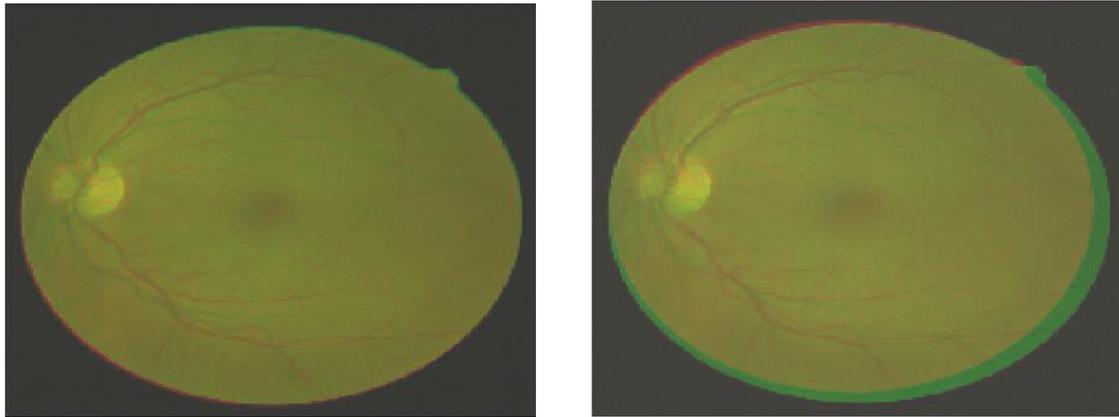


Figura 33 - ICP - a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento I_1 (a verde) e I_2 (a vermelho)
 b) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento I_1 (a verde) e I_2 (a vermelho) após alinhamento

Na Figura 34 a) apresenta-se a imagem de erro inicial das imagens independentes I_1 e I_2 , na Figura 34 b) apresenta-se a imagem de erro final das imagens independentes I_1 e I_2 .

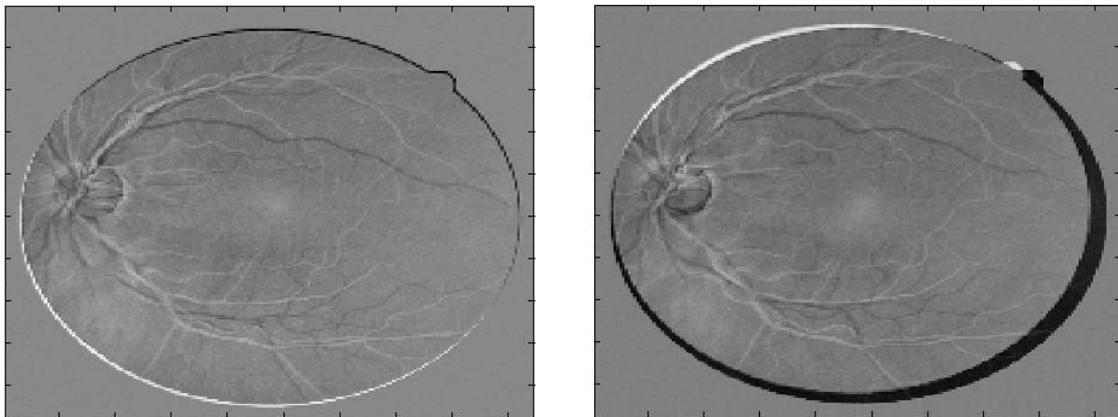


Figura 34 - ICP - a) Imagem de erro inicial - b) Imagem de erro final

4.4.2 Alinhamento e normalização de intensidade simultâneos (SRIN)

O teste foi efectuado para as mesmas transformações utilizadas no teste descrito no capítulo 4.5. No teste são medidas as percentagens de não convergências do algoritmo por percentagem de CP (ver Gráfico 9) e é registado o $Erro_{RMS\ médio}$ do algoritmo por percentagem de CP (ver Gráfico 10).

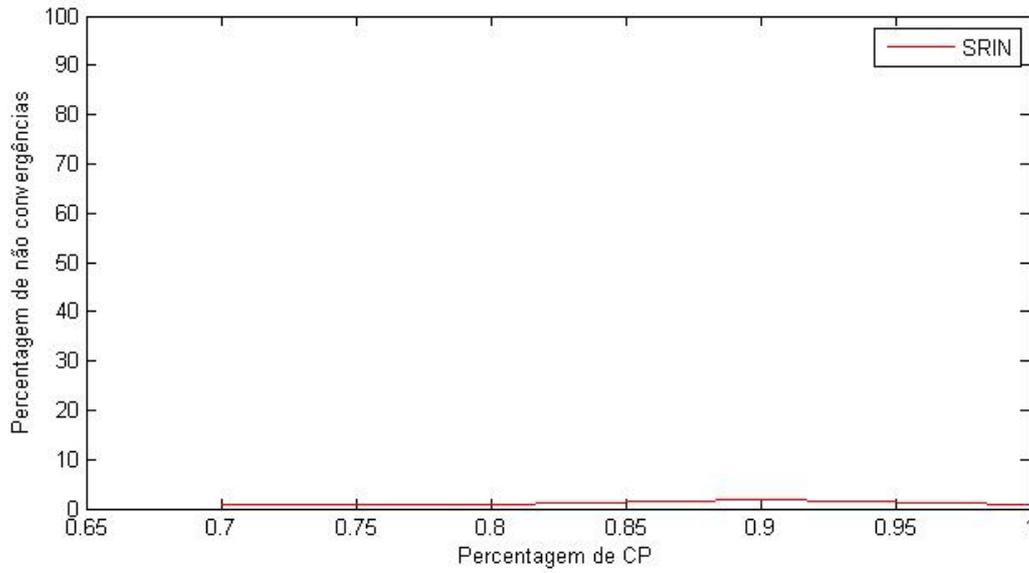


Gráfico 9 - SRIN - Percentagem de não convergências por percentagem de CP na imagem dos vasos sanguíneos da retina humana

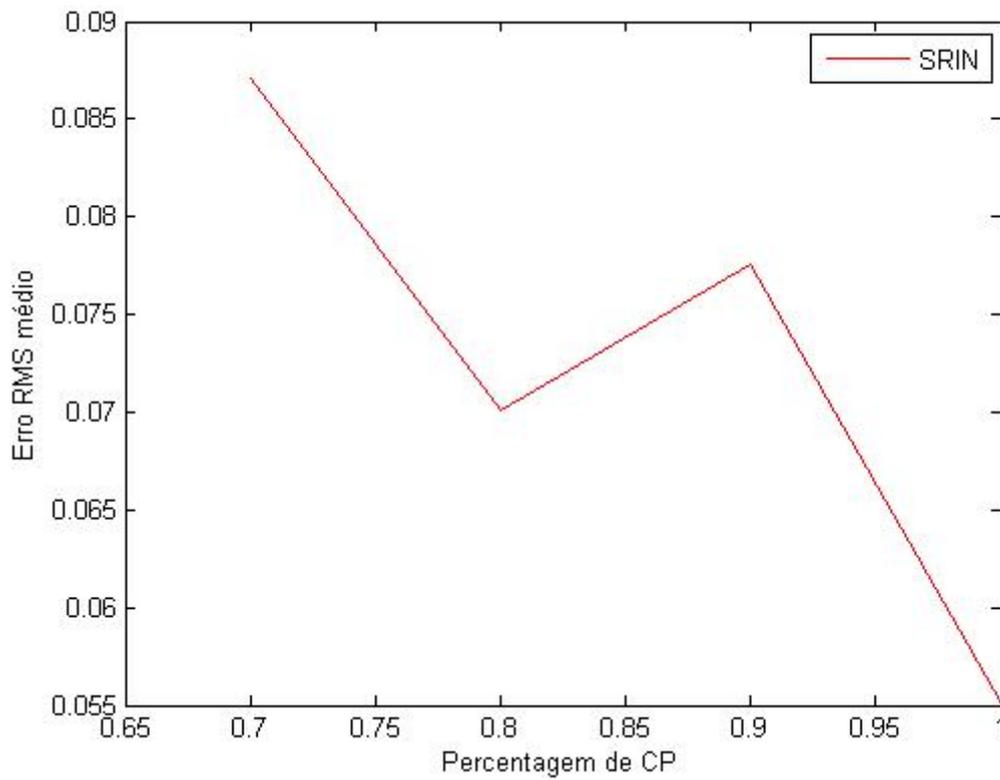


Gráfico 10 - SRIN - $Erro_{RMS\ médio}$ por percentagem de CP na imagem dos vasos sanguíneos da retina humana

Nos primeiros exemplos são utilizadas matrizes de transformação T1 (67) e T2 (68) previamente usadas nos exemplos do ICP.

Para o exemplo com a transformação T1 (67), o $Erro_{RMS}$ foi igual a 0.0239 e na Figura 35 a) visualizam-se as imagens binarizadas dos vasos sanguíneos da retina humana desalinhadas, a imagem representada a verde foi sintetizada por aplicação da transformação geométrica T1 à imagem original a vermelho e na Figura 35 b) apresenta-se a sobreposição das imagens binarizadas dos vasos sanguíneos da retina humana alinhadas. A imagem verde foi alinhada após ser sintetizada por aplicação da transformação geométrica T1 à imagem original verde.

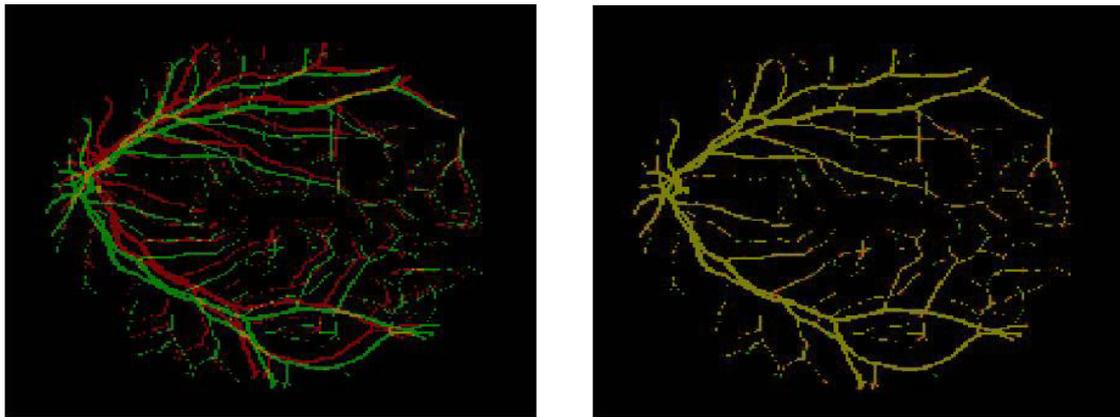


Figura 35 - SRIN - a) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi sintetizado por aplicação da transformação geométrica T1 ao corte original a vermelho
b) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a vermelho

Na Figura 36 a) visualizam-se as imagens em escala de cinzento dos vasos sanguíneos da retina humana desalinhadas, a imagem a vermelho foi sintetizada por aplicação da transformação geométrica T1 à imagem original a verde e na Figura 36 b) apresenta-se a sobreposição das imagens em escala de cinzento dos vasos sanguíneos da retina humana alinhadas. A imagem a vermelho foi alinhada após ser sintetizada por aplicação da transformação geométrica T1 à imagem original verde.

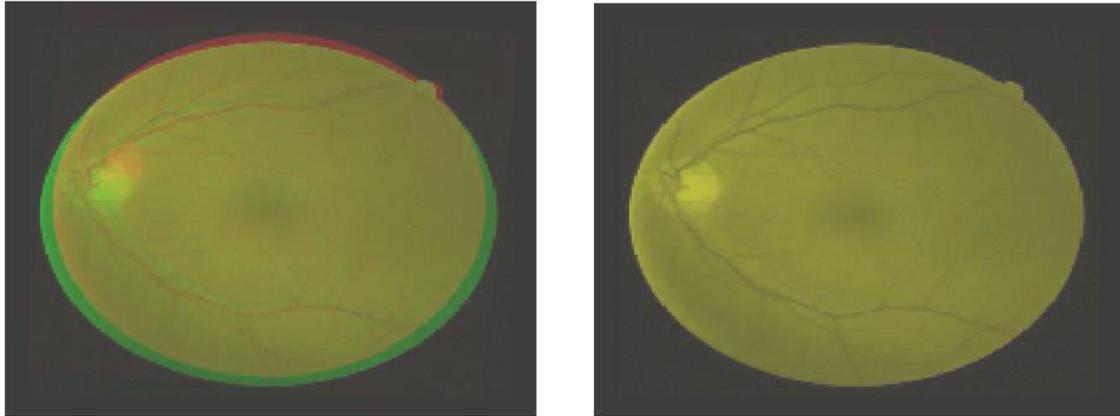


Figura 36 - SRIN -

a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original verde

b) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original verde

Para o exemplo com a transformação T2 (68), o $Erro_{RMS}$ foi igual a 0.0502 e na Figura 37 a) visualizam-se as imagens binarizadas dos vasos sanguíneos da retina humana desalinhadas, a imagem representada a verde foi sintetizada por aplicação da transformação geométrica T2 à imagem original a vermelho e na Figura 37 b) apresenta-se a sobreposição das imagens binarizadas dos vasos sanguíneos da retina humana alinhadas. A imagem verde foi alinhada após ser sintetizada por aplicação da transformação geométrica T2 à imagem original verde.

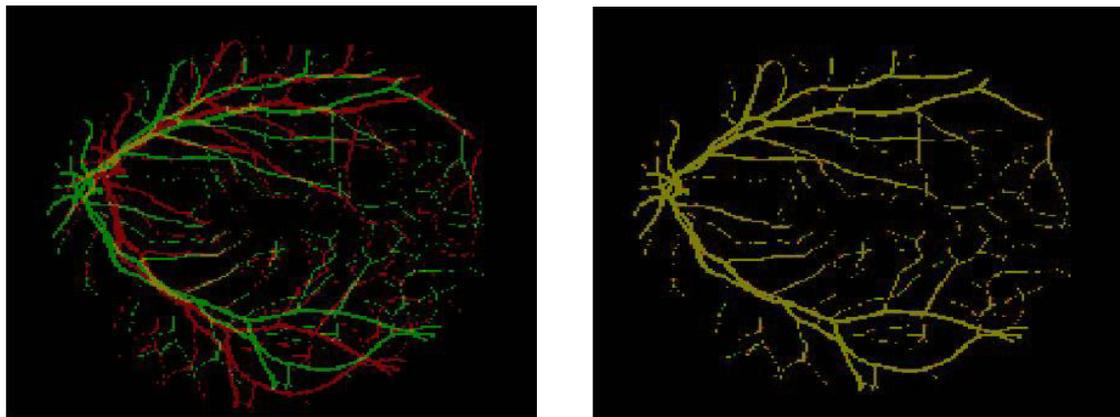


Figura 37 - SRIN -

a) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi sintetizado por aplicação da transformação geométrica T2 ao corte original a vermelho

b) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas. O corte a verde foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original a vermelho

Na Figura 38 a) visualizam-se as imagens em escala de cinzento dos vasos sanguíneos da retina humana desalinhadas, a imagem a vermelho foi sintetizada por aplicação da transformação geométrica T2 à imagem original a verde e na Figura 38 b) apresenta-se a sobreposição das imagens em escala de cinzento dos vasos sanguíneos da retina humana alinhadas. A imagem a vermelho foi alinhada após ser sintetizada por aplicação da transformação geométrica T2 à imagem original verde.

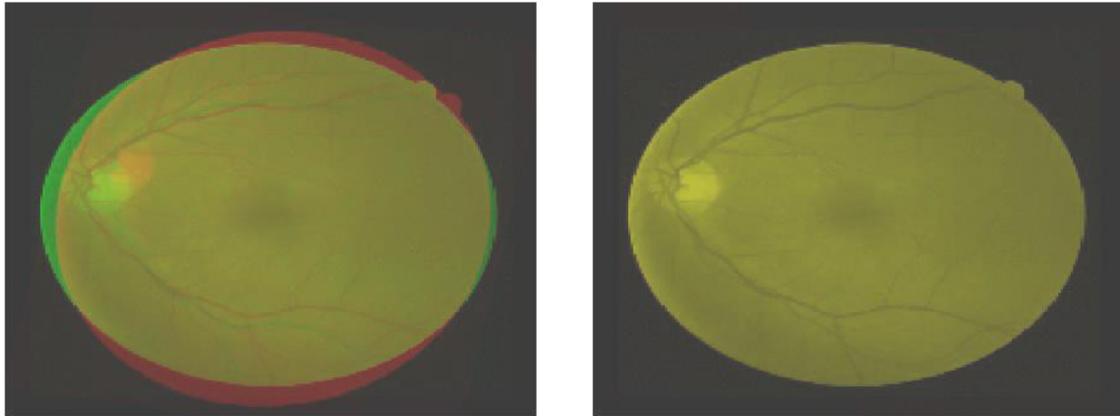


Figura 38 - SRIN - a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi sintetizado por aplicação da transformação geométrica T2 ao corte original verde

b) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento. O corte vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original verde

No último exemplo é mostrado o alinhamento entre duas imagens independentes, idênticas às utilizadas para exemplificar o ICP, I_1 e I_2 . O objectivo deste exemplo é a verificação que o alinhamento de imagens executado com imagens de características é diferente ao realizado com o algoritmo SRIN utilizando as intensidades originais da imagem. O exemplo possui duas fases: inicialmente o alinhamento é executado utilizando as imagens binárias e na segunda fase o alinhamento é realizado utilizando as imagens em escala de cinzento.

Na Figura 39 a) apresentam-se sobrepostas as imagens dos vasos sanguíneos da retina humana independentes binarizadas de I_1 (a verde) e I_2 (a vermelho), na Figura 39 b) a sobreposição das imagens da retina humana independentes binarizadas de I_1 (a verde) e I_2 (a vermelho) alinhadas pelo algoritmo SRIN em imagem de características.

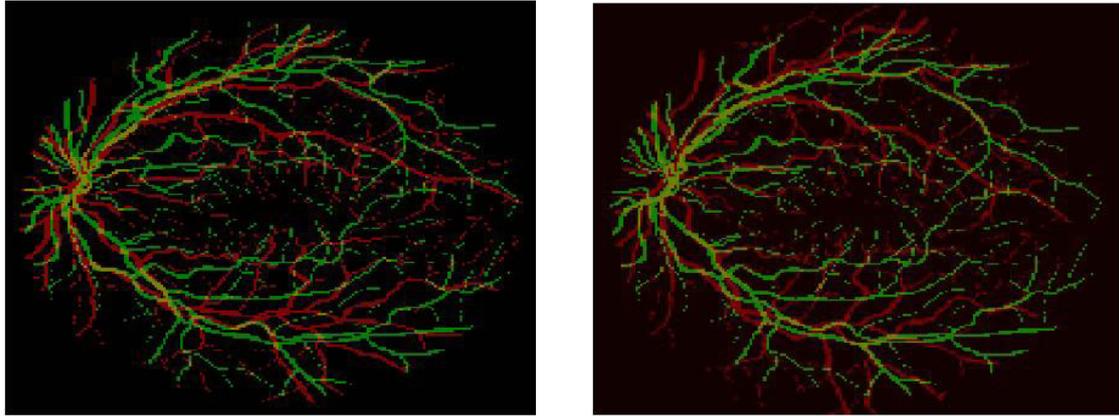


Figura 39 - SRIN em imagem de características - a) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas I_1 (a verde) e I_2 (a vermelho)
b) Sobreposição das imagens dos vasos sanguíneos da retina humana binarizadas I_1 (a verde) e I_2 (a vermelho) após alinhamento com o algoritmo SRIN em imagem de características

Na Figura 40 a) apresentam-se sobrepostas as imagens dos vasos sanguíneos da retina humana independentes em escala de cinzento de I_1 (a verde) e I_2 (a vermelho), e na Figura 40 b) a sobreposição das imagens da retina humana independentes em escala de cinzento de I_1 (a verde) e I_2 (a vermelho) alinhadas pelo algoritmo SRIN em imagem de características.

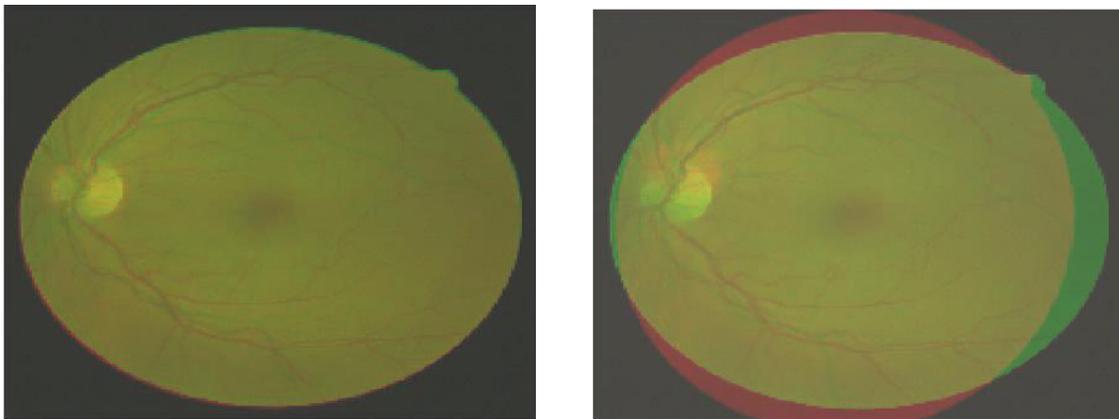


Figura 40 - SRIN em imagem de características - a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento I_1 (a verde) e I_2 (a vermelho)
b) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento I_1 (a verde) e I_2 (a vermelho) após alinhamento com o algoritmo SRIN em imagem de características

Na Figura 41 a) apresenta-se a imagem de erro inicial das imagens independentes I_1 e I_2 , na Figura 41 b) apresenta-se a imagem de erro final das imagens independentes I_1 e I_2 .

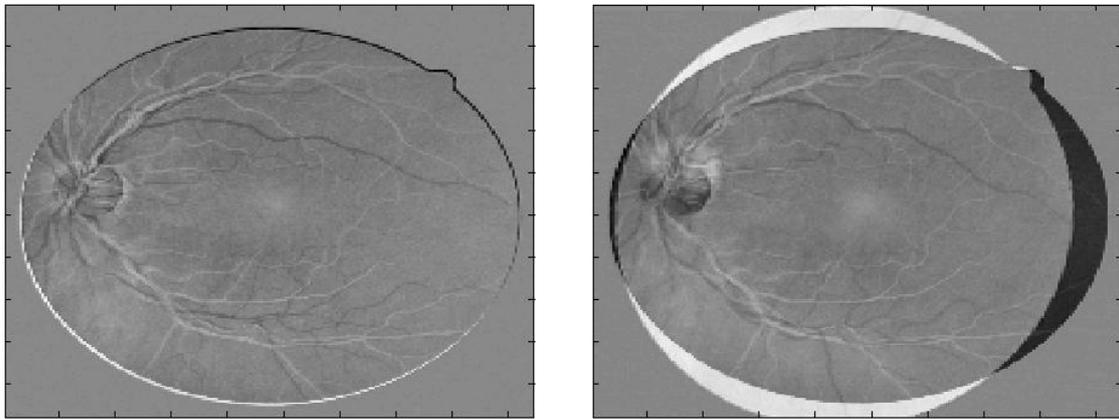


Figura 41 - SRIN em imagem de características - a) Imagem de erro final b) Imagem de erro final

Após o processo de alinhamento utilizando as intensidades originais da imagem, a Figura 42 a) apresentam-se sobrepostas as imagens dos vasos sanguíneos da retina humana independentes em escala de cinzento de I_1 (a verde) e I_2 (a vermelho), na Figura 42 b) a sobreposição das imagens da retina humana independentes em escala de cinzento de I_1 (a verde) e I_2 (a vermelho) alinhadas pelo algoritmo SRIN por intensidade original.

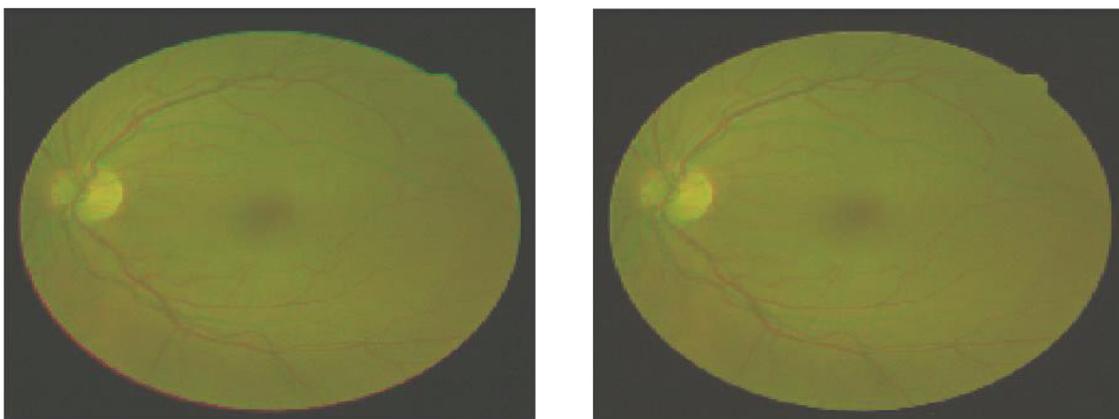


Figura 42 - SRIN por intensidade original - a) Sobreposição das imagens dos vasos sanguíneos da retina humana em escala de cinzento I_1 (a verde) e I_2 (a vermelho) b) Sobreposição das imagens dos vasos sanguíneos da

retina humana em escala de cinzento I_1 (a verde) e I_2 (a vermelho) após alinhamento pelo algoritmo SRIN nas intensidades originais

Na Figura 43 a) apresenta-se a imagem de erro inicial das imagens independentes I_1 e I_2 , na Figura 43 b) apresenta-se a imagem de erro final das imagens independentes I_1 e I_2 .

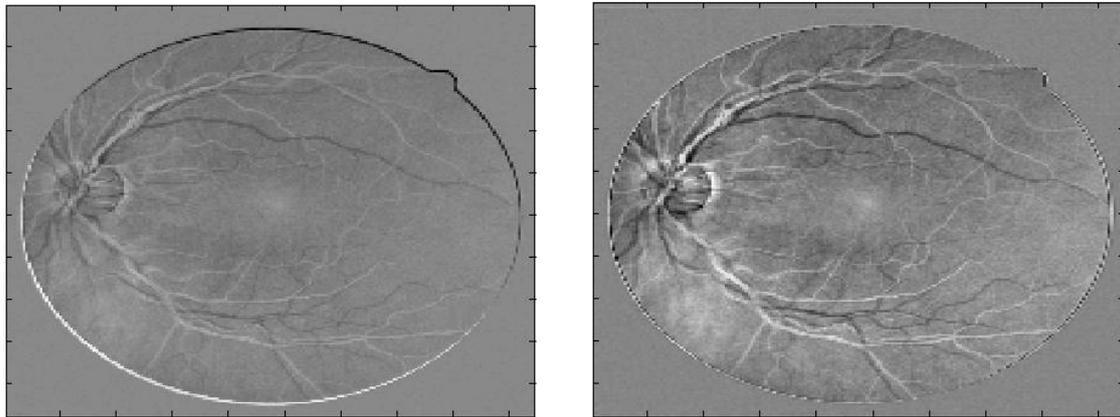


Figura 43 - SRIN por intensidade original - a) Imagem de erro inicial b) imagem de erro final

4.4.3 Análise

Para se poder comparar os resultados de ambos os algoritmos estudados dos dados obtidos no teste, foram sobrepostos o Gráfico 7 e Gráfico 9 (ver Gráfico 11) e o Gráfico 8 e Gráfico 10 (ver Gráfico 12).

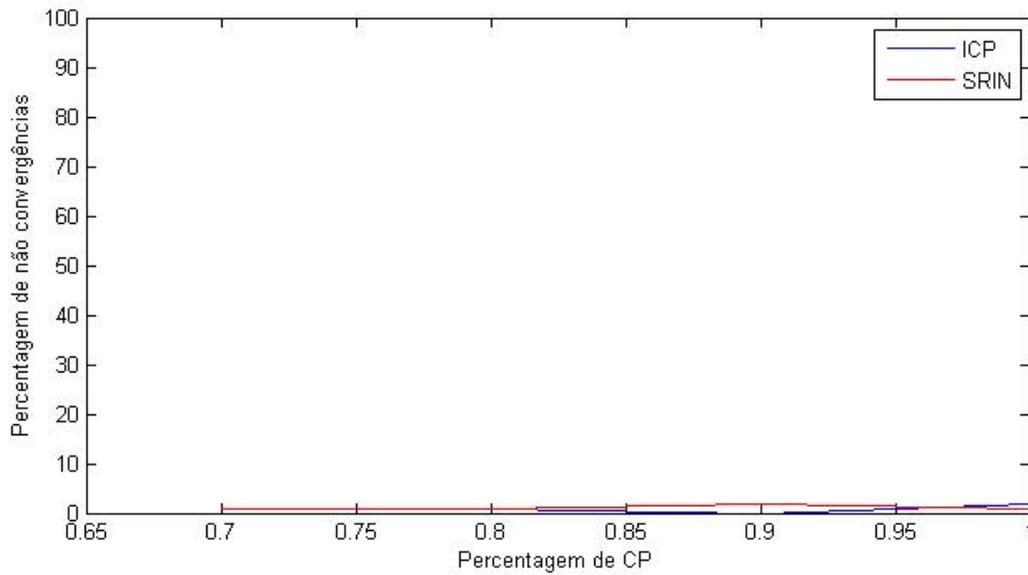


Gráfico 11 - Sobreposição da porcentagem de não convergências por porcentagem de CP na imagem dos vasos sanguíneos da retina humana

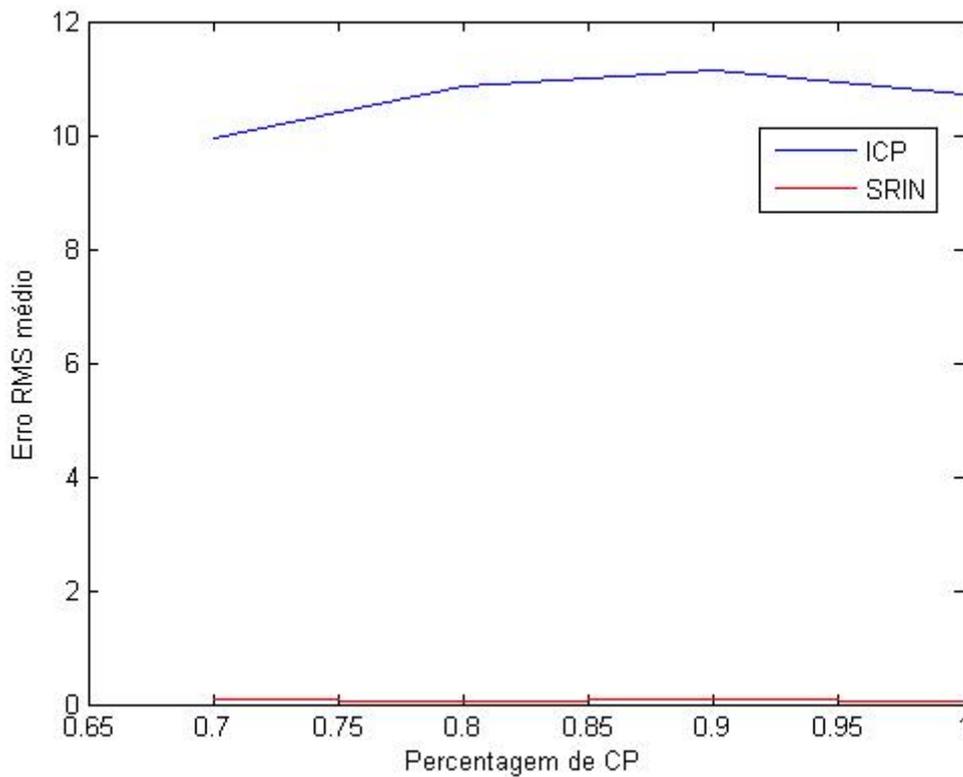


Gráfico 12 - Sobreposição do $Erro_{RMS\ médio}$ por porcentagem de CP na imagem dos vasos sanguíneos da retina humana

Verifica-se uma equivalência nos valores da percentagem de convergência, estando os dois algoritmos equiparados. Já em termos de $Erro_{RMS\ médio}$, o algoritmo SRIN volta a mostrar-se muito superior, apresentado mesmo $Erro_{RMS\ médio}$ inferiores a 0.1 em todas as percentagens de CP. Já o ICP volta a demonstrar a sua tendência para convergências para mínimos locais, apresentado novamente $Erro_{RMS\ médio}$ na ordem de 10.

4.5 Resultados obtidos com volume de galerias romanas adquirido por sensor laser

Para ambos os algoritmos de alinhamento, foi efectuado o seguinte teste: Os *CP* foram reduzidos controladamente até ao máximo do multiplicador 0,7 do original, sendo incrementados em 0,1 após serem testadas com imagens com transformações afim aleatórias. As transformações afim possuem os seguintes limites: As translações podem ir de -10 a 10 em todos os eixos, os factores de escala podem ir de 0.85 a 1.15 em todos os eixos e as rotações podem ser de -10° a 10° em todos os eixos, podendo o seu centro de rotação deslocar-se do centro da imagem em qualquer eixo 5 *voxels*. São utilizados 4 factores de escala para o número de *CP* utilizados no alinhamento (0.7, 0.8, 0.9 e 1), em cada um deles são testadas com imagens com transformações aleatórias.

Posteriormente são apresentados dois alinhamentos efectuados por cada algoritmo com transformações afim geradas manualmente, com o objectivo de ilustrar o processo de alinhamento. Um outro exemplo é exposto baseado na aquisição real deste tipo de imagem, que apenas implica transformações de corpo rígido (ver capítulo 2.4.1.1). Deste modo, é fornecido manualmente aos algoritmos uma função de transformação de corpo rígido, a qual deve ser estimada de modo a solucionar o problema de alinhamento. Por fim é exibido o alinhamento em corpo rígido mas, retirando partes da imagem transformada, para que a imagem original e a imagem a alinhar possuam um número de *CP* diferente.

4.5.1 Iterative Closest Point (ICP)

No teste desenvolvido são medidas as percentagens de não convergências do algoritmo por percentagem de *CP* (ver Gráfico 13) e é registado o $\bar{Erro}_{RMS\ médio}$ do algoritmo por percentagem de *CP* (ver Gráfico 14).

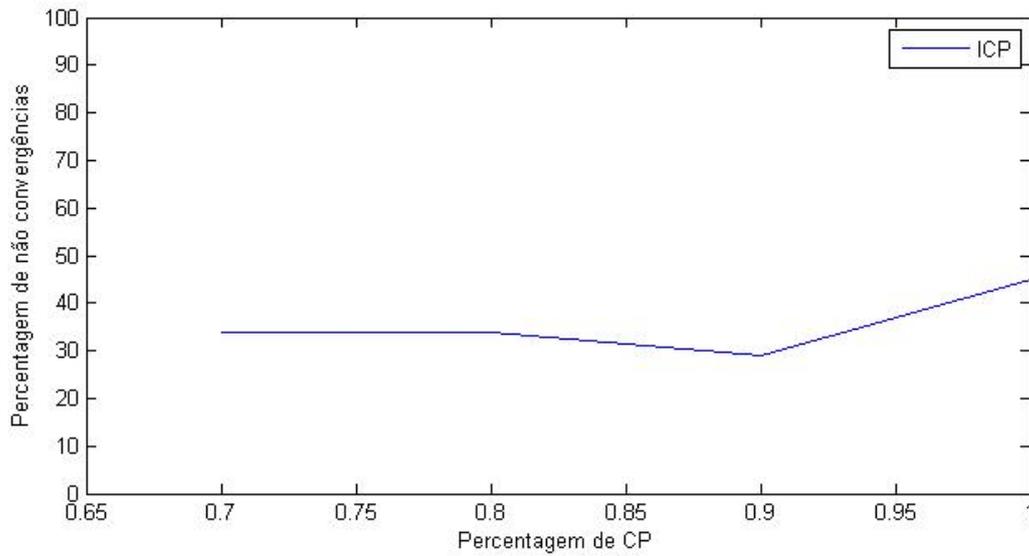


Gráfico 13 - ICP - Percentagem de não convergências por percentagem de *CP* nas galerias romanas

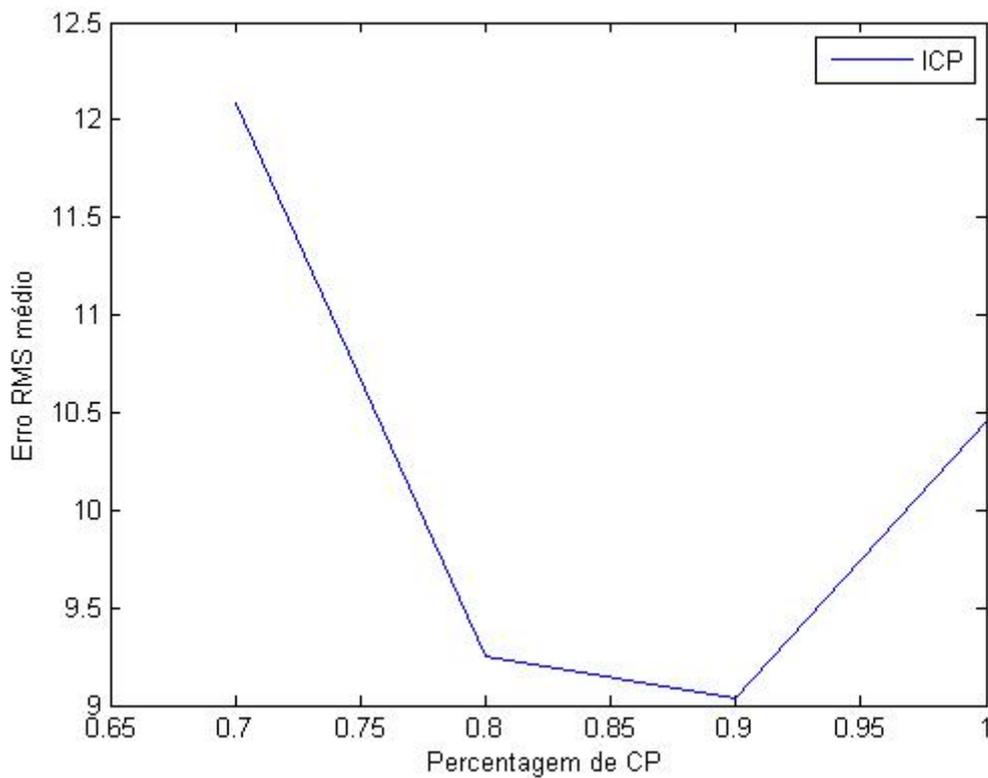


Gráfico 14 - ICP - $Erro_{RMS\ médio}$ por percentagem de CP nas galerias romanas

Seguidamente são expostos dois exemplos de alinhamentos efectuados pelo algoritmo com transformações afim geradas manualmente.

No primeiro exemplo é utilizada a matriz de transformação afim T1 com os seguintes parâmetros

$$T1 = \begin{bmatrix} 0.797 & 0.0697 & 0 & 0 \\ -0.0915 & 1.046 & 0 & 0 \\ 0 & 0 & 0.98 & 0 \\ 6.2967 & -7.3137 & 3 & 1 \end{bmatrix} \quad (65)$$

correspondentes a uma transformação com translações de 1, -2 e 3 nos eixos x , y e z respectivamente, factores de escala de 0.8, 1.05 e 0.98 nos eixos x , y e z , e a uma rotação de 5° sobre o eixo dos z .

Na Figura 44 a) visualizam-se os volumes de galerias romanas desalinhasdas, o volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao volume

original a verde e na Figura 44 b) apresenta-se -se os volumes de galerias romanas alinhadas, O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao volume original a verde



Figura 44 - ICP - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao volume original a verde
b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao volume original a verde

Na Figura 45 a) representa-se a sobreposição dos cortes transversais das galerias romanas desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde e na Figura 45 b) apresenta-se a sobreposição dos cortes transversais das galerias romanas alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde.

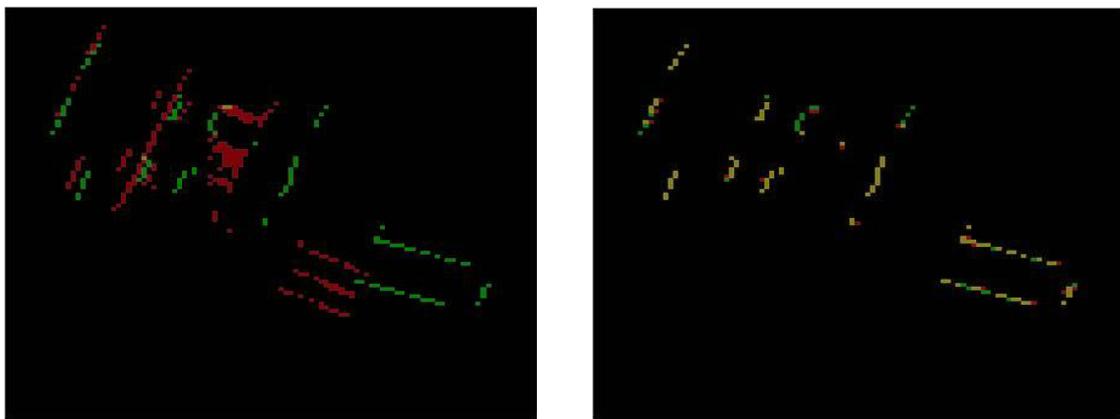


Figura 45 - ICP - a) Sobreposição dos cortes transversais das galerias romanas desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde
b) Sobreposição dos cortes transversais das galerias romanas alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde

O $Erro_{RMS}$ do processo de alinhamento é igual a 0.4512.

Realizou-se uma nova transformação afim T2 com os seguintes parâmetros

$$T2 = \begin{bmatrix} 0.7970 & 0.0697 & 0 & 0 \\ -0.0915 & 1.046 & 0 & 0 \\ 0 & 0 & 0.98 & 0 \\ 9.2967 & -10.3137 & 6 & 1 \end{bmatrix} \quad (66)$$

correspondentes a uma transformação com translações de 4, -5 e 6 nos eixos x , y e z respectivamente, factores de escala de 0.8, 1.05 e 0.98 nos eixos x , y e z , e a uma rotação de 5° sobre o eixo dos z .

Na Figura 46 a) visualizam-se os volumes de galerias romanas desalinhadas, o volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao volume original a verde e na Figura 46 b) apresenta-se -se os volumes de galerias romanas alinhadas, O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao volume original a verde



**Figura 46 - ICP - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao volume original a verde
b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao volume original a verde**

A Figura 47 a) representa a sobreposição dos cortes transversais das galerias romanas desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao corte original a verde e na Figura 47 b) apresenta-se a sobreposição dos cortes transversais das galerias romanas alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original a verde.

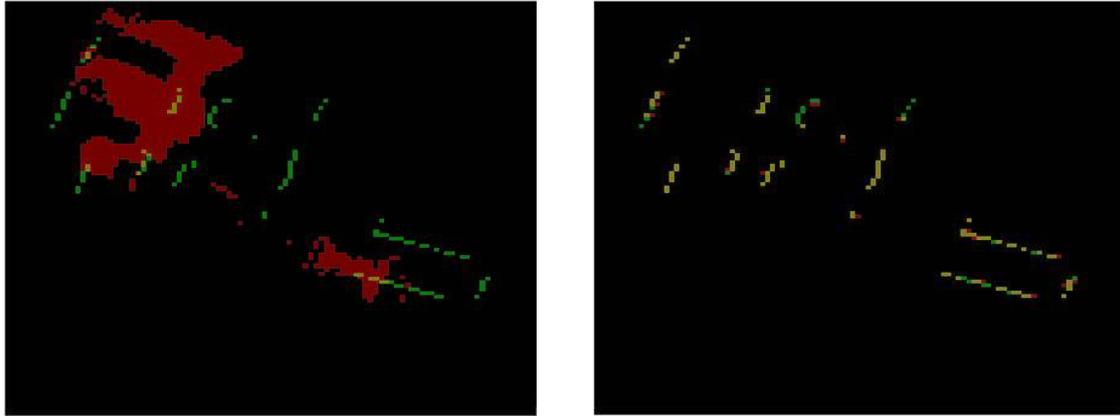


Figura 47 - ICP - a) Sobreposição dos cortes transversais das galerias romanas desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao corte original a verde.
 b) Sobreposição dos cortes transversais das galerias romanas alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original a verde

O $Erro_{RMS}$ do processo de alinhamento é igual a 0.4768

A aquisição por sensor laser do modelo das galerias romanas só deforma, na sua utilização real, as imagens por um modelo de corpo rígido (ver capítulo 2.4.1.1). Assim, neste exemplo são fornecidas manualmente duas transformações de corpo rígido, que serão estimadas pelo algoritmo de forma a resolver o problema de alinhamento.

É utilizada a matriz de transformação de corpo rígido T3 com os seguintes parâmetros

$$T3 = \begin{bmatrix} 0.9848 & -0.1736 & 0 & 0 \\ 0.1736 & 0.9848 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ -2.1069 & 1.9078 & 5 & 1 \end{bmatrix} \quad (67)$$

correspondentes a uma transformação com translações de 7, -10 e 5 nos eixos x , y e z respectivamente e a uma rotação de -10° sobre o eixo dos z . Na Figura 48 a) visualizam-se os volumes de galerias romanas desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde e na Figura 48 b) apresentam-se os volumes de galerias romanas alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde.



Figura 48 - ICP -
a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde-
b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde

O $Erro_{RMS}$ do processo de alinhamento é igual a 0.1372 .

Executou-se um segundo exemplo com a matriz de transformação T4 de corpo rígido com os seguintes parâmetros

$$T4 = \begin{bmatrix} 0.9899 & -0.0562 & 0.0596 & 0 \\ 0.0596 & 0.9899 & -0.0562 & 0 \\ -0.0562 & 0.0596 & 0.9899 & 0 \\ 1.6699 & -6.2612 & 9.5913 & 1 \end{bmatrix} \quad (68)$$

correspondentes a uma transformação com translações de 3, -8 e 10 nos eixos x , y e z respectivamente e a uma rotação de -10° sobre o eixos x , y e z . Na Figura 49 a) visualizam-se os volumes de galerias romanas desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde e na Figura 49 b) apresentam-se os volumes de galerias romanas alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde.



Figura 49 - ICP - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde.
b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde

O $Erro_{RMS}$ do processo de alinhamento é igual a 0.4922 .

Por fim, o último exemplo recorre às funções de transformação T3 (65) e T4 (66) da demonstração anterior. A diferença para este é a retirada de secções da imagem transformada, de forma a esta ter menos CP que o volume original. Com este exemplo pretende-se ilustrar que o algoritmo não perde precisão nos alinhamentos obtidos.

Utilizando a função de mapeamento T3 (65), a Figura 50 a) apresenta os volumes de galerias romanas desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde e retirando-lhe uma secção e na Figura 50 b) visualizam-se os volumes de galerias romanas alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde e retirando-lhe uma secção.



Figura 50 - ICP -
 a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde, e retirando-lhe CP
 b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde e retirando-lhe CP

O $Erro_{RMS}$ do processo de alinhamento é igual a 0.0744.

O exemplo utilizando a função de transformação T4 (66), a Figura 51 a) apresenta os volumes de galerias romanas desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde e retirando-lhe uma secção e na Figura 51 b) visualizam-se os volumes de galerias romanas alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde e retirando-lhe uma secção.



Figura 51 - ICP -
 a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde, e retirando-lhe CP
 b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde e retirando-lhe CP

Após o processo de alinhamento o $Erro_{RMS}$ é igual a 0.3459.

4.5.2 Alinhamento e normalização de intensidade simultâneos (SRIN)

O teste foi efectuado para as mesmas transformações utilizadas no teste descrito no capítulo 4.4. No teste são medidas as percentagens de não convergências do algoritmo por percentagem de CP (ver Gráfico 15) e é registado o $Erro_{RMS\ médio}$ do algoritmo por percentagem de CP (ver Gráfico 16).

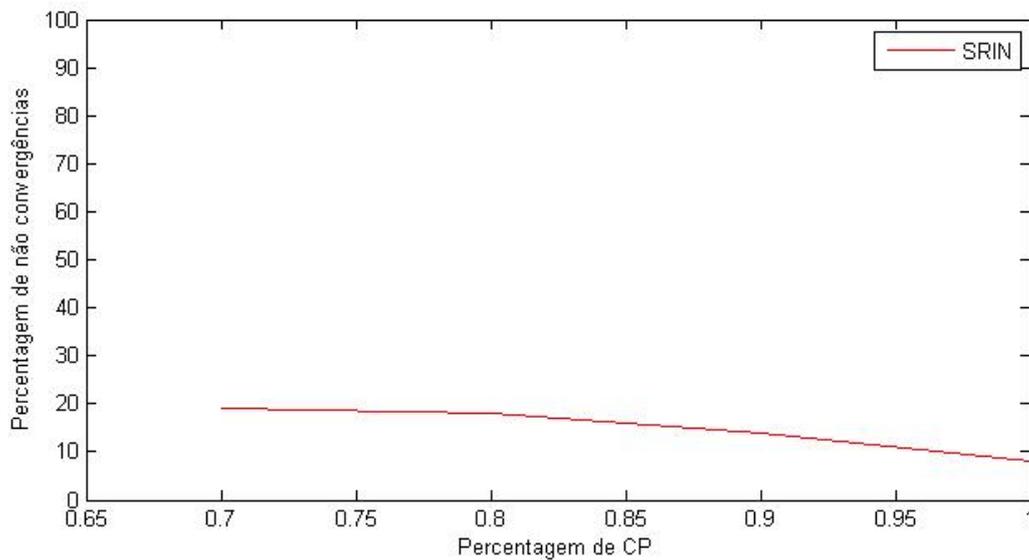


Gráfico 15 - SRIN - Percentagem de não convergências por percentagem de CP nas galerias romanas

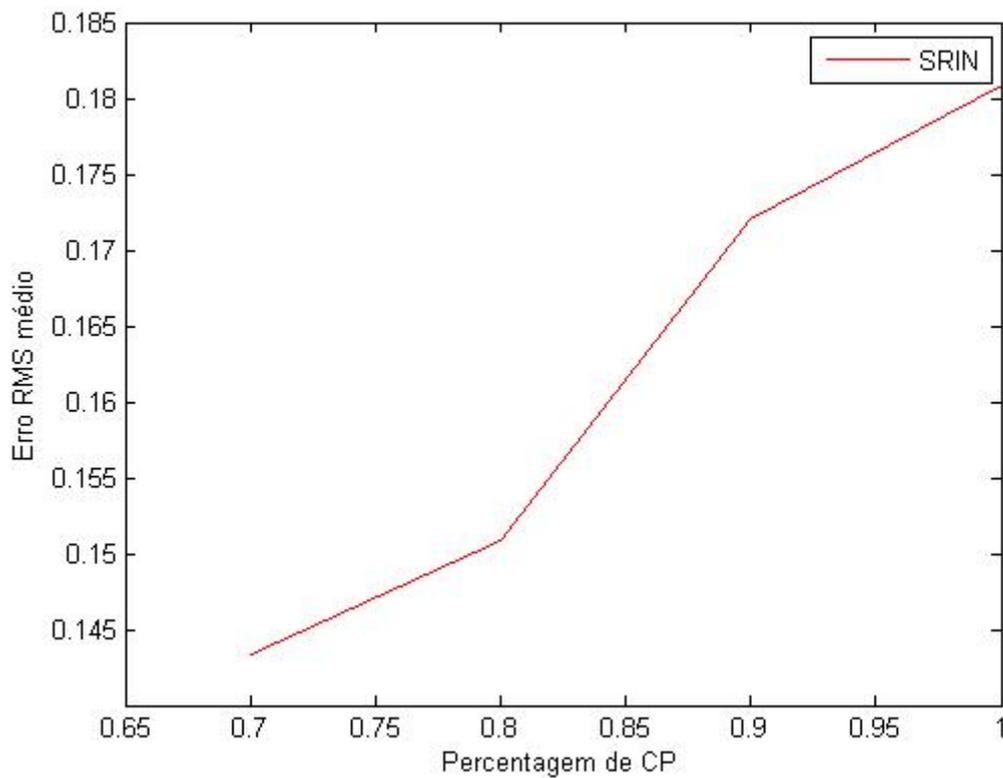


Gráfico 16 - SRIN - $Erro_{RMS\ médio}$ por percentagem de CP nas galerias romanas

Seguidamente são mostrados dois exemplos de alinhamentos efectuados pelo algoritmo com transformações afim geradas manualmente.

Nestes exemplos são utilizadas matrizes de transformação T1 (63) e T2 (64) previamente usadas no exemplo de alinhamento de corpo rígido ao ICP.

Para o exemplo com a transformação T1 (63), o $Erro_{RMS}$ do processo de alinhamento foi igual a 0.3172

Na Figura 52 a) visualizam-se os volumes de galerias romanas desalinhados, o volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao volume original a verde e na Figura 52 b) apresenta-se -se os volumes de galerias romanas alinhados, O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao volume original a verde



Figura 52 - SRIN - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao volume original a verde
 b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao volume original a verde

A Figura 53 a) mostra a sobreposição dos cortes transversais das galerias romanas desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde e na Figura 53 b) apresenta-se a sobreposição dos cortes transversais das galerias romanas alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde.

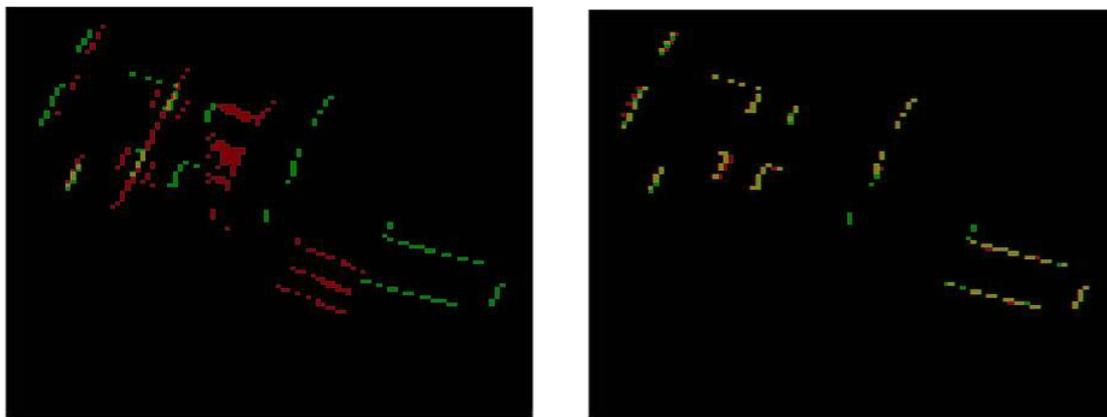


Figura 53 - SRIN - a) Sobreposição dos cortes transversais das galerias romanas desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T1 ao corte original a verde
 b) Sobreposição dos cortes transversais das galerias romanas alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T1 ao corte original a verde

No exemplo com a função de mapeamento T2 (62), o $Erro_{RMS}$ do processo de alinhamento foi igual a 0.3772 e na Figura 54 a) visualizam-se os volumes de galerias romanas desalinhados, o volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao

volume original a verde e na Figura 54 b) apresenta-se -se os volumes de galerias romanas alinhados, O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao volume original a verde

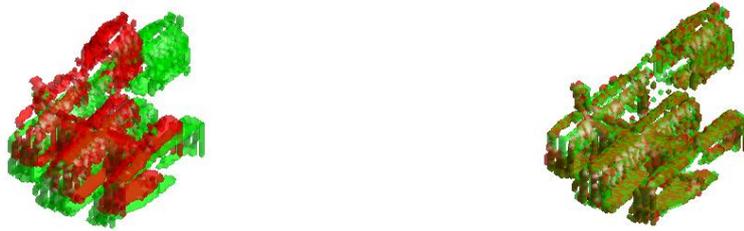


Figura 54 - SRIN - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao volume original a verde
b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao volume original a verde

Na Figura 55 a) observa-se a sobreposição dos cortes transversais das galerias romanas desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao corte original a verde e na Figura 55 b) apresenta-se a sobreposição dos cortes transversais das galerias romanas alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original a verde.

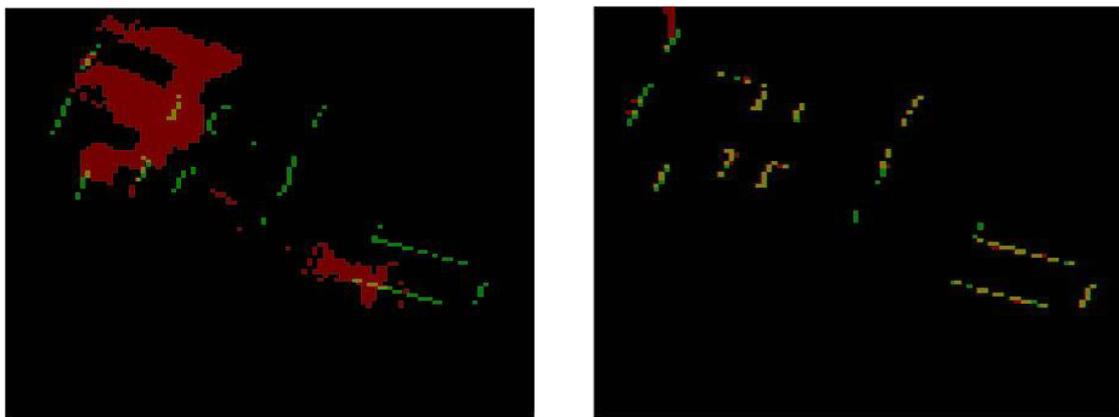


Figura 55 - SRIN - a) Sobreposição dos cortes transversais das galerias romanas desalinhados. O corte representado a vermelho foi sintetizado por aplicação da transformação geométrica T2 ao corte original a verde
b) Sobreposição dos cortes transversais das galerias romanas alinhados. O corte representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T2 ao corte original a verde

A aquisição por sensor laser do modelo das galerias romanas só deforma, na sua utilização real, as imagens por um modelo de corpo rígido (ver capítulo 2.4.1.1). Assim, neste exemplo são fornecidas manualmente duas transformações de corpo rígido, que serão estimadas pelo algoritmo de forma a resolver o problema de alinhamento.

Nestes exemplos são utilizadas matrizes de transformação de corpo rígido T3 (65) e T4 (66) previamente usadas nos exemplos para o ICP.

Para o exemplo com a transformação T3 (65), o $Erro_{RMS}$ do processo de alinhamento foi igual a 0.1106 e na Figura 56 a) visualizam-se os volumes de galerias romanas desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde e na Figura 56 b) apresentam-se os volumes de galerias romanas alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde.



Figura 56 - SRIN - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde.
b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde

No exemplo com a função de mapeamento T4 (66), o $Erro_{RMS}$ do processo de alinhamento foi igual a 0.1492 e na Figura 57 a) visualizam-se os volumes de galerias romanas desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde e na Figura 57 b) apresentam-se os volumes de galerias romanas alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde.



Figura 57 - SRIN - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde
 b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde

O último exemplo recorre às funções de transformação T3 (65) e T4 (66) da demonstração anterior. A diferença para este é a retirada de secções da imagem transformada, de forma a esta ter menos CP que o volume original. São extraídos os mesmos pontos que na demonstração para o ICP. Com este exemplo pretende-se ilustrar que o algoritmo não perde precisão nos alinhamentos obtidos.

No teste com a função de mapeamento T3 (65), o $Erro_{RMS}$ do processo de alinhamento foi igual a 0.2481 e na Figura 58 a) visualizam-se os volumes de galerias romanas desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde e retirando-lhe uma secção, na Figura 58 b) apresentam-se os volumes de galerias romanas alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde e retirando-lhe uma secção.



Figura 58 - SRIN - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume

original a verde e retirando-lhe CP

b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T3 de corpo rígido ao volume original a verde e retirando-lhe CP

No exemplo com a função de mapeamento T4 (66), o $Erro_{RMS}$ do processo de alinhamento foi igual a 0.0904 e na Figura 59 a) visualizam-se os volumes de galerias romanas desalinhados. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde e retirando-lhe uma secção, na Figura 59 b) apresentam-se os volumes de galerias romanas alinhados. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde e retirando-lhe uma secção.



Figura 59 - SRIN - a) Volumes de galerias romanas desalinhadas. O volume representado a vermelho foi sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde e retirando-lhe CP

b) Volumes de galerias romanas alinhadas. O volume representado a vermelho foi alinhado após ser sintetizado por aplicação da transformação geométrica T4 de corpo rígido ao volume original a verde e retirando-lhe CP

4.5.3 Análise

Para se poder comparar os resultados de ambos os algoritmos estudados, foram sobrepostos o Gráfico 13 e Gráfico 15 (ver Gráfico 17) e o Gráfico 14 e Gráfico 16 (ver Gráfico 18).

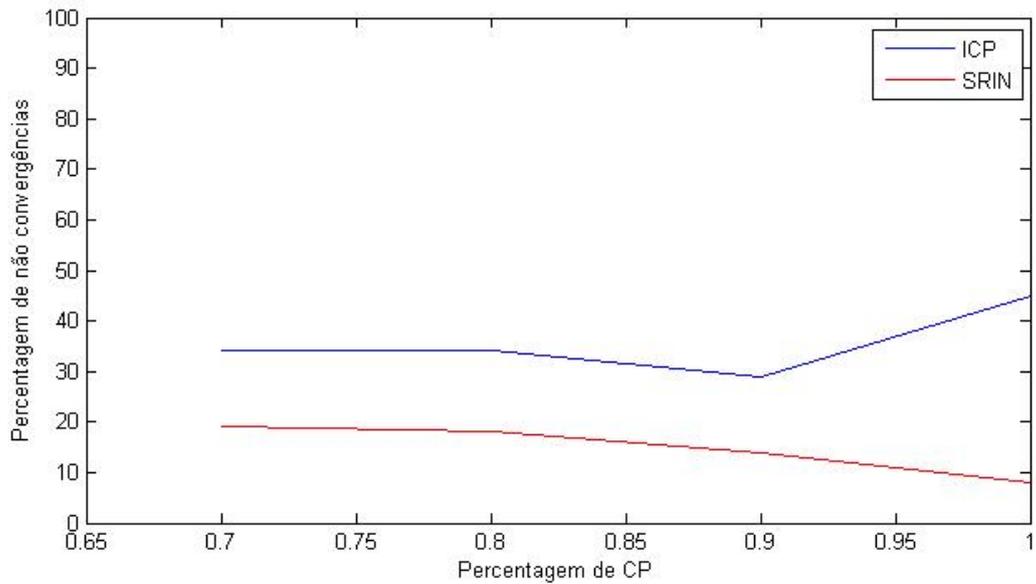


Gráfico 17 - Comparação das percentagens de não convergências por percentagens de CP nas galerias romanas entre o ICP e o SRIN

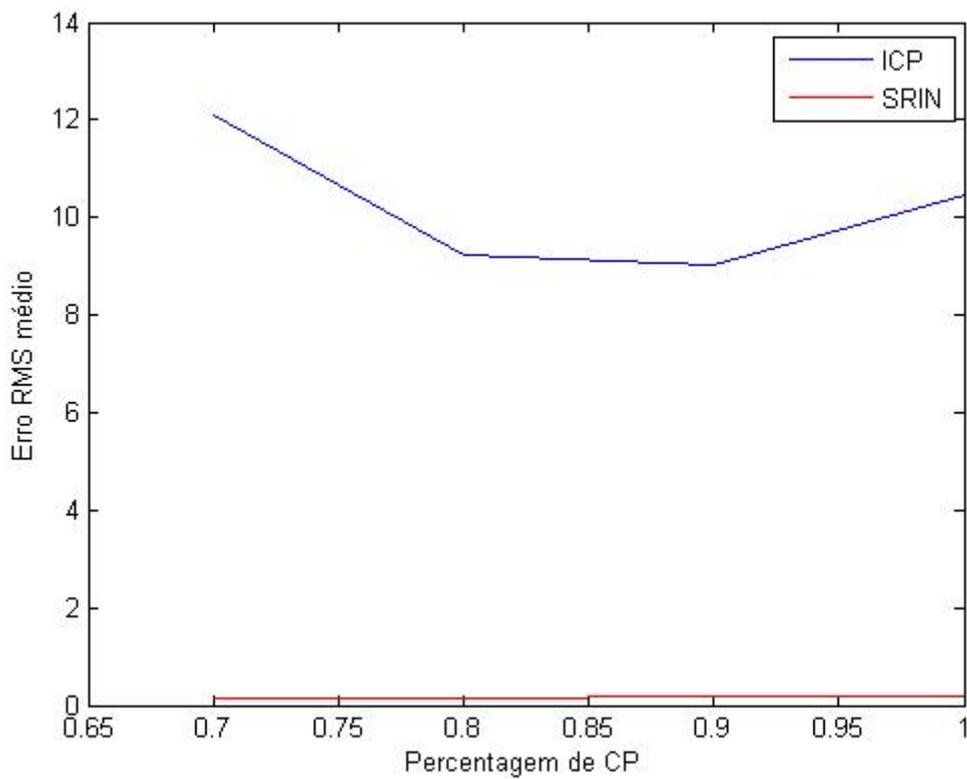


Gráfico 18 - Comparação do $Erro_{RMS\ médio}$ por percentagens de CP nas galerias romanas entre o ICP e o SRIN

Nota-se uma clara superioridade do algoritmo SRIN sobre o ICP. O ICP volta a demonstrar uma tendência para convergir para mínimos locais. Volta-se a notar também um aumento da percentagem de não convergências e do $Erro_{RMS\ médio}$ quando são utilizados a totalidade dos CP, corroborando a explicação de emparelhamentos entre características executadas de maneira errónea. Chama-se a atenção para o comportamento do SRIN que ao aumento da percentagem de CP evidencia uma maior capacidade de convergência mas o seu $Erro_{RMS\ médio}$ vai-se deteriorando ligeiramente.

Capítulo 5

Conclusões e trabalho futuro

Os testes realizados nesta dissertação permitiram verificar que o algoritmo SRIN exibe uma maior percentagem de convergências e maior precisão de alinhamento, mesmo com um número baixo de *CP*. Os testes mostram uma superioridade do algoritmo SRIN sobre o ICP tanto em termos de percentagem de convergência como de $Erro_{RMS\ médio}$. O algoritmo ICP demonstrou uma tendência para convergências para mínimos locais, o que indica que a aproximação inicial de igualar as médias dos dois conjuntos não é o suficiente para proporcionar alinhamentos correctos. Verificou-se que o uso da totalidade dos CP em imagens 3D por parte do ICP provoca um maior número de alinhamentos incorrectos e de não convergências devido ao aumento de emparelhamentos de características incorrectos. Os testes realizados mostram que o algoritmo SRIN executado sobre imagens de características proporciona uma notável percentagem de convergência e exactidão no processo de alinhamento, evitando com sucesso a fase de correspondência entre características exigidas aos algoritmos baseados nestas.

Em futuros estudos seria bom comparar a utilização do algoritmo SRIN em imagens de características com o algoritmo SRIN em imagens de intensidade, com diferentes dificuldades na extracção de características e em presença de ruído, de modo a estudar em que situações, cada um dos modos de utilização é superior.

Bibliografia

1. Besl, P.J. and H.D. McKay, *A method for registration of 3-D shapes*. Pattern Analysis and Machine Intelligence, 1992. **14**(2): p. 239 - 256
2. Silveira, M. and P.M.Q. Aguiar, *Simultaneous Registration and Intensity Normalization of SPECT Perfusion Images*, in *30th IEEE EMBS Annual International Conference*. 2008: Canadá.
3. Zitova, B., J. Flusser, and F. Sroubek. *Image registration methods: a survey and recent advances*. in *International Conference on Image Processing*. 2005. Genova, Itália.
4. Goshtasby, A., G.C. Stockman, and C.V. Page., *A region-based approach to digital image registration with subpixel accuracy*. IEEE Trans. Geoscience and Remote Sensing, 1986. **24**(3): p. 390 - 399.
5. Hsieh, Y.C., D.M. McKeown, and F.P. Perlant, *Performance evaluation of scene registration and stereo matching for cartographic feature extraction*. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 1992. **14**(2): p. 214 - 238.
6. Roux, M., *Automatic registration of SPOT images and digitized maps*, in *Image Processing, 1996. Proceedings., International Conference on*. 1996. p. 625 - 628
7. Alhichri, H.S. and M. Kamel., *Virtual circles: A new set of features for fast image registration*. Pattern Recognition Letters, 2003. **24**: p. 1181–1190.
8. Tuytelaars, T. and L.V. Gool., *Matching widely separated views based on affinity invariant neighbourhoods*. International Journal of Computer Vision, 2001.
9. Noble, A., *Finding corners*. Image and Vision Computing, 1988. **6**: p. 121–128.
10. Matas, J., S. Obdržálek, and O. Chum., *Local affine frames for wide-baseline stereo*, in *16th International Conference on Pattern Recognition ICPR 2002*. 2002. p. 363–366.
11. Govindu, V., C. Shekhar, and R. Chellapa. *Using geometric properties for correspondence-less image alignment*. in *Procedures International Conference on Pattern Recognition ICPR'98*. 1998. Australia.
12. Shin, D., J.K. Pollard, and J.P. Muller., *Accurate geometric correction of ATSR images*. IEEE Trans. Geoscience and Remote Sensing, 1997. **35**: p. 997–1006.
13. Li, S.Z., J. Kittler, and M. Petrou. *Matching and recognition of road networks from aerial images*. in *2nd European Conference on Computer Vision ECCV'92*,. 1992. Italy.
14. Vujovic, N. and D. Brzakovic, *Establishing the correspondence between control points in pairs of mammographic images*. IEEE Trans. Image Processing, 1997. **6**.
15. Canny, J., *A computational approach to edge detection*. IEEE Trans. Pattern Analysis and Machine Intelligence, 1986. **8**: p. 679–698.
16. Sobel and F. G., *A 3x3 Isotropic Gradient Operator for Image Processing*, in *Pattern Classification and Scene Analysis*. 1968. p. 271 - 272.
17. Li, H., B.S. Manjunath, and S.K. Mitra, *A contour-based approach to multisensor image registration*. IEEE Trans. Image Processing, 1995. **4**: p. 320–334.

18. Stockman, G., S. Kopstein, and S. Benett., *Matching images to models for registration and object detection via clustering*. IEEE Trans. Pattern Analysis and Machine Intelligence, 1982. **4**: p. 229–241.
19. Bhattacharya, D. and S. Sinha., *Invariance of stereo images via theory of complex moments*. Pattern Recognition Letters, 1997. **30**: p. 1373–1386.
20. Grove, S. and R. Tonjes. *A knowledge based approach to automatic image registration*. in *Procedures IEEE International Conference on Image Processing ICIP'97*. 1997. California.
21. Ton, J. and A. K.Jain, *Registering Landsat images by point matching*. IEEE Trans. Geoscience and Remote Sensing, 1989. **27**: p. 642–651.
22. Ehlers, M. *Region-based matching for image registration in remote sensing databases*. in *Procedures International Geoscience and Remote Sensing Symposium IGARSS'91*. 1991. Finland.
23. Ali, W.S.I. and F.S. Cohen, *Registering coronal histological 2-D sections of a ratbrain with coronal sections of a 3-D brain atlas using geometric curve invariants and B-spline representation*. IEEE Trans. Medical Imaging, 1998. **17**: p. 957–966.
24. Smith, S.M. and J.M. Brady, *SUSAN – A new approach to low level image processing*. International Journal of Computer Vision, 1997. **23**: p. 45–78.
25. Kitchen, L. and A. Rosenfeld., *Gray-level corner detection*. Pattern Recognition Letters, 1982. **1**: p. 95 – 102.
26. Dreschler, L. and H. Nagel. *Volumetric model and 3-D trajectory of a moving car derived from monocular TV-frame sequence of a street scene*. in *Procedure International Joint Conference Artificial Intelligence*. 1981. Canada.
27. Zitová, B., et al., *Robust detection of significant points in multiframe images*. Pattern Recognition Letters, 1999. **20**: p. 199–206.
28. Goshtasby, A. and G.C. Stockman, *Point pattern matching using convex hull edges*. IEEE Trans. Systems, Man and Cybernetics, 1985. **15**: p. 631–637.
29. Lehmann, T.M. *A two stage algorithm for model-based registration of medical images*. in *Int'l. Conf. on Pattern Recognition ICPR'98*. 1998. Austrália.
30. Zheng, Q. and R. Chellapa, *A computational vision approach to image registration*. IEEE Trans. Image Processing, 1993. **2**: p. 311–325.
31. Dai, X. and S. Khorram, *A feature-based image registration algorithm using improved chaincode representation combined with invariant moments*. IEEE Trans. Geoscience and Remote Sensing, 1999. **37**: p. 2351–2362.
32. Bentoutou, Y., et al., *An invariant approach for image registration in digital subtraction angiography*. Pattern Recognition Letters, 2002. **35**: p. 2853–2865.
33. Flusser, J., J. Boldys, and B. Zitova, *Moment forms invariant to rotation and blur in arbitrary number of dimensions*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003. **25**: p. 234–246.
34. Wang, W.H. and Y.C. Chen, *Image registration by control points pairing using the invariant properties of line segments*. Pattern Recognition Letters, 1997. **18**: p. 269–281.
35. Govindu, V. and C. Shekhar, *Alignment using distributions of local geometric properties*. IEEE Trans. Pattern Analysis and Machine Intelligence, 1999. **21**: p. 1031–1043.

36. Mitra, R.S. and N.N. Murthy, *Elastic maximal matching*. Pattern Recognition Letters, 1991. **24**: p. 747–753.
37. Ranade, S. and A. Rosenfeld, *Point pattern matching by relaxation*. Pattern Recognition Letters, 1980. **12**: p. 269–275.
38. Medioni, G. and R. Nevatia, *Matching images using linear features*. IEEE Trans. Pattern Analysis and Machine Intelligence, 1984. **6**: p. 675–685.
39. Wang, C.Y., S.Y. H. Sun, and A. Rosenfeld., *Some experiments in relaxation image matching using corner features*. Pattern Recognition Letters, 1983. **16**: p. 269–281.
40. Althof, R.J., M.G.J. Wind, and J.T. Dobbins, *A rapid and automatic image registration algorithm with subpixel accuracy*. IEEE Trans. Medical Imaging, 1997. **16**: p. 308–316.
41. Pratt, W.K., *Digital Image Processing*. 1991: John Wiley.
42. Roche, A., et al. *The correlation ratio as a new similarity measure for multimodal image registration*. in *Proc. of First Int. Conf. on Medical Image Computing and Computer-Assisted Intervention (MICCAI'98)*. 1998. Cambridge.
43. Mathworks. *Registering an Image Using Normalized Cross-Correlation*. [cited; Available from: <http://www.mathworks.com/products/image/demos.htmlfile=/products/demos/shipping/images/ipexnormxcorr2.html>].
44. Wolberg, G. and S. Zokai, *Robust image registration using log-polar transform*, in *Proc. IEEE Intl. Conference on Image Processing*. 2000: Canadá. p. MA12.09.
45. Maes, F., et al., *Multimodality image registration by maximization of mutual information*. IEEE Trans. Medical Imaging, 1997. **16**: p. 187–198.
46. Thevenaz, P. and M. Unser. *Spline pyramids for inter-modal image registration using mutual information*. in *Proc. SPIE: Wavelet Applications in Signal and Image Processing*. 1997. California.
47. Baker, S. and I. Matthews, *Lucas-Kanade 20 Years On: A Unifying Framework*. International Journal of Computer Vision, 2004. **56**(3): p. 221-255.
48. Jukic, D. *The problem of the initial approximation for a special nonlinear least squares problem*. in *Mathematical Colloquium*. 1995.
49. Thepaut, O., K. Kpalma, and J. Ronsin, *Automatic registration of ERS and SPOT multisensor images in a data fusion context*. Forest Ecology and Management, 2000. **128**: p. 93–100.
50. J.S.Marques, *Notas sobre processamento de imagem e visão*. 2006: IST/ISR.
51. Goshtasby, A., *Piecewise linear mapping functions for image registration*. Pattern Recognition Letters, 1986. **19**: p. 459–466.
52. Goshtasby, A., *Piecewise cubic mapping functions for image registration*. Pattern Recognition Letters, 1987. **20**: p. 1987.
53. Little, J.A., D.L.G. Hill, and D.J. Hawkes, *Deformations incorporating rigid structures*. Computer Vision and Image Understanding, 1997. **66**: p. 223–232.
54. Fornefett, M., K. Rohr, and H.S. Stiehl, *Radial basis functions with compact support for elastic registration of medical images*. Image and Vision Computing, 2001. **19**: p. 87–96.

55. Goshtasby, A., *Registration of images with geometric distortions*. IEEE Trans. Geoscience and Remote Sensing, 1988. **26**: p. 631–637.
56. Rohr, K., *Landmark-Based Image Analysis: Using Geometric and Intensity Models*. 2001. **21**.
57. Bajcsy, R. and S. Kovacic, *Multiresolution elastic matching*. Computer Vision, Graphics and Image Processing, 1989. **46**: p. 1–21.
58. Bro-Nielsen, M. and C. Gramkow. *Fast fluid registration of medical images*. in *Visualization in Biomedical Computing*. 1996. Hamburg.
59. Toraichi, K., S. Yang, and R. Mori., *Two-dimensional spline interpolation for image reconstruction*. Pattern Recognition Letters, 1988. **21**: p. 275–284.
60. Dodgson, N.A., *Quadratic interpolation for image resampling*. IEEE Trans. Image Processing, 1997. **6**: p. 1322–1326.
61. Lehmann, T.M., C. Goner, and K. Spitzer, *B-spline interpolation in medical image processing*. IEEE Transaction on medical imaging, 2001. **20**: p. 660–665.
62. Appledorn, C.R., *A new approach to the interpolation of sampled data*. IEEE Trans. Medical Imaging, 1996. **15**: p. 369–376.
63. Thévenaz, P., T. Blu, and M. Unser, *IEEE Trans. on Medical Imaging*. 2000. **19**: p. 739–758.
64. Rusinkiewicz, S. and M. Levoy. *Efficient variants of the ICP algorithm*. in *3-D Digital Imaging and Modeling, 2001. Proceedings. Third International Conference on*. 2001.
65. Zinßer, T., J. Schmidt, and H. Niemann. *Point Set Registration with Integrated Scale Estimation*. in *The 8-th International Conference on Pattern Recognition and Information Processing*. 2005.
66. Eggert, D.W., et al., *Estimating 3-D rigid body transformations: a comparison of four major algorithms* Machine Vision and Applications, 1997. **9**(5 - 6): p. 272-290.
67. Sharifi, M., M. Fathy, and M.T. Mahmoudi. *A classified and comparative study of edge detection algorithms*. in *Information Technology: Coding and Computing, 2002. Proceedings. International Conference on*. 2002.
68. Center, D.-H.M. *Brain perfusion SPECT. Case 5*. 2006 [cited; Available from: http://www.dhmc.org/webpage.cfm?site_id=2&org_id=72&morg_id=0&sec_id=0&qsec_id=1508&item_id=38248].
69. Altunbasak, Y., R. Merserau, and A. Patti, *A fast parametric motion estimation algorithm with illumination and lens distortion correction*. IEEE Trans. on Image Processing, 2003. **12**(4).
70. Aguiar, P.M.Q., *Unsupervised Simultaneous Registration and Exposure Correction*. IEEE Conference on Image Processing,, 2006: p. 361-364.
71. Cocosco, C.A., et al. *BrainWeb: Online Interface to a 3D MRI Simulated Brain Database*. in *Proceedings of 3-rd International Conference on Functional Mapping of the Human Brain*. 1997. Copenhagen.
72. Engenharia, A. *Galerias romanas da Rua da Prata, Portugal 2007* [cited; Available from: C:\Users\user\Desktop\Albatroz Engenharia - Modelos tridimensionais das galerias romanas na Rua da Prata em Lisboa.mht].
73. Staal, J.J., et al., *Ridge based vessel segmentation in color images of the retina*. IEEE Transactions on Medical Imaging, 2004. **23**: p. 501-509.

